

UNIWERSYTET ŁÓDZKI  
WYDZIAŁ EKONOMICZNO-SOCJOLOGICZNY

mgr Adam Juszcak

**ZASTOSOWANIE DANYCH SKRAPOWANYCH  
I SKANOWANYCH W POMIARZE INFLACJI**

Rozprawa doktorska napisana  
w Katedrze Metod Statystycznych  
pod kierunkiem naukowym  
prof. UŁ dr hab. inż. Jacka Białka

Łódź 2023

*Pierwszym lekarstwem dla źle zarządzanego państwa jest inflacja, drugim zaś wojna. Oba rozwiązania przynoszą chwilową poprawę koniunktury; oba prowadzą do trwałej ruiny. Ale oba są ucieczką dla politycznych i ekonomicznych oportunistów.*

Ernest Hemingway (1935), *Notes on the Next War: A Serious Topical Letter*

# Spis treści

Wstęp .....	5
<b>1. Tradycyjny pomiar inflacji .....</b>	<b>8</b>
1.1. Podstawowe miary inflacji: CPI vs HICP .....	9
1.2. Źródła danych o cenach .....	14
1.3. Źródło danych o poziomie konsumpcji .....	16
1.4. Źródła obciążenia pomiaru inflacji .....	18
Obciążenie z tytułu substytucji dóbr ( <i>substitution bias</i> ) .....	18
Obciążenie wynikające z pojawiania się nowych dóbr na rynku ( <i>new good bias</i> ) .....	19
Obciążenie wynikające z miejsce notowania cen ( <i>outlet bias</i> ) .....	20
Obciążenie wynikające ze zmian jakości produktów ( <i>quality bias</i> ) .....	20
Obciążenie wynikające z metody kalkulacji ( <i>formula bias</i> ) .....	21
1.5. Wpływ pandemii COVID-19 na pomiar inflacji .....	24
<b>2. Dane skrapowane jako alternatywne źródło danych w pomiarze inflacji .....</b>	<b>29</b>
2.1. Definicja i geneza danych skrapowanych .....	29
2.2. Metodyka pozyskiwania danych skrapowanych .....	32
2.3. Zalety stosowania danych skrapowanych .....	37
2.4. Ograniczenia aplikacyjne i wyzwania metodologiczne .....	39
2.5. Formuły indeksów cen .....	41
Indeks Jevonsa .....	41
łańcuchowy indeks Jevonsa .....	41
Indeks GEKS-J .....	42
Propozycja alternatywnych metod opartych na indeksie Dutot .....	42
Metoda CLIP (Clustering Large Datasets into Price indices) .....	43
Metody aktualizacji okna obliczeniowego .....	43
<b>3. Dane skanowane .....</b>	<b>46</b>
3.1. Definicja i geneza danych skanowanych .....	46
3.2. Metodyka pozyskiwania danych skanowanych .....	50
3.3. Zalety stosowania danych skanowanych .....	54
3.4. Ograniczenia aplikacyjne i wyzwania metodologiczne .....	55
3.5. Formuły indeksów cen .....	58
Indeksy bilateralne .....	58
Indeksy łańcuchowe .....	59
Indeksy multilateralne .....	59
Metody aktualizacji okna obliczeniowego .....	64
<b>4. Zastosowanie danych skrapowanych w pomiarze dynamiki cen .....</b>	<b>65</b>

4.1. Charakterystyka wykorzystanych zbiorów danych .....	65
4.2. Porównanie nieważonych indeksów bilateralnych i multilateralnych .....	71
4.3. Analiza metod rozszerzeń indeksów multilateralnych.....	80
4.4. Ocena wpływu filtrowania danych na końcowy wskaźnik cen .....	84
5. Zastosowanie danych skanowanych w pomiarze dynamiki cen.....	97
5.1. Charakterystyka wykorzystanych zbiorów danych .....	97
5.2. Porównanie indeksów bilateralnych i multilateralnych .....	100
5.3. Analiza metod rozszerzeń indeksów multilateralnych.....	108
5.4. Ocena wpływu filtrowania na końcowy wskaźnik cen.....	113
5.5. Wpływ metod agregacji na indeksy cen .....	136
6. Porównanie formuł indeksowych na bazie sztucznych zbiorów danych skanowanych .....	144
6.1. Charakterystyka generowanych zbiorów danych.....	144
6.2. Ocena wpływu zmienności cen i ilości na różnice pomiędzy indeksami cen.....	145
6.3. Porównanie indeksów cenowych ze względu na czas ich kalkulacji.....	153
6.4. Porównanie zmienności indeksów cen metodą <i>jackknife</i> .....	156
Podsumowanie .....	163
Literatura.....	166
Źródła internetowe.....	172
Aneks.....	174
Spis tabel i wykresów .....	211

## Wstęp

Historia pieniądza jest nieodłącznie związana z historią rozwoju cywilizacji. Choć środki wymiany w postaci muszli, patyków lub kości towarzyszyły ludzkości już 20-30 tysięcy lat temu wyprzedzając sam wynalazek pisma, za przełom uważa się wprowadzenie w VII wieku p.n.e. monet opartych na kruszcu. Co ciekawe, niezależnie stało się to w tym samym okresie na terenach Lidii i Fenicji oraz Chin. Pierwsze doniesienia o spadku wartości pieniądza (poprzez obniżanie zawartości metali szlachetnych w bitych monetach) także pochodzą z czasów antycznych - zjawisko to miało miejsce między innymi w Atenach w czasach wojen peloponeskich i w Rzymie podczas drugiej wojny punickiej.

Samo pojęcie „inflacja” pochodzi od łacińskiego słowa *inflare*, co można tłumaczyć jako „puchnąć” (*inflatio* – „puchnięcie”) i według *Słownika Oxfordzkiego* zostało użyte w kontekście spadku wartości pieniądza w 1838 r. Na popularności zyskało po raz pierwszy podczas wojny domowej w USA w latach 1861-1865, podczas której złoty dolar został zastąpiony przez banknot wydany przez rząd i stosunkowo szybko tracił na realnej wartości<sup>1</sup>.

Niewielki poziom inflacji ma, według badań, pozytywny wpływ na gospodarkę. Większość krajów na świecie stara się kontrolować poziom inflacji poprzez politykę pieniężną prowadzoną przez banki centralne. Za optymalny poziom inflacji w Polsce (i jednocześnie cel inflacyjny Narodowego Banku Polskiego) uważa się 2,5% (+/- 1 pkt. proc.), a w strefie euro 2%.

Utrzymywanie inflacji na niskim poziomie i uniknięcie negatywnych konsekwencji dla gospodarki związanych z wysoką inflacją, a także prowadzenie polityki państwa popartej wiedzą na temat inflacji (jak np. waloryzacja emerytur i świadczeń społecznych) wymaga szybkiego i szczegółowego pomiaru. Praktyka pokazuje, że prawidłowe oddanie zmian cen i koszyka konsumenta wiąże się z wieloma potencjalnymi obciążeniami pomiaru i utrudnieniami w realizacji badań. Najświeższym przykładem może tu być pandemia COVID-19, która nie tylko utrudniła prowadzenie badań przez ankieterów i pracę statystyków Głównego Urzędu Statystycznego (skutkowało to między innymi tymczasowym zawieszeniem publikacji tzw. szybkiego szacunku Flash), ale także spowodowała duże obciążenie pomiaru związane z nagłą zmianą koszyka konsumenta.

Nowe technologie i metody pozyskania danych, jak np. dane skanowane (dane o sprzedaży produktów uzyskane z elektronicznych terminali handlowych) i dane skrapowane (dane o

---

<sup>1</sup> Bernholtz, P.(2003), *Monetary Regimes and Inflation: History, Economic and Political Relationships*, Edward Elgar Publishing Ltd, London.

produktach automatycznie zaciągane ze stron internetowych i aplikacji) stanowią szansę na znaczące ulepszenie pomiaru inflacji w przyszłości – zarówno w kontekście szybszej dostępności danych, jak i zmniejszenia obciążenia pomiaru.

Głównym celem pracy jest omówienie zalet i ograniczeń, związanych z wykorzystaniem nowych źródeł danych w pomiarze inflacji. Autor w swojej dysertacji skupia się przede wszystkim na gruntownym porównaniu szeregu formuł indeksowych i sprawdzeniu możliwości ich zastosowania w ramach poszczególnych, alternatywnych źródeł danych.. W szczególności, celem pracy była ocena przydatności szeregu metod mających na celu zmniejszenie obciążenia pomiaru inflacji bazującego na danych skanowanych i skrapowanych, takich jak metody rozszerzania okna czasowego dla wyznaczenia indeksów multilateralnych, metody filtracji danych oraz eliminacji obserwacji nietypowych, a także metody agregacji danych ze względu na homogeniczne podgrupy produktów i outlety danej sieci handlowej. Obliczenia zostały wykonane w języku R z wykorzystaniem m.in. pakietów *PriceIndices* i *microbenchmark*, przy czym obejmowały operacje na 3 typach zbiorów danych:

- danych skrapowanych pozyskanych z jednego z najpopularniejszych sklepów internetowych oferujących odzież i obuwie;
- dwóch zbiorów danych skanowanych umieszczonych w pakiecie *PriceIndices* i zbiorze danych dołączonych do publikacji Międzynarodowego Funduszu Walutowego (CPI Manual);
- siedmiu zbiorów sztucznie wygenerowanych przez autora.

Praca składa się ze wstępu, sześciu rozdziałów właściwych oraz podsumowania. Całość dopełnia spis literatury wykorzystanej przy pisaniu pracy oraz wykaz tabel i wykresów.

Pierwszy rozdział zawiera krótki rys historyczny rozwoju badań nad inflacją. Zaprezentowano także historię i charakterystykę wskaźników CPI (*Consumer Price Index*) i HICP (*Harmonised Indices of Consumer Prices*). Następnie omówiono źródła danych o cenach i konsumpcji. Na koniec omówiono poszczególne rodzaje obciążeń pomiaru inflacji i zaprezentowano, w jaki sposób na dokładności pomiaru odbiła się nagła zmiana struktury konsumpcji spowodowana pandemią COVID-19.

Drugi rozdział stanowi wprowadzenie do idei wykorzystania danych skrapowanych jako alternatywnego źródła danych w pomiarze inflacji. Poza samą definicją danych skanowanych, zawiera on informację o genezie tych danych, metodyce ich pozyskiwania oraz zaletach stosowania. Omówiono także ograniczenia aplikacyjne i wyzwania metodologiczne związane

z wdrażaniem danych skanowanych w praktyce. Na koniec zaprezentowano formuły indeksów używanych do obliczeń dynamiki cen produktów z wykorzystaniem danych skrapowanych.

W trzecim rozdziale, w analogiczny sposób do rozdziału drugiego, omówiono ideę wykorzystania danych skanowanych do pomiaru inflacji. Zaprezentowano definicję i genezę, a także metodykę pozyskiwania, przetwarzania, klasyfikacji i dopasowania tego rodzaju danych. Opisano też największe wyzwania metodologiczne i aplikacyjne stojące przed urzędami statystycznymi chcącymi stosować dane skanowane w szacunkach inflacji. Na koniec omówiono formuły indeksów wykorzystywanych do obliczeń dynamiki cen produktów skanowanych ze szczególnym uwzględnieniem formuł multilateralnych.

Czwarty rozdział stanowi badanie empiryczne zrealizowane na danych skrapowanych pozyskanych od jednego z największych sklepów internetowych handlujących odzieżą i obuwem. Poza wynikami obliczeń dla poszczególnych formuł indeksowych, zaprezentowano też wpływ metod rozszerzeń okna obliczeń i metod filtrowania na wynik.

W piątym rozdziale omówiono wyniki analiz zrealizowanych na danych skanowanych pozyskanych z publikacji CPI Manual oraz stanowiące dodatek do pakietu *PriceIndices*. Omówiono różnice między wynikami poszczególnych formuł indeksów dla trzech analizowanych zbiorów danych. Zaprezentowano także wpływ poszczególnych metod filtrowania oraz rozszerzania okna czasowego obliczeń na wyniki indeksów cen. Sprawdzone również metody agregacji danych według podgrup produktów i według outletów dla wybranych formuł indeksów. Obliczenia podparto także analizą czasu kalkulacji potrzebnego na wykorzystywanie poszczególnych sposobów agregacji danych.

W ostatnim, szóstym rozdziale przeprowadzono symulację wpływu zmienności cen i ilości (poziomu konsumpcji) na wartości poszczególnych formuł indeksów przy uwzględnieniu siedmiu sztucznie wygenerowanych zbiorów danych. Oceniono także poszczególne formuły indeksowe ze względu na czas ich kalkulacji w zależności od wielkości zbioru danych. Rozdział ten prezentuje także porównanie odporności formuł indeksów na zmiany struktury próby za pomocą metody jackknife.

## 1. Tradycyjny pomiar inflacji

Pomiar inflacji, dziś będącej jednym z podstawowych wskaźników ekonomicznych, sięga początków XVII wieku. Brytyjski biskup William Fleetwood zakwestionował w swoim dziele *Chronicon Preciosum*, pochodzącym z połowy XV wieku, regułę mówiącą o tym, że stypendyści na Uniwersytecie Oxfordzkim tracą prawo do stypendium, jeśli ich dochód przekracza 5 funtów. Badając ceny zboża, mięsa, napitków oraz ubrań stwierdził, że 5 funtów w latach 1440-1460 było równoważnością aż 25-30 funtów w okresie 1686-1706<sup>2</sup>.

Formalnie pierwszy nieważony indeks cen datowany jest na 1738 rok. Zaproponował go francuski ekonomista Nicolas Dutot, który podjął próbę sprawdzenia realnej zmiany przychodów króla Ludwika XII (posługując się danymi z 1515 r.) i Ludwika XV (dane z 1735 r.) posługując się w swoim koszyku nie tylko dobrami materialnymi, ale także dodając do niego usługi<sup>3</sup> i ujmując w nim m.in. belkę siana, gołębia, królika, kurę, kozę i dzienną pensję kobiet i mężczyzn.

Kolejnymi ekonomistami zgłębiającymi temat indeksów cen byli Giovanni Carli (1774 r., porównanie cen zboża, wina i oliwy) oraz William Stanley Jevons, który w 1863 r. zaproponował formułę podobną do indeksu Nicolasa Dutot proponując jednak, by zamiast średniej arytmetycznej użyć średniej geometrycznej indeksów cząstkowych. O ile wobec indeksu Carliego dziś utrzymują się liczne zastrzeżenia metodologiczne<sup>4</sup>, to indeksy Dutot i Jevonsa (wraz z modyfikacjami) są do dziś wykorzystywane przez urzędy statystyczne<sup>5, 6</sup>.

Na przełomie XIX i XX wieku pojawiła się idea indeksów agregatowych, które miały łączyć dobra i usługi w grupy tak, by oddać ich udział w koszyku konsumenta. Wśród najważniejszych należy wymienić indeksy Laspeyреса (1871 r.), Paaschego (1874 r.) i Fishera (1921 r.). Pojawia się także zaproponowana przez A. Konúsa (1924 r.)<sup>7</sup> idea indeksu COLI (*Cost of Living*

---

<sup>2</sup> O'Neill, R., Ralph, J., Smith, P. (2018), *The rise and rise of inflation*, <https://rss.onlinelibrary.wiley.com/doi/full/10.1111/j.1740-9713.2018.01129.x> [dostęp: 17.04.2023].

<sup>3</sup> Białek, J. (2019), *Metodologia pomiaru inflacji: stan Obecny i wyzwania*, [https://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/6375/2/1/1/pomiar\\_inflacji.\\_stan\\_obecny\\_i\\_wyzwania.pdf](https://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/6375/2/1/1/pomiar_inflacji._stan_obecny_i_wyzwania.pdf) [dostęp: 19.04.2023].

<sup>4</sup> Lewell, P. (2015), *Is the Carli index flawed?: assessing the case for the new retail price index RPIJ*, "Journal of the Royal Statistical Society", No. 178(2).

<sup>5</sup> [https://ec.europa.eu/eurostat/cache/metadata/en/prc\\_hicp\\_esmshi\\_pl.htm](https://ec.europa.eu/eurostat/cache/metadata/en/prc_hicp_esmshi_pl.htm) [dostęp: 19.04.2023]

<sup>6</sup> [https://ec.europa.eu/eurostat/cache/metadata/EN/prc\\_hicp\\_esmshi\\_lt.htm](https://ec.europa.eu/eurostat/cache/metadata/EN/prc_hicp_esmshi_lt.htm) [dostęp: 19.04.2023]

<sup>7</sup> <https://www.ilo.org/public/english/bureau/stat/download/cpi/ch17.pdf> [dostęp: 19.04.2023]



*Index*), definiowanego jako stosunek minimalnych kosztów wymaganych, by utrzymać daną użyteczność koszyka dóbr w stosunku do różnych wektorów cen<sup>89</sup>.

W ramach rozwoju teorii indeksów statystycznych nastąpił rozwój licznych kierunków, z których najistotniejsze są:

- **ujęcie aksjomatyczne**, w którym określamy pożądane własności matematyczne indeksów (zwane także *testami*). Poszukiwania indeksu optymalnego opierają się na sprawdzeniu, który indeks spełnia najwięcej postulatów;
- **ujęcie stochastyczne**, w którym szukając optymalnej formuły indeksu nie opieramy się na testach, ale na własnościach statystycznych indeksów (np. minimalizacji wariancji);. Pewnym wariantem tego ujęcia (tzw. nowe podejście stochastyczne) jest dążenie do ekonometrycznego wymodelowania cen dóbr i usług, tak aby nieznanym lecz szacowanym parametrem tego modelu był poszukiwany indeks cenowy.
- **ujęcie ekonomiczne**, które wywodzi się z pomiaru inflacji za pomocą indeksu COLI. W przeciwieństwie do dwóch poprzednich ujęć nie opiera się wyłącznie na bezpośrednio obserwowalnych zmiennych. Nie zakłada się tu także braku zależności między ilościami a cenami – zamiast tego przyjmuje się, że relacje te określają modele mikroekonomiczne<sup>10</sup>.

### 1.1. Podstawowe miary inflacji: CPI vs HICP

W statystyce publicznej w Europie (choć nie tylko) oblicza się 2 wskaźniki cen konsumpcyjnych. Pierwszym z nich jest CPI (*Consumer Price Index*), który obliczany jest przez narodowe urzędy statystyczne. Metodologia liczenia wskaźnika CPI nie jest jednorodna między krajami, jednak jest tworzona na podstawie wytycznych i rekomendacji międzynarodowych<sup>11</sup>. W Polsce wskaźnik CPI publikowany jest dwa razy w miesiącu. Najpierw (zwykle na koniec danego miesiąca) publikowany jest tzw. szybki szacunek („Flash”) na podstawie części dostępnych danych dotyczących cen detalicznych, a w połowie następnego

---

<sup>8</sup> Juszcak A. (2020), Estimation of the Optimal Parameter of Delay in Young and Lowe Indices in the Fisher Index Approximation, *Statistika: Statistics and Economy Journal* - No. 1/2020

<sup>9</sup> Unayama. T. (2008), Measuring the substitution bias in Japan: the demand system approach and a superlative index, *“Applied Economics”*, No. 40, s. 1795–1806.

<sup>10</sup> Białek, J. (2012), Propozycja indeksu cen, „Wiadomości Statystyczne”, nr 7, , s. 13-24.

<sup>11</sup> IMF (2004), *Consumer Price Index Manual*, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms\\_331153.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms_331153.pdf) [dostęp: 19.04.2023].

miesiąca publikowany jest pełny wynik wskaźnika CPI opierający się na agregacji ok. 350 tys. cen detalicznych – w ujęciu miesięcznym, kwartalnym i rocznym<sup>12</sup>.

Indeks CPI został zaprojektowany w USA podczas I wojny światowej. Gwałtowny wzrost cen przełożył się na konieczność korekt w wynagrodzeniach i aby je wyznaczyć wzięto pod uwagę zmiany cen z 92 ośrodków przemysłowych z lat 1917-1919. Od 1919 r. Bureau of Labor Statistics (BLS) rozpoczęło publikację indeksów dla 32 miast, a od 1921 r. także publikację indeksu krajowego (średnia z wyników dla poszczególnych miast USA)<sup>13</sup>. Historia indeksu HICP jest znacznie krótsza i sięga 23 października 1995 r., kiedy to Rada Unii Europejskiej przyjęła regulację prawną dającą podstawę pod budowę wspólnej zharmonizowanej metodologii liczenia indeksów cen krajach UE i krajach Europejskiego Obszaru Gospodarczego<sup>14</sup>.

Jedną z podstawowych decyzji metodologicznych w procesie liczenia inflacji pozostaje konstrukcja koszyka konsumenckiego. Przy opracowaniu wag od 2014 r. Główny Urząd Statystyczny (GUS), dostosowując się do zaleceń Eurostatu, używa pięciocyfrowego szczebla agregacji do Klasyfikacji Spożycia Indywidualnego według Celu (COICOP). Składa się ona z następujących szczebli:

- Dwucyfrowy – 12 działów,
- Trzycyfrowy – 44 grupy,
- Czterocyfrowy – 110 klas,
- Pięciocyfrowy – 296 podklas.

Dodatkowo na poziomie krajowym dopuszczone są sześciocyfrowe grupy elementarne<sup>15</sup>.

Główne działy w klasyfikacji oddają podział dóbr i usług według określonych potrzeb:

01. Żywność i napoje bezalkoholowe;

02. Napoje alkoholowe i wyroby tytoniowe;

---

<sup>12</sup> Białek, J., Kłopotek, M., Panek, T. (2022), Nowoczesne technologie i nowe źródła danych w pomiarze inflacji, Główny Urząd Statystyczny, Warszawa.

<sup>13</sup> <https://forsal.pl/artykuly/1456807,bialek-metoda-pomiaru-inflacji-ewoluuje-i-jej-zmiany-sa-konieczne-wywiad.html> [dostęp: 19.04.2023].

<sup>14</sup> Rada Europy (1995), Regulacja nr 2494/95, <https://eur-lex.europa.eu/legal-content/PL/ALL/?uri=CELEX%3A31995R2494> [dostęp: 19.04.2023].

<sup>15</sup> GUS (2013), Systemy ważenia w badaniach cen towarów i usług konsumpcyjnych, [https://stat.gov.pl/gfx/portalinformacyjny/userfiles/\\_public/wyniki\\_wstepne/coicop\\_12\\_2013.pdf](https://stat.gov.pl/gfx/portalinformacyjny/userfiles/_public/wyniki_wstepne/coicop_12_2013.pdf) [dostęp: 19.04.2023].

03. Odzież i obuwie;
04. Użytkowanie mieszkania lub domu i nośniki energii;
05. Wyposażenie mieszkania i prowadzenie gospodarstwa domowego;
06. Zdrowie;
07. Transport;
08. Łączność;
09. Rekreacja i kultura;
10. Edukacja;
11. Restauracje i hotele;
12. Inne towary i usługi.

Przykładowa klasyfikacja towarów według kodów COICOP wygląda więc następująco:

- CP01 – Jedzenie i napoje bezalkoholowe -> CP011 - Jedzenie -> CP0112 - Mięso -> CP01122 - Wieprzowina
- CP04 – Użytkowanie mieszkania lub domu i nośniki energii -> CP045 – Elektryczność, gaz i inne paliwa -> CP0454 – Paliwa stałe -> CP04541 – Węgiel
- CP12 – Inne towary i usługi -> CP121 – Pielęgnacja osobista -> CP1211 - Salony fryzjerskie i salony pielęgnacji osobistej -> CP12112 – Fryzjer damski<sup>16</sup>

Badanie zmian cen konsumpcyjnych polega na obserwacji wytypowanego zestawu towarów i usług, czyli tzw. reprezentantów. Obserwacje reprezentantów są prowadzone przez GUS raz w miesiącu i dotyczą wyłącznie towarów dostępnych w sprzedaży na terenie kraju. Pomiar zmian cen nie odzwierciedla też ruchów cen związanych ze zmianą atrybutów towarów, jak jakość czy użyteczność. Główne założenia budowy systemu wag do obliczania CPI w Polsce są następujące:

---

<sup>16</sup> Opracowanie własne na podstawie danych Eurostatu.

Tabela 1. Główne założenia budowy systemu wag do obliczania CPI w Polsce

Założenia	Opis
Zakres geograficzny	Koncepcja narodowa
Populacja	Prywatne gospodarstwa domowe
Zakres przedmiotowy	<p>Wydatki konsumpcyjne z wyłączeniem:</p> <ul style="list-style-type: none"> <li>• Związanych z biznesem.</li> <li>• Przeznaczonych na aktywa takie jak dzieła sztuki, inwestycje finansowe (w odróżnieniu od usług finansowych), płatności kładek na ubezpieczenie społeczne, grzywny, podatki dochodowe, płatności odsetek lub spłat długów.</li> </ul> <p>Transakcje pieniężne realizowane:</p> <ul style="list-style-type: none"> <li>• w gotówce,</li> <li>• czekiem,</li> <li>• kartą kredytową</li> <li>• jako inne zobowiązanie finansowe do zapłaty w zamian za nabycie towaru lub usługi.</li> </ul> <p>Z wyłączeniem transakcji niepieniężnych w zakresie:</p> <ul style="list-style-type: none"> <li>• wydatków na żywność i usług wyprodukowanych na własny rachunek,</li> <li>• wynagrodzeń rzeczowych,</li> <li>• żywności i usług dostarczanych bezpłatnie lub dotowanych przez rząd i instytucje non profit.</li> </ul>
Koncepcja	Wagi plutokratyczne
Struktura wag	<p>Wagi według grupowania przyjęto w klasyfikacji międzynarodowej w tym także regionalne.</p> <p>W każdym województwie wytypowane rejony badania cen (wielkość zależy od wielkości województwa).</p> <p>Punkty sprzedaży odpowiadają najpowszechniejszym lokalom handlowym i odzwierciedlają różnorodność sieci dystrybucji w rejonie badania cen.</p> <p>Obecnie przyjęte założenia w zakresie konwencjonalnych źródeł danych nie przewidują stosowania wag według rodzaju sklepów. Ceny towarów i usług konsumpcyjnych zbierane są w ok. 170 punktach sprzedaży</p>

	<p>detailed in the region. In 2008, e-commerce was excluded. The share of e-commerce in specific COICOP categories is based on data from the Household Budget Surveys concerning internet purchases.</p>
--	----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------

Źródło: Biątek, J., Kłopotek, M., Panek, T. (2022), *Nowoczesne technologie i nowe źródła danych w pomiarze inflacji*, Główny Urząd Statystyczny, Warszawa.

Ze względu na różnice metodologiczne i różne koszyki konsumenckie (koszyki CPI) w poszczególnych krajach UE indeksy te nie powinny być używane do międzynarodowych porównań. Z tego względu Eurostat publikuje także wskaźnik HICP (*Harmonised Index of Consumer Prices*). Powstało także kilka innych typów indeksów opracowywanych przez Eurostat:

- MUICP (*Monetary Union Index of Consumer Prices*) – indeks agregujący dane dla członków strefy euro,
- EICP (*European Index of Consumer Prices*) – indeks agregujący dane pochodzące od wszystkich krajów członkowskich Unii Europejskiej,
- EEAICP (*European Economic Area Index of Consumer Prices*) – indeks który uwzględni dodatkowo dane z Norwegii i Islandii.

Ponadto obliczany jest także indeks HICP indywidualnie dla krajów członkowskich UE, a także dla krajów kandydackich.

W przeciwieństwie do CPI, metodologia liczenia indeksu HICP ma ugruntowane podstawy prawne. Pierwsza regulacja dająca ramy metodologiczne do liczenia indeksu HICP miała miejsce w 1995 r.<sup>17</sup>. Udoskonalana była później kolejnymi regulacjami precyzującymi m.in. sposób liczenia wag<sup>18</sup> lub traktowania mieszkań własnościowych przy kalkulowaniu kosztów życia<sup>19</sup>. W 2016 r. wprowadzono nowe rozporządzenie dotyczące HICP zastępujące poprzednie prawo uchwalone w 1995 r. Nowe rozporządzenie ramowe obejmuje takie kwestie, jak: kompilacja i porównywalność zharmonizowanych wskaźników, wymogi dotyczące danych (w tym szybkich szacunków dla strefy euro) i ich częstotliwości, terminy przesyłania danych do Eurostatu, standardy wymiany i korekty.

Różnice w podejściu do definicji *konsumenta* (HICP uwzględnia, poza wydatkami konsumentów indywidualnych, będących rezydentami, także wydatki nierezydentów oraz


<sup>17</sup> Rada Europy (1995), Regulacja nr 2494/95, <https://eur-lex.europa.eu/legal-content/PL/ALL/?uri=CELEX%3A31995R2494> [dostęp: 19.04.2023].

<sup>18</sup> <https://eur-lex.europa.eu/eli/reg/2010/1114/oj> [dostęp: 19.04.2023].

<sup>19</sup> <https://eur-lex.europa.eu/eli/reg/2013/93/oj> [dostęp: 19.04.2023].

gospodarstw zbiorowych, takich jak szpitale, więzienia, domy opieki)<sup>20</sup> i różnice poziomów wag w koszyku inflacyjnym (CPI bazuje to na *Badaniu Budżetów Gospodarstw Domowych*, natomiast HICP na *rachunkach narodowych*) skutkują różnicami w wartościach CPI oraz HICP. Różnice te nabierają znaczenia zwłaszcza w okresie podwyższonej inflacji – między styczniem a sierpniem 2022 r. inflacja CPI publikowana przez GUS (r/r) była o 1 pkt. proc. wyższa niż wskaźnik HICP publikowany dla Polski przez Eurostat (wykres 1)<sup>21</sup>.

Wykres 1. Porównanie wartości indeksów HICP i CPI w okresie I 2021 - VIII 2022



Źródło: opracowanie własne na podstawie danych GUS i Eurostatu

## 1.2. Źródła danych o cenach

W ramach tzw. „tradycyjnej kolekcji” dane notowane są przez ankieterów urzędów statystycznych bezpośrednio w punktach sprzedaży detalicznej. W przypadku cen zarządzanych przez administrację publiczną (centralną lub samorządy) i niektórych przedsiębiorstw (np. spółek sprzedających energię elektryczną) źródłem informacji o cenach mogą być także cenniki. Urzędy statystyczne na świecie – w tym GUS – korzystają także już w pewnym zakresie z danych pozyskiwanych ze stron internetowych i bezpośrednio od gestorów danych z ich systemów informatycznych, jednak dominuje ciągle tradycyjny sposób zbierania informacji o cenach.

W Polsce badane są ceny ok 1,5 tys. reprezentantów towarów i usług konsumpcyjnych, których lista nie zmienia się przez cały rok i obowiązuje na terenie całego kraju. Wyróżnia się dwa rodzaje reprezentantów: produkty opisane bardzo dokładnie, z podaniem konkretnych

<sup>20</sup> Gatnar, E. (2018), *Statystyczne modele pomiaru inflacji w praktyce banków centralnych*, „Prace Naukowe Uniwersytetu Ekonomicznego we Wrocławiu”, nr 507, doi: 10.15611/pn.2018.507.07.

<sup>21</sup> Obliczenia własne.

parametrów ściśle określających ich cechy i produkty stanowiące wąskie grupy asortymentowe, reprezentujące, np. ubiory, bieliznę, obuwie itp. Wśród reprezentantów objętych badaniem cen konsumpcyjnych znajdziemy zarówno towary kupowane często, jak pieczywo, mleko, warzywa, owoce, mięso, środki czystości i higieny osobistej, jak i towary trwałe, takie jak sprzęt RTV i AGD, meble i komputery. Uwzględniane są także ceny opłat za usługi ponoszone przez gospodarstwa domowe, takie jak ceny nośników energii czy wydatki na cele turystyczne.

Należy zaznaczyć, że lista reprezentantów towarów i usług konsumpcyjnych występujących w badaniu cen detalicznych jest weryfikowana co roku. Proces ten odbywa się na początku roku (nowy koszyk inflacyjny publikowany jest zwykle na przełomie lutego i marca). Weryfikacja listy reprezentantów odbywa się na podstawie danych z innych źródeł niż badanie cen, m.in. danych z książeczek budżetowych respondentów Badania Budżetów Gospodarstw Domowych. W jego ramach następuje aktualizacja opisów, usuwanie opisów produktów, które przestały być reprezentatywne i dodanie nowych, które zwiększyły udział w wydatkach gospodarstw domowych.

Bez uwzględnienia cen skanowanych polski wskaźnik CPI oparty jest na agregacji ok. 350 tys.<sup>22</sup> cen w miesiącu (wzrost z ok. 200 tys. w 2018 r.). Dla porównania, w USA CPI jest liczone na podstawie ok. 94 tys. cen miesięcznie<sup>23</sup>, a w Australii – jest to ok. 100 tys.<sup>24</sup>. Najwięcej wśród mierzonych przez GUS cen przypada na transport (131,8 tys. pomiarów miesięcznie w 2021 r.) oraz żywność i napoje bezalkoholowe (71 tys. cen miesięcznie)<sup>25</sup>.

Notowania realizowane są przez ankietatorów w punktach sprzedaży detalicznej w 207 rejonach (194 miasta) na terenie kraju<sup>26</sup>. Zbierane są informacje z dużych punktów sprzedaży (hipermarkety, domy towarowe, dyskonty), jak i z małych (stragany, osiedlowe sklepy). Ceny towarów i usług notowane są raz w miesiącu z wyjątkiem owoców i warzyw, których ceny są spisywane 2 razy w ciągu miesiąca. Notowania cen paliw silnikowych i oleju opałowego, których ceny mogą się zmieniać częściej niż raz na miesiąc, są prowadzone tak, aby uwzględnić wszystkie zmiany cen w tym okresie. W uzasadnionych przypadkach, jak np. leki refundowane,

---

<sup>22</sup> Białek, J., Kłopotek, M., Panek, T. (2022), *Nowoczesne technologie i nowe źródła danych w pomiarze inflacji*, Główny Urząd Statystyczny, Warszawa.

<sup>23</sup> BLS (2020), Handbook of methods, <https://www.bls.gov/opub/hom/cpi/pdf/cpi.pdf> [dostęp: 19.04.2023].

<sup>24</sup> <https://www.rba.gov.au/education/resources/explainers/inflation-and-its-measurement.html> [dostęp: 19.04.2023].

<sup>25</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

<sup>26</sup> Rejon badania cen to wytypowane do badania miasto, część dużego miasta, gmina lub dzielnica, na obszarze których znajdują się punkty notowań cen detalicznych. Przykładowo, Warszawa podzielona jest na 6 rejonów, Łódź na 2 rejony, <https://stat.gov.pl/metainformacje/slownik-pojec/pojecia-stosowane-w-statystyce-publicznej/422,pojecie.html> [dostęp: 19.04.2023].

których ceny zmieniają się raz na kilka miesięcy (według wykazu prowadzonego przez Ministerstwo Zdrowia), ceny te sprawdzane są rzadziej niż raz na miesiąc.

### 1.3. Źródło danych o poziomie konsumpcji

Poza danymi dotyczącymi cen reprezentantów które zbierane są przez ankieterów GUS (i później agregowane do 340 grup elementarnych) do obliczenia wskaźnika CPI niezbędne są dane dotyczące struktury wydatków konsumpcyjnych gospodarstw domowych (w 2019 r. w badaniu brało udział ok. 37 tys. gospodarstw domowych)<sup>27</sup>. Wagi te obliczane są w Polsce na podstawie Badania Budżetów Gospodarstw Domowych, a do ich obliczania stosowane są dane dotyczące wydatków pieniężnych gospodarstw domowych. W niektórych przypadkach zalecane jest jednak uzupełnianie tych informacji o dane z innych źródeł. Tak dzieje się np. w przypadku wydatków „wstydlivych” (alkohol, wyroby tytoniowe, restauracje). Należy też zaznaczyć, że niektóre wydatki, jak np. wydatki na narkotyki, nie są wliczane w obliczane wagi<sup>28</sup>.

Według definicji GUS, branej pod uwagę przy Badaniu Budżetów Gospodarstw Domowych, gospodarstwo domowe to „zespół osób spokrewnionych ze sobą lub niespokrewnionych, mieszkających razem i wspólnie utrzymujących się (gospodarstwo domowe wieloosobowe) lub osoba utrzymująca się samodzielnie, bez względu na to, czy mieszka sama, czy też z innymi osobami”. Oznacza to, że członkowie rodziny mieszkający wspólnie, ale utrzymujący się oddzielnie tworzą osobne gospodarstwa domowe. W jednym mieszkaniu lub domu może być zatem więcej niż jedno gospodarstwo domowe. Jednocześnie do wspólnego gospodarstwa domowego zaliczamy:

- osoby mieszkające razem w gospodarstwie domowym i wspólnie utrzymujące się, przebywające bądź zamierzające przebywać w gospodarstwie domowym przez okres co najmniej roku;
- osoby nieobecne w gospodarstwie domowym z racji pracy zawodowej, jeśli dochody z pracy tych osób przekazywane są rodzinie na utrzymanie (niezależnie od okresu przebywania poza gospodarstwem domowym);

---

<sup>27</sup> <https://stat.gov.pl/dla-mediow/komunikaty-prasowe/wskaznik-cen-towarow-i-uslug-konsumpcyjnych-pot-inflacja,100,1.html> [dostęp: 19.04.2023].

<sup>28</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.



- osoby nieobecne w gospodarstwie domowym, w wieku do 15 lat włącznie, pobierające naukę poza miejscem zamieszkania, mieszkające w internatach lub w domach prywatnych;
- osoby przebywające w zakładzie karnym, jeżeli ich rzeczywisty lub przewidywany okres pobytu poza gospodarstwem domowym jest krótszy niż rok;
- osoby nieobecne w gospodarstwie domowym w okresie badania, przebywające w zakładach opiekuńczo-wychowawczych, w domach opieki lub szpitalach, jeżeli ich rzeczywisty lub zamierzony okres pobytu poza gospodarstwem domowym jest krótszy niż rok.

Do składu gospodarstwa domowego, według definicji GUS, nie zalicza się natomiast:

- osób nieobecnych w gospodarstwie domowym, w wieku powyżej 15 lat, pobierających naukę poza miejscem zamieszkania, mieszkających w internatach, domach akademickich lub w domach prywatnych;
- osób przebywających w zakładzie karnym, jeżeli ich rzeczywisty lub przewidywany okres pobytu poza gospodarstwem domowym jest dłuższy niż rok;
- osób nieobecnych w gospodarstwie domowym w okresie badania, przebywających w zakładach opiekuńczo-wychowawczych, w domach opieki lub w szpitalach, jeżeli ich rzeczywisty lub zamierzony okres pobytu poza gospodarstwem domowym jest dłuższy niż rok;
- osób przebywających w gospodarstwie domowym w okresie badania (gości), obecnych w gospodarstwie domowym lub zamierzających w nim przebywać przez okres krótszy niż rok;
- lokatorów, w tym uczniów i studentów na stancji (z wyjątkiem sytuacji, gdy są oni traktowani przez badane gospodarstwo domowe jako członkowie gospodarstwa);
- osób wynajmujących pokój lub łóżko, na okres pracy w danej miejscowości (dotyczy to np.: takich prac jak melioracje, pomiar gruntów, wyrąb lasów, budowa);
- osób mieszkających wspólnie z gospodarstwem domowym, zatrudnionych przez to gospodarstwo, np.: pomocy domowych, robotników rolnych, uczniów i praktykantów w zawodzie<sup>29</sup>.

---

<sup>29</sup> GUS (2018), *Zeszyt metodologiczny. Badanie Budżetów Gospodarstw Domowych*, Warszawa.

## 1.4. Źródła obciążenia pomiaru inflacji

Niniejszy podrozdział podejmuje tematykę źródeł obciążeń pomiaru inflacji.

### Obciążenie z tytułu substytucji dóbr (*substitution bias*)

Najlepiej rozpoznany źródłem obciążenia wskaźnika CPI jest obciążenie z tytułu substytucji dóbr. Konsumenci reagują na zmiany cen towarów i usług szukając tańszych zamienników. Na przykład, w sytuacji podwyższenia ceny masła – więcej klientów kupuje margarynę, a w przypadku wzrostu cen paliwa – więcej osób korzysta z transportu zbiorowego. Indeksy takie jak CPI korzystają jednak z wag dla okresu bazowego – w tym przypadku jest to koszyk inflacyjny publikowany przez GUS na przełomie lutego i marca na podstawie danych zbieranych w poprzednich miesiącach. Z tego względu indeksy te nie mogą uchwycić w pełni zmian dynamiki konsumpcji, co skutkuje obciążeniem substytucyjnym.

Najpopularniejszym podejściem do liczenia indeksów cen jest stosowanie wag opartych na strukturze wydatków w okresie poprzednim (lub jeszcze wcześniejszym) albo obecnym. Do ich obliczenia stosujemy np. indeks Laspeyresa (wagi z okresu bazowego):

$$P_{La} = \frac{\sum_{i=1}^n p_{i,t} q_{i,0}}{\sum_{i=1}^n p_{i,0} q_{i,0}}, \quad (1)$$

oraz Pascheego (wagi z okresu obecnego):

$$P_{Pa} = \frac{\sum_{i=1}^n p_{i,t} q_{i,t}}{\sum_{i=1}^n p_{i,0} q_{i,t}}, \quad (2)$$

gdzie:  $p_i$  – cena dobra  $i$ ,  $q_i$  – ilość dobra  $i$  w koszyku konsumpcyjnym, indeks  $t$  – okres bieżący, indeks 0 – okres bazowy<sup>30</sup>.

Ze względu na zmianę struktury konsumpcji oba te indeksy są obciążone. Indeks Laspeyresa, bazując na strukturze w okresie poprzednim, może przeszacowywać rzeczywistą inflację, Wykazano to już w raporcie M.J. Booskina (1996), w którym określono obciążenie z tytułu substytucji na 0,4 pkt. proc.<sup>31</sup>.

---

<sup>30</sup> Hałka, A., Leszczyńska, A. (2011), Wady i zalety wskaźnika cen towarów i usług konsumpcyjnych – szacunki obciążenia dla Polski, „Gospodarka Narodowa”, nr 9, s. 60-61.

<sup>31</sup> Boskin, M.J., Dulberger, E., Gordon, R., Griliches, Z., Jorgenson, D. (1996), Toward a More Accurate Measure of the Cost of Living, Final Report to the Senate Finance Committee, (w:) Getting Prices Right, Roulledge, London.

### Obciążenie wynikające z pojawiania się nowych dóbr na rynku (*new good bias*)

Nowo pojawiające się towary i usługi nie są od razu uwzględniane w koszyku inflacyjnym. Zwykle pojawiają się one z dużym opóźnieniem, co prowadzi do dodatkowych obciążeń wskaźnika. Przykładowo, mimo że pierwszy operator komórkowy pojawił się w Polsce w 1992 r., a na przełomie XX i XXI w. duża część społeczeństwa posiadała już telefon komórkowy, to usługa telefonii komórkowej została uwzględniona w polskim koszyku inflacyjnym dopiero w 2006 r.

Wpływ nowych dóbr nie ogranicza się jednak do uwzględnienia ich samych w wydatkach społeczeństwa. Nowe technologie powodują duży spadek cen produktów poprzedniej generacji oraz ich dostępność dla ogółu. Jednocześnie nowe technologie mogą także wpływać na ceny bardziej tradycyjnych dóbr i usług, usprawniając procesy produkcyjne co pozwala obniżyć ich ceny. Należy także zwrócić uwagę na moment wprowadzania nowych produktów do koszyka inflacyjnego - nowe rozwiązania mają tendencję do bycia początkowo drogimi i dostępnymi tylko dla części społeczeństwa, jednak następuje tam bardzo szybki spadek ceny. Jeśli w trakcie tego procesu dobro takie zostanie wprowadzone do koszyka, jego cena może ostatecznie być przeszacowana.

Odmianą omawianego błędu może być obciążenie wynikające z pojawiania się nowych marek produktów na rynku (*new brand bias*). Zwiększenie ilości dostępnych produktów zaspokajających tę samą potrzebę powoduje zwiększenie wyboru konsumenta i może „napędzić” konkurencję między produktami zmniejszając koszt, który musi ponieść konsument<sup>32</sup>.

Nowe produkty mogą także wypierać starsze produkty, co jest problematyczne z punktu liczenia cen, jeśli dzieje się w środku badanego okresu. Aby uchronić indeksy od kolejnych zmian, niektóre urzędy statystyczne w Europie (m.in. we Włoszech) stosują metodę przeliczania ceny między starym i nowym produktem. Wykorzystuje się do tego tymczasowy wskaźnik cen wyliczany z równania uwzględniające proporcje cen dóbr A (starsze już niedostępne) i B (nowe) w miesiącu poprzednim, gdy oba te dobra były dostępne. Dzięki temu utrzymuje się kontynuację indeksu uwzględniając zmianę jakościową oraz cenową jakiej poddany jest konsument<sup>33</sup>.

---

<sup>32</sup> Durcharme, L.M. (2000), The canadian CPI and the bias issue: present and future outlooks, "ESTADÍSTICA ESPAÑOLA", Vol. 42, Núm. 145, s. 29-30.

<sup>33</sup> Drudi, I. (2003), The treatment of substitution bias in consumer price index: an alternative approach, "Statistical Methods&Applications", No. 11, s. 397-398.

### Obciążenie wynikające z miejsce notowania cen (*outlet bias*)

Duża liczba kanałów dystrybucji, od małych sklepów i targów, poprzez dyskonty i hipermarkety, a kończąc na sklepach internetowych, wpływa na dużą różnorodność cen, które konsument płaci za te same dobra i usługi. Jednocześnie ankietrzy są w stanie odwiedzić tylko niewielką część sklepów, w których dokonują oni pomiarów w równych odstępach czasu. Każdy towar zestawiony jest z danym sklepem w parze, więc późniejszą cenę wylicza się zestawiając wyliczone wskaźniki inflacji na dany produkt we wszystkich sklepach. Konsumenty, w przeciwieństwie do ankietrzy, zmieniają miejsce zakupu kierując się cenami i promocjami w alternatywnych miejscach zakupu<sup>34</sup>.

Różnica między wyborami miejsc badań przez urzędy statystyczne a wyborami konsumentów została zbadana w Czechach. W czasie prowadzenia badania hipermarkety odpowiadały za 10 proc. notowanych cen z grupy żywności i napojów, podczas gdy w rzeczywistości ich udział w rynku wynosił dwukrotnie więcej. Podobnie było w przypadku odzieży i obuwia - 10 proc. dóbr podchodziło z hipermarketów, podczas gdy ich udział w badaniach ankietrzy cen tej kategorii wynosił 5 proc.<sup>35</sup>.

Aby zmniejszyć ten problem, sklepy obejmowane badaniem wybierane są rotacyjnie. W USA wybór nowego miejsca notowania cen jest dokonywany na zasadzie prawdopodobieństwa, które ma odzwierciedlać odsetek konsumentów wybierających dany sklep. W Kanadzie wybór dokonywany jest w sposób arbitralny. Tu jednak powstaje kolejny problem – przy zmianie sklepu cena porównywana jest z ceną w tym obiekcie w poprzednim okresie, nie zaś z ceną towaru w poprzednio uwzględnionym w próbie sklepie.

### Obciążenie wynikające ze zmian jakości produktów (*quality bias*)

Część towarów, jak chociażby duża część produktów spożywczych, pozostaje przez lata na podobnym poziomie jakości. Parametry dostępnego w sklepach masła dziś i 10 lat temu nie różnią się między sobą w znaczący sposób. W przypadku części dóbr, jak komputery, samochody czy telefony komórkowe, widać jednak ciągłą poprawę jakości, ich nowe funkcje i lepsze parametry. Cena laptopa może więc przykładowo w ciągu roku wzrosnąć o 3 proc., ale

---

<sup>34</sup> Greenlees, J.S., McClelland, R. (2008), New Evidence on Outlet Substitution Effects in Consumer Price Index Data, BLS WORKING PAPERS 421.

<sup>35</sup> Filer, R.K., Hanousek, J. (2003), Inflationary bias in middle to late transition Czech Republic, "Economic Systems", No. 27, s. 367-376.

jednocześnie zmianie ulegają jego parametry, jak szybkość procesora, wielkość pamięci RAM czy karta graficzna<sup>36</sup>.

Obciążenie wynikające ze zmian jakości produktów (*quality bias*) jest często omawiane łącznie z obciążeniem wynikającym z pojawiania się na rynku nowych produktów ze względu na częste łączenie się tych efektów. Według raportu komisji Boskina, stanowiły one łącznie jedno z największych obciążeń wskaźnika CPI w USA wynosząc nawet 0,6 pkt. proc. Wedle późniejszych wyliczeń (Gordon oraz Lebow i Rudd) obciążenie CPI tego rodzaju mieści się w przedziale 0,3-0,4 pkt. proc. W Japonii natomiast pod koniec XX wieku oszacowano je na poziomie nawet 0,7 pkt. proc.<sup>37</sup>.

Jedną z ciekawszych metod radzenia sobie z tym rodzajem obciążenia CPI jest metoda estymacji hedonistycznej. Na podstawie pełnych danych obejmujących nie tylko cenę, ale i dokładny opis parametrów towaru, budowany jest model regresji panelowej wykorzystujący wartość każdego z komponentów, które składają się na jego cenę<sup>38</sup>. Następnie zestawiając ze sobą produkty różniące się poszczególnymi cechami za pomocą współczynnika regresji można wyznaczyć, o ile zmiana danej cechy skutkuje zmianą ceny produktu. Metoda ta sięga swoją historią połowy XX wieku, kiedy w USA zastosowano ją przy liczeniu zmian cen czynszu uwzględniając liczbę pokoi oraz inne istotne elementy mieszkania<sup>39</sup>.

#### Obciążenie wynikające z metody kalkulacji (*formula bias*)

Poszczególne urzędy statystyczne różnią się wyborem metody obliczeń na najniższym poziomie agregacji danych<sup>40, 41</sup>. Obciążenie, które niesie ze sobą wybór poszczególnych metod nazywa się obciążeniem wynikającym z metody kalkulacji lub obciążeniem indeksu elementarnego. Wyróżnić można trzy stosowane indeksy elementarne:

---

<sup>36</sup> Juszcak, A. (2018), Pomiar i redukcja obciążenia wskaźnika cen dóbr i usług konsumpcyjnych (CPI), Praca Magisterska, Uniwersytet Łódzki, Łódź.

<sup>37</sup> Nahm, D. (2015), The Effects of New Goods and Substitution on the Korean CPI as a Measure of Cost of Living, "International Economic Journal", Vol. 29, No. 1 s. 59.

<sup>38</sup> <https://www.bls.gov/cpi/quality-adjustment/questions-and-answers.htm> [dostęp: 19.04.2023].

<sup>39</sup> Wells, J., Restieaux, A. (2014), Review of Hedonic Quality Adjustment in UK Consumer Price Statistics and Internationally, ONS, <https://www.data.gov.uk/dataset/9f837ab0-4508-4f91-bd14-92b7b9674f1a/review-of-hedonic-quality-adjustment-in-uk-consumer-price-statistics-and-internationally> [dostęp: 19.04.2023].

<sup>40</sup> Ze względu na unijne regulacje żaden z 27 krajów UE nie używa indeksu Carliego.

<sup>41</sup> Przykładowo, w Wielkiej Brytanii ok 70% elementarnych agregatów oblicza się za pomocą metody Jevonsa. Do reszty natomiast stosuje się metodę Dutota w wyłączeniu nielicznych przypadków, gdy używa się innych rzadkich metod.

- Indeks Carliego polegający na wyliczeniu średniej arytmetycznej proporcji cen poszczególnych dóbr w danym okresie w stosunku do okresu bazowego. Indeks ten opiera się na użyciu średniej arytmetycznej z cząstkowych indeksów cen:

$$P_c = \frac{1}{n} \sum_{i=1}^n \frac{p_{i,t}}{p_{i,0}} \quad (3)$$

gdzie:  $p_{i,t}$  – cena dobra  $i$  w okresie  $t$ ,  $p_{i,0}$  – cena dobra  $i$  w okresie bazowym.

- Indeks Dutot - można sprowadzić do ilorazu średniej arytmetycznej cen w okresie  $t$  i średniej arytmetycznej cen w okresie bazowym 0:

$$P_D = \frac{\frac{1}{n} \sum p_{i,t}}{\frac{1}{n} \sum p_{i,0}} = \frac{\sum_{i=1}^n p_{i,t}}{\sum_{i=1}^n p_{i,0}} \quad (4)$$

gdzie:  $p_{i,0}$  - cena dobra  $i$  w okresie bazowym,  $p_{i,t}$  – cena dobra  $i$  w okresie  $t$ .

- Indeks Jevonsa, który ma analogiczną konstrukcję jak indeks Dutot ale stosuje średnią geometryczną zamiast średniej arytmetycznej:

$$P_J = \frac{\prod_{i=1}^n p_{i,t}^{\frac{1}{n}}}{\prod_{i=1}^n p_{i,0}^{\frac{1}{n}}} \quad (5)$$

gdzie:  $p_{i,0}$  - cena dobra  $i$  w okresie bazowym,  $p_{i,t}$  – cena dobra  $i$  w okresie  $t$ .

Użycie metody opartej na średniej arytmetycznej do wyliczenia agregatu może skutkować przeszacowaniem końcowego wskaźnika. Jeśli natomiast do obliczania cen najpierw wyliczymy średnią cenę z punktu notowań i dopiero tę średnią odniesiemy do średniej z okresu bazowego, to nie powinniśmy mieć obciążenia. W wielu krajach uważa się jednak, że najmniejsze obciążenie dają rachunki oparte na średniej geometrycznej, tak jak czyni to formuła Jevonsa<sup>42</sup>.

Problem obciążenia wskaźnika cen konsumenta w stosunku do COLI od lat jest badany w wielu krajach. Najbardziej znane są wnioski z raportu Komisji Boskina (1996), które wykazały, że obciążenie wskaźnika CPI w USA wynosiło ok 1,1 pkt. proc w skali roku. Istotną składową obciążenia było obciążenie z tytułu substytucji dóbr (0,4 pkt. proc.). Zmiana jakości dóbr i wprowadzanie nowych dóbr odpowiadały za 0,6 pkt .proc., a obciążenie z tytułu zmian miejsca robienia zakupów – 0,1 pkt. proc.

---

<sup>42</sup> Hałka, A., Leszczyńska, A. (2011), Wady i zalety wskaźnika cen towarów i usług konsumpcyjnych – szacunki obciążenia dla Polski, „Gospodarka Narodowa”, nr 9, s. 60-61.

Liczne badania obciążenia wskaźników inflacji wskazują zwykle na przeszacowanie inflacji (patrz tabela 2<sup>43</sup>), wśród powodów wskazując między innymi na długie okresy stosowania niezmiennych wag i późne wprowadzanie nowych produktów i usług do koszyka inflacyjnego<sup>44</sup>.

Tabela 2. Przegląd badań nad obciążeniem wskaźników cen konsumenta

Kraj, lata badania	Obciążenie wskaźnika r/r	Średnia stopa inflacji r/r	Źródło
USA, 1995-1996	CPI łącznie przeszacowuje inflację o +1,1 pkt proc. (0,8-1,6) w tym: substytucji dóbr 0,4 pkt proc., miejsca notowania cen 0,1 i zmiany jakości lub nowych dóbr 0,6 pkt proc. W okresie badania wagi pochodziły sprzed 14 lat	2,90%	Boskin et al. [1996]
USA, 1914-2003	Obciążenie cen wynajmu (składnik CPI) wynosi ok. -1 pkt proc.	3,40%	Gordon, van Goethem [2005]
USA, 1968-1994	CPI przeszacowuje inflację o 1,5 pkt proc. (metoda subiektywna)	5,70%	Nordhaus [1998]
Wielka Brytania 1995-1996	RPI przeszacował inflację o 0,35 – 0,8 pkt proc., w tym: substytucja dóbr 0-0,1 pkt proc. Wagi zmieniane co rok	ok. 3%	Cunningham [1996]
Wielka Brytania, 1996-2004 i Włochy, 1990-2004	W Wielkiej Brytanii nie stwierdzono obciążenia. We Włoszech przed przystąpieniem do strefy Euro HICP nie wykazywał obciążenia, jednak w okresie 2002-2004 HICP był zanizony w stosunku do inflacji postrzeganej przez konsumentów o 6 pkt proc. (metoda subiektywna)	Wielka Brytania: 1,3% Włochy: 2,3%	Marini, Piergallini, Scaramozzino [2007]
Kanada 1962-1994	Łączne przeszacowanie CPI: do +0,7 pkt proc. w tym: substytucja 0,2 pkt proc. (w tym substytucja dóbr 0,1 pkt proc.), nowe produkty i zmiana jakości 0,5 pkt proc. Wagi aktualizowane co 4 lata	5,30%	Crawford [1998]

<sup>43</sup> Najnowsze badania – dotyczące wpływu pandemii COVID-19 i dynamicznej zmiany koszyka inflacyjnego rok do roku zostały omówione w podrozdziale 1.5.

<sup>44</sup> Tamże.

Hiszpania 1992-1998	Badanie „luki plutokratycznej”. Łączne obciążenie: od -0,12 pkt proc. (niedoszacowanie) do +0,03 pkt proc. (przeszacowanie)	6,80%	Ruiz-Castillo, Ley, Izquierdo [2002]
Czechy, 1990- 1999	CPI łącznie przeszacowywał prawdziwą inflację od +4,4 do +4,8 pkt proc. rocznie	ok. 10%	Filer, Hanousek [2003]
Francja 1995- 1996	Łączne przeszacowanie: od +0,10 do +0,25 pkt proc. w tym substytucja dóbr 0,05-0,10 pkt proc. Wagi zmieniane co roku	2,00%	Lequiller [1997]
Japonia 1982- 2002	Obciążenie CPI liczone jako różnica pomiędzy indeksem Laspeyresa (opublikowany CPI) a indeksem Fishera (indeks superlatywny): 0,03 pkt proc.	0,80%	Unayama [2004]
Tanzania 2003-2006	Indeks CPI niedoszacował inflacji mierzonej indeksem plutokratycznym średnio o 2,7 pkt proc.	5,60%	Ngasamiaku, Mkenda [2009]

Źródło: Hałka, A., Leszczyńska, A. (2011), *Wady i zalety wskaźnika cen towarów i usług konsumpcyjnych – szacunki obciążenia dla Polski*, „Gospodarka Narodowa”, wrzesień.


### 1.5. Wpływ pandemii COVID-19 na pomiar inflacji

Pandemia COVID-19 zmusiła rządy na całym świecie do wprowadzenia obostrzeń w postaci lockdownów, ograniczania masowych spotkań i możliwości podróży. To przyczyniło się do drastycznych zmian w koszykach konsumenckich. Większość urzędów statystycznych aktualizuje swoje koszyki inflacyjne raz w roku (zwykle na jego początku) korzystając z danych o konsumpcji z 2 poprzednich lat. W okresie stabilizacji gospodarczej roczne zmiany w schematach konsumpcji nie są wysokie, jednak w obliczu kryzysów mogą one być znacznie poważniejsze, co prowadzi do znacznego zwiększenia obciążeń w pomiarze inflacji.

Drastyczne zmiany w koszyku konsumenckim można zaobserwować na przykładzie indeksu HICP dla UE-27. Według danych z 2020 r. (włączonych do koszyka inflacyjnego w 2021 r.), średnia bezwzględna zmiana udziału 12 głównych kategorii COICOP w koszyku inflacyjnym wyniosła ponad 10 proc. (w por. z 1,17 proc. w poprzednim roku). Udział wydatków na restauracje i hotele spadł o 25 proc. a wydatków na transport o ponad 11 proc. Jednocześnie zwiększył się udział żywności i napojów bezalkoholowych (o 12 proc.) i napoi alkoholowych i wyrobów tytoniowych (12 proc., wykres 2).




Wykres 2. Porównanie zmian udziału 12 głównych kategorii COICOP w koszyku inflacyjnym w UE-27



Źródło: opracowanie własne na podstawie danych Eurostatu.

W Polsce średnia zmiana udziału poszczególnych kategorii w koszyku inflacyjnym na 2021 r. była niższa i wyniosła niecałe 7 proc. (wobec 1,7 proc. w roku poprzednim). Wynikało to między innymi z niższego niż w innych krajach UE-27 udziału sektorów rekreacji i kultury oraz restauracji i hoteli w koszyku inflacyjnym. Co interesujące, w pierwszym roku pandemicznym znacząco spadł udział wydatków na odzież i obuwie (14 proc.), by w kolejnym roku, gdy obostrzenia były mniejsze, wzrosnąć o 15 proc. O 13,6 proc. wzrósł też udział wydatków na zdrowie (wykres 3).

Wykres 3. Porównanie zmian udziału 12 głównych kategorii COICOP w koszyku inflacyjnym w Polsce



Źródło: opracowanie własne na podstawie danych Eurostatu.

W wyniku tak znaczących zmian koszyka inflacyjnego, zwłaszcza w szoku podczas pierwszych miesięcy całkowitego lockdownu, nastąpiło znaczące niedoszacowanie inflacji, jako że spadały ceny głównie tych towarów, na które drastycznie spadł popyt (transport, usługi restauracyjne, paliwo, hotele), a jednocześnie znacząco wzrosły ceny towarów, na które rósł popyt (środki do dezynfekcji, maseczki). Używając danych z kart kredytowych, Cavallo (2020) stworzył wskaźnik *Covid-CPI* i porównał majową inflację z CPI polegającym na przedpandemicznych wagach (tabela 3)<sup>45</sup>.

<sup>45</sup> Cavallo, A. (2020), Inflation with Covid consumption baskets, Working Paper 27352 <http://www.nber.org/papers/w27352> [dostęp: 19.04.2023].

Tabela 3. Porównanie CPI i Covid CPI w wybranych krajach

Kraj	CPI	Covid CPI
Brazylia	1,65	2,53
Urugwaj	10,99	11,81
USA	0,13	0,95
Korea	-0,45	0,04
Chile	2,68	3,05
Francja	0,55	0,88
Kolumbia	2,72	2,97
Kanada	-0,34	-0,12
Turcja	11,56	11,73
Japonia	0,07	0,22
Hiszpania	-0,18	-0,09
Wielka Brytania	0,59	0,67
Argentyna	43,38	43,45
Niemcy	0,57	0,53
Irlandia	-0,85	-0,91
Holandia	1,20	1,13
Włochy	0,86	0,52
Grecja	0,25	-0,10

Źródło: Cavallo, A. (2020), *Inflation with Covid consumption baskets*, Working Paper 27352,

<http://www.nber.org/papers/w27352> [dostęp: 01.07.2022]

W większości krajów, dla których dokonano obliczeń indeks *Covid CPI* był wyższy niż w przypadku wag z okresu t-1, a średnia bezwzględna różnica wynosiła 0,31 pkt. proc. Mimo pewnych ograniczeń (wagi indeksu *Covid – CPI* we wszystkich krajach były zmieniane posługując się zmianami zachowań konsumentów z USA), wnioski Cavallo zostały powielone w kolejnych badaniach. Cleys i Guetta-Jeanreanaud (2021), porównując indeks HICP oficjalnie wyliczony przez Eurostat z indeksem *ex post* wyliczonym na podstawie wag realnych znanych z badań gospodarstw domowych w 2020 r., pokazali, że różnice w poszczególnych miesiącach pierwszego roku pandemii wynosiły od 0,2 pkt. proc. do nieco ponad 0,3 pkt. proc., podczas gdy w większości miesięcy przedpandemicznych zastosowanie koszyka inflacyjnego *ex post* zmieniało wynik o 0,01-0,03 pkt. proc.<sup>46</sup>.

Kwestia rozdziwku między koszykami inflacyjnymi bazującymi na danych o konsumpcji sprzed roku, a faktycznym zachowaniem konsumentów jest także widoczna w 2021 r. (patrz wykresy 2 i 3). Z dużym prawdopodobieństwem także obecny od początku 2022 r. kryzys na rynku energii skutkujący m.in. bardzo wysokimi różnicami w konsumpcji paliw stałych w gospodarce i istotnymi (choć mniej niż w przypadku lockdownów) zmianami zachowań

<sup>46</sup> Cleys, G., Guetta-Jeanreanaud, L. (2021), How has COVID-19 affected inflation measurement in the euro area?, Bruegel Blog, 24 March.

konsumentów może powodować dodatkowe obciążenia przy liczeniu inflacji. Stawia to pytanie o konieczność przyspieszenia prac nad nowymi metodami pozyskiwania danych o konsumpcji, które – choć częściowo – mogą posłużyć do rewizji koszyka inflacyjnego w okresie krótszym niż rokroczny, na przykład w postaci dodatkowo publikowanego wskaźnika CPI.

## 2. Dane skrapowane jako alternatywne źródło danych w pomiarze inflacji

W rozdziale 2 przedstawiono metodologię wykorzystania danych skrapowanych do obliczenia inflacji. W pierwszym podrozdziale omówiono definicję i genezę danych skrapowanych. Następnie omówiono metodykę ich pozyskiwania, przetwarzania, klasyfikacji i dopasowania produktów w czasie. W trzecim podrozdziale zaprezentowano zalety danych skrapowanych, a w czwartym ograniczenia aplikacyjne i wyzwania metodologiczne z nimi związane. W ostatnim, piątym podrozdziale, omówiono formuły indeksów cen dedykowane danym skrapowanym.

### 2.1. Definicja i geneza danych skrapowanych


Skrapowanie (*web-scraping* znane także jako *web harvesting*, *web data extraction*) to proces pozyskiwania danych ze stron internetowych. Choć w teorii *web-scraping* może być wykonywany manualnie przez użytkownika strony, zwykle to określenie stosuje się w odniesieniu do zautomatyzowanego procesu wydobycia i skopiowania określonych wcześniej informacji za pomocą oprogramowania lub skryptu zwanego także *botem* lub *web crawlerem*.

Pełne zautomatyzowanie pozyskiwania informacji może być źródłem ogromnej ilości danych na temat dóbr i usług, a także trendów rynkowych (w tym cen). Jest to tym istotniejsze, że w ostatnich latach znacząco zwiększył się odsetek osób dokonujących zakupów przez internet. Według badania przeprowadzonego przez UNCTAD w Brazylii, Chinach, Niemczech, Włoszech, Republice Korei, Federacji Rosyjskiej, RPA, Szwajcarii i Turcji, mimo że średnie wydatki online spadły z powodu kryzysu gospodarczego, odsetek aktywnych kupujących online dokonujących co najmniej jednego zakupu online w ostatnich dwóch miesiącach wzrosła o 6 pkt. proc. do 10 pkt. proc. w większości kategorii produktów<sup>47</sup>. W 2021 r. aż 69% obywateli UE wskazało, że dokonało przynajmniej jednego zakupu przez internet w ostatnim roku (wzrost o 2 pkt. proc. w stosunku do 2020 r.), a 57% w ostatnich 3 miesiącach (wzrost z 54% w 2020 r., Eurostat, wykres 4).

---

<sup>47</sup> <https://unctad.org/news/covid-19-has-changed-online-shopping-forever-survey-shows> [dostęp: 19.04.2023]

Wykres 4. Odsetek osób, które dokonały przynajmniej jednego zakupu przez internet w 2021 r.



Źródło: opracowanie własne na podstawie danych Eurostatu.

Geneza skrapowania sięga 1989 r. i powstania stron internetowych *www* (*world wide web*), których inicjatorem był pracujący wówczas w Europejskiej Organizacji Badań Jądrowych CERN Tim Berners-Lee<sup>48</sup>. Szybki rozwój idei stron internetowych przełożył się na powstanie pierwszego oprogramowania do skrapowania i już w 1993 r. powstały pierwsze *web-crawlers* – World Wide Web Wanderer i Jump station. Natomiast w 2000 r. powstało API (Application Programming Interface) wraz z pierwszym opartym na API *crawlerem*.

Badania nad wykorzystaniem danych skrapowanych do pomiaru cen sięgają połowy lat 2000ych. Lunneymann i Wintr (2006) zauważyli w swoim badaniu różnicę pomiędzy lepkością cen (*price stickiness*) w sklepach fizycznych i sklepach online. Dwa lata później Cavallo i Rigobon, reprezentujący Uniwersytety Harvarda oraz MIT, założyli Billion Prices Project, w ramach którego zbierali codziennie ceny od setek sprzedawców internetowych na całym świecie. Mimo że projekt oficjalnie zakończył się w 2016 r., ciągle skutkuje dodatkowymi analizami, jak *Inflation Verdadera Argentina*, *Inflation Verdadera Venezuela*, które oferują alternatywne pomiary inflacji w kontrze do oficjalnych statystyk rządowych<sup>49</sup> czy *Pricestats Daily Inflation Indicators*, w ramach którego prowadzone są badania inflacji i wskaźników siły nabywczej w 20 krajach<sup>50</sup>. W 2021 r. zmierzono także alternatywny wskaźnik inflacji w trakcie

<sup>48</sup> <https://eu.usatoday.com/story/tech/news/2019/03/12/world-wide-web-turns-30-berners-lee-contract-thoughts-internet/3137726002/> [dostęp: 19.04.2023]

<sup>49</sup> <http://www.inflacionverdadera.com/argentina/english/> [dostęp: 19.04.2023]

<sup>50</sup> <https://www.pricestats.com/inflation-series> [dostęp: 19.04.2023]

pandemii COVID-19 bazujący na koszykach inflacyjnych odpowiadających realiom lockdownów.

Stosunkowo szybko rozwinęły się także inne projekty wykorzystujące dane skrapowane do pomiaru cen. Zaczęto je wykorzystywać w licznych urzędach statystycznych, m.in. w Austrii Kanadzie, Niemczech, Holandii, Norwegii czy USA (Auer & Boettcher<sup>51</sup>; Bosch<sup>52</sup>; Chuanyang & Lee<sup>53</sup>; Polidoro et al.<sup>54</sup>). Jednym z pierwszych urzędów statystycznych, które na dużą skalę zaczęły projekty z wykorzystaniem danych skrapowanych był brytyjski ONS (*Office of National Statistics*), który początkowo wykorzystywał do analizy dane z trzech sieci handlowych (Tesco, Sainsbury's oraz Waitrose & Partners). Według ankiety przeprowadzonej przez Eurostat i Europejski Bank Centralny (2020), dwadzieścia z ankietowanych krajów Europy już wprowadziło dane skrapowane do pomiaru inflacji, choć kilka z nich było dopiero w fazie testowania. Najczęściej były to takie kategorie dóbr i usług, jak odzież i obuwie, przedmioty gospodarstwa domowego, używane samochody, pasażerski transport kolejowy i lotniczy, telefony komórkowe, komputery, książki i wycieczki wakacyjne wraz z zakwaterowaniem. W ten sposób zaczęto też zbierać ceny niektórych usług regulowanych administracyjnie lub przez duże firmy, jak energia elektryczna i gaz.

Dane skrapowane są używane nie tylko do pomiaru inflacji, ale także jej prognozowania. Pierwsza udana próba użycia danych skrapowanych do wyznaczania prognoz dynamiki cen (zarówno nowcastingu jak i w dłuższym terminie) całego koszyka została podjęta przez M. Bertolotto, A. Cavallo i R. Rigobona<sup>55</sup>, ale w przypadku poszczególnych kategorii koszyka inflacyjnego udane próby podejmowano już wcześniej. Z tego powodu dane skrapowane znajdują się także w kręgu zainteresowań badań banków centralnych. Przykładowo, banki centralne w Armenii i Szwecji zbierają internetowe ceny żywności do prognozowania cen żywności.

---

<sup>51</sup> Auer, J., Boettcher, I. (2017), From price collection to price data analytics. How new large data sources require price statisticians to re-think their index compilation procedures. Experiences from web-scraper and scanner data, Praca opublikowana w ramach spotkań Grupy Ottawskiej.

<sup>52</sup> Bosch, O. (n.d.), Uses of web scraping for official statistics ESTP course on Big Data Sources – Web, Social Media and Text Analytics, [https://circabc.europa.eu/sd/a/5e250346-44a9-471b-87f1-5b5ddb59aa77/1\\_Big%20Data%20Sources%20part3-Day%201-A%20Use.pdf](https://circabc.europa.eu/sd/a/5e250346-44a9-471b-87f1-5b5ddb59aa77/1_Big%20Data%20Sources%20part3-Day%201-A%20Use.pdf) [dostęp: 19.04.2023].

<sup>53</sup> Chuanyang, F., Lee Wen Hao, J. (2016), Experiences with the Use of Online Prices in Consumer Price Index, *Statistics Singapore Newsletter*, Singapore.

<sup>54</sup> Polidoro, F., Giannini, R., Lo Conte, R., Mosca, S., Rosetti, F. (2015), Web scraping techniques to collect data on consumer electronics and airfares for Italian HICP compilation, "Statistical Journal of the IAOS", No. 31(2), s. 165-176, doi: 10.3233/sji-150901

<sup>55</sup> Bertolotto, M., Cavallo, A., Rigobon, R. (2014), Using Online Prices to Anticipate Official CPI Inflation, UTokyo Price Project Working Paper Series 031, University of Tokyo, Graduate School of Economics, Tokyo.

W Polsce funkcjonowało lub nadal funkcjonuje kilka projektów związanych z wykorzystaniem cen skrapowanych do liczenia inflacji. Pierwszy z nich, założony w listopadzie 2009 r. projekt eCPI Narodowego Banku Polskiego, skupia się na prognozowaniu inflacji na podstawie bieżących danych. Według wstępnych wyników badań, dzięki codziennej aktualizacji danych, metody *nowcastingu*<sup>56</sup> oparte na danych z sieci mogą być o 11% mniej obciążone niż najlepsze modele ARMA<sup>57</sup>. Także Centrum Badań Społeczno-Ekonomicznych (CASE) od 2016 r. publikuje Online CASE CPI, który zbiera dane od około 50 detalistów, obejmując 87% produktów w koszyku inflacyjnym<sup>58</sup>. Także GUS używa web – skrapingu (m.in. zrealizowany projekt INSTACENY) do pozyskiwania cen leków i wybranych produktów spożywczych<sup>59</sup>.

## 2.2. Metodyka pozyskiwania danych skrapowanych

W przypadku pozyskiwania danych o cenach ze sklepów internetowych do wyboru mamy kilka opcji. Pierwszą z nich jest zwyczajnie poproszenie przez skrapującego (np. urząd statystyczny) właściciela strony o otwarty dostęp do API (*Application Programming Interface*). Umożliwia to stworzenie trwalszych metod skrapowania na czele z użyciem dostępu do bazy danych cen, zamiast skrapowania bezpośrednio ze strony, co jest rozwiązaniem znacznie bardziej stabilnym i odpornym na zmiany kodu strony. Celem API jest zapewnienie zorganizowanego i kontrolowanego dostępu do określonych danych lub usług na serwerze. Interfejsy API mogą być publicznie dostępne lub zablokowane za pomocą klucza.

Za przykład praktycznego wykorzystania API może służyć skrapowanie cen lotów przez urząd statystyczny w Finlandii za pomocą *Amadeus API*. Dane pobierane są z użyciem wcześniej stworzonej tabeli mapującej stworzonej w Excelu zawierającej informacje o destynacji lotu, informacji o dniach wylotu, czasu między lotami, klasą podróży itp. Taka tabela wygląda w następujący sposób:

---

<sup>56</sup> *Nowcasting* to pojęcie będące połączeniem angielskich pojęć *now* (teraz) i *forecasting* (prognozowanie). Jest to zbiór technik służących do krótkoterminowego prognozowania z wykorzystaniem danych zbieranych z dużą częstotliwością. Celem *nowcastingu* jest ustalenie „wczesnego oszacowania” prognozowanej wielkości, zanim dane o wielkościach rzeczywistych zostaną podane.

<sup>57</sup> Macias, P., Stelmasiak, D. (2018), Food Inflation nowcasting with web skraped data, “NBP Working Paper”, No. 302.

<sup>58</sup> Radzikowski, B., Smietanka, A. (2016), Online CASE CPI, Proceedings of the 1st International Conference on Advanced Research Methods and Analytics, Universitat Politècnica de València, Valencia,

<sup>59</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op.cit.



Tabela 4. Przykładowa tabela mapująca używana do skrapowania lotów za pomocą Amadeus API

Nazwa destynacji	Destynacja	Dni tygodnia	Noce	Klasa
Londyn	LON	0,2	1,3	EKONOMICZNA
Luksemburg	LUX	4,5	5,7	BIZNES

Źródło: Eurostat (2020), *Practical guidelines on web scraping for the HICP*, <https://ec.europa.eu/eurostat/documents/272892/12032198/Guidelines-web-scraping-HICP-11-2020.pdf> [dostęp: 17.04.2023].

W powyższym przykładzie wyszukujemy loty klasą ekonomiczną do Londynu w poniedziałek (0) lub środę (2) i chcemy zostać na miejscu 1 lub 3 noce. W drugim przypadku szukamy lotu klasą biznes do Luksemburga w piątek lub sobotę i chcemy wrócić za 5 lub 7 dni. Taki format tabeli pozwala na łatwe zmiany szukanych parametrów<sup>60</sup>.

W praktyce całość procesu ściągania danych za pomocą API wygląda następująco:

- Potrzebne pakiety i funkcje, a także tabela mapowania są importowane do Pythona.
- Podejmowana jest decyzja, z jakim wyprzedzeniem zbieramy informacje o lotach (miesiąc przed wylotem, 3 miesiące przed itp.). Mając zdefiniowane wszystkie loty należące do próbki można przystąpić do skrapowania.
- Uruchamiany jest kod pobierający dane z Amadeus API za pomocą następujących pętli:
  - a) pętla przechodząca przez każdy wiersz w tabeli mapowania,
  - b) pętla przechodząca przez wszystkie daty przed wyjazdem zdefiniowane w kroku 2 (jeden miesiąc, trzy miesiące, sześć miesięcy),
  - c) pętla przechodząca przez wszystkie zdefiniowane dni tygodnia,
  - d) pętla przechodząca przez odpowiednie czasy między datą wyjazdu a datą powrotu (czas trwania całej podróży). Zostają zebrane informacje o każdym locie odpowiadającym wyszukiwanym parametrom:
    - ✓ następuje import pakietu Amadeus do Pythona i zalogowanie się do AP,
    - ✓ parametry wyszukiwania lotów z API zostają zdefiniowane i przesłane do API: cel lotu i klasa podróży są pobierane z tabeli mapowania. Daty wyjazdu, daty powrotu, najpóźniejszy czas przyjazdu, najpóźniejszy czas powrotu są przetwarzane na podstawie informacji o dniach tygodnia i

<sup>60</sup> Eurostat (2020), *Practical guidelines on web scraping for the HICP*, <https://ec.europa.eu/eurostat/documents/272892/12032198/Guidelines-web-scraping-HICP-11-2020.pdf> [dostęp: 17.04.2023].

nocach pobytu z tabeli mapującej. Określona jest też waluta, miejsce wylotu oraz tzw. non-stop (1 to lot bezpośredni itp.),

- ✓ zebrane są metadane oraz informacje o cenach lotu,
- ✓ Po zakończeniu wszystkich pętli zebrane informacje są zachowane w pliku Excel.

W przypadku braku możliwości zastosowania API możliwe jest użycie alternatywnych metod skrapowania. Jednym z nich są gotowe programy do skrapowania (OctoParse, Scrapy, Parsehub). Literatura jednak w większości zaleca unikać ich wykorzystywania na szerszą skalę. Część z nich ze względu na ograniczenia może nadawać się do zbierania pojedynczych zmian cen i kusić łatwym interfejsem, ale gorzej radzą sobie one w przypadku bardziej zaawansowanych formatów strony. Ponadto, gotowe programy do skrapowania nie będą dostosowane w odpowiedni sposób do kodu strony, co może powodować większą liczbę błędów. Warto też zwrócić uwagę, że niektóre z gotowych programów mogą przechowywać zebrane dane na serwerach poza granicami kraju, co może stwarzać pewne problemy prawne.

Zalecanym sposobem skrapowania w takim wypadku jest budowanie skryptów zindywidualizowanych pod konkretne strony sklepów. Każda przeglądarka umożliwia otwarcie kodu strony i sprawdzenie jego elementów odnoszących się do poszczególnych elementów strony (patrz rysunki 1 i 2). Poszczególne elementy kodu strony zaznaczone na rys. 2 odpowiadają informacjom widocznym na stronie www na rys. 1. Czarnym kolorem na obu rysunkach zaznaczono kategorię towaru, na czerwono nazwę produktu, a na zielono jego cenę. Możliwe jest także uzyskanie takich informacji, jak cena za kilogram czy liczba gwiazdek, które konsumenci przyznają danemu produktowi.

Rysunek 1. Kod strony internetowej Obi wraz z zaznaczonymi elementami kodu odpowiadającymi za nazwę kategorii, nazwę produktu oraz jego cenę.

```

... <section class="content-wrapper breadcrumb" data-nosnippet="true">...</section> == 50
  <section class="results-overview results-overview--aues content-wrapper two-columns auto-init clearfix" data-module="obi/shop-overview">
    ::before
    <header class="header"></header>
    <div id="AjaxHolder">
      <div class="mobile-filter clearfix js-sticky-filter">...</div>
      <div class="wrapper-flap-two-columns">
        <a id="Flap" wt_name="wt_ignore" data-webtrekk="button.tablet.menu_fade_out_fade_in">...</a>
        <div class="two-columns-wrapper">
          <div class="sidebar-wrapper" data-nosnippet="true">...</div>
          <div class="column-expand sidebar-width">
            <div class="block-context">
              <h1 class="hidden-phone" data-ui-name="aues.headline">Tynk, zaprawa i cement</h1>
            </div>
            <div class="filter-channel-wrapper clearfix top">
              ::before
              <div class="column column-first">...</div>
              <div class="filter-pagination">...</div>
              <div class="variants hidden-phone hidden-tablet" data-productcount="454" data-ui-name="total.products.header">produktów: 454&nbsp;variantów: 455</div>
              ::after
            </div>
          </div>
        <div id="ShopContent">
          <div class="shop-content">
            <div class="product-container auto-init" data-module="obi/compare" data-snippet="unveil">
              <div id="CompareLayer">...</div>
              <ul class="row-fluid products-wp">
                <li class="product large">
                  <a class="product-wrapper wt_ignore" data-ui-name="aues.product.1" href="https://www.obi.pl/suche-zaprawy/kreisel-wylewka-betonowa-ktb-wa3-25-kg/p/4572509" data-position="1" data-pagenum="1" data-setcookie="{\"pagesize\":71,\"position\":1,\"pageNum\":1}">
                    ::before
                    <span class="image-container">...</span>
                    <span class="info-container js-product-data">
                      <input type="hidden" name="action" value="validateAddToCart">
                      <input type="hidden" name="source" value="aues">
                      <input type="hidden" name="code" value="4572509">
                      <input type="hidden" name="_csrf" value="1g6hMu70ZSTRwFz7x5yit93EfmCtXBSn">
                    </span>
                    <div class="wrapper-compare-nin clearfix">
                      <span class="description" style="height: 38px;">
                        <p>Kreisel Wylewka betonowa KTB WA3 25 kg</p>
                      </span>
                      <div class="rating rating--100" data-ui-name="aues.product.rating.span">
                        <div class="rating_star_wrap">...</div>
                      </div>
                      <button class="green-btn-box btn wt_ignore js-oneclick-to-cart" type="button" data-name="ecm" data-webtrekk="cart_aues" data-ui-name="aues.one-click.4572509.button">
                        <span class="order-detail">
                          <span class="price" data-ui-name="aues.product.price.span">
                            <span>9,40 zł</span>
                          </span>
                        </span>
                      <span class="green-btn btn btn-green">...</span>
                    </div>
                  </a>
                </li>
              </ul>
            </div>
          </div>
        </div>
      </div>
    </div>
  </section>

```

Źródło: strona internetowa sklepu Obi.

Rysunek 2. Produkty widoczne na stronie sklepu internetowego Obi

The screenshot shows the Obi online store interface. At the top, there's a navigation bar with 'Budować' and a search bar containing 'h1.hidden-phone 927 x 40,25 cement'. Below this is a category filter 'Materiały budowlane (2391)' and a sorting option 'Sortuj wg: Popularność'. The main content area displays four product cards. The first card, 'Kreisel Wylewka betonowa KTB WA3 25 kg', is highlighted with a red box around its title and a green box around its price '9,40 zł'. The other three cards are 'Górażdze Cement Premium CEM I 42,5 R 20 kg' (12,99 zł), 'Cement Classic Monolit 25 kg' (10,99 zł), and 'Górażdze Cement Uni CEMIV/B(V) 32,5 N 20 kg' (11,60 zł). Each card includes a 'Dodaj' button and a 'Zapisz' icon.

Źródło: strona internetowa sklepu Obi.

Najczęściej do *web-scrapingu* używa się języka Python (pakiety Selenium, BeautifulSoup) lub R (Rvest, RSelenium). Pakiety BeautifulSoup i Rvest w niewielkim stopniu obciążają stronę internetową i doskonale nadają się do zbierania informacji w przypadku statycznej organizacji strony<sup>61</sup>.

W przypadku, gdy na stronie pojawiają się elementy dynamiczne (konieczność zamknięcia popupów, wypełnienia formularza, rozwinięcia listy, scrollowania strony) konieczne może okazać się użycie pakietu Selenium<sup>62</sup>. Pakiet ten, pierwotnie powstały do automatyzacji testów aplikacji webowych, pozwala zautomatyzować działania symulując ruch użytkownika na stronie www. Z tego powodu bardziej obciąża stronę internetową niż pozostałe pakiety. Dlatego też zaleca się jego stosowanie tylko w stosunku do dynamicznych elementów stron internetowych, gdzie utrudnione lub niemożliwe jest użycie innych pakietów.


<sup>61</sup> Juszcak A. (2021), Zastosowanie danych scrapowanych w pomiarze dynamiki cen, „Acta Universitatis Lodzianis. Folia Oeconomica”, nr 1(352), s. 25-37.

<sup>62</sup> Tamże.

### 2.3. Zalety stosowania danych skrapowanych

Jak wspomniano w podrozdziale 2.1., większość obywateli UE dokonuje już zakupów przez internet. Usługi i towary w ten sposób nabywane stają się częścią naszego codziennego życia. Niektóre z usług i towarów przestają być dostępne w fizycznej sprzedaży lub opierają swój model sprzedaży na tzw. cenach dynamicznych. Dotyczy to chociażby takich usług, jak przewozy taksówkarskie, bilety na pociąg czy bilety lotnicze. Za pomocą metod skrapowanych możliwe jest zaprojektowanie „bazy klientów” odpowiadającej badaniom rynku, która na bieżąco sprawdza ceny poszczególnych połączeń w zależności od daty (dzień tygodnia, okres zwykły lub świąteczny itp.), okresu poprzedzającego kupno przed samym dniem podróży czy klasy. W taki sposób urząd statystyczny w Finlandii skrapuje ceny lotów, norweski - ceny taksówek, a francuski – ceny biletów pociągowych. Według podsumowania badania pilotażowego francuskiego INSEE, różnice między tradycyjnym pomiarem kosztów transportu pociągiem a szacunkiem za pomocą danych skrapowanych potrafią różnić się w okresach świątecznych nawet powyżej 7 pkt. proc. (wykres 5)<sup>63</sup>.

Wykres 5. Różnice między dynamiką cen transportu liczoną metodą tradycyjną i z udziałem danymi skrapowanymi (w pkt. proc.)



Źródło: opracowanie własne na podstawie danych Eurostatu.

<sup>63</sup> Eurostat (2020), op. cit.

Nawet w przypadku towarów, których ceny można zbierać dalej za pomocą tradycyjnego wysyłania ankietów, zastosowanie metod skrapingowych może przynieść liczne korzyści. Zautomatyzowanie procesu pozyskiwania danych pozwala na ich zbieranie z częstotliwością znacznie wyższą (najczęściej codzienną) niż w przypadku danych zbieranych tradycyjnie (pomiar raz w miesiącu) i dostarczać większej ilości informacji. Obserwacja internetowych źródeł danych pozwala także lepiej zrozumieć wzorce danych i nowe trendy zachowań konsumenckich. Korzystając z *web-scrapingu* można obserwować ceny na poziomie częstszym niż godzinowe, co zwiększa poziom wiedzy o ich zmienności i pozwala udoskonalić strategię ich zbierania. Na dodatek *web-scraping* umożliwia zebranie znacznie większej ilości dodatkowych metadanych (np. charakterystyka produktu) co pozwala na udoskonalenie procesu pomiaru cen<sup>64</sup>. Wykorzystanie danych skrapowanych pozostaje także tańsze niż analogiczna praca wykonana za pomocą setek zatrudnionych ankietów. Porównanie zalet i wad obu metod zbierania danych przedstawiono w tabeli 5.

Tabela 5. Cechy danych skrapowanych i informacji pozyskanych z pomocą tradycyjnego procesu z udziałem ankietów

<b>Web-scraping</b>	<b>Tradycyjne pozyskiwanie danych przez ankietów</b>
<ul style="list-style-type: none"> <li>- Automatyczne zbieranie danych</li> <li>- Wysoka częstotliwość (najczęściej codzienna)</li> <li>- Dane zbierane ze stron dużych sieci handlowych</li> <li>- Brak reprezentacji niektórych kategorii COICOP</li> <li>- Wymaga przetworzenia dużej ilości danych</li> <li>- Zbierane są ceny ofertowe nie transakcyjne</li> </ul>	<ul style="list-style-type: none"> <li>- Reprezentowane są zarówno duże jak i małe sklepy</li> <li>- Niższa częstotliwość pozyskiwanych danych (najczęściej miesięczna)</li> <li>- Wyższy koszt pozyskiwania danych</li> <li>- Dane dostępne z opóźnieniem</li> <li>- Pozyskane dane są dostosowane do koszyka inflacyjnego</li> </ul>

Źródło: Juszcak, A. (2021), *Usage of scraped data in price dynamic measurement*, „Acta Universitatis Lodzianis. Folia Oeconomica”, nr 1(352).

<sup>64</sup> Eurostat (2020), op. cit.

## 2.4. Ograniczenia aplikacyjne i wyzwania metodologiczne

Dane skrapowane, mimo licznych zalet, posiadają też pewne ograniczenia możliwości ich użycia w liczeniu wskaźnika CPI. Ograniczenia te można podzielić na kilka głównych kategorii. Bardzo istotne jest ograniczenie reprezentatywności. Nawet dla 15% dóbr i usług, ceny nie są dostępne online (lub reprezentowane są wyłącznie przez przedstawicieli z tzw. „górną półką”)<sup>65</sup>. Jeżeli buduje się indeks oparty wyłącznie o dane skrapowane, to skutkuje to koniecznością pominięcia tych kategorii COICOP i rozłożenie wag brakujących kategorii proporcjonalnie na pozostałe znajdujące się w tym samym agregacie<sup>66</sup>. Dodatkowym problemem jest tu brak zbierania danych z mniejszych sklepów, targowisk i ograniczenie do większych podmiotów, które umieszczają swoje cenniki online.

Głównym problemem związanym z reprezentatywnością danych skrapowanych pozostaje brak informacji na temat zachowania konsumentów, czyli ilości sprzedanych poszczególnych dóbr. Zjawisko to jest dostrzegalne zwłaszcza w sektorach, w których mamy dużo unikatowych produktów bez daty ważności, jak książki, płyty z filmami i muzyką, sprzęt elektroniczny. W efekcie towar, dostępny w magazynie sieci sklepów w liczbie kilku sztuk, posiada domyślnie taką samą wagę jak najlepiej sprzedające się towary w danej kategorii. Dlatego też niektóre z urzędów statystycznych (np. norweski) pobierają w przypadku niektórych grup towarów informację jedynie z kategorii „najlepiej sprzedające się”. W literaturze pojawiają się także inne propozycje rozwiązania tego problemu. Chessa i Griffioen proponują szacowanie wagi produktu w końcowym indeksie na podstawie liczby polubień („like’ów”) na podstronie danego produktu<sup>67</sup>. Rozważane jest także szacowanie udziału produktów skrapowanych w oparciu o rozkład prawdopodobieństwa poziomów konsumpcji w danej grupie produktów wyprowadzony z alternatywnych badań statystycznych<sup>68</sup>.

Drugą kategorią ograniczeń danych skrapowanych pozostają kwestie techniczne. W przypadku zmian w kodzie skrapowanych stron lub dodania dodatkowych zabezpieczeń utrudniających skrapowanie, program może nagle przestać działać, co skutkuje luką w szeregach czasowych

---

<sup>65</sup> Radzikowski, B., Śmietanka, A. (2016), *Online CASE CPI. 1st International Conference on Advanced Research Methods and Analytics*, Universitat Politècnica de València, València.

<sup>66</sup> Tamże.

<sup>67</sup> Chessa, A.G., Griffioen, R. (2019), Comparing Price Indices of Clothing and Footwear for Scanner Data and Web Scraped Data, “Economie et Statistique / Economics and Statistics”, No. 509, s. 49-68, doi:10.24187/ecostat.2019.509.1984.

<sup>68</sup> Zhang, L. (2020), Proxy expenditure weights for Consumer Price Index: audit sampling inference for big data statistics, “Journal of the Royal Statistical Society”, Series A, <https://rss.onlinelibrary.wiley.com/doi/epdf/10.1111/rssa.12632> [dostęp: 19.04.2023].

do czasu korekty kodu skrapera<sup>69</sup>. Należy też oddzielić system, na którym działają skrapery od reszty sieci tak, aby w razie pobrania ze strony złośliwego oprogramowania nie przedostało się ono dalej. Niektóre z urzędów statystycznych prowadzą także pomiary z dwóch niezależnych od siebie miejsc tak, by w razie awarii serwera lub tymczasowej utraty dostępu do internetu uniknąć braków danych. Warto też zauważyć, że ogromne ilości danych, które ściągane są ze sklepów internetowych wymagają przetworzenia co wymaga dostosowania i przetworzenia.

Kolejnym elementem, na który należy zwrócić uwagę są uwarunkowania prawne. Te zwykle różnią się w zależności od kraju. W większości przypadków jednak urzędy statystyczne na mocy Zasady 2 Europejskiego kodeksu praktyk statystycznych<sup>70</sup> nie powinny w tej kwestii napotykać żadnych problemów. Mimo to Eurostat w swoim przewodniku na temat *web-scrapingu* zaleca kilka dobrych praktyk, które pozwolą uniknąć zarówno blokady skrapera ze strony skrapowanej strony, jak i zapobiec stwarzaniu problemów dla właściciela, takich jak:

- zapewnienie możliwości identyfikacji skrapera jako należącego do urzędu statystycznego;
- wprowadzenie w kodzie odpowiednich przerw czasowych (np. 1 sekundowych) między requestami tak, by unikać przeciążenia serwerów;
- uruchamianie skrapersów poza godzinami szczytu tam, gdzie to możliwe;
- przestrzeganie regulaminu strony i uszanowanie prośby właściciela w przypadku, gdy zabrania ona automatycznego skrapowania<sup>71</sup>.

Mimo tych wytycznych połowa z ankietowanych przez Eurostat urzędów statystycznych nie informuje sklepów o skrapowaniu ich oferty, a ponad połowa nie identyfikuje swoich skrapersów<sup>72</sup>.

Należy mieć także na uwadze, że agregacja źródeł danych pozyskiwanych za pomocą *web-scrapingu* z istniejącymi procesami kompilacji indeksu cen wymaga zmian w metodologii liczenia wskaźnika inflacji, w szczególności zmiany formuły indeksu cenowego.

---

<sup>69</sup> [https://www.unescap.org/sites/default/files/incorporating\\_non\\_traditional\\_sources\\_CPI.pdf](https://www.unescap.org/sites/default/files/incorporating_non_traditional_sources_CPI.pdf) [dostęp: 19.04.2023].

<sup>70</sup> Eurostat (2017), Europejski Kodeks Praktyk Statystycznych dla krajowych organów statystycznych i Eurostatu (organu statystycznego UE), Luksemburg, doi: 10.2785/319604.

<sup>71</sup> Eurostat (2020), op. cit.

<sup>72</sup> Tamże.



## 2.5. Formuły indeksów cen

Charakterystyczną cechą danych skrapowanych jest to, że nie zawierają one danych o konsumpcji. Z tego powodu formuły przedstawione w poniższym rozdziale oparte są o indeksy nieważone.

### Indeks Jevonsa

Indeks Jevonsa (1865) jest nieważonym indeksem bilateralnym, który porównuje okres obecny ( $t$ ) z określonym okresem bazowym (0). Bilateralny indeks Jevonsa można zapisać następującym wzorem

$$P_J^{0,t} = \prod_{j \in G_{0,t}} \left( \frac{p_j^t}{p_j^0} \right)^{\frac{1}{N_{0,t}}}, \quad t = 1, 2, \dots, T \quad (6)$$

gdzie:  $p_j^t$  – to cena produktu  $j$  w okresie  $t$ ,  $p_j^0$  – to cena produktu  $j$  w okresie 0,  $N_{0,t}$  – odpowiada produktom dostępnym w obu okresach - 0 (bazowym) and  $t$  (obecnym),  $N_{0,t} = \text{Card}(G_{0,t})$ , a  $G_{0,t}$  to produkty z rozważanej homogenicznej grupy produktów, które są dostępne jednocześnie w okresie bazowym 0 i okresie badanym  $t$ .

Warto zaznaczyć, że w przypadku dużej rotacji produktów indeks Jevonsa będzie bardziej obciążony niż indeksy oparte o formuły łańcuchowe i multilateralne. Dzieć się tak będzie zwłaszcza w przypadku długich szeregów czasowych, ponieważ z czasem liczba produktów występujących zarówno w okresie bazowym, jak i okresie badanym, będzie stanowić coraz mniejszy odsetek produktów dostępnych w ofercie.

### łańcuchowy indeks Jevonsa

To indeks, który uwzględnia wszystkie momenty czasowe z okna  $[0, t]$ , tj. 0, 1, 2, 3, ...,  $t$ , przy czym stanowi iloraz wszystkich indeksów Jevonsa wyznaczonych dla sąsiadujących ze sobą okresów, tj.

$$P_{CH-J}^{0,t} = \prod_{\tau=1}^t P_J^{\tau-1,\tau} = P_J^{0,1} P_J^{1,2} \dots P_J^{t-1,t} \quad (7)$$

gdzie:  $P_J^{\tau-1,\tau}$  to indeks Jevonsa porównujący okres  $t$  do okresu  $t-1$

Łańcuchowy indeks Jevonsa, uwzględniający wszystkie momenty pośrednie między okresami 0 i  $t$ , jest bardziej adekwatny do analizy danych skrapowanych. Wynika to z faktu, że dane skrapowane charakteryzują się dużą rotacją produktów, więc dzieląc długie okno czasowe na serię dwuokresowych interwałów, dokonujemy znacząco mniejszej redukcji próby niż w przypadku indeksu Jevonsa o stałej podstawie w okresie 0.

## Indeks GEKS-J

Indeks GEKS jest indeksem multilateralnym, którego początki, podobnie jak innych indeksów multilateralnych, sięgają porównań cen między krajami i regionami (Gini<sup>73</sup>; Eltetö, Köves<sup>74</sup>; Szulc<sup>75</sup>). Jedną z podstawowych zalet tych indeksów było spełnianie aksjomatu przechodniości co uniezależniało wynik obliczeń od wyboru kraju lub regionu służącego za podstawę<sup>77</sup>. Indeks GEKS-J, będący odmianą indeksu GEKS, został zaproponowany stosunkowo niedawno - w 2009 roku<sup>78</sup>. Formuła indeksu GEKS-J działa na zadanym z góry oknie czasowym  $[0, T]$ , jest średnią geometryczną średnią  $T+1$  stosunków indeksów cen  $P_j^{\tau, t}$  i  $P_j^{\tau, 0}$  i przedstawia się następująco:

$$P_{GEKS-J}^{0,t} = \prod_{\tau=0}^T \left( \frac{P_j^{\tau,t}}{P_j^{\tau,0}} \right)^{\frac{1}{T+1}} \quad (8)$$

## Propozycja alternatywnych metod opartych na indeksie Dutot

Jako alternatywę wobec indeksów opartych na indeksie Jevonsa można także zaproponować oparcie kalkulacji indeksów typu GEKS na indeksie Dutot<sup>79, 80</sup>:

$$P_D^{0,t} = \frac{\sum_{j \in G_{0,t}} P_j^t}{\sum_{j \in G_{0,t}} P_j^0} \quad (9)$$

wraz z jego wersją łańcuchową:

$$P_{CH-D}^{0,t} = \prod_{\tau=1}^t P_D^{\tau-1,\tau} \quad (10)$$

a także opartą na indeksie Dutot wersją indeksu GEKS:

$$P_{GEKS-D}^{0,t} = \prod_{\tau=0}^T \left( \frac{P_D^{\tau,t}}{P_D^{\tau,0}} \right)^{\frac{1}{T+1}} \quad (11)$$

<sup>73</sup> Gini, C. (1931), On the circular test of index numbers, "Metron", No. 9(9), s. 3-24.

<sup>74</sup> Eltetö, Ö., Köves, P. (1964), Egy nemzetközi összehasonlításoknál fellépő indexszámítás problémáról, "Statisztikai Szemle", No. 42(10), s. 507-518, [https://www.ksh.hu/statszemle\\_archive/all/1964/1964\\_05/1964\\_05\\_0507\\_0518.pdf](https://www.ksh.hu/statszemle_archive/all/1964/1964_05/1964_05_0507_0518.pdf) [dostęp: 19.04.2023].

<sup>75</sup> Szulc, B. (1964), Indices for multiregional comparisons, "Przegląd Statystyczny", nr 3, s. 239-254.

<sup>76</sup> de Haan, J., Willenborg, L., Chessa, A.G. (2016), An Overview of Price Index Methods for Scanner Data, Paper presented at the Meeting of the Group of Experts on Consumer Price Indices, 2-4 May, Geneva.

<sup>77</sup> Białek, J., Bobel, A. (2019), Comparison of Price Index Methods for CPI Measurement Using Scanner Data, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.

<sup>78</sup> Ivanic, L., Diewert, E.W., Fox, K. (2011), Scanner data, time aggregation and the construction of price indexes, "Journal of Econometrics", Vol. 161(1), s. 24-35.

<sup>79</sup> Juszcak, A. (2021), op. cit.

<sup>80</sup> Dutot, C. (1738), Reflexions Politiques sur les Finances et le Commerce, La Haye, Chez les Freres Vaillant & Nicolas Prevost.

## Metoda CLIP (Clustering Large Datasets into Price indices)

Brytyjski Urząd Statystyczny (ONS) zaproponował inną niż tradycyjne indeksy metodę kalkulacji indeksów cen na podstawie danych skrapowanych. Zamiast śledzić zmiany poszczególnych produktów w czasie proponują oni śledzić zmiany, które dokonują się na całej grupie „podobnych” do siebie produktów. Ma to pomóc rozwiązać problem dużej rotacji produktów wewnątrz danej kategorii (np. danego rodzaju odzieży czy obuwia). CLIP śledzi grupy produktów w czasie i pozwala na wykorzystanie większej ilości danych, ponieważ poszczególne produkty nie muszą być dopasowywane w czasie. Oznacza to, że nawet jeśli produkt pojawi się tylko w jednym okresie, to i tak zostanie uwzględniony w indeksie. Metoda ta korzysta z metod analizy skupień na podstawie takich cech, jak nazwa produktu, sklep, czy opis produktu<sup>81</sup>.

## Metody aktualizacji okna obliczeniowego

Jak wspomniano, indeksy multilateralne wykorzystują dane o cenach z okna czasowego. Rozszerzanie okna obliczeniowego o nowe dane może zmieniać wartość poprzednio już obliczonych indeksów. Zmian tego typu powinno się unikać w przypadku obliczenia indeksu CPI. Jednym z możliwych sposobów unikania rewizji danych mogą być metody „rolowania okna” (*rolling window methods*), które przesuują okno estymacji (wynoszące zwykle 13 lub 25 miesięcy) o jeden okres (w tym wypadku miesiąc) do przodu. W zależności od wyboru miesiąca, który służy do połączenia indeksu wyznaczonego na starym oknie z indeksem bazującym na nowym oknie (*linking month*), możliwe jest zastosowanie takich metod, jak *mean splice*, *half splice*, *movement splice* i *window splice*<sup>8283</sup> (szerzej omówione w dalszej części rozdziału). Niektóre kraje (np. Holandia) stosują także modyfikacje wymienionych metod bazujące na publikowanych wskaźnikach, np. WISP (*window splice on published indices*) lub HASP (*half splice on published indices*), w których bazowe okno składa się z 25 miesięcy<sup>84</sup>.

Metody łączenia okien czasowych mogą skutkować efektem dryfu łańcuchowego, stąd w literaturze można spotkać się także z propozycjami metod bazujących na rozszerzaniu okna

---

<sup>81</sup>

<https://www.ons.gov.uk/economy/inflationandpriceindices/articles/researchindicesusingwebscrapedpricedata/clusteringlargedatasetsintopriceindicesclip> [dostęp: 19.04.2023].

<sup>82</sup> Juszczak, A. (2023), The use of web-scraped data to analyze the dynamics of clothing and footwear prices, Wiadomości Statystyczne (praca zaakceptowana do druku)

<sup>83</sup> Chessa, A.G. (2019), A comparison of index extension methods for multilateral methods, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.

<sup>84</sup> Tamże.

czasowego. Chessa<sup>85</sup> zaproponował metodę, która wykorzystuje okno czasowe o stałej podstawie każdego roku (domyślnie grudzień), które jest powiększane co miesiąc – *Fixed Base Monthly Expanding Window* (FBEW). W 2017 r. Lamboray zaproponował *Fixed Base Moving Window* (FBMW), który jest mieszanką metody FBEW i metody splicingu za pomocą okna przesuwanego, w którym ostatni miesiąc pełni rolę stałej podstawy (podobnie jak w metodzie FBEW)<sup>86</sup>.

### Metoda *movement splice*

Zaproponowana przez de Haana i van der Grienta<sup>87</sup> metoda *movement splice* używa jako łącznika ostatniego miesiąca z poprzedniego okna:

$$P_{MS}^{0,t} = P_{MS}^{0,t-1} P_{t-T+1,t}^{t-1,t} \quad (12)$$

### Metoda *window splice*

Metoda *window splice* oblicza indeks dla nowego miesiąca używając jako łącznika drugiego miesiąca z poprzedniego okna czasowego<sup>88</sup>:

$$P_{WS}^{0,t} = P_{0,T}^{0,1} P_{1,T+1}^{1,2} \dots P_{t-T,t}^{t-T+1,t} \quad (13)$$

### Metoda *half splice*

Metoda *half splice* łączy miesiąc w nowym oknie czasowym z połową poprzedniego okna czasowego ( $t = \frac{T+1}{2}$  jeśli T jest nieparzyste i  $t = \frac{T}{2}$  jeśli T jest parzyste). W ten sposób, jeżeli okno czasowe wynosi 13 miesięcy, miesiącem łącznikiem zostaje siódmy miesiąc poprzedniego okna czasowego<sup>89</sup>.

$$P_{HS}^{0,t} = P_{HS}^{0,t-1} \frac{P_{t-\frac{T+1}{2}+1,t}^{t-\frac{T+1}{2}+1,t}}{P_{t-T,t-1}^{t-\frac{T+1}{2}+1,t-1}} \quad (14)$$

<sup>85</sup> Chessa, A.G. (2016), A new methodology for processing scanner data in the Dutch CPI, "Eurostat Review of National Accounts and Macroeconomic Indicators", No. 1, <https://ec.europa.eu/eurostat/documents/3217494/7556543/KS-GP-16-001-EN-N.pdf/70e246de-734c-42ba-bee2-bc0b3dd97faa> [dostęp: 19.04.2023].

<sup>86</sup> Lamboray, C. (2017), The Geary Khamis index and the Lehr index: how much do they differ?, 15th meeting of the Ottawa Group, Eltville.

<sup>87</sup> de Haan, J., van der Grient, H.A. (2011), Eliminating chain drift in price indexes based on scanner data, "Journal of Econometrics", No. 161(1), s. 36–46. doi: 10.1016/j.jeconom.2010.09.004.

<sup>88</sup> Krsinich, F. (2014), The FEWS index: fixed effects with a window splice – non-revisable quality adjusted price indexes with no characteristic information, Meeting of the Group of Experts on Consumer Price Indices, Geneva.

<sup>89</sup> Van Loon, K., Roels, D. (2018), Integrating big data in the Belgian CPI, Meeting of the Group of Experts on Consumer Price Indices, Geneva.

### Metoda *mean splice*

W tym wypadku miesiącem łącznikiem jest każdy potencjalny miesiąc z poprzedniego okna, a wszystkie wyniki są uśrednianie za pomocą średniej geometrycznej wyników cząstkowych:

$$P_{GMS}^{0,t} = P_{GMS}^{0,t-1} \prod_{l=t-T+1}^{t-1} \left( \frac{P_{t-T+1,t}^{l,t}}{P_{t-T,t-1}^{l,t-1}} \right)^{\frac{1}{T-1}} \quad (15)$$

### Metoda *Fixed Base Monthly Expanding Window* (FBEW)

Metoda ta, zaproponowana przez Chessa, ustala grudzień poprzedniego roku jako miesiąc rozpoczynający nowe okno czasowe i rozszerza się co miesiąc o jeden okres, aż do grudnia kolejnego roku. W ten sposób w styczniu okno czasowe zawiera 2 miesiące, w lutym 3 miesiące itp.<sup>90</sup>.

$$P_{FBEW}^{0,t} = P_{b-T,b}^{b-T,b} P_{b,t}^{b,t} \quad (16)$$

### Metoda *Fixed Base Moving Window* (FBMW)

Metoda ta powstała jako wypadkowa metody FBEW i metody *movement splice* w następujący sposób<sup>91</sup>:

$$P_{FBMW}^{0,t} = P_{b-T,b}^{b-T,b} P_{t-T,t}^{b,t} \quad (17)$$

---

<sup>90</sup> Chessa, A.G. (2019), A comparison of index extension methods for multilateral methods, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.

<sup>91</sup> Lamboray, C. (2017), *The Geary Khamis index and the Lehr index: how much do they differ?*, 15th meeting of the Ottawa Group, Eltville.

### 3. Dane skanowane

W rozdziale omówiono teorię wykorzystania danych skanowanych do obliczenia inflacji. W pierwszym podrozdziale omówiono definicję i genezę danych skanowanych. Następnie omówiono metodykę ich pozyskiwania, przetwarzania, klasyfikacji i dopasowania. W trzecim podrozdziale omówiono zalety danych skanowanych, a czwartym ograniczenia aplikacyjne i wyzwania metodologiczne. W ostatnim, piątym podrozdziale omówiono formuły indeksów wykorzystujących dane skanowane, ze szczególnym uwzględnieniem indeksów multilateralnych.

#### 3.1. Definicja i geneza danych skanowanych

Dane skanowane (*scanner data*) według definicji pochodzącej z CPI Manual<sup>92</sup> to: „szczegółowe dane o dobrach konsumpcyjnych uzyskane dzięki skanowaniu ich kodów kreskowych w punktach sprzedaży”. Najczęściej stosowanymi obecnie kodami identyfikującymi produktu są: GTIN (*Global Trade Item Number*), EAN (*European Article Number*), PLU (*Price Look-Up*) i SKU (*Stock Keeping Unit*). Kody GTIN mogą zawierać 8, 12, 13 i 14 cyfr (1 cyfra wskazująca poziom pakowania, 3 cyfrowy kod organizacji krajowej GS1 (Global Standards 1), 4-7 cyfr numeru jednostki kodującej GS1, 2-5 cyfr kodu produktu i cyfry kontrolnej). Niektóre urzędy statystyczne podkreślają jednak, że duża szczegółowość kodu GTIN (i będącego jego odmianą kod EAN) może skutkować problemami przy porównywaniu produktów – ten sam produkt różniący się jedynie kolorem czy kształtem opakowania posiada w systemie GTIN dwa różne kody. Z uwagi na powyższe, niektóre urzędy statystyczne zalecają stosowanie mniej detalicznych kodów, np. kodu SKU<sup>93</sup>. Poza kodem kreskowym dane skanowane zawierają także informacje o jednostce sprzedaży (np. kilogram, sztuka, litr itp.), wartości sprzedaży i ilości sprzedanych produktów<sup>94</sup>. Dane skanowane pozwalają także uchwycić realną cenę sprzedaży produktu uwzględniającą promocje i rabaty, co jest niewątpliwym plusem w porównaniu do danych skrapowanych, które uwzględniają jedynie cenę ofertową sprzedaży. Dane skanowane zawierają także najczęściej etykietę produktu, która stanowi mniej lub bardziej drobiazgowy opis produktu. Dzięki etykietce i

---

<sup>92</sup> IMF (2004), Consumer Price Index Manual, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms\\_331153.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms_331153.pdf) [dostęp: 19.04.2023].

<sup>93</sup> Dalen, J. (2017). Unit values in scanner data and some operational issues. Paper presented at the fifteenth Ottawa Group Meeting. Eltville am Rhein, Germany.

<sup>94</sup> Często sieci stosują także własne metody kodowania o niższym poziomie szczegółowości niż kody GTIN.

kodom produktu możliwa jest klasyfikacja produktów do grup COICOP oraz dopasowanie produktów w czasie (*matching*).

Technologia kodów kreskowych jest w powszechnym użyciu od lat 70. XX wieku. Jednak dopiero w ostatnich 20 latach rozmachu nabrały badania dotyczące możliwości ich wykorzystania do poprawy analizy szacunków dotyczących zmian cen i obliczania wskaźników inflacji takich jak CPI<sup>95</sup>. Pierwszym krajem UE, który zdecydował się na użycie w tym celu danych skanowanych była Holandia (od 2001 r.). Do 2015 r. dołączyła do nich Szwecja oraz z krajów stowarzyszonych z UE – Szwajcaria i Norwegia. Obecnie badania nad wykorzystaniem danych skanowanych do liczenia wskaźnika CPI prowadzą urzędy statystyczne w wielu krajach UE m.in. Danii, Belgii, Luksemburgu, Portugalii i Francji<sup>96</sup>. W 2022 r. ok. 1/3 krajów UE korzysta z danych skanowanych do pomiaru inflacji, a w większości pozostałych mają miejsce zaawansowane projekty badawcze mające na celu wykorzystanie tych danych w oficjalnym pomiarze.

W Polsce, w okresie styczeń 2019 r. – czerwiec 2022 r., GUS wraz ze Szkołą Główną Handlową (SGH) i Instytutem Podstaw Informatyki Polskiej Akademii Nauk (IPI PAN) realizował projekt *InstatCeny*, którego celem było „utworzenie systemu informatycznego pozwalającego na zarządzanie pozyskiwanymi danymi oraz integrację heterogenicznych i rozproszonych zbiorów danych, a także stworzenie systemu dedykowanych narzędzi dla wsparcia procesu analizy danych dotyczących cen przez statystyków”<sup>97</sup>. W 2022 r. GUS współpracował z trzema sieciami handlowymi (i prowadził rozmowy z kolejnymi dwoma) w celu pozyskaniu danych skanowanych. Dane pozyskane przez GUS służyły do oceny reprezentatywności produktów i oraz imputacji braków danych wywołanych pandemią COVID-19, jednak według zapowiedzi ekspertów GUS w niedalekiej przyszłości planowane jest oficjalne wdrożenie danych skanowanych jako źródła danych do pomiaru wskaźnika CPI<sup>98</sup>.

W Holandii, która była jednym z prekursorów użycia danych skanowanych w Unii Europejskiej, dane skanowane wykorzystano po raz pierwszy w 2001 r. rozwijając następnie liczbę współpracujących sieci supermarketów z dwóch (w 2002 r.) do dziesięciu (w 2016 r.). Od 2017 r. w grono dostawców danych włączono też sklepy samoobsługowe i biura podróży. Obecnie ponad 20% CPI w Holandii liczonych jest na podstawie danych skanowanych. Warto

---

<sup>95</sup> Białek, J. (2020), Wykorzystanie danych skanowanych do pomiaru inflacji – doświadczenia międzynarodowe i wyzwania metodologiczne, „Wiadomości Statystyczne”, Vol. 65(1), s. 9-33.

<sup>96</sup> [https://konferencja230.stat.gov.pl/K230/Content/File/presentacja\\_JBialekABobel.pdf](https://konferencja230.stat.gov.pl/K230/Content/File/presentacja_JBialekABobel.pdf) [dostęp: 19.04.2023].

<sup>97</sup> <https://stat.gov.pl/statystyki-eksperymentalne/gospostrateg/instatceny/> [dostęp: 19.04.2023].

<sup>98</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

dodać, iż holenderscy statystycy uznali kod GTIN za zbyt szczegółowy i dlatego w Holandii preferowany jest kod SKU<sup>99</sup>.

Także w Szwecji historia eksperymentów z danymi skanowanymi ma ponad 20 lat. Pierwsze prace na temat wykorzystania danych skanowanych w mierzeniu dynamiki cen sięgają tam 1997 r. Wtedy to firma AC Nielsen stworzyła dla urzędu statystycznego bazę danych zawierających cztery homogeniczne grupy produktów – mrożone ryby, płatki śniadaniowe, tłuszcze i detergenty. Stopniowo dodawano także dane ze sklepów i aptek farmaceutycznych (od 2010 r.), marketów, supermarketów i hipermarketów, których udziały pokrywają 80% rynku (od 2011 r.) i sklepów monopolowych (od 2016 r.). W przypadku aptek i sklepów z alkoholem prowadzone jest tzw. badanie pełne, natomiast w przypadku marketów losowane jest 60 punktów sprzedaży. Łącznie szacuje się, że te źródła danych skanowanych pokrywają ok 19% szwedzkiego CPI (warzywa, owoce, mięso, wyroby tytoniowe, leki, napoje alkoholowe, lampy i baterie, środki czystości, żywność dla zwierząt i środki higieny osobistej)<sup>100</sup>.

Krajami Europy, nienależącymi do UE, które również korzystają z danych skanowanych przy liczeniu inflacji są:

- Islandia, która prace nad wdrożeniem danych skanowanych do pomiaru CPI rozpoczęła w 2015 r. w trzech sieciach handlowych. W 2020 r. około 16% islandzkiego CPI szacowane było na bazie danych skanowanych;
- Norwegia, która rozpoczęła pracę z danymi skanowanymi w późnych latach 90. i w 2001 r. otrzymała pierwsze dane skanowane od wszystkich dużych sprzedawców żywności oraz państwowych sklepów alkoholowych;
- Szwajcaria, która rozpoczęła proces włączania danych skanowanych do pomiaru CPI w 2006 r., kiedy to urząd statystyczny wysłał zapytanie do 10 największych sieci handlowych o ich gotowość do współpracy w tym zakresie. Jako że wszystkie zapytane sieci handlowe odpowiedziały pozytywnie, w 2008 r. rozpoczęto pilotażowy projekt. Obecnie z przetwarzania danych skanowanych pochodzi ok 12% szwajcarskiego CPI<sup>101</sup>.

---

<sup>99</sup> Białek, J. (2020), op. cit.

<sup>100</sup> Tamże.

<sup>101</sup> <https://www.efta.int/Statistics/news/Transaction-data-consumer-price-index-518411> [dostęp: 19.04.2023].



Poza Europą, zaawansowane prace nad wykorzystaniem danych skanowanych prowadzi m.in. Japonia, która od 1988 r.<sup>102</sup> gromadzi dane pochodzące z ponad 300 sieci supermarketów z kraju. Ich dostarczycielem jest firma Nikkei Digital Media Inc. Japonia od 2000 r. używała danych skanowanych do hedonistycznego modelowania zmian cen dla komputerów osobistych, a od 2003 r. – także dla aparatów fotograficznych (w obu przypadkach urząd statystyczny korzystał z danych zakupionych od firm zewnętrznych). Od 2020 r. Japonia wykorzystuje dane skanowanych do oficjalnego pomiaru inflacji w przypadku takich towarów, jak telewizory, komputery, drukarki i odtwarzacze wideo<sup>103</sup>. W ramach wykorzystania danych skanowanych od dekady jest tam także realizowany projekt *UTokyo Daily Price Index*, w ramach którego codziennie publikowane są roczne indeksy cen z zaledwie trydniowym opóźnieniem<sup>104</sup>.

Wczesnym wykorzystaniem danych skanowanych może pochwalić się także urząd statystyczny w Nowej Zelandii, który od 1999 r. wykorzystywał je do budowania modeli fluktuacji cen używanych samochodów. Od 2014 r. zaczęto używać danych skanowanych do oceny zmian cen elektroniki w oficjalnym pomiarze CPI. W tym samym okresie wprowadzono też do użytku opracowany we współpracy z holenderskim urzędem statystycznym indeks ITRYGEKS (*Imputation Törnqvist Rolling Year GEKS*). W zaawansowanym stadium wykorzystania danych skanowanych przy pomiarze inflacji jest także australijski urząd statystyczny, który zbiera je od 2011 r., a po 3 latach testów w 2014 r. rozpoczął wdrażanie tych danych do oficjalnego pomiaru CPI. Obecnie ponad 40% CPI (według wag produktów) Australii pochodzi z danych pozyskiwanych w sposób nietradycyjny, z czego ponad połowa udziału przypada danym skanowanym<sup>105</sup>.

Długą i bogatą historię pozyskiwania i wykorzystywania danych skanowanych mają też Stany Zjednoczone. Pierwsze informacje o współpracy amerykańskiego urzędu statystycznego z dostawcami danych skanowanych pochodzą z 1993 r., a o kalkulacji indeksów cen bazujących na danych skanowanych z 1995 r., kiedy to BLS (Bureau of Labor Statistics) rozpoczął współpracę z firmą A.C. Nielsen. Obecnie, tylko w przypadku wyrobów medycznych przy każdej, comiesięcznej aktualizacji indeksu cenowego w USA uwzględnia się ok. 600 mln rekordów produktów skanowanych, co przekłada się na 2,5 TB danych.

---

<sup>102</sup> Watanabe, K., Watanabe T. (2014), Estimating Daily Inflation Using Scanner Data: A progress report, Understanding Persistent Deflation in Japan, "Working Paper Series", No. 037

<sup>103</sup> [https://www.unescap.org/sites/default/files/incorporating\\_non\\_traditional\\_sources\\_CPI.pdf](https://www.unescap.org/sites/default/files/incorporating_non_traditional_sources_CPI.pdf)

<sup>104</sup> [https://www.jef.or.jp/journal/pdf/191st\\_cover2-03.pdf](https://www.jef.or.jp/journal/pdf/191st_cover2-03.pdf) [dostęp: 19.04.2023].

<sup>105</sup> [https://www.unescap.org/sites/default/files/incorporating\\_non\\_traditional\\_sources\\_CPI.pdf](https://www.unescap.org/sites/default/files/incorporating_non_traditional_sources_CPI.pdf) [dostęp: 19.04.2023].

### 3.2. Metodyka pozyskiwania danych skanowanych

Dane skanowane mogą być pozyskiwane z kilku rodzajów źródeł. Pierwszym, są firmy zajmujące się badaniami rynku, takie jak Nielsen, Kantar czy GfK. Firmy te specjalizują się zwłaszcza w zdobywaniu danych dotyczących dóbr FMCG (*Fast Moving Consumer Goods*) i działają na podstawie rekrutacji próby konsumentów, których potem wyposażają w czytnik danych skanowanych (mogą oni też zbierać paragony na potwierdzenie swoich zakupów)<sup>106</sup>. Zaletą tego sposobu pozyskiwania danych jest możliwość doprecyzowania szczegółów uzyskiwanej próby pod kątem dostawców, rejonów czy grup produktów. Ten sposób pozyskiwania danych skanowanych jest obciążony wysokimi kosztami. Jest to główny powód, dla którego wiele urzędów statystycznych (w tym GUS) nie decyduje się na skorzystanie z usług tego rodzaju firm zewnętrznych.

Drugą z dostępnych opcji jest pozyskiwanie danych skanowanych bezpośrednio od sieci handlowych. W porównaniu do poprzedniego sposobu, pozwala to na wynegocjowanie niższych (lub zerowych) kosztów, uzyskanie większego koszyka produktów oraz ustawienie poziomu agregacji danych tak, by zapewnić homogeniczność grup produktów i wysoką częstotliwość pozyskiwanych danych<sup>107</sup>. Negocjacje z sieciami handlowymi mogą jednak stanowić wyzwanie dla urzędu statystycznego i zwykle trwają wiele miesięcy. Przykłady holenderskiego, szwajcarskiego i australijskiego urzędów statystycznych wskazują, że proces ten może trwać średnio 6 miesięcy i obejmować szeroki zakres zagadnień - od formatu dostarczanych danych do zastrzeżeń dotyczących poufności danych. Zwykle proces negocjacji pomiędzy urzędem statystycznym a siecią handlową finalizowany jest sformalizowanym porozumieniem.

Ostatnim źródłem danych skanowanych są duże platformy handlowe (e-bay, Allegro, OLX), które zrzeszają dużą liczbę sprzedawców detalicznych i hurtowników, a niektóre z nich archiwizują dane o sprzedaży na poziomach kodów EAN. To źródło danych charakteryzuje się kilkoma istotnymi zaletami, takimi jak możliwość szczegółowego filtrowania danych o sprzedaży, szeroki asortyment sprzedawanych produktów i wysoki wolumen obrotów produktów. Przykładowo, serwis TradeWatch dawał szerokie możliwości filtrowania danych o sprzedaży produktów na [allegro.pl](https://allegro.pl)<sup>108</sup>, bazując na kodach kreskowych EAN, dostarczał też

---

<sup>106</sup> Dubois, P., Griffith, R., O'Connell, M. (2022), The Use of Scanner Data for Economics Research, [https://pierredubois.github.io/DGO\\_ScannerData.pdf](https://pierredubois.github.io/DGO_ScannerData.pdf) [dostęp: 19.04.2023].

<sup>107</sup> <https://www.imf.org/-/media/Files/Data/CPI/chapter-10-scanner-data.ashx> [dostęp: 19.04.2023].

<sup>108</sup> Serwis TradeWatch przestał oferować aktualne dane w 2021 r. ze względu na uaktualnienie API serwisu allegro, <https://liveprice.pl/tradewatch/> [dostęp: 19.04.2023].

informacji dotyczących charakterystyk opisowych, sprzedawców i momentu dokonania zakupu<sup>109</sup>.

W następstwie pozyskania danych skanowanych przez urząd statystyczny konieczna jest ich „obróbka” przed finalnym liczeniem wskaźnika cen. By była ona możliwa należy zainwestować w opracowanie systemu IT, który jest w stanie przetwarzać bardzo duże ilości danych. System taki musi móc procesować zestawy danych o różnych strukturach klasyfikacji i formatach (dane mogą być dostarczane m.in. jako pliki xls, xlsx, xml, csv). Wynika to z faktu, że różne sieci handlowe rozwijają systemy informatyczne opierając się na własnych wewnętrznych potrzebach raportowania i różnych środowiskach programistycznych. Niezbędne są więc procedury ujednolicenia danych na potrzeby systemu ich przetwarzania wykorzystywanego przez dany urząd statystyczny

Pierwszym, niezbędnym do wykonania krokiem jest sprawdzenie poprawności danych. Konieczne jest gruntowne sprawdzenie jakości dostarczanych danych, chociażby weryfikacja poprawności zapisów, rzędów wielkości danych, ewentualnych duplikatów czy brakujących danych. Takie działania powinny być zautomatyzowane i przeprowadzane cyklicznie. Procedury sprawdzania poprawności danych dzielą się na całościowe (*global check*) i szczegółowe (*detailed checks*).

Całościowe (zwane też globalnymi) procedury odnoszą się do szeroko zakrojonych procedur jakościowych dokonywanych zwykle w momencie otrzymania nowego zbioru danych. Te kontrole zapewniają informacje, czy zestaw danych jest spójny z poprzednimi, dostarczonymi przez tego samego dostawcę i mogą dotyczyć formatu danych, liczby pozycji w zbiorze, czy całkowitego dochodu danego punktu sprzedaży.

Procedury szczegółowe są natomiast stosowane najczęściej na poziomie grup towarów. Kontrole te mają na celu zidentyfikowanie niespodziewanych znaczących zmian w ilościach sprzedaży i cenach towarów, a także przychodach punktów sprzedaży. Ten zestaw procedur znany jest także w literaturze jako „mikroedycja danych cenowych”.

W obu przypadkach takie kontrole powinny być procesami zautomatyzowanymi, które generują raporty analizowane później przez pracowników urzędu statystycznego. W przypadku wątpliwości dotyczącego jakości zestawu danych może okazać się konieczny kontakt z

---

<sup>109</sup> Białek, J. (2020), Wykorzystanie danych skanowanych do pomiaru inflacji – doświadczenia międzynarodowe i wyzwania metodologiczne, „Wiadomości Statystyczne”, Vol. 65(1), s. 9-33.

dostawcą danych lub porównanie ich z alternatywnymi źródłami informacji (np. w postaci cen online)<sup>110</sup>.

Dane dostarczane przez poszczególnych dostawców zwykle mają własny wewnętrzny system klasyfikacji. Konieczne jest ich uwspólnianie tak, by odpowiadały systemowi COICOP (w EU minimalnym wymogiem jest COICOP 5). Odbywa się to zwykle na podstawie kodów produktów i etykiet. Jeśli jednak to nie wystarcza, konieczne jest użycie dodatkowych informacji o produkcie, wykorzystując do tego nowoczesne metody przetwarzania danych<sup>111</sup>. Należy zaznaczyć, że to wymóg występujący głównie w przypadku otrzymywania danych bezpośrednio od sieci handlowych. Umowy zawarte z firmami zajmującymi się badaniami rynku zwykle uwzględniają obowiązek dostosowania danych do klasyfikacji CPI wykorzystywanego przez dany urząd statystyczny<sup>112</sup>.

Klasyfikacja danych skanowanych odbywa się najczęściej za pomocą dwóch metod –za pomocą słów i fraz kluczowych i uczenia maszynowego. Oparcie klasyfikacji produktów na analizie tekstu jest skuteczną i stosunkowo prostą techniką. Wymaga ona jednak by opisy produktów były kompletne i odpowiednio szczegółowe. W takim przypadku za pomocą zestawu słów i fraz kluczowych można przyporządkować dany produkt do odpowiedniej kategorii. Zestaw fraz i słów kluczowych dzieli się zwykle na 3 rodzaje parametrów:

- *include* – frazy opcjonalne ale nie wymagane,
- *must* – frazy które muszą się pojawić,
- *exclude* – frazy których wystąpienie oznacza, że produkt nie należy do danej kategorii<sup>113</sup>.

Przykładowo, chcąc klasyfikować cukier jako parametr *must* oznaczylibyśmy ciąg znaków „cukier”, a jako parametr *exclude* „cukierki”<sup>114</sup>. Zaletą tego typu klasyfikacji jest fakt, że na bieżąco można śledzić i zmieniać zestawy klasyfikujące tak by prowadziły do 100% poprawnej klasyfikacji.

---

<sup>110</sup> IMF (2020), Consumer Price Index Manual Concepts and Methods, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms\\_761444.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms_761444.pdf) [dostęp: 19.04.2023].

<sup>111</sup> Do popularnych metod uczenia maszynowego wykorzystywanych przez urzędy statystyczne do klasyfikacji produktów w grupy COICOP można zaliczyć: naiwny klasyfikator bayesowski, regresję logistyczną, metodę k-najbliższych sąsiadów i sieci neuronowe (UNECE, 2021)

<sup>112</sup> IMF (2020), op. cit.

<sup>113</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

<sup>114</sup> Macias, P., Stelmasiak, D. (2018), Food Inflation nowcasting with web scraped data, “NBP Working Paper”, No. 302.

Drugą opcją jest klasyfikacja za pomocą uczenia maszynowego (*machine learning*). Punktem wyjścia dla wdrożenia modelu uczenia maszynowego jest utworzenie *zbioru uczącego* i *zbioru testowego*. Istotny jest także dobór indykatorów dla modelu, którymi mogą być zwłaszcza etykieta produktu, kod produktu, gramatura produktu, jednostka sprzedaży, cena i ilość sprzedaży (wolumen obrotu) oraz opcjonalnie stawka VAT. Do najpopularniejszych metod uczenia maszynowego wykorzystywanych przez urzędy statystyczne do klasyfikacji produktów można zaliczyć: naiwny klasyfikator Bayesowski, regresję logistyczną, metodę wektorów nośnych (SVM), drzewa decyzyjne i lasy losowe, metodę *k*-najbliższych sąsiadów czy sieci neuronowe. Warto wspomnieć, że GUS w ramach projektu ISTATCENY wdrożył dwuetapową procedurę klasyfikacji korzystając zarówno z metod klasyfikacji opartych na słowach i frazach kluczowych, jak i z metod uczenia maszynowego<sup>115</sup>.

Przygotowane i sprawdzone dane można poddać procesowi dopasowania w czasie, czyli tzw. *matchingowi*, co polega na dopasowaniu tych samych produktów z różnych miesięcy analizy. Dotyczy to zarówno produktów sprzedawanych całorocznie (mleko, chleb itp.), jak i produktów sprzedawanych sezonowo (przykładowo niektóre warzywa i owoce). Proces ten zwykle dokonywany jest poprzez wykorzystanie etykiet produktów. Można go jednak wesprzeć dodatkowymi informacjami, jak opis produktu czy wewnętrzne kodowanie produktu w ramach sieci handlowej<sup>116</sup>. Elastyczność procedury jest istotna, ponieważ nie wszystkie sieci dostarczają kody zewnętrzne produktu.

Przykładowo, w projekcie GUS ISTATCENY produkty są uznane za dopasowane, gdy mają ten sam kod zewnętrzny produktu (GTIN, EAN lub SKU) i kod wewnętrzny (oznaczenie nadane przez sprzedawcę). Jeżeli produkty mają różny jeden lub oba kody, do oceny podobieństwa wykorzystuje się porównanie etykiet tekstowych obu produktów. Do oceny podobieństwa etykiet produktów stosuje się metodę Jaccarda. Jeżeli produkty różnią się tylko 1 z 2 kodów produkt uznaje się za dopasowany, jeżeli etykiety są wystarczająco podobne (należy ustalić próg niepodobieństwa). W przypadku niezgodności obu etykiet odległość tekstowa miary Jaccarda musi być równa 0 (etykiety są identyczne), by produkty uznano za dopasowane<sup>117</sup>.

---

<sup>115</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

<sup>116</sup> Tamże.

<sup>117</sup> Tamże.

### 3.3. Zalety stosowania danych skanowanych

Jak wspomniano w rozdziale 3.1., historia wykorzystywania danych skanowanych do pomiaru inflacji w wielu krajach ma blisko 30 lat. Już w pierwszej dekadzie XXI wieku rozważano możliwość ich powszechnego użycia do minimalizacji obciążenia z tytułu substytucji dóbr<sup>118</sup>. Dziś dane skanowane są w powszechnym użyciu w wielu krajach w tym części krajów UE.

Coraz powszechniejsze użycie danych skanowanych wynika z licznych zalet ich stosowania. Do najważniejszych należą:

- a) **Niższe koszty** pozyskania – nawet w przypadku konieczności uiszczenia opłat za dostęp do danych od sieci handlowych oraz stworzenia i utrzymania systemu IT do przetworzenia danych jest to tańsza alternatywa wobec tradycyjnego sposobu pomiaru. Coraz powszechniejsze użycie danych skanowanych i skrapowanych daje nadzieję na znaczne ograniczenie wydatków związanych z pracą ankieterów w przyszłości;
- b) **Automatyzacja procesu produkcyjnego wskaźników cen**, która przekłada się na większe możliwości wprowadzania zmian w procesie zbierania i przetwarzania danych, jak i częstsza aktualizację danych oraz mniejsze opóźnienie w dostępie do nich;
- c) **Rozszerzenie próby i poprawa reprezentatywności** ze względu na dostęp do ogromnych ilości danych (Big Data);
- d) **Kompletność na najniższym poziomie agregacji**, co umożliwia uzyskanie informacji o cenach produktów oraz ich sprzedaży na poziomie elementarnym<sup>119</sup>. Kompletność danych skanowanych pozwala na aktualizację wag poszczególnych produktów w koszyku inflacyjnym dla każdego badanego okresu, a nie tylko w okresie bazowym. Kompletność na najniższym poziomie agregacji pozwala na użycie ważonych indeksów bilateralnych i multilateralnych w kalkulacji CPI czy HICP, co nie jest możliwe w przypadku danych pochodzących z tradycyjnego pomiaru<sup>120, 121</sup>;
- e) **Możliwość użycia danych skanowanych do sprawdzenia poprawności danych z innych źródeł**. Dostępność danych skanowanych i ich charakter daje możliwość

---

<sup>118</sup> Ivanic, L. (2005), Can scanner data be used to reduce substitution bias in the CPI? : A review of the issues and evidence, Centre for applied economic research, Working Paper 01.

<sup>119</sup> Białek, J. (2020), Wykorzystanie danych skanowanych do pomiaru inflacji – doświadczenia międzynarodowe i wyzwania metodologiczne, „Wiadomości Statystyczne”, Vol. 65(1), s. 9-33.

<sup>120</sup> <https://forsal.pl/artykuly/1456807,bialek-metoda-pomiaru-inflacji-ewoluuje-i-jej-zmiany-sa-konieczne-wywiad.html> [dostęp: 19.04.2023].

<sup>121</sup> Eurostat (2022), Guide on Multilateral Methods in the Harmonised Index of Consumer Prices, <https://ec.europa.eu/eurostat/documents/3859598/14503841/KS-GQ-21-020-EN-N.pdf/243796c9-f5ad-2155-e546-c94e17d9a7eb?t=1649074284236> [dostęp: 19.04.2023].

obliczenia tzw. *unit value*, czyli przeciętnej ceny danego dobra jakiej doświadcza konsument w danym okresie czasu. Miara ta bardziej odzwierciedla faktyczną cenę płaconą przez konsumenta niż ceny zbierane jednorazowo w danym momencie miesiąca (*point in time pricing*) m.in. ze względu na lepszą możliwość odzwierciedlenia przecen, promocji i wyprzedaży<sup>122</sup>.

- f) **Aktualizacja pomiarów cen.** Tradycyjnie zbierane dane przez ankietatorów mają wybranych reprezentantów w sposób nielosowy i celowy. To może obciążać pomiar zmiany cen. Dobór reprezentantów zwykle jest dwuwymiarowy – jest to kombinacja z próby dostępnych produktów, jak i dostępnych miejsc zakupu. Jeśli mamy dużą reprezentatywność danych skanowanych w obu wymiarach mogą one służyć do dokonywania aktualizacji cen. Dane skanowane mogą także być użyte do sprawdzania, czy produkt nie stracił zainteresowania konsumentów poprzez przeprowadzenia tzw. testu istotności (*relevance test*). Dzięki niemu można określić udział danego produktu w sprzedaży produktów z jego grupy elementarnej i na tej podstawie określić, czy powinien dalej pełnić rolę reprezentanta<sup>123</sup>.

### 3.4. Ograniczenia aplikacyjne i wyzwania metodologiczne

Użycie danych skanowanych do pomiaru inflacji jest obarczone pewnymi ograniczeniami. Jednym z najistotniejszych jest wspomniany w rozdziale 4.2. wybór dostawcy danych. Doświadczenia z wielu krajów okazują się być skrajnie różne. O ile w Szwajcarii duże sieci handlowe zgodziły się bez większych oporów na dostarczanie danych do urzędów statystycznych, to w wielu krajach stanowi to istotne wyzwanie. Konieczność oddelegowania pracowników do współpracy z urzędem statystycznym oraz obawa przed wyciekami poufnych danych sprawia, że nie wszystkie sieci są chętne na podjęcie takiej kooperacji. Średnio w UE proces negocjacji urzędu statystycznego z dostawcą danych trwa ok. 6 miesięcy<sup>124</sup>.

Kolejnym wyzwaniem, które staje przed urzędem statystycznym jest format używanego kodu kreskowego. Format GTIN (Global Trade Item Number) jest najczęściej używanym, ale są także inne formaty, takie jak *price look-up* (PLU) czy *stock-keeping units* (SKU). Kody GTIN są przez niektóre urzędy statystyczne uważane za zbyt szczegółowe, co może utrudniać

---

<sup>122</sup> Przykładem mogą tu być takie sklepy, jak Żabka, Lidl czy Biedronka, w których promocje mają zwykle charakter krótkotrwały – są tygodniowe lub nawet trwające tylko 1 dzień.

<sup>123</sup> Eurostat (2022), Guide on Multilateral Methods in the Harmonised Index of Consumer Prices, <https://ec.europa.eu/eurostat/documents/3859598/14503841/KS-GQ-21-020-EN-N.pdf/243796c9-f5ad-2155-e546-c94e17d9a7eb?t=1649074284236> [dostęp: 19.04.2023].

<sup>124</sup> <https://circabc.europa.eu/sd/a/8e1333df-ca16-40fc-bc6a-1ce1be37247c/Practical-Guide-Supermarket-Scanner-Data-September-2017.pdf> [dostęp: 19.04.2023]

dopasowanie danych (nawet mała zmiana np. koloru opakowania produktu może zmienić jego kod). W efekcie, wiele urzędów statystycznych preferuje format SKU (np. urząd statystyczny w Holandii). Ponadto, w przypadku pozyskiwania danych od wielu różnych dostawców może istnieć konieczność łączenia tych źródeł w systemie danych opartych na różnych formatach identyfikacji produktu, co wymaga dodatkowego upewnienia się, że wszystkie dane odpowiadają ujednoliconym formatom. Chessa<sup>125</sup> argumentuje, że niezbędne są ustępstwa między homogenicznością a stabilnością pomiaru w czasie. Jeżeli homogeniczność danego typu produktu zostanie zdefiniowana zbyt szeroko możliwe jest obciążenie pomiaru (*unit value bias*). Z kolei zbyt wąski podział produktów na grupy może spowodować nieuchwycenie ponownego wypuszczenia produktu na rynek, ale ze zmienionym kodem kreskowym (przykładowo tabliczka czekolady tej samej firmy sprzedawana była w opakowaniach 100 g, a teraz sprzedawana jest w opakowaniu 120 g)<sup>126</sup>.

Przed dalszym procesem klasyfikacji i dopasowanie danych w czasie (*matching*) pracownicy urzędu statystycznego powinni także upewnić się, że dane nie zawierają transakcji *business-to-business*, które muszą być wyłączone z kalkulacji CPI<sup>127</sup>.

Istotną kwestią do rozważenia staje się także dobór próby. W zależności od liczebności sieci handlowych, z którymi współpracuje dany urząd statystyczny oraz zróżnicowania demograficznego i geograficznego kraju, stosowane są próby losowe lub celowe<sup>128</sup>. Konieczne jest tu także wzięcie pod uwagę rejonizacji (jeśli sieci oferują ceny zależne od regionu, w jakim znajdują się poszczególne placówki) i wyboru momentów czasowych dla poboru próby (blisko weekendów ceny są zwykle zawyżane) oraz ich częstotliwości.

W każdym okresie badawczym zestaw dostępnych produktów może się różnić w obrębie danej sieci handlowej, ponieważ pojawiają się nowe produkty oraz wycofywane są produkty o słabej sprzedaży. Pojawia się zatem naturalne pytanie o to, czy powinno się stosować statyczny koszyk konsumencki z ustalonymi wcześniej wagami, czy zastosować podejście oparte na dynamice asortymentu produktów i zmianą wag tak, by odpowiadały one okresom

---

<sup>125</sup> Chessa, A.G. (2019), A comparison of index extension methods for multilateral methods, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.

<sup>126</sup> Lamboray, C. (2021), Index Compilation Techniques for Scanner Data, [https://unece.org/sites/default/files/2021-05/Session\\_1\\_Eurostat\\_Paper.pdf](https://unece.org/sites/default/files/2021-05/Session_1_Eurostat_Paper.pdf) [dostęp: 17.04.2023].

<sup>127</sup> Białek, J., Beresewicz, M. (2020), Scanner data in inflation measurement: from raw data to price indices, <https://arxiv.org/abs/2005.11233> [dostęp: 19.04.2023].

<sup>128</sup> Eurostat (2018), Harmonised Index of Consumer Prices (HICP) Methodological Manual, <https://ec.europa.eu/eurostat/documents/3859598/9479325/KS-GQ-17-015-EN-N.pdf/d5e63427-c588-479f-9b19-f4b4d698f2a2> [dostęp: 19.04.2023].



funkcjonowania w sprzedaży. W Szwajcarii, Danii, Francji czy Szwecji stosuje się wagi stałe, natomiast w Belgii, Finlandii, Norwegii czy Holandii – wagi dynamiczne. Poszczególne kraje różnią się także wyborem metody aktualizacji okna czasowego i wyborem samego indeksu (patrz tabela 6).

Tabela 6. Przegląd rozwiązań stosowanych przy włączaniu danych skanowanych przez urzędy statystyczne w wybranych krajach Europy

<b>Kraj</b>	<b>Stosowany indeks</b>	<b>Metoda aktualizowania okna czasowego</b>	<b>Zakres wykorzystanych danych</b>	<b>Wagi</b>
Belgia	CCDI	Half-splice (25 mies.)	Cały zestaw danych	Zmienne
Finlandia	Törnqvista	Ponowne próbkowanie indeksu bezpośredniego (raz w roku)	Cały zestaw danych	Zmienne
Włochy	Jevonsa	Ponowne próbkowanie indeksu łańcuchowego (raz w miesiącu)	Próba	Zmienne
Luksemburg	CCDI	Half-splice (25 mies.)	Cały zestaw danych	Zmienne
Norwegia	CCDI	Half-splice (25 mies.)	Cały zestaw danych	Zmienne
Holandia	Geary'ego-Khamisa	FBEW	Cały zestaw danych	Zmienne
Słowenia	Jevonsa	Ponowne próbkowanie indeksu łańcuchowego (raz w miesiącu)	Próba	Zmienne
Hiszpania	Jevonsa	Ponowne próbkowanie indeksu łańcuchowego (raz w miesiącu)	Próba	Zmienne
Szwajcaria	Jevonsa	Ponowne próbkowanie indeksu bezpośredniego (raz w roku)	Próba	Stałe

Dania	Ważonego Jevonsa	Ponowne próbkowanie indeksu łańcuchowego (raz w roku)	Próba	Stałe
Francja	Geometrycznego Laspeyresa	Ponowne próbkowanie indeksu bezpośredniego (raz w roku)	Cały zestaw danych	Stałe
Islandia	Ważonego Jevonsa	Ponowne próbkowanie indeksu bezpośredniego (raz w roku)	Próba	Stałe
Szwecja	Ważonego Jevonsa	Ponowne próbkowanie indeksu bezpośredniego (raz w roku)	Próba	stałe

Źródło: Lamboray, C. (2021), *Index Compilation Techniques for Scanner Data*, [https://unece.org/sites/default/files/2021-05/Session\\_1\\_Eurostat\\_Paper.pdf](https://unece.org/sites/default/files/2021-05/Session_1_Eurostat_Paper.pdf) [dostęp: 17.04.2023].

### 3.5. Formuły indeksów cen

Jedną z największych zalet danych skanowanych jest to, że zawierają one informację o poziomie konsumpcji każdego produktu z dokładnością wyznaczaną przez kod kreskowy. Pozwala to na stosowanie ważonych formuł indeksów cen (bilateralnych i multilateralnych), przy czym nie jesteśmy tu ograniczeni do wag z okresu bazowego (jak w przypadku tradycyjnej kolekcji danych).

#### Indeksy bilateralne

Część krajów stosuje bilateralne formuły indeksów cenowych do pomiaru dynamiki cen skanowanych, mimo iż formuły te uwzględniają jedynie okres bazowy i bieżący<sup>129</sup>. Takie podejście może generować obciążenie pomiaru, ponieważ indeksy tego rodzaju nie uwzględniają informacji o cenach i konsumpcji produktów, które pojawiły się w międzyczasie. Formalnie można jednak zastosować tu indeks nieważony Jevonsa (omówiony w rozdziale 2), a także ważne indeksy superlatywne<sup>130</sup>. Indeksy superlatywne są uważane są najlepsze przybliżenie indeksu kosztów utrzymania COLI (ang. Cost of Living Index), a ich przedstawicielami są indeksy Fishera (patrz rozdział 2) oraz Törnqvista (1936):

<sup>129</sup> IMF (2004), *Consumer Price Index Manual*, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms\\_331153.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms_331153.pdf) [dostęp: 19.04.2023].

<sup>130</sup> Diewert, W. (1976), Exact and superlative index numbers, "Journal of Econometrics", No. 4, issue 2, s. 115-145, <https://EconPapers.repec.org/RePEc:eee:econom:v:4:y:1976:i:2:p:115-145> [dostęp: 19.04.2023].

$$P_T^{0,t} = \prod_{i \in G_{0,t}} \left( \frac{p_i^t}{p_i^0} \right)^{\frac{s_i^0 + s_i^t}{2}} \quad (18)$$

gdzie:  $s_i^\tau$  oznacza relatywny udział sprzedaży i-tego produktu w okresie  $\tau$ <sup>131</sup>.

### Indeksy łańcuchowe

Indeksy bilateralne porównują ze sobą jedynie dwa okresy badawcze, czyli okres bieżący i okres bazowy. W dłuższym okresie czasu i przy dużej rotacji produktów (*product churn*) użycie indeksów bilateralnych do danych skrapowanych skutkowałoby dużym obciążeniem pomiaru. Liczba kodów kreskowych występujących w obu okresach (tj. badanym i bazowym) wraz z wycofywaniem produktów oferty stanowiłaby coraz mniejszy odsetek realnej oferty sklepu. Alternatywą, która stara się uchwycić dynamikę produktów w całym przedział czasu jest wykorzystanie indeksów łańcuchowych, których ogólna idea może być wyrażona następującą formułą:

$$P_{ch}^{0,t} = P^{0,1} * P^{1,2} * \dots * P^{t-1,t} = \prod_{\tau=0}^{t-1} P^{\tau,\tau+1} \quad (19)$$

gdzie:  $P^{\tau,\tau+1}$  to dowolny bilateralny indeks cenowy wyznaczony dla okresów  $\tau, \tau + 1$ .

Wykorzystanie indeksów łańcuchowych opartych na ważonych indeksach bilateralnych może prowadzić do obciążenia pomiaru wynikającego z efektu dryfu łańcuchowego, który powstaje, gdy ceny i ilości wracają do wyjściowego poziomu (czyli poziomu z okresu bazowego) po pewnym czasie ale wartość indeksu nie powraca do jedności. Efekt łańcuchowego dryfu może generować wymierne obciążenie pomiaru inflacji chociażby w przypadku dóbr sezonowych<sup>132</sup>.

### Indeksy multilateralne

Indeksy multilateralne pierwotnie wykorzystywano do porównań cenowych między krajami i regionami. Ze względu na spełniony aksjomat *tranzytywności*, wartość indeksu multilateralnego nie zależy od wyboru kraju lub regionu służącego za podstawę do porównań<sup>133</sup>. Z czasem zaczęto również używać indeksów multilateralnych do pomiaru inflacji. Indeksy multilateralne są nieco bardziej złożone od indeksów bilateralnych czy łańcuchowych, ponieważ działają na zadanym z góry oknie czasowym  $[0, T]$ . W konsekwencji ich wyznaczenie wymaga więcej czasu, co w przypadku dużych zbiorów danych skanowanych może mieć

<sup>131</sup> Białek, J. (2020), Wykorzystanie danych skanowanych do pomiaru inflacji – doświadczenia międzynarodowe i wyzwania metodologiczne, „Wiadomości Statystyczne”, Vol. 65(1), s. 9-33.

<sup>132</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

<sup>133</sup> Białek, J., Bobel, A. (2019), Comparison of Price Index Methods for CPI Measurement Using Scanner Data, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.

znaczenie praktyczne. Mimo to zyskują w ostatnich latach na popularności, m.in. ze względu na wspomnianą własność tranzytywności (niewrażliwość na wybór referencyjnego okresu) jak i niwelowania zjawiska dryfu łańcuchowego. Poniżej omówiono najpopularniejsze indeksy multilateralne.

### *Indeksy GEKS*

Podobnie jak w przypadku danych skrapowanych, także do kalkulacji inflacji opartej na danych skanowanych można używać indeksów bazujących na formule GEKS. Indeksy GEKS to indeksy będące geometryczną średnią  $T+1$  stosunków indeksów cen  $P^{\tau,t}$  i  $P^{\tau,0}$  w oparciu o arbitralnie przyjętą, bazową formułę indeksu cenowego. W przypadku danych skrapowanych, jako bazową formułę zwykle przyjmuje się indeks Jevonsa (indeks GEKS-J). W przypadku danych skanowanych, najczęściej przyjmuje się, iż bazowym indeksem jest formuła superlatywna, np. indeks Fishera<sup>134</sup>:

$$P_{GEKS}^{0,t} = \prod_{\tau=0}^T \left( \frac{P_F^{\tau,t}}{P_F^{\tau,0}} \right)^{\frac{1}{T+1}} \quad (20)$$

Inną formułą superlatywną, jaką często wykorzystuje się w ciele metody GEKS, jest indeks Törnqvista. Powstała w ten sposób formuła indeksu GEKS-T, często oznaczana jako indeks CCDI, ma wówczas następującą postać:

$$P_{CCDI}^{0,t} = \prod_{\tau=0}^T \left( \frac{P_T^{\tau,t}}{P_T^{\tau,0}} \right)^{\frac{1}{T+1}} \quad (21)$$

Ciekawą wariacją opartą na indeksie GEKS są formuły GEKS-L i GEKS-GL oparte odpowiednio na indeksie Laspeyresa i geometrycznym indeksie Laspeyresa. Korzystają one jednak z zaproponowanych przez Białka modyfikacji koncepcji GEKS nazywanej częściowym indeksem GEKS (*semi-GEKS*). Indeksy bilateralne użyte w tej modyfikacji koncepcji GEKS nie są superlatywne, nie spełniają testu odwrotności w czasie (ang. *time reversal test*) i wykorzystują dane o ilości tylko z jednego z dwóch porównywanych okresów. Formuła generalna dla indeksu *semi-GEKS* prezentuje się następująco<sup>135</sup>:

$$P_{GS-GEKS}^{0,t} = \prod_{\tau=0}^T \left( \frac{f_{G_{\tau,t}}(q^{\tau}, p^{\tau} p^t)}{f_{G_{\tau,t}}(q^{\tau}, p^{\tau} p^0)} \right)^{\frac{1}{T+1}} \quad (22)$$

<sup>134</sup> Chessa, A.G. (2016), A new methodology for processing scanner data in the Dutch CPI, "Eurostat Review of National Accounts and Macroeconomic Indicators", No. 1, <https://ec.europa.eu/eurostat/documents/3217494/7556543/KS-GP-16-001-EN-N.pdf/70e246de-734c-42ba-bee2-bc0b3dd97faa> [dostęp: 19.04.2023].

<sup>135</sup> Białek, J. (2022), Improving quality of the scanner CPI: proposition of new multilateral methods, "Quality & Quantity", doi: 10.1007/s11135-022-01506-6.

Definiujemy funkcję  $f_{G_{\tau,t}}(q^\tau, p^\tau p^s)$  jako:

$$f_{G_{\tau,s}}^L(q^\tau, p^\tau p^s) = \frac{\sum_{i \in G_{\tau,s}} q_i^\tau p_i^s}{\sum_{i \in G_{\tau,s}} q_i^\tau p_i^\tau} \quad (23)$$

gdzie:  $p_i^s$  to wybrana formuła indeksu bilateralnego ( $s = 0, t$ ), a funkcja  $f_{G_{\tau,t}}(q^\tau, p^\tau p^s)$  bierze pod uwagę produkty z zestawu  $G_{\tau,s}$ .

Łącząc formuły (22) i (23) otrzymujemy:

$$P_{GEKS-L}^{0,t} = \prod_{\tau=0}^T \left( \frac{\frac{\sum_{i \in G_{\tau,t}} q_i^\tau p_i^t}{\sum_{i \in G_{\tau,t}} q_i^\tau p_i^\tau}}{\frac{\sum_{i \in G_{\tau,0}} q_i^\tau p_i^0}{\sum_{i \in G_{\tau,0}} q_i^\tau p_i^\tau}} \right)^{\frac{1}{T+1}} \quad (24)$$

Analogicznie możemy zdefiniować funkcję  $f_{G_{\tau,t}}(q^\tau, p^\tau p^s)$  jako:

$$f_{G_{\tau,s}}^{GL}(q^\tau, p^\tau p^s) = \prod_{i \in G_{\tau,s}} \left( \frac{p_i^s}{p_i^\tau} \right) w_i^{\tau,s}(\tau) \quad (25)$$

gdzie:

$$w_i^{\tau,s}(\tau) = \frac{q_i^\tau p_i^\tau}{\sum_{k \in G_{\tau,s}} q_k^\tau p_k^\tau} \quad (26)$$

Łącząc formuły (26) i (27) otrzymujemy:

$$P_{GEKS-GL}^{0,t} = \prod_{\tau=0}^T \left( \frac{\prod_{i \in G_{\tau,t}} \left( \frac{p_i^t}{p_i^\tau} \right) w_i^{\tau,t}(\tau)}{\prod_{i \in G_{\tau,0}} \left( \frac{p_i^0}{p_i^\tau} \right) w_i^{\tau,0}(\tau)} \right)^{\frac{1}{T+1}} \quad (27)$$

Wśród indeksów opartych na formule GEKS można także wymienić proponowane przez Białka indeksy GEKS-AQU i GEKS-AQI, których idea bierze swój początek w koncepcji wartości jednostkowej (*unit value*), czyli przeciętnej ceny danego dobra jakiej doświadcza konsument w danym okresie czasu. Agregacja danych o ilości może jednak być trudna lub wręcz niemożliwa, jeśli dany zestaw produktów nie jest homogeniczny. Formuły obu indeksów przedstawiają się następująco<sup>136</sup>:

<sup>136</sup> Białek, J.(2022), The general class of multilateral indices and its two special cases, 17th Meeting of the Ottawa Group, 7-10 June, Rome.

$$P_{GEKS-AQU}^{0,t} = \prod_{\tau=0}^T \left( \frac{\frac{\sum_{i \in G_{\tau,t}} q_i^{\tau} p_i^t}{\sum_{i \in G_{\tau,t}} v_i p_i^{\tau}}}{\frac{\sum_{i \in G_{\tau,0}} q_i^{\tau} p_i^0}{\sum_{i \in G_{\tau,0}} v_i p_i^{\tau}}} \right)^{\frac{1}{T+1}} \quad (28)$$

$$P_{GEKS-AQI}^{0,t} = \prod_{\tau=0}^T \left( \frac{\frac{\frac{\sum_{i \in G_{\tau,t}} q_i^{\tau} q_i^{\tau} p_i^t}{\sum_{i \in G_{\tau,t}} v_i q_i^{\tau}}}{\sum_{i \in G_{\tau,0}} v_i q_i^{\tau} p_i^0}}{\frac{\sum_{i \in G_{\tau,0}} v_i q_i^{\tau}}{\sum_{i \in G_{\tau,0}} v_i q_i^{\tau}}}} \right)^{\frac{1}{T+1}} \quad (29)$$

gdzie:

$$v_i = \frac{\sum_{t=0}^T p_i^t q_i^t}{\sum_{t=0}^T q_i^t} \quad (30)$$

#### *Time Product Dummy*

Indeks TPD (Time Product Dummy) zaproponowany przez De Haana<sup>137</sup> jest indeksem, dla którego punktem wyjścia jest budowa ekonometrycznego modelu regresji panelowej opisującego zachowanie cen w przedziale czasowym  $\{0, 1, \dots, T\}$ :

$$\ln p_i^t = \alpha + \sum_{t=1}^T \delta^t D_i^t + \sum_{j=1}^{N-1} \gamma_j D_i^j + \varepsilon_i^t \quad (31)$$

gdzie:

$D_i^t$  to zmienna przyjmująca wartość 1, gdy  $i$ -ty produkt jest dostępny w okresie  $t$ , lub 0, gdy nie jest dostępny;

$D_i^j$  to zmienna przyjmująca wartość 1, gdy  $i$ -ty produkt należy do  $j$ -ej homogenicznej grupy produktów lub 0 w przypadku przeciwnym;

$\alpha, \delta^t, \gamma_j$  są parametrami modelu;

$\varepsilon_i^t$  to składnik losowy o średniej równej 0.

W konsekwencji, po przeprowadzeniu estymacji parametrów modelu ważoną metodą najmniejszych kwadratów WLS, indeks TPD można wyrazić następująco:

---

<sup>137</sup> de Haan, J. (2015), A Framework for Large Scale Use of Scanner Data in the Dutch CPI, Paper presented at the fourteenth Ottawa Group Meeting, 20-22 May, Tokyo.

$$P_{TPD}^{0,t} = \frac{\prod_{i \in G_t} \left( \frac{p_i^t}{\exp(\bar{y}_i)} \right)^{s_i^t}}{\prod_{i \in G_0} \left( \frac{p_i^0}{\exp(\bar{y}_i)} \right)^{s_i^0}} \quad (32)$$

gdzie:

$G_\tau$  to zbiór produktów dostępnych w sprzedaży w okresie  $\tau$ ;

$s_i^\tau$  to relatywny udział  $i$ -tego produktu w sprzedaży w okresie  $\tau$ .<sup>138</sup>

#### Metoda Geary'ego-Khamisa

Metoda Geary'ego-Khamisa, podobnie jak indeks GEKS-AQU, bierze swój początek w koncepcji wartości jednostkowej (*unit value*), czyli przeciętnej ceny danego dobra jakiej doświadcza konsument w danym okresie czasu. Jak wspomniano wcześniej, agregacja danych o ilości może jednak być trudna lub wręcz niemożliwa, jeśli dany zestaw produktów nie jest homogeniczny. Metoda Geary'ego-Khamisa proponuje więc użycie współczynnika dostosowania jakości  $v_i^{GK}$  by rozwiązać ten problem (podobnie jak metody GEKS-AQU czy GEKS-AQI). Współczynnik ten zamienia sprzedane ilości poszczególnych dóbr na wartość  $v_i^{GK} q_i^t$  a ceny na  $\frac{p_i^t}{v_i^{GK}}$  otrzymując tzw. *quality adjusted unit value* (QU)  $\tilde{p}^t$  dla zestawu produktów w miesiącu  $t$ :

$$\tilde{p}^t = \frac{\sum_{i \in G_t} p_i^t q_i^t}{\sum_{i \in G_t} v_i^{GK} q_i^t} \quad (33)$$

Indeks Geary'ego – Khamisa przedstawia się jako:

$$P_{GK}^{0,t} = \frac{\tilde{p}^t}{\tilde{p}^0} \quad (34)$$

lub równoważnie jako:

$$P_{GK}^{0,t} = \frac{\sum_{i \in G_t} p_i^t q_i^t / \sum_{i \in G_0} p_i^0 q_i^0}{\sum_{i \in G_t} v_i^{GK} q_i^t / \sum_{i \in G_0} v_i^{GK} q_i^0} \quad (35)$$

gdzie:

$$v_i^{GK} = \sum_{z=0}^T \varphi_{i,GK}^z \frac{p_i^z}{P_{GK}^{0,z}} \quad (36)$$

$$\varphi_{i,GK}^z = \frac{q_i^z}{\sum_{\tau=0}^T q_i^\tau} \quad (37)$$

<sup>138</sup> Białek, J., Kłopotek, M., Panek, T. (2022), op. cit.

Współczynnik dostosowania jakości wykorzystuje dane w okresie  $[0, T]$ . Co istotne, ponieważ indeks cenowy jest używany do obliczania współczynnika dostosowania jakości, a ten wykorzystywany jest do liczenia indeksu cen, równania należy rozwiązywać równocześnie np. za pomocą metody iteracyjnej<sup>139, 140</sup>.

### Metoda SPQ

Indeks SPQ został opracowany przez Diewerta w 2020 r.<sup>141</sup> i opiera się na względnej mierze podobieństwa (niepodobieństwa) cen i ilości  $\Delta SPQ$ . Miara ta jest wykorzystana do łączenia ze sobą iteracyjnie wyznaczanych indeksów Fishera według poniższego algorytmu<sup>142</sup>:

- 1) Dla okresu bazowego (0) ustawia  $P_{SPQ}^{0,0} = 1$  i oblicza  $P_{SPQ}^{0,1} = P_F(p^0, p^1, q^0, q^1)$  dla okresu 1;
- 2) Dla okresu 2 określa  $P_{SPQ}^{0,2} = P_F(p^0, p^2, q^0, q^2)P_{SPQ}^{0,0}$  jeżeli  $\min\{\Delta SPQ(p^0, p^2, q^0, q^2), \Delta SPQ(p^1, p^2, q^1, q^2)\}$  jest równe  $\Delta SPQ(p^0, p^2, q^0, q^2)$  lub  $P_{SPQ}^{0,2} = P_F(p^1, p^2, q^1, q^2)P_{SPQ}^{0,1}$  w przeciwnym przypadku;
- 3) Kontynuować procedurę w sposób analogiczny tak że dla okresu  $t, r^*$  można określić jako:
 
$$\min\{\Delta SPQ(p^r, p^t, q^r, q^t), r = 1, 2, \dots, t - 1\} = \Delta SPQ(p^{r^*}, p^t, q^{r^*}, q^t)$$
 gdzie dla analizowanego okresu  $P_{SPQ}^{0,t} = P_F(p^{r^*}, p^t, q^{r^*}, q^t)P_{SPQ}^{0,r^*}$ .

### Metody aktualizacji okna obliczeniowego

Metody aktualizacji okna obliczeniowego zostały już omówione w rozdziale 2.5. Warto dodać, że zarówno w przypadku aktualizacji indeksów multilateralnych liczonych na danych skrapowanych, jak i skanowanych można je wyznaczyć w pakietach *IndexNumR* i *PriceIndices*.

<sup>139</sup> Białek, J. (2020), Remarks on Price Index Methods for the CPI Measurement Using Scanner Data, "Statistika - Statistics and Economy Journal", No. 100(1).

<sup>140</sup> Van Loon, K., Roels, D. (2018), Integrating big data in the Belgian CPI, Meeting of the Group of Experts on Consumer Price Indices, Geneva.

<sup>141</sup> Diewert, W.E. (2020), The chain drift problem and multilateral indexes. Technical Report, Discussion Paper 20-07, Vancouver School of Economics, Vancouver.

<sup>142</sup> Białek, J. (2022), Improving quality of the scanner CPI: proposition of new multilateral methods, "Quality & Quantity", doi: 10.1007/s11135-022-01506-6.



## 4. Zastosowanie danych skrapowanych w pomiarze dynamiki cen

W rozdziale omówiono wyniki badań empirycznych przeprowadzonych na danych skrapowanych, tj. danych pozyskanych ze strony internetowej wybranego sklepu. W pierwszym podrozdziale omówiono charakterystykę pozyskanych danych oraz kroki konieczne do ich przetworzenia, tak by można było je poddać analizie w pakiecie *PriceIndices* w języku R. Następnie omówione zostały wyniki analiz dla indeksów bilateralnych i multilateralnych używanych do procedowania danych skrapowanych (podrozdział 4.2.) i wpływ metod rozszerzania okna (*window extension methods*) na wyniki indeksów multilateralnych (podrozdział 4.3.). W ostatnim podrozdziale 4.4. omówiono wpływ metod filtracji produktów skrapowanych na kompletność zestawu danych i finalne wartości indeksów.

### 4.1. Charakterystyka wykorzystanych zbiorów danych

Użyte w pracy doktorskiej dane pochodzą z jednego z najbardziej popularnych sklepów zajmujących się sprzedażą odzieży przez internet w Polsce. Dane były regularnie skrapowane od lutego 2018 r. do końca października 2019 r. za pomocą pakietów *Selenium* i *Beautiful Soup* w środowisku Python<sup>143</sup>.

Dane pobierane były każdego dnia do osobnego pliku *txt* wraz z dodatkowym raportem opisującym problemy, jakie danego dnia napotkał kod web-scrapingowy. Przykładowe zebrane dane prezentowały się w sposób pokazany na rysunku 3.

---

<sup>143</sup> Dane były pobierane w ramach projektu eCPI prowadzonego przez Narodowy Bank Polski, w którym autor brał udział. Ze względu na Kodeks dobrych praktyk dotyczących danych skrapowanych (obejmujących m.in. anonimizację poszczególnych sklepów), autor zdecydował się nie ujawniać w treści samej pracy nazwy sklepu z którego pochodzą dane.

Rysunek 3. Przykładowy wygląd surowych danych z jednego dnia analizy

```

lid~~marka~~nazwa~~cena~~cena_poprz~~kategoria~~kategoria_eng~~nazwa_promocji~~nowe~~ma_rozne_ceny~~promocja_na_wybrane_rozmiary~~premium
M0822A08F-K11~~Burton Menswear London~~Spodnie garniturowe - navy~~139.00~~139.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
M0822A08J-Q11~~Burton Menswear London~~STRETCH - Spodnie garniturowe - black~~139.00~~139.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
M0822E06C-K11~~Burton Menswear London~~STRETCH - Spodnie garniturowe - navy~~129.00~~129.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
HUT72D08W-A11~~HUGO~~KERY SLIM FIT - Koszula biznesowa - open white~~226.85~~349.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~35%~~0~~0~~1
T1022D045-Q11~~Tommy Hilfiger Tailored~~SLIM FIT - Koszula biznesowa - black~~263.20~~329.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~20%~~0~~0~~0
BRH22D01J-K11~~Brave Soul~~TUDOR - Koszula biznesowa - dark navy~~32.45~~59.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~45%~~0~~0~~0
M3I22T0AG-K11~~Massimo Dutti~~Marynarka garniturowa - dark blue~~995.00~~995.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~Nowe~~0~~0~~0
4BE22D03F-K15~~Benetton~~Koszula - navy~~107.10~~119.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~10%~~0~~0~~0
HU722D04V-K13~~HUGO~~ELISHA EXTRA SLIM FIT - Koszula biznesowa - light blue~~209.30~~299.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~30%~~0~~0~~1
PI922D07A-A11~~Pier One~~Koszula biznesowa - white~~76.45~~139.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~45%~~0~~0~~0
HU722D0A1-K13~~HUGO~~ETRAN SLIM FIT - Koszula biznesowa - pastel blue~~319.00~~319.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~Nowe~~0~~0~~1
HU722D04V-Q11~~HUGO~~ELISHA EXTRA SLIM FIT - Koszula biznesowa - black~~209.30~~299.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~30%~~0~~0~~1
PI922A02D-C11~~Pier One~~Garnitur - dark grey~~286.30~~409.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~30%~~0~~0~~0
T1022D060-A11~~Tommy Hilfiger Tailored~~STRETCH CLASSIC SLIM - Koszula biznesowa - white~~289.00~~289.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
HU752E00E-D11~~HUGO~~E LIBERTY - Spinka do mankietów - silver-coloured~~249.00~~249.00~~Męczyźni_Odzież_Kategorie_Garnitury~~accessoires~~0~~0~~1
M0822A08X-C11~~Burton Menswear London~~Spodnie garniturowe - grey~~229.00~~229.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
EAB52L023-D11~~Emporio Armani~~Spinka do mankietów - silver-coloured~~449.00~~449.00~~Męczyźni_Odzież_Kategorie_Garnitury~~accessoires~~0~~0~~1
DR222A02E-C11~~DRYKORN~~VERMONT - Marynarka garniturowa - grey melange~~1119.00~~1119.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~1
LG522A014-C11~~Lindbergh~~MENS SUIT SLIM FIT - Garnitur - grey check~~659.00~~659.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
PI922A02C-K11~~Pier One~~Garnitur - blue~~449.00~~449.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
SE622D0PM-G11~~Selected Homme~~SHDONENEN MARK SLIM FIT - Koszula biznesowa - bordeaux~~169.00~~169.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
HU722D04D-A11~~HUGO~~JACQUES SLIM FIT - Koszula biznesowa - open white~~263.20~~329.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~20%~~0~~0~~1
OLB22D00A-A11~~OLYMP~~MODERN FIT - Koszula biznesowa - white~~122.85~~189.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~35%~~0~~0~~0
T0122D08B-Q11~~Tommy Hilfiger~~Koszula - flag black~~299.00~~299.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
OL822D0E2-A11~~OLYMP~~BODY FIT - Koszula - white~~249.00~~249.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
T1022D066-A12~~Tommy Hilfiger Tailored~~POPLIN CLASSIC SLIM FIT - Koszula biznesowa - white~~289.00~~289.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0
HU722D0CB-A11~~HUGO~~KOEY SLIM FIT - Koszula biznesowa - white~~379.00~~379.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~1
TWC22A01L-Q11~~Twisted Tailor~~LYNX SUIT EXCLUSIVE - Garnitur - black~~701.40~~1169.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~40%~~0~~0~~0
EAB22D00V-K12~~Emporio Armani~~Koszula biznesowa - dark blue~~299.50~~599.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~50%~~1~~0~~1
PI922DA31-A11~~Pier One~~Koszula biznesowa - white~~119.00~~119.00~~Męczyźni_Odzież_Kategorie_Garnitury~~clothing~~0~~0~~0

```

Źródło: opracowanie własne.

Aby utworzyć jeden plik z danymi, które mogły być poddane analizie w języku R, została utworzona procedura działająca w pętli, która:

- sczytywała wszystkie pliki z danymi skrapowanymi, które pobrano do wspólnego folderu;
- z nazwy każdego pliku kopiowała szereg znaków od 11 do 20 (data skrapowania danych) i zapisywała ją jako zmienną czasową (docelowo kolumna 'time');
- przyporządkowała zmienną czasową do każdego rekordu i zmieniała format na datę z dokładnością do roku, miesiąca i dnia;
- dodawała zbiór danych z każdego pliku wraz z przyporządkowaną zmienną czasową do wspólnego zbioru „dane”

Rysunek 4. Kod w programie R odpowiedzialny za połączenie plików z danymi z poszczególnych dni analizy w jeden plik dostosowany do dalszych analiz

```
library("dplyr")
setwd("D:/Dane R")
pliki<-list.files("D:/Dane R/R")
dane<-data.frame()

for(i in 1:length(pliki)) {
  dane_day<-read.table(file=pliki[i], header=TRUE, fill = TRUE, sep="~",encoding="UTF-8")
  czas<-substr(pliki[i], 11,20)
  czas<-as.Date(gsub("_", "-",czas))
  dane_day$time<-czas
  dane<-rbind(dane, dane_day)
}

kolumny<-seq(from=1,to=34, by=3)
kolumny

dane<-dane[,c(35,kolumny)]
dane

dane$prodID<-dane$id
dane$prices<-dane$cena
dane$kategoria <- dane$kategoria
dane$quantities<-1
dane

dane <- select(dane, time, prodID, prices, quantities, kategoria)
```

Źródło: opracowanie własne w R.

Następnie usunięto nagminnie występujące znaki „~” oraz ujednolicono kategorie danych, tak by odpowiadały wymogom pakietu *PriceIndices*. Dodano także dodatkową zmienną *quantities* która w przypadku danych skrapowanych zawsze wynosi 1 (brak wag). Następnie za pomocą funkcji *select* wybrano zmienne niezbędne do dalszej analizy: *time* – moment czasu kiedy zbierane dane, *prodID* - unikatowe ID produktu, *price* - cena produktu [PLN], *quantities* - ilości ustawione na 1, *kategoria* – kategoria w jakiej znajduje się produkt.

Ramka danych, po zastosowaniu omówionej wyżej procedury, miała postać jak na rysunku 5.

Rysunek 5. Struktura ramki danych po zastosowaniu procedury z rys nr. 4

	time	prodID	quantities	prices	kategoria
1	2018-02-09	WR122E00T-K23	1	299.0	Mężczyźni_Odzież_Kategorie_Jeansy
2	2018-02-09	WR122E00T-K28	1	339.0	Mężczyźni_Odzież_Kategorie_Jeansy
3	2018-02-09	WR122E00T-K14	1	329.0	Mężczyźni_Odzież_Kategorie_Jeansy
4	2018-02-09	OS322G05U-Q11	1	129.0	Mężczyźni_Odzież_Kategorie_Jeansy
5	2018-02-09	PE122G05J-K12	1	379.0	Mężczyźni_Odzież_Kategorie_Jeansy
6	2018-02-09	DI122G0GF-Q11	1	579.0	Mężczyźni_Odzież_Kategorie_Jeansy
7	2018-02-09	C1822G030-K11	1	419.0	Mężczyźni_Odzież_Kategorie_Jeansy
8	2018-02-09	LE422A01O-K33	1	309.0	Mężczyźni_Odzież_Kategorie_Jeansy
9	2018-02-09	HU722G03H-Q11	1	459.0	Mężczyźni_Odzież_Kategorie_Jeansy
10	2018-02-09	SC322G07D-K11	1	679.0	Mężczyźni_Odzież_Kategorie_Jeansy
11	2018-02-09	YO122GA03-Q12	1	109.0	Mężczyźni_Odzież_Kategorie_Jeansy
12	2018-02-09	C1822G031-Q11	1	419.0	Mężczyźni_Odzież_Kategorie_Jeansy
13	2018-02-09	YO122G02A-K11	1	149.0	Mężczyźni_Odzież_Kategorie_Jeansy
14	2018-02-09	JA222G00D-K11	1	169.0	Mężczyźni_Odzież_Kategorie_Jeansy

Źródło: opracowanie własne w R.

Następnie dane poddano dalszej obróbce polegającej na (patrz rysunek 6):

- wybraniu poszczególnych kategorii lub podkategorii za pomocą funkcji *filter* i *grep* z pakietu *dplyr*;
- zagregowaniu danych dziennych do danych miesięcznych za pomocą funkcji *data\_aggregating* z pakietu *PriceIndices*;

Rysunek 6. Procedura filtracji danych po kategoriach i ich agregacji

```
MO1 <- filter(Dane3, grep("Mężczyźni_Odzież", kategoria))
MO1 <- data_aggregating(MO1)
MO1$time <- as.Date(MO1$time)
lubridate::month(MO1$time) <- lubridate::month(MO1$time)-2
MO1$quantities <- 1
MO1 <- na.omit(MO1)
```

Źródło: opracowanie własne w R.

Powyższe działania pozwoliły ograniczyć ilość obserwacji z 37,5 mln do 4,1 mln. Ograniczyły także ilość zmiennych poddawanych analizie przy liczeniu indeksów do czterech, tj. do: ID produktu, cen, jednostkowej ilości i daty pomiaru. Dane po procedurze okrojania i agregacji prezentowały się jak na rysunku 7.

Rysunek 7. Wygląd ramki danych po procedurze agregacji

	time	prodID	prices	quantities
1	2017-12-01	0VB11L000-J11	838.7550	1
2	2017-12-01	10K41A01Q-A11	120.5750	1
3	2017-12-01	10K41A01Q-Q12	127.2000	1
4	2017-12-01	10K41A01R-B11	149.3750	1
5	2017-12-01	10K41A01R-Q11	119.2500	1
6	2017-12-01	10K41A027-A11	169.0000	1
7	2017-12-01	10K41A027-C11	169.0000	1
8	2017-12-01	10K41A027-Q11	169.0000	1
9	2017-12-01	10K41A029-Q11	129.2400	1
10	2017-12-01	10K41A02G-C11	127.2000	1

Źródło: opracowanie własne w R.

Jak wspomniano w rozdziale 1, rotacja produktów (*product churn*) jest istotnym problemem w przypadku analizy odzieży i obuwia, zwłaszcza z sektora *Fast Fashion*. Analiza powyższych danych potwierdza ten wniosek. Spośród wszystkich produktów obecnych w pierwszym miesiącu analizy jedynie 2,63% występowała dalej w zbiorze danych po 21 miesiącach. Największy odsetek produktów dalej występujących miał miejsce w przypadku męskiego obuwia (3,41%), a najniższy (1,72%) w przypadku damskiego obuwia (patrz tabela 7).

Tabela 7. Odsetek produktów występujących jednocześnie w pierwszym i ostatnim miesiącu analizy


Zbiór danych	Produkty będące w próbie w ostatnim i pierwszym miesiącu analizy
Cały zbiór danych	2,63%
Odzież damska	2,60%
Odzież męska	3,27%
Obuwie męskie	3,41%
Obuwie damskie	1,72%

Źródło: opracowanie własne w R.

Analizując dopasowanie danych w poszczególnych miesiącach można zauważyć, że gwałtowny spadek następuje już w pierwszych 3 miesiącach od rozpoczęcia obserwacji, po których odsetek obecnych w próbie towarów spadł poniżej 50%. Po kolejnych 5 miesiącach odsetek ten wynosi już znacznie poniżej 10% (wykres 6). We wszystkich kategoriach spadek


powtarzalności produktów następował w podobny sposób (wykresy 7-10). W przypadku niektórych podkategorii (męskie klapki, męskie trampki i sneakersy) w próbie nie występował ani jeden produkt, który znalazłby się zarówno w pierwszym, jak i ostatnim miesiącu w analizowanym koszyku. W przypadku części podkategorii odsetek powtarzalności jest znacząco wyższy niż dla głównych kategorii i przekracza 5-6% (męskie obuwie *outdoor*, obuwie biznesowe).

Wykres 6. Odsetek obecności produktów w kolejnych miesiącach analizy




Źródło: opracowanie własne w R.


Wykres 7. Odsetek obecności produktów z kategorii kobiece obuwie w kolejnych miesiącach analizy




Wykres 9. Odsetek obecności produktów z kategorii odzież damska w kolejnych miesiącach analizy



Wykres 8. Odsetek obecności produktów z kategorii męskie obuwie w kolejnych miesiącach analizy



Wykres 10. Odsetek obecności produktów z kategorii odzież męska w kolejnych miesiącach analizy



Źródło: opracowanie własne w R.

## 4.2. Porównanie nieważonych indeksów bilateralnych i multilateralnych

Indeksami bilateralnymi mogącymi mieć zastosowanie w kalkulacji indeksów opartych na danych skrapowanych (a więc takimi, dla których nie posiadamy informacji o poziomie konsumpcji poszczególnych dóbr) są indeks Jevonsa, indeks Dutot i indeks Carliego, czyli tzw. formuły elementarne (szerzej omówione w rozdziale 1). W przypadku cen odzieży i obuwia można zaobserwować, że średnia bezwzględna różnica między przeciętnym odczytem dla poszczególnych indeksów była stosunkowo zbliżona do siebie i wahała się od 1,1 pkt. proc. (między indeksem Dutot i Jevonsa) do 1,7 pkt. proc. (między indeksem Jevonsa i Carliego). Co istotne, różnice pomiaru były wyłącznie jednokierunkowe w przypadku zestawienia indeksu Carliego i Jevonsa, natomiast różnokierunkowe w przypadku różnic obu tych indeksów, a indeksem Dutot. Wynika to z faktu, że indeks Dutot wykazywał największą rzadkość do osiągnięcia skrajnych wartości pomiaru (we wrześniu 2019 r. różnica między indeksem Dutot a indeksem Carliego osiągnęła blisko 7 pkt. proc., tabela 8, wykres 11).

Tabela 8. Porównanie wartości dla jednopodstawowych indeksów bilateralnych

x	Indeks Jevonsa	Indeks Carliego	Indeks Dutot	Jevons - Carli	Jevons - Dutot	Carli - Dutot
2017-12	1,0000	1,0000	1,0000	0,0000	0,0000	0,0000
2018-01	0,9913	0,9959	0,9924	-0,0046	-0,0011	0,0035
2018-02	0,9503	0,9575	0,9509	-0,0071	-0,0005	0,0066
2018-03	0,9574	0,9649	0,9637	-0,0076	-0,0063	0,0012
2018-04	0,8911	0,9038	0,8753	-0,0127	0,0158	0,0285
2018-05	0,8409	0,8621	0,8079	-0,0212	0,0330	0,0542
2018-06	0,8833	0,8997	0,8786	-0,0164	0,0047	0,0211
2018-07	0,8707	0,8861	0,8764	-0,0154	-0,0057	0,0097
2018-08	0,9734	0,9875	0,9880	-0,0141	-0,0147	-0,0006
2018-09	0,8633	0,9057	0,8365	-0,0424	0,0268	0,0692
2018-10	0,9312	0,9475	0,9471	-0,0163	-0,0159	0,0004
2018-11	0,9335	0,9528	0,9492	-0,0192	-0,0157	0,0035
2018-12	0,9130	0,9346	0,9244	-0,0216	-0,0113	0,0102
2019-01	0,9557	0,9677	0,9695	-0,0119	-0,0138	-0,0018
2019-02	0,9410	0,9544	0,9509	-0,0134	-0,0098	0,0036
2019-03	0,8849	0,8981	0,8862	-0,0131	-0,0012	0,0119
2019-04	0,8973	0,9132	0,9094	-0,0158	-0,0121	0,0038
2019-05	0,8696	0,8935	0,8781	-0,0239	-0,0085	0,0155
2019-06	0,8657	0,8887	0,8699	-0,0229	-0,0042	0,0187
2019-07	0,8805	0,9018	0,8939	-0,0214	-0,0134	0,0080
2019-08	0,9272	0,9411	0,9458	-0,0140	-0,0187	-0,0047
średnia różnica pomiaru	x	x	x	-0,0168	-0,0036	0,0131
średnia bezwzględnej różnicy pomiaru	x	x	x	0,0168	0,0117	0,0138

Źródło: opracowanie własne w R.

Identyczne wyniki można uzyskać przy użyciu funkcji *compare\_distances* w pakiecie *PriceIndices*. Średnia absolutna różnica między wartościami dla indeksu Jevonsa a indeksu Carliego wynosi 1,68 pkt. proc. Niższą różnicę można zaobserwować między indeksem Jevonsa a indeksem Dutot (1,166 pkt. proc.) i między indeksem Dutot a indeksem Carliego (1,38 pkt. proc., tabela 9).

Tabela 9. Średnia różnica między wartościami jednopodstawowych indeksów bilateralnych (w pkt. proc.)

	Jevons	Carli	Dutot
Jevons	0,000	1,675	1,165
Carli	1,675	0,000	1,384
Dutot	1,165	1,384	0,000

Źródło: opracowanie własne w R.




Wykorzystując funkcję *compare\_to\_target* w pakiecie *PriceIndices* można uzyskać także wyniki dla tzw. połowicznych indeksów (ang. semi-indices), które obrazują średnie wartości przeszacowań powyżej i poniżej indeksu referencyjnego. W przypadku indeksu Carliego można zaobserwować wyłącznie przeszacowania w stosunku do indeksu Jevonsa. Dla indeksu Dutot wartości przeszacowań są dwukrotnie wyższe niż niedoszacowań (0,76 pkt. proc. vs 0,4 pkt. proc., tabela 10)

Tabela 10. Średnia różnica między indeksami Carliego i Dutot w porównaniu do indeksu Jevonsa (w pkt. proc.)

	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Jevons	0	0	0
Carli	1,675	0	1,675
Dutot	1,165	0,401	0,764

Źródło: opracowanie własne w R.

Wykres 11. Porównanie wartości dla jednopodstawowych indeksów bilateralnych.




Źródło: opracowanie własne w R.


Podobne różnice zaobserwować można w przypadku osobnych pomiarów dla 4 głównych kategorii danych. Warto jednak zwrócić uwagę, że odchylenia indeksu Dutot od pozostałych indeksów są większe dla męskiej i damskiej odzieży niż obuwia (wykresy 12-15). W przypadku danych dla męskiego obuwia można zauważyć wyższe niż dla innych kategorii odchylenia dla indeksu Jevonsa (wykres 13). Wszystkie grupy są jednak ciągle na zbyt wysokim poziomie

dezagregacji by można było nazwać je homogenicznymi. Wysoka różnorodność produktów i fluktuacja cen skutkuje istotnymi różnicami między indeksami elementarnymi.


Wykres 12. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla damskiego obuwia




Wykres 14. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla damskiej odzieży



Wykres 13. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla obuwia męskiego



Wykres 15. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla męskiej odzieży



Źródło: opracowanie własne w R.

W przypadku łańcuchowych wersji indeksów Carliego, Jevonsa i Dutot można zaobserwować znaczącą różnicę w stosunku do ich jednopodstawowych wersji. Widoczny silny efekt kumulacji obciążeń pomiaru z poprzednich okresów przekłada się na spadek indeksu o 52-59 pkt. proc. po 21 miesiącach (w porównaniu do 5-7 pkt. proc. dla wersji jednopodstawowych). Znacznie ciężiej zauważyć także „efekt wyprzedzący” w miesiącach przełomu sezonów (widocznych zwłaszcza przed latem i zimą, tabela 11)<sup>144</sup>.

<sup>144</sup> Ze względu na dostosowanie danych do wymogów metod rozszerzenia okna obliczeń dane zostały przesunięte o 2 miesiące do tyłu. Początek pierwszej wyprzedzającej ma więc realnie miejsce w czerwcu (zamiast jak na wykresie – w kwietniu), a drugiej w listopadzie (zamiast jak na wykresie we wrześniu).

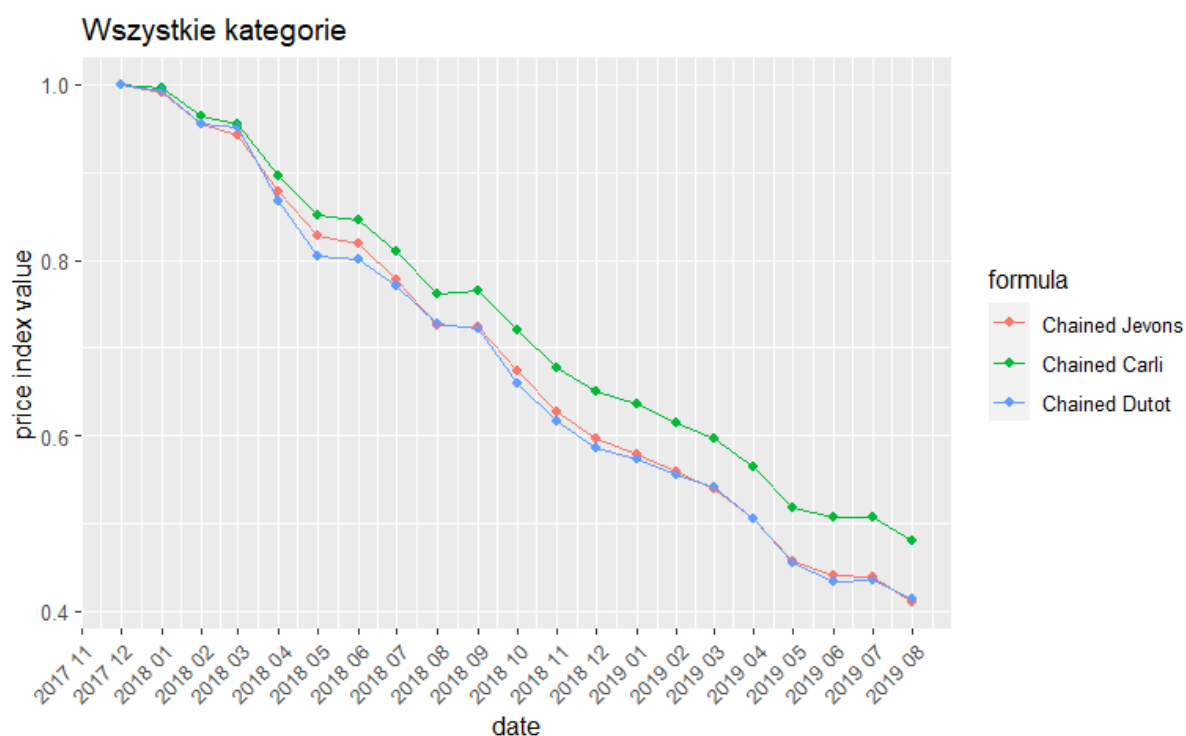
Tabela 11. Porównanie wartości dla indeksów łańcuchowych

	łańcuchowy indeks Jevonsa	łańcuchowy indeks Carliego	łańcuchowy indeks Dutot	łańcuchowy indeks Jevonsa - Carliego	łańcuchowy indeks Jevonsa - Dutot	łańcuchowy indeks Carliego - Dutot
2017-12	1,00000	1,00000	1,00000			
2018-01	0,99133	0,99589	0,99241	-0,00457	-0,00108	0,00349
2018-02	0,95473	0,96321	0,95571	-0,00848	-0,00097	0,00750
2018-03	0,94344	0,95593	0,95198	-0,01250	-0,00855	0,00395
2018-04	0,87899	0,89680	0,86662	-0,01781	0,01237	0,03017
2018-05	0,82761	0,85067	0,80458	-0,02307	0,02302	0,04609
2018-06	0,81956	0,84636	0,80110	-0,02680	0,01846	0,04526
2018-07	0,77765	0,81071	0,77015	-0,03306	0,00751	0,04057
2018-08	0,72583	0,76250	0,72773	-0,03667	-0,00190	0,03477
2018-09	0,72353	0,76463	0,72225	-0,04110	0,00129	0,04238
2018-10	0,67413	0,72032	0,66040	-0,04619	0,01373	0,05992
2018-11	0,62748	0,67714	0,61592	-0,04965	0,01156	0,06122
2018-12	0,59667	0,65038	0,58688	-0,05370	0,00980	0,06350
2019-01	0,57978	0,63599	0,57451	-0,05621	0,00527	0,06147
2019-02	0,55851	0,61551	0,55583	-0,05700	0,00268	0,05968
2019-03	0,53903	0,59722	0,54183	-0,05819	-0,00280	0,05539
2019-04	0,50606	0,56473	0,50521	-0,05867	0,00085	0,05952
2019-05	0,45653	0,51818	0,45618	-0,06165	0,00035	0,06200
2019-06	0,44089	0,50719	0,43475	-0,06631	0,00614	0,07244
2019-07	0,43849	0,50711	0,43487	-0,06862	0,00362	0,07224
2019-08	0,40991	0,48024	0,41439	-0,07032	-0,00448	0,06584
średnia różnica pomiaru	x	x	x	-0,04253	0,00484	0,04737
średnia bezwzględnej różnicy pomiaru	x	x	x	0,04253	0,00701	0,04957

Źródło: opracowanie własne w R.

Wyższe niż w przypadku indeksów jednopodstawowych pozostają także średnie bezwzględne różnice między indeksem Carliego, a indeksami Dutot i Jevonsa przekraczając w obu przypadkach 4 pkt. proc. Indeksy Dutot i Jevonsa charakteryzują się w większości omawianych miesięcy bardziej zbliżonymi wynikami (średnia bezwzględna różnica na poziomie 0,7 pkt. proc., tabela 11, wykres 16).

Wykres 16. Porównanie wartości dla indeksów łańcuchowych



Źródło: opracowanie własne w R.

Wyniki uzyskane powyżej potwierdzają obliczenia w pakiecie *PriceIndices*. Różnice między indeksem łańcuchowym Jevonsa a łańcuchowym indeksem Dutot są 7-krotnie niższe (0,7 pkt. proc.) niż między łańcuchowymi indeksami Jevonsa i Carliego (4,3 pkt. proc., tabela 12). Łańcuchowy indeks Carliego wyłącznie przeszacowuje wartości w porównaniu do łańcuchowego indeksu Jevonsa, natomiast wartości indeksu Dutot w analizowanych okresach mniej więcej po równo przeszacowuje i niedoszacowuje w porównaniu do łańcuchowego indeksu Jevonsa (tabela 13).

Tabela 12. Średnia różnica między wartościami indeksów łańcuchowych (w pkt. proc.)

	chain Jevons	chain Carli	chain Dutot
chain Jevons	0	4,253	0,682
chain Carli	4,253	0	4,737
chain Dutot	0,682	4,737	0

Źródło: opracowanie własne w R.

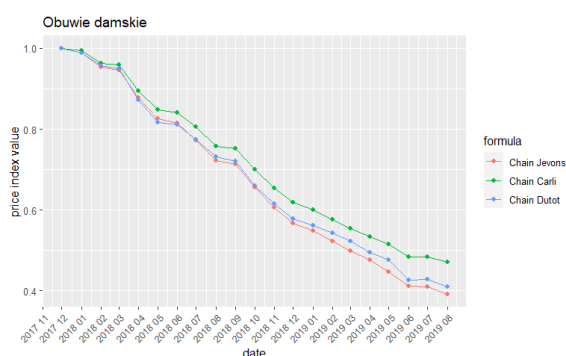
Tabela 13. Średnia różnica między łańcuchowymi indeksami Carliego i Dutot w porównaniu do łańcuchowego indeksu Jevonsa (w pkt. proc.)

	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
chain Jevons	0	0	0
chain Carli	4,253	0	4,253
chain Dutot	0,682	0,583	0,099


Źródło: opracowanie własne w R.

Różnica między łańcuchowym indeksem Dutot a łańcuchowym indeksem Jevonsa zauważalnie zwiększa się w przypadku obliczeń dla cen damskiego i męskiego obuwia (wykresy 17-20).


Wykres 17. Porównanie wartości dla indeksów łańcuchowych dla damskiego obuwia




Wykres 18. Porównanie wartości dla indeksów łańcuchowych dla męskiego obuwia



Wykres 19. Porównanie wartości dla indeksów łańcuchowych dla damskiej odzieży



Wykres 20. Porównanie wartości dla indeksów łańcuchowych dla męskiej odzieży



Źródło: opracowanie własne w R.

Dodatkowo zdecydowano się na porównanie jednopodstawowej i łańcuchowej wersji indeksu Jevonsa z indeksem multilateralnym GEKS opartym na formule Jevonsa (GEKS-J) oraz

nieważoną formułą indeksu Time Product Dummy (TPD). Ze względu na charakter indeksu TPD, który opiera się na modelu regresji panelowej opisującego zachowanie się cen, autor pracy zdecydował się na wykorzystanie mniejszego zbioru danych ograniczając się do jednej z mniej licznych podkategorii produktów (mokasyny). Większe zbiory danych nieproporcjonalnie wydłużają czas obliczeń konsumowany przez indeks TPD, co jest zresztą wskazywane jako jedna z jego najpoważniejszych wad<sup>145</sup>.

Końcowe wyniki kalkulacji dokonywanych za pomocą indeksów opartych na formule Jevonsa i nieważonego indeksu UTPD (Unweighted Time Product Dummy) znacząco różnią się między sobą. Najmniejszą różnicę (1,7 pkt. proc) można zauważyć między indeksami Jevonsa i GEKS-J. Multilateralny indeks GEKS-J charakteryzował się jednak znacznie stabilniejszym odczytem w okresach pomiędzy pierwszym i ostatnim miesiącem analizy, podczas gdy indeks Jevonsa bardzo dynamicznie reagował na okresy wyprzedzaży. Wynika to z charakterystyki bilateralnych jednopodstawowych indeksów – najpierw reagują silnym spadkiem wartości indeksu ze względu na spadek cen związanych z promocjami, a następnie, gdy przecenione produkty są usuwane ze sklepów (a co za tym idzie z próby), indeks odnosi się już wyłącznie do dynamiki między produktami obecnymi w próbie w 1 miesiącu, a tymi, które w niej pozostały w dotychczasowych (tj. nieobniżonych) cenach.

Nieważony indeks TPD z kolei początkowo zachowuje się bardzo podobnie do indeksu Jevonsa i łańcuchowego indeksu Jevonsa, które w początkowych miesiącach wykazują silniejszy trend spadkowy niż indeks GEKS-J. Nieważony indeks TPD nie ulega jednak ani wyraźnemu dryfowi, ani bardzo dużym wahaniom wartości indeksu miesiąc do miesiąca poprzedniego. W efekcie od 8. miesiąca analizy nieważony indeks UTPD charakteryzuje się wartościami znajdującymi się pomiędzy wartościami łańcuchowego indeksu Jevonsa a wartościami indeksu GEKS-J. Finalna wartość nieważonego indeksu TPD wynosi 0,54 i jest o 13 pkt. proc. powyżej łańcuchowego indeksu Jevonsa i 14 pkt. proc. poniżej indeksu GEKS-J (tabela 14, wykres 21). To bardzo duże różnice, które jednoznacznie dowodzą, jak ważnym aspektem przy wdrażaniu danych skrapowanych do pomiaru inflacji jest wybór indeksu cenowego.

---

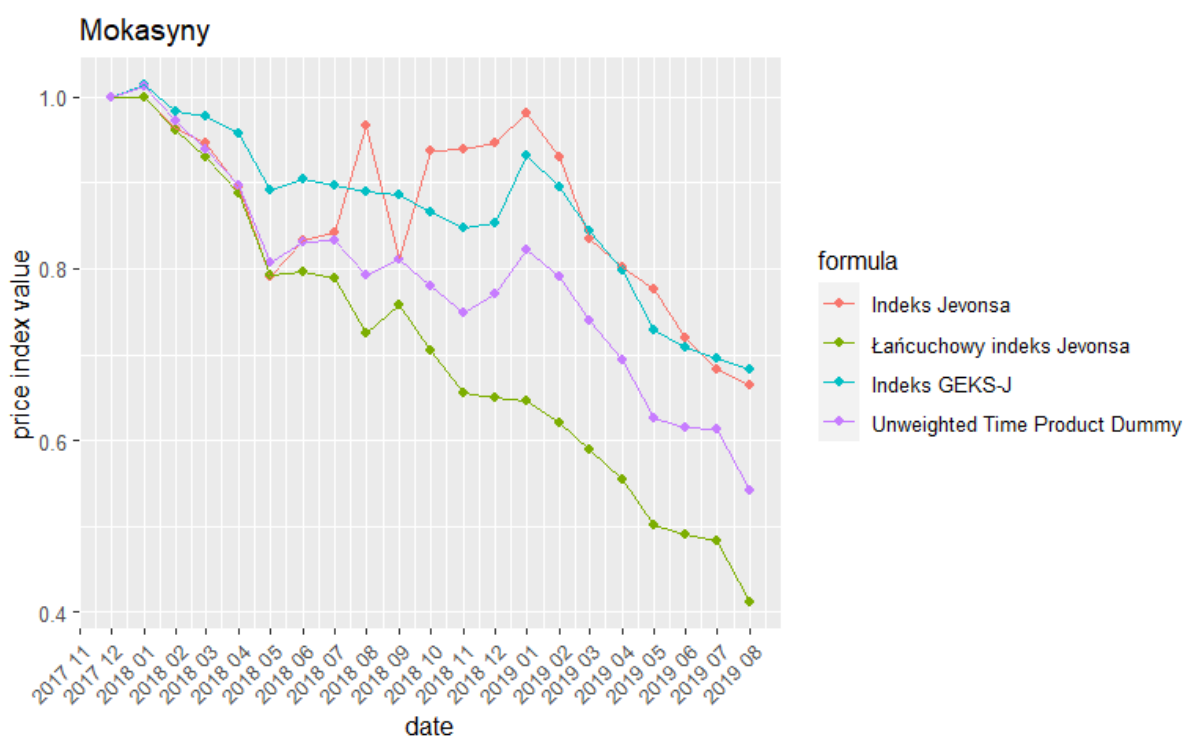
<sup>145</sup> Białek, J. (2022), Improving quality of the scanner CPI: proposition of new multilateral methods, "Quality & Quantity", doi: 10.1007/s11135-022-01506-6.

Tabela 14. Porównanie wartości dla formuł bazujących na indeksie Jevonsa oraz nieważonego indeksu TPD dla mokasynów

Miesiąc	łańcuchowy			Unweighted Time Product Dummy
	Indeks Jevonsa	Indeks Jevonsa	Indeks GEKS-J	
2017-12	1,00000	1,00000	1,00000	1,00000
2018-01	0,99879	0,99879	1,01408	1,01131
2018-02	0,96365	0,96090	0,98370	0,97202
2018-03	0,94606	0,93041	0,97801	0,93860
2018-04	0,89538	0,88780	0,95697	0,89763
2018-05	0,79156	0,79264	0,89212	0,80796
2018-06	0,83212	0,79685	0,90445	0,83120
2018-07	0,84238	0,78964	0,89628	0,83258
2018-08	0,96709	0,72470	0,88940	0,79333
2018-09	0,81067	0,75844	0,88504	0,81099
2018-10	0,93774	0,70481	0,86514	0,77915
2018-11	0,93871	0,65516	0,84714	0,74826
2018-12	0,94556	0,64997	0,85303	0,77132
2019-01	0,98177	0,64654	0,93132	0,82112
2019-02	0,92914	0,62035	0,89486	0,79003
2019-03	0,83491	0,58942	0,84457	0,73896
2019-04	0,80235	0,55499	0,79767	0,69409
2019-05	0,77559	0,50205	0,72883	0,62518
2019-06	0,71943	0,49130	0,70917	0,61526
2019-07	0,68313	0,48313	0,69542	0,61233
2019-08	0,66500	0,41112	0,68190	0,54129

Źródło: opracowanie własne w R.

Wykres 21. Porównanie wartości dla formuł bazujących na indeksie Jevonsa i nieważonego indeksu TPD dla mokasynów



Źródło: opracowanie własne w R.

### 4.3. Analiza metod rozszerzeń indeksów multilateralnych

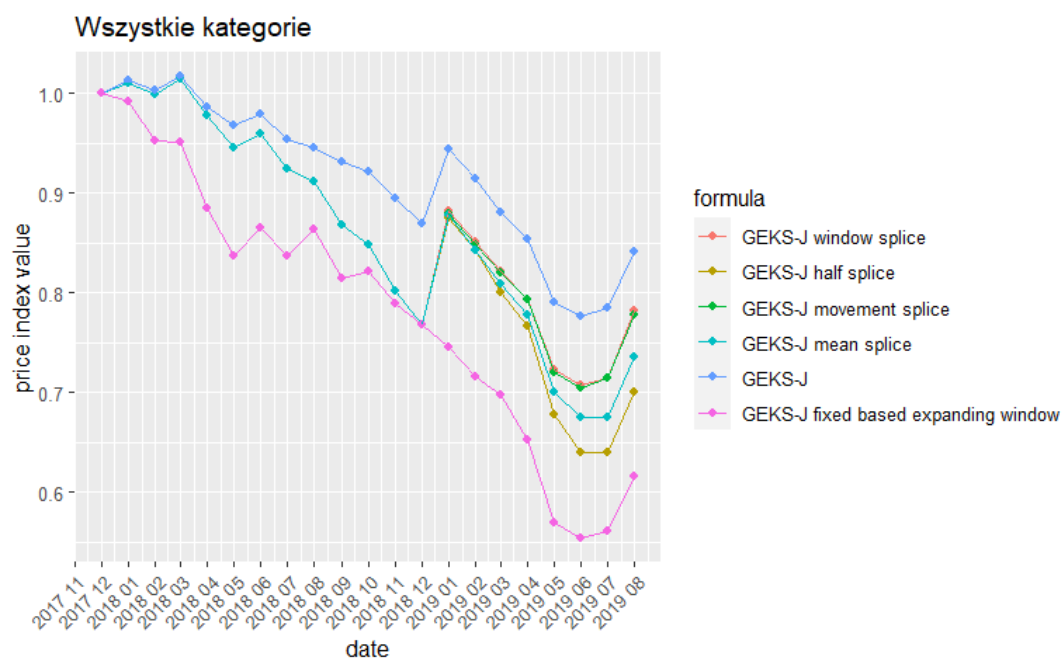
Zastosowanie różnych metod rozszerzania okna czasowego dla indeksów multilateralnych skutkuje wysokim zróżnicowaniem wyników. W analizie porównawczej, indeksem służącym do porównań może być multilateralny indeks wyznaczony dla pełnego, szerokiego okna czasowego (np. dwuletniego). Takim indeksem będzie u nas indeks GEKS-J liczony dla pełnego okna obserwacji. Najniższymi wskazaniem, bo znajdującymi się blisko 22 pkt. proc. poniżej wartości indeksu GEKS-J, charakteryzowała się metoda FBEW (patrz rozdział 2). Dużą różnicę w stosunku do zwykłego indeksu GEKS-J widać także w przypadku metody FBMW<sup>146</sup> (17 pkt. proc.).

Bliższe wyniki do „pełnego” indeksu GEKS-J prezentują metody „splątania” okna (od 14 do 6 pkt. proc. różnicy). Warto zauważyć, że 2 metody splątania okna – metoda *movement splice* i *window splice* w całym oknie analizy prezentują bardzo zbliżone do siebie wartości. Końcowa różnica między wynikami uzyskanymi za pomocą tych metod wynosi jedynie 0,3 pkt. proc (tabela 15, wykres 22).

<sup>146</sup> Wyniki dla metody FBMW są dostępne jedynie od 12.2018. Metoda do obliczeń wymaga 12-miesięcznego okna poprzedzającego moment analizy. Wyniki indeksu GEKS-J FBMW z okresów sprzed 12.2018 są więc niemożliwe do obliczenia ze względu na zbyt krótki szereg czasowy.



Wykres 22. Porównanie metod rozszerzeń okna indeksu GEKS-J dla pełnego zestawu danych



Źródło: opracowanie własne w R.

Tabela 15. Porównanie metod rozszerzeń okna indeksu GEKS-J dla pełnego zestawu danych

x	GEKSJ window	GEKSJ half	GEKSJ movement	GEKSJ mean	GEKSJ	GEKS fbew	GEKS fbmw
2017-12	1,00000	1,00000	1,00000	1,00000	1,00000	1,00000	x
2018-01	1,01031	1,01031	1,01031	1,01031	1,01246	0,99133	x
2018-02	0,99806	0,99806	0,99806	0,99806	1,00280	0,95179	x
2018-03	1,01443	1,01443	1,01443	1,01443	1,01704	0,95098	x
2018-04	0,97758	0,97758	0,97758	0,97758	0,98662	0,88538	x
2018-05	0,94584	0,94584	0,94584	0,94584	0,96707	0,83703	x
2018-06	0,95980	0,95980	0,95980	0,95980	0,97830	0,86503	x
2018-07	0,92470	0,92470	0,92470	0,92470	0,95429	0,83705	x
2018-08	0,91134	0,91134	0,91134	0,91134	0,94539	0,86406	x
2018-09	0,86762	0,86762	0,86762	0,86762	0,93053	0,81465	x
2018-10	0,84859	0,84859	0,84859	0,84859	0,92062	0,82074	x
2018-11	0,80162	0,80162	0,80162	0,80162	0,89502	0,78966	x
2018-12	0,76778	0,76778	0,76778	0,76778	0,86987	0,76778	0,76778
2019-01	0,88225	0,87451	0,87842	0,87770	0,94407	0,74604	0,87842
2019-02	0,85111	0,84207	0,84819	0,84194	0,91363	0,71614	0,84241
2019-03	0,82075	0,80015	0,82071	0,80835	0,87997	0,69802	0,80839
2019-04	0,79389	0,76634	0,79277	0,77733	0,85343	0,65246	0,76921
2019-05	0,72229	0,67832	0,72032	0,69991	0,79079	0,57007	0,67883
2019-06	0,70678	0,64003	0,70430	0,67544	0,77618	0,55354	0,64051
2019-07	0,71486	0,64021	0,71417	0,67580	0,78450	0,56086	0,62705
2019-08	0,78184	0,70073	0,77831	0,73610	0,84117	0,61536	0,67573

Źródło: opracowanie własne w R.

W przypadku obliczeń dla bardziej homogenicznej grupy produktów, jaką są mokasyny, widoczne różnice wskazań indeksów cenowych w przypadku całości danych dla obuwia i

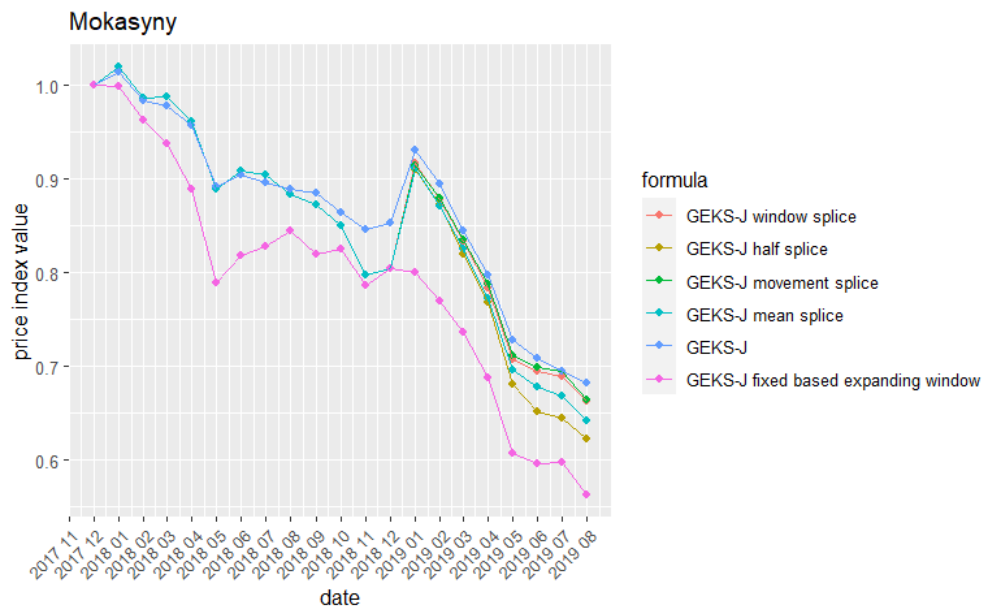
odzieży pozostają podobne, jednak różnica między rozważanymi metodami rozszerzeń okna czasowego jest znacząco niższa. W tym przypadku, między metodą FBEW a niepoddanym metodom rozszerzania indeksem GEKS-J, wynosi ona 8 pkt. proc (tabela 16, wykres 23).

Tabela 16. Porównanie metod rozszerzeń okna indeksu GEKS-J dla kategorii Mokasyny

Miesiąc	GEKS-J window splice	GEKS-J half	GEKS-J movement splice	GEKS-J mean splice	GEKS-J	GEKS-J FBEW	GEKS-J FBMW
2017-12	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	x
2018-01	1,0130	1,0130	1,0130	1,0130	1,0113	0,9988	x
2018-02	0,9737	0,9737	0,9737	0,9737	0,9720	0,9623	x
2018-03	0,9401	0,9401	0,9401	0,9401	0,9386	0,9360	x
2018-04	0,8985	0,8985	0,8985	0,8985	0,8976	0,8885	x
2018-05	0,8094	0,8094	0,8094	0,8094	0,8080	0,7932	x
2018-06	0,8329	0,8329	0,8329	0,8329	0,8312	0,8155	x
2018-07	0,8323	0,8323	0,8323	0,8323	0,8326	0,8190	x
2018-08	0,7909	0,7909	0,7909	0,7909	0,7933	0,7696	x
2018-09	0,8060	0,8060	0,8060	0,8060	0,8110	0,7924	x
2018-10	0,7601	0,7601	0,7601	0,7601	0,7791	0,7532	x
2018-11	0,6999	0,6999	0,6999	0,6999	0,7483	0,6948	x
2018-12	0,7039	0,7039	0,7039	0,7039	0,7713	0,7039	0,7039
2019-01	0,7515	0,7528	0,7345	0,7497	0,8211	0,7002	0,7345
2019-02	0,7290	0,7352	0,7052	0,7276	0,7900	0,6738	0,7087
2019-03	0,7035	0,7087	0,6729	0,7005	0,7390	0,6473	0,6796
2019-04	0,6531	0,6664	0,6330	0,6555	0,6941	0,6106	0,6361
2019-05	0,5749	0,5926	0,5699	0,5843	0,6252	0,5441	0,5658
2019-06	0,5630	0,5778	0,5596	0,5720	0,6153	0,5314	0,5516
2019-07	0,5578	0,5760	0,5575	0,5683	0,6123	0,5288	0,5464
2019-08	0,4886	0,5091	0,4914	0,5002	0,5413	0,4633	0,4804

Źródło: opracowanie własne w R.

Wykres 23. Porównanie metod rozszerzeń okna indeksu GEKS-J dla kategorii Mokasyny



Źródło: opracowanie własne w R.


Tabela 17. Porównanie metod rozszerzeń okna nieważonego indeksu TPD dla kategorii Mokasyny

Miesiąc	UTPD window splice	UTPD half splice	UTPD movement splice	UTPD mean splice	UTPD	UTPD FBEW	UTPD FBMW
2017-12	1,0000	1,0000	1,0000	1,0000	1,0000	1,0000	x
2018-01	1,0130	1,0130	1,0130	1,0130	1,0113	0,9988	x
2018-02	0,9737	0,9737	0,9737	0,9737	0,9720	0,9623	x
2018-03	0,9401	0,9401	0,9401	0,9401	0,9386	0,9360	x
2018-04	0,8985	0,8985	0,8985	0,8985	0,8976	0,8885	x
2018-05	0,8094	0,8094	0,8094	0,8094	0,8080	0,7932	x
2018-06	0,8329	0,8329	0,8329	0,8329	0,8312	0,8155	x
2018-07	0,8323	0,8323	0,8323	0,8323	0,8326	0,8190	x
2018-08	0,7909	0,7909	0,7909	0,7909	0,7933	0,7696	x
2018-09	0,8060	0,8060	0,8060	0,8060	0,8110	0,7924	x
2018-10	0,7601	0,7601	0,7601	0,7601	0,7791	0,7532	x
2018-11	0,6999	0,6999	0,6999	0,6999	0,7483	0,6948	x
2018-12	0,7039	0,7039	0,7039	0,7039	0,7713	0,7039	0,7039
2019-01	0,7515	0,7528	0,7345	0,7497	0,8211	0,7002	0,7345
2019-02	0,7290	0,7352	0,7052	0,7276	0,7900	0,6738	0,7087
2019-03	0,7035	0,7087	0,6729	0,7005	0,7390	0,6473	0,6796
2019-04	0,6531	0,6664	0,6330	0,6555	0,6941	0,6106	0,6361
2019-05	0,5749	0,5926	0,5699	0,5843	0,6252	0,5441	0,5658
2019-06	0,5630	0,5778	0,5596	0,5720	0,6153	0,5314	0,5516
2019-07	0,5578	0,5760	0,5575	0,5683	0,6123	0,5288	0,5464
2019-08	0,4886	0,5091	0,4914	0,5002	0,5413	0,4633	0,4804

Źródło: opracowanie własne w R.

W przypadku metod rozszerzenia okna dla nieważonego indeksu UTPD widoczne są podobne zależności jak w przypadku indeksu GEKS-J. Różnice między indeksem niepoddanym metodom rozszerzenia okna (na wykresie „UTPD”) a indeksem FBEW wynoszą 6 pkt. proc. Zauważmy, iż w tym przypadku indeks UTPD rozszerzany metodą FBEW wykazuje bardzo podobne wartości do indeksów spleowanych aż do 12. miesiąca analizy (tabela 17, wykres 24).

Wykres 24. Porównanie metod rozszerzeń okna nieważonego indeksu TPD dla kategorii Mokasyny



Źródło: opracowanie własne w R.

#### 4.4. Ocena wpływu filtrowania danych na końcowy wskaźnik cen

W przypadkach kalkulacji indeksów cen, podobnie jak w przypadku wielu statystycznych analiz, nietypowe wartości (*outliers*) mogą mieć negatywny wpływ na osiągnięty rezultat. W celu sprawdzenia, jak wysoki wpływ na wartości omawianych indeksów mogły mieć wartości nietypowe, dane (zarówno w wersji pełnego zestawu, jak i podzielonych na poszczególne kategorie i podkategorie) poddano działaniom czterech filtrów:

- **filtr 1** – usunięcie produktów o najmniejszej i największej zmianie cen (1-y i 99-y percentyl zmiany ceny z miesiąca na miesiąc);
- **filtr 2** – usunięcie produktów o najmniejszej i największej zmianie cen (5-y i 95-y percentyl zmiany ceny z miesiąca na miesiąc);
- **filtr 3** – usunięcie produktów o najmniejszej i największej zmianie cen (1-y i 9-y decyl zmiany ceny z miesiąca na miesiąc);

- **filtr 4** – usunięcie produktów, których cena spadła poniżej 50% wartości z poprzedniego miesiąca lub wzrosła w tym czasie więcej niż dwukrotnie.

Zarówno w przypadku pełnego zestawu danych, jak i odzieży męskiej i damskiej można zauważyć, że działanie **filtrów 1, 2 i 4** miało pozytywny wpływ na wskaźnik powtarzalności produktów w pierwszym i ostatnim miesiącu analizy. Wnioskować zatem możemy, iż z półek sklepowych znikają zwłaszcza te produkty, dla których malejący popyt powoduje drastyczne przeceny lub których duże podwyżki cenowe diametralnie obniżają popyt. Wyjątkiem od tej reguły był **filtr 3**, który usuwał z próby zbyt wysoką liczbę produktów. Przeciwny wpływ filtrów na wskaźnik powtarzalności produktów można zaobserwować w przypadku męskiego i damskiego obuwia – w tym przypadku każdy z zastosowanych sposobów filtracji zmniejszył odsetek produktów występujących jednocześnie w pierwszym i ostatnim miesiącu analizy (tabela 18).

Tabela 18. Odsetek produktów z pierwszego miesiąca analizy występujący w ostatnim miesiącu analizy

Zestaw danych	Wszystkie produkty	Odzież damska	Damskie obuwie	Odzież męska	Męskie obuwie
Bez filtra	2,67%	2,60%	1,72%	3,27%	3,41%
Filtr 1	3,01%	3,10%	1,66%	3,77%	3,35%
Filtr 2	2,82%	3,00%	1,60%	3,47%	3,08%
Filtr 3	2,32%	2,66%	1,30%	2,94%	2,69%
Filtr 4	2,99%	3,01%	1,65%	3,76%	3,50%

Źródło: opracowanie własne w R.

Filtracja produktów powinna odbywać się na grupach jak najbardziej homogenicznych. W przypadku produktów o skrajnie różnych charakterystykach, filtry, zwłaszcza percentylowe, mogą usuwać z próby nadmierną liczbę danych wpływając negatywnie na reprezentatywność próby. Podobne zjawisko można zauważyć w przypadku odzieży i obuwia. Filtry zastosowane na wszystkich danych zebranych ze sklepu redukowały próbę z 4,1 mln rekordów do 2,9-3,3 mln rekordów (średnia z 4 filtrów to 77% oryginalnych danych). W przypadku kategorii bardziej homogenicznych, jak damskie obuwie czy męska odzież, odsetek rekordów po filtracji spadał średnio do ok 90% (z wyjątkiem męskiego obuwia), natomiast dla takich podkategorii, jak mokasyny, sukienki czy jeansy męskie, średni odsetek po filtracji wynosił od 91% do 94% (tabele 19 i 20)

Tabela 19. Liczba rekordów w poszczególnych kategoriach w zależności od zastosowanego sposobu filtracji danych

Kategoria	Bez filtra	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty <sup>147</sup>	4080440	3248429	3124240	2920060	3274449
Odzież damska	1895732	1758400	1690806	1579168	1773439
Damskie obuwie	603421	563633	541235	506387	567073
Odzież męska	977866	926631	892552	835520	933047
Męskie obuwie	305534	259803	250385	235386	261526
Jeansy męskie	85251	80544	77695	72947	81079
Męskie kurtki i marynarki	111806	104268	100230	93791	105044
Płaszczki męskie	20296	18448	17642	16465	18604
Męskie bluzy i swetry	196972	185527	178390	167129	186925
Koszule męskie	119091	113334	109288	102264	114041
Spodnie męskie	125682	119130	114944	107635	119918
Garnitury	65245	62079	59754	55985	62477
Obuwie męskie sznurowane	22565	21452	20692	19511	21555
Obuwie biznesowe	26958	25713	24885	23409	25882
Półbuty męskie	45775	43534	41982	39547	43823
Swetry i bluzy damskie	247410	229694	220497	206395	231577
Sukienki	363447	336765	324304	303281	339341
Baleriny	32363	30599	29422	27607	30733
Szpilki	120702	113112	109061	102354	113677
Czółenka	89647	84665	81625	76669	85122
Mokasyny	2822	2726	2628	2483	2746

Źródło: opracowanie własne w R.

<sup>147</sup> Kategoria „wszystkie produkty” zawiera także produkty nienależące do żadnej z 4 głównych kategorii oraz dane, w przypadku których skrypt nie zebrał informacji o kategorii do której należał produkt.

Tabela 20. Odsetek rekordów pozostałych w próbie po użyciu poszczególnych z analizowanych filtrów

Kategoria	Filtr 1	Filtr 2	Filtr 3	Filtr 4	średnia filtrów
Wszystkie produkty	79,61%	76,57%	71,56%	80,25%	77,00%
Odzież damska	92,76%	89,19%	83,30%	93,55%	89,70%
Damskie obuwie	93,41%	89,69%	83,92%	93,98%	90,25%
Odzież męska	94,76%	91,28%	85,44%	95,42%	91,72%
Męskie obuwie	85,03%	81,95%	77,04%	85,60%	82,40%
Jeansy męskie	94,48%	91,14%	85,57%	95,11%	91,57%
Męskie kurtki i marynarki	93,26%	89,65%	83,89%	93,95%	90,19%
Płaszcz męskie	90,89%	86,92%	81,12%	91,66%	87,65%
Męskie bluzy i swetry	94,19%	90,57%	84,85%	94,90%	91,13%
Koszule męskie	95,17%	91,77%	85,87%	95,76%	92,14%
Spodnie męskie	94,79%	91,46%	85,64%	95,41%	91,82%
Garnitury	95,15%	91,58%	85,81%	95,76%	92,07%
Obuwie męskie sznurowane	96,46%	90,95%	86,47%	95,52%	92,35%
Obuwie biznesowe	96,78%	91,04%	86,84%	96,01%	92,67%
Półbuty męskie	96,43%	90,84%	86,39%	95,74%	92,35%
Swetry i bluzy damskie	96,00%	89,86%	83,42%	93,60%	90,72%
Sukienki	96,30%	90,06%	83,45%	93,37%	90,79%
Baleriny	96,15%	90,22%	85,30%	94,96%	91,66%
Szpilki	96,42%	90,49%	84,80%	94,18%	91,47%
Czółenka	96,41%	90,56%	85,52%	94,95%	91,86%
Mokasyny	96,60%	93,13%	87,99%	97,31%	93,75%

Źródło: opracowanie własne w R.

Należy zwrócić uwagę, że nietypowe wartości dla kategorii męskie obuwie przy jednocześnie niskim odsetku odfiltrowanych produktów w podkategoriach składowych może wskazywać na wyjątkowo niską homogeniczność tej kategorii i wysoce zmienną politykę między różnymi rodzajami męskiego obuwia. Potwierdza to spadek unikatowych ID produktów po poddaniu filtracji do poniżej 52-54% próby oryginalnej (z 73,5 tys. do 38,5-40 tys.), podczas gdy w przypadku pozostałych kategorii sięga on blisko 83-89% (tabele 21 i 22).

Tabela 21. Liczba unikatowych produktów w próbie w zależności od zastosowanego filtra

Kategoria	Brak filtra	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty	630845	552005	544228	532098	553544
Odzież damska	356551	311297	306407	298797	312384
Damskie obuwie	113317	97367	96144	94254	97539
Odzież męska	162954	143734	141998	139445	144062
Męskie obuwie	73482	39486	39032	38448	39584

Źródło: opracowanie własne w R.

Tabela 22. Odsetek unikatowych produktów pozostały w próbie po użyciu poszczególnych filtrów


Kategoria	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty	87,5%	86,3%	84,3%	87,7%
Odzież damska	87,3%	85,9%	83,8%	87,6%
Damskie obuwie	85,9%	84,8%	83,2%	86,1%
Odzież męska	88,2%	87,1%	85,6%	88,4%
Męskie obuwie	53,7%	53,1%	52,3%	53,9%

Źródło: opracowanie własne w R.

W przypadku indeksu Jevonsa już filtr 1 wykazuje duże ograniczenie w zmienności miesiąc do miesiąca poprzedniego (m/m), jaka charakteryzuje indeksy jednopodstawowe. Widoczne jest to zwłaszcza dla okresu 08-09. 2018 (spadek zmienności m/m z ok. 10 pkt. proc. do ok 1 pkt. proc.). Między wynikami poszczególnych filtrów różnica jest znacznie niższa (wykres 25). W bardzo podobny sposób na zjawisko filtrowania reaguje indeks Dutot (wykres 26).




Wykres 25. Porównanie wyników filtrowania danych dla indeksu Jevonsa dla pełnego zestawu danych



Źródło: opracowanie własne w R.

Wykres 26. Porównanie wyników filtrowania danych dla indeksu Dutot dla pełnego zestawu danych




Źródło: opracowanie własne w R.

W przypadku oceny wpływu filtrowania produktów na wartości indeksu Carliego, widoczne są podobne korzyści jak ma to miejsce dla indeksu Jevonsa i indeksu Dutot. Efekty wpływu są jednak nieco mniej zauważalne, co wynika z mniej dynamicznego zachowania indeksu Carliego (spadek w omawianym okresie 08-09. 2018 wynosił dla indeksu Carliego ok. 7 pkt. proc., a

najniższy wynik indeksu w 05.2018 był na poziomie 0,86 w porównaniu do 0,8 dla indeksu Dutot i i 0,83 dla indeksu Jevonsa)


Wykres 27. Porównanie wyników filtrowania danych dla indeksu Carliego dla pełnego zestawu danych



Źródło: opracowanie własne w R.

Dla kategorii „Mokasyny”, filtracja danych wykazała podobne korzyści w przypadku ograniczenia nietypowego zachowania indeksu Jevonsa w okresie 08-09. 2018. Widoczna jest jednak wysoka różnica wyników między filtrem 3, który w ostatnim miesiącu analizy prowadzi do wysokiego wzrostu cen, a filtrem 4, który konsekwentnie dalej generuje trend spadkowy we wskazaniu indeksu cenowego Jevonsa. Ostateczna różnica wyników w ostatnim miesiącu analizy sięga ok 13 pkt. proc. (wykres 28).


Wykres 28. Porównanie wyników filtrowania danych dla indeksu Jevonsa dla kategorii Mokasyny



Źródło: opracowanie własne w R.


Wartości łańcuchowego indeksu Jevonsa, kalkulowane na podstawie danych niefiltrowanych oraz danych z wykorzystaniem filtrów 1 i 4, wykazują mało zauważalne różnice. Widoczne są natomiast różnice w przypadku efektów filtrów 2 i 3 – odcięcie 10% i 20% najbardziej zmiennych cen wpłynęło na pomiar dynamiki cen podwyższając wyraźnie wyniki indeksu łańcuchowego (wykres 29). Podobną sytuację można zauważyć w przypadku łańcuchowego indeksu Dutot (wykres 30) i łańcuchowego indeksu Carliego (wykres 31). A zatem, wpływ omawianych filtrów nie różnicuje w tej grupie produktów wskazań łańcuchowych indeksów nieważonych cen.

Wykres 29. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Jevonsa dla pełnego zestawu danych




Źródło: opracowanie własne w R.

Wykres 30. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Dutot dla pełnego zestawu danych



Źródło: opracowanie własne w R.


Wykres 31. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Carliego dla pełnego zestawu danych



Źródło: opracowanie własne w R.

Co istotne, wpływ różnego rodzaju filtrowania produktów jest podobny w przypadku danych na niższym poziomie agregacji. W tym przypadku, wpływ filtracji danych na różnice między indeksami jest jeszcze niższy niż analogiczny wpływ na indeksy cenowe wyznaczone dla mniej homogenicznych grup produktów (wykres 32).


Wykres 32. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Jevonsa dla kategorii Mokasyny



Źródło: opracowanie własne w R.


W przypadku indeksu GEKS-J wyniki uzyskane po przetworzeniu danych filtrowanych wykazują wyraźne wygładzenie, zwłaszcza w pierwszych miesiącach analizy (niwelując efekt wzrostu wskaźnika cen w okresie 12.2017-03.2018). Zjawisko to występuje dla wszystkich filtrów w przypadku indeksów liczonych na pełnych danych dla odzieży i obuwia (wykres 33). W homogenicznej grupie produktów, jaką są mokasyny, można zauważyć, że wyniki indeksu oparte na danych z użyciem filtra 1 pozostają w pierwszych miesiącach analizy bardziej zbliżone do wyników indeksów bez narzuconego filtra. Widoczne są także wysokie różnice między indeksem opartym na danych niepoddanych filtracji a indeksami obliczanymi dla danych filtrowanych w okresie 08.12-10.12. Warto zwrócić uwagę, że indeks obliczony na podstawie danych poddanych filtrowi 3 wyraźnie różnił się w kilku miesiącach analizy od pozostałych indeksów GEKS-J (wykres 34).

Wykres 33. Porównanie wyników filtrowania danych dla indeksu GEKS-J dla pełnego zestawu danych



Źródło: opracowanie własne w R.


Wykres 34. Porównanie wyników filtrowania danych dla indeksu GEKS-J dla kategorii Mokasyny



Źródło: opracowanie własne w R.

W przypadku nieważonego indeksu *Time Product Dummy* (UTPD) różnice między danymi odfiltrowanymi a danymi surowymi są nieco wyższe niż w przypadku indeksu GEKS-J. Podobnie jak dla indeksu GEKS-J można zaobserwować dużą różnicę dla wyników indeksu na podstawie danych poddanych filtrowi numer 3 (wykres 35).

Wykres 35. Porównanie wyników filtrowania danych dla nieważonego indeksu TPD dla kategorii Mokasyny



Źródło: opracowanie własne w R.

Metody filtrowania okazały się szczególnie istotne w przypadku indeksów jednopodstawowych – już pierwszy filtr percentylowy znacząco ograniczył zmienność wartości indeksów Jevonsa, Carliego i Dutot. Wyraźne różnice między wartościami indeksów opartych na danych filtrowanych i opartymi na danych niefiltrowanych można także zaobserwować w przypadku indeksów GEKS-J i UPD. Z kolei indeksy łańcuchowe wykazują stosunkowo niewielką wrażliwość na filtrację danych – zwłaszcza w przypadku filtrów 1 i 4. Warto zaznaczyć, że różnice między wartościami dla danych filtrowanych i danych niefiltrowanych były wyższe dla danych ogólnych niż dla homogenicznych grup towarów. Wyniki badania wskazują więc, że filtrowanie jest potrzebne w przypadku danych na niskim poziomie agregacji, a zastosowanie filtra 1 może w znaczący sposób poprawić wartości analizowanych indeksów i uodpornić je na wahania wynikające z wartości nietypowych nie wpływając w znaczący sposób na liczebność próby.



## 5. Zastosowanie danych skanowanych w pomiarze dynamiki cen

W poniższym rozdziale omówiono wyniki badań empirycznych porównujące wartości dla wybranych indeksów cen obliczonych na danych skanowanych. W pierwszym rozdziale przedstawiono charakterystykę pozyskanych danych i kroki potrzebne do ich przetworzenia tak, by można je było poddać dalszej analizie. Następnie omówiono wyniki analiz dla indeksów bilateralnych i multilateralnych używanych do szacowania dynamiki cen produktów skanowanych (podrozdział 2), wpływ poszczególnych metod rozszerzania okna obliczeń na wyniki indeksów multilateralnych (podrozdział 3) i wpływ metod filtracji danych na kompletność danych do analizy i wartości indeksów (podrozdział 4). W ostatnim, 5 podrozdziale omówiono wpływ metod agregacji danych na końcowe wyniki analizy.

### 5.1. Charakterystyka wykorzystanych zbiorów danych

Użyte w poniższym rozdziale dane pochodzą z dwóch źródeł. Zbiory „milk” i „coffee” dotyczą danych o sprzedaży produktów z kategorii mleko i kawa. Zbiory te są dostępne w pakiecie *PriceIndices* i właściwie nie wymagają wstępnego czyszczenia czy deduplikacji. Dane zbioru CPI (nazwane później – „owoce”) to dane pochodzące z publikacji *CPI Manual*<sup>148</sup>.

Dane te prezentowały się jak na rysunku 8:

Rysunek 8. Przykładowa ramka ze zbioru danych *Consumer Price Index Manual* przed przetworzeniem danych

	time	product	price	quantities	turnover
1	1	Lemons	5.41	0.370	2.00170
2	2	Lemons	4.99	0.701	3.49799
3	3	Lemons	5.14	0.661	3.39754
4	4	Lemons	5.08	0.689	3.50012
5	5	Lemons	5.19	0.751	3.89769
6	6	Lemons	5.66	0.724	4.09784
7	7	Lemons	7.40	0.595	4.40300
8	8	Lemons	10.62	0.452	4.80024
9	9	Lemons	9.27	0.647	5.99769
10	10	Lemons	8.15	0.724	5.90060
11	11	Lemons	7.30	0.712	5.19760
12	12	Lemons	6.78	0.678	4.59684

Źródło: opracowanie własne w R.

<sup>148</sup> IMF (2020), *Consumer Price Index Manual Concepts and Methods*, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms\\_761444.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms_761444.pdf) [dostęp: 19.04.2023].

Ze względu na wymogi pakietu *PriceIndices* wartościom „time” w przedziale od „1” do „72” przyporządkowano kolejne miesiące od 01.12.2014 r. do 01.11.2020 r. Usunięto także kolumnę „turnover” jako niepotrzebną do dalszych obliczeń. Dane po zakończeniu procesu przetwarzania prezentowały się jak na rysunku 9:

Rysunek 9. Przykładowa ramka ze zbioru danych *Consumer Price Index Manual* po przetworzeniu danych

	time	prices	quantities	prodID
1	2014-12-01	5.41	0.370	Lemons
2	2015-01-01	4.99	0.701	Lemons
3	2015-02-01	5.14	0.661	Lemons
4	2015-03-01	5.08	0.689	Lemons
5	2015-04-01	5.19	0.751	Lemons
6	2015-05-01	5.66	0.724	Lemons
7	2015-06-01	7.40	0.595	Lemons
8	2015-07-01	10.62	0.452	Lemons
9	2015-08-01	9.27	0.647	Lemons
10	2015-09-01	8.15	0.724	Lemons
11	2015-10-01	7.30	0.712	Lemons
12	2015-11-01	6.78	0.678	Lemons

Źródło: opracowanie własne w R.

Po procesie przetworzenia danych CPI (owoce) podstawowe informacje dotyczące wykorzystywanych zbiorów przedstawiały się jak w tabeli 23:

Tabela 23. Charakterystyka wykorzystanych zbiorów danych

Zbiór danych	Unikatowe produkty (ID)	Liczba okresów (długość okna w miesiącach)	Liczba sklepów
Milk	68	21	5
Coffee	79	36	20
CPI (owoce)	14	74	1

Źródło: opracowanie własne.

Za pomocą funkcji *matched\_index* w pakiecie *PriceIndices* dokonano obserwacji, ile unikatowych produktów z ostatniego i pierwszego okresu analizy dla każdego zestawu danych powtarza się w obu analizowanych okresach. Uzyskano także informację o produktach nowych w okresie ostatnim i produktach znikających (funkcja *product* z pakietu *PriceIndices*). W każdym z przypadków większość lub wszystkie produkty dostępne w pierwszym okresie

analizy były także dostępne w ostatnim okresie analizy (tabela 24). Jest to istotna różnica w stosunku do analizowanych w poprzednim rozdziale danych o odzieży, gdzie odsetek ten wynosił 2-3%.


Tabela 24. Powtarzalność produktów dla analizowanych zestawów danych

	Kawa	Mleko	Owoce
Produkty dostępne w obu okresach	68	44	7
Nowe produkty	6	9	0
Znikające produkty	4	9	0

Źródło: opracowanie własne w R.


Powtarzalność produktów z okresu na okres w całości analizy dla kawy przedstawia się na nieco niższym poziomie (70%, wykres 36) niż dla porównania między pierwszym i ostatnim okresem. Podobnie w przypadku danych dla mleka (ok. 63%, wykres 37). Natomiast w przypadku danych z CPI Manual dotyczących owoców można zaobserwować bardzo wysoką sezonowość. Z 7 produktów jedynie 1 dostępny był całorocznie (wykres 38).

Wykres 36. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Wykres 37. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Wykres 38. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.


## 5.2. Porównanie indeksów bilateralnych i multilateralnych

W przeciwieństwie do danych skrapowanych, w przypadku danych skanowanych istnieje znacznie szerszy zakres indeksów bilateralnych, które mogą znaleźć zastosowanie, co wynika z dostępności danych o konsumpcji, a nie wyłącznie o cenach. Do analizy wybrano indeksy o ugruntowanej pozycji w literaturze: indeksy Fishera, Laspeyresa, Paascheego, Törnqvista i Walsha. Wykorzystano też zyskujący na popularności indeks Sato-Vartia, który

zaprojektowany został w celu spełnienia testu odwracalności w czasie (co sprawia, że może być alternatywą dla indeksu Fishera)<sup>149</sup>. Dodatkowo dla celów porównawczych w analizie uwzględniono indeks Jevonsa.

W przypadku cen mleka można zauważyć znaczące różnice w zachowaniu indeksu Jevonsa i pozostałych indeksów. Indeks Laspeyresa wykazuje wyższe wartości w stosunku do indeksu Fishera, co jest zgodne z nierównością Bortkiewicza<sup>150</sup> i obserwowaną ujemną korelacją cen i ilości. W porównaniu do indeksu Fishera zgodnie z wyznacznikami literatury indeks Laspeyresa wykazuje wartości wyższe średnio o 1,44 pkt. proc., a indeks Paaschego wartości średnio o 1,41 pkt. proc. niższe (wykres 39). Indeksy Törnqvista, Walsha i Sato-Vartia wykazują bardzo podobne wartości do indeksu Fishera (różnice znacząco poniżej 1 pkt. proc. – najniższa średnia różnica w przypadku indeksu Törnqvista – 0,05 pkt. proc.) co jest zgodne wobec wzajemnej aproksymacji indeksów superlatywnych<sup>151</sup>.

Wykres 39. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.


<sup>149</sup> Abe, N. (2019), Multilateral Sato-Vartia Index for International Comparisons of Prices and Real Expenditures, "RCESR Discussion Paper Series", No. DP19-1.

<sup>150</sup> von der Lippe, Peter (2012), Covariances and relationships between price indices: Notes on a theorem of Ladislaus von Bortkiewicz on linear index functions, <https://mpra.ub.uni-muenchen.de/38566/> [dostęp: 19.04.2023].

<sup>151</sup> Diewert, W. (1976), Exact and superlative index numbers, "Journal of Econometrics", No. 4, issue 2, s. 115-145, <https://EconPapers.repec.org/RePEc:eee:econom:v:4:y:1976:i:2:p:115-145> [dostęp: 19.04.2023].

Wysokie różnice między indeksami bilateralnymi widoczne są także w przypadku zbioru danych o cenach i sprzedanych ilości kawy. W tym wypadku jednak indeks Jevonsa wykazuje bardziej zbliżone tendencje do indeksu Fishera niż w przypadku danych o konsumpcji mleka. Podobnie jak w przypadku poprzedniego zbioru danych, indeksy Törnqvista, Walsha i Sato-Vartia charakteryzują się niewielkimi odchyleniami od wartości indeksu Fishera – odpowiednio różnice te wynoszą: 0,19; 0,4 i 0,29 pkt. proc. (wykres 40).


Wykres 40. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

W przypadku indeksów cen dotyczących owoców można zaobserwować znacznie wyraźniejsze wahania wartości, wynikające z sezonowości tego typu produktów niż w przypadku mleka i kawy. Zachowanie indeksu Jevonsa pozostaje znacznie bardziej zbliżone do reszty indeksów niż w przypadku pozostałych zbiorów danych. Mimo znacznie wyższych wahań wartości indeksu średnie odchylenie wartości indeksu Jevonsa od indeksu Fishera wynosi niespełna 7 pkt. proc. Podobnie jak w przypadku poprzednich 2 zbiorów danych, najmniejsza średnia absolutna różnica w stosunku do indeksu Fishera jest obserwowana w przypadku indeksu Törnqvista (wykres 41).


Wykres 41. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.

W przypadku indeksów łańcuchowych można zauważyć wyraźne tendencje łańcuchowych indeksów Laspeyresa i Pascheego do dryfu łańcuchowego. W przypadku pozostałych indeksów, a w szczególności w przypadku łańcuchowego indeksu Jevonsa, zaobserwowano względną stabilność wartości. Podobnie jak w przypadku indeksów jednopodstawowych najmniejszą różnicą w stosunku do łańcuchowej wersji indeksu Jevonsa wykazuje indeks Törnqvista (0,06 pkt. proc., wykres 42).


Wykres 42. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla zbioru danych kawy można zauważyć wyraźny wzrost występowania zjawiska dryfu łańcuchowego dla indeksów Paschego i Laspeyresa (wykres 43). W przypadku łańcuchowego indeksu Laspeyresa wartości po 36 okresach (3 latach) wykazują wzrost o 500 pkt. proc. Większe są też różnice w przypadku pozostałych indeksów. Łańcuchowy indeks Walsha średnio różni się od łańcuchowego indeksu Fishera o 1,3 pkt. proc., co jest wynikiem wyższym od analogicznego wyniku uzyskanego dla łańcuchowego indeksu Sato-Vartia (0,89 pkt. proc.) i łańcuchowego indeksu Törnqvista (0,32 pkt. proc.).

Wykres 43. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Wartości indeksów łańcuchowych wyznaczone dla zbioru „owoce” wyraźnie wskazują na sezonowość – podobnie jak w przypadku indeksów jednopodstawowych (wykres 44). Co istotne, dla tego zbioru danych różnica między indeksem Fishera a indeksem Törnqvista jest wielokrotnie niższa (0,2 pkt. proc.) niż łańcuchowych indeksów Sato-Vartia (0,74 pkt. proc.) i Walsha (0,99 pkt. proc.).



Wykres 44. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

W tym podrozdziale autor zdecydował się także na porównanie indeksu GEKS-J z najpopularniejszymi indeksami multilateralnymi używanymi do kalkulacji indeksów opartych na danych skanowanych – GEKS-L (GEKS-Laspeyres), GEKS-GL (GEKS-Geometric Laspeyres), CCDI (znany także jako GEKS-Törnqvist), GEKS-AQU, GEKS-AQI, Time Product Dummy, Geary-Khamis i SPQ (indeksy te zostały szerzej omówione w rozdziale 3).

W przypadku danych dla mleka poszczególne indeksy wykazują podobne tendencję w analizowanym okresie. Indeks GEKS-J dla w istotny sposób różni się od indeksów multilateralnych opartych na formułach ważonych – średnio o od 2,9 pkt. proc. (od indeksu TDP i Geary’ego-Khamisa) do 3,4 pkt. proc. (GEKS-L, GEKS-GL, GEKS-AQU, GEKS-AQI). Wyniki pozostałych indeksów pozostają stosunkowo zbliżone do siebie (średnia różnica poniżej 1 pkt. proc., wykres 45, tabela 25).

Wykres 45. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.


Tabela 25. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży kawy (w pkt proc)

	GEKS-J	GEKS-L	GEKS-GL	GEKS-AQU	GEKS-AQI	SPQ	CCDI	TPD	GK
GEKS-J	0	3,378	3,388	3,370	3,381	2,958	3,088	2,855	2,892
GEKS-L	3,378	0	0,065	0,008	0,007	0,610	0,458	0,787	0,876
GEKS-GL	3,388	0,065	0	0,060	0,066	0,580	0,403	0,729	0,818
GEKS-AQU	3,370	0,008	0,060	0	0,013	0,605	0,454	0,783	0,872
GEKS-AQI	3,381	0,007	0,066	0,013	0	0,611	0,458	0,786	0,875
SPQ	2,958	0,610	0,580	0,605	0,611	0	0,257	0,292	0,328
CCDI	3,088	0,458	0,403	0,454	0,458	0,257	0	0,329	0,418
TPD	2,855	0,787	0,729	0,783	0,786	0,292	0,329	0	0,092
GK	2,892	0,876	0,818	0,872	0,875	0,328	0,418	0,092	0

Źródło: opracowanie własne w R.

W przypadku wyników indeksów dla mleka różnice między indeksem GEKS-J a pozostałymi indeksami wahają się od 1,6 pkt. proc. do 1,9 pkt. proc. Stosunkowo zbliżone wyniki można zaobserwować między indeksami GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI (średnia różnica poniżej 0,5 pkt. proc.) – zwłaszcza w przypadku indeksów GEKS-AQU i GEKS-AQI, które różnią się jedynie o 0,02 pkt. proc. Zbliżonymi wartościami (różnica ok 0,26 pkt. proc.) charakteryzują się indeksy TDP i Geary’ego-Khamisa (wykres 46, tabela 26).

Wykres 46. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.


Tabela 26. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży mleka (w pkt proc)

	GEKS-J	GEKS-L	GEKS-GL	GEKS-AQU	GEKS-AQI	SPQ	CCDI	TPD	GK
GEKS-J	0	1,768	1,630	1,769	1,755	1,738	1,607	1,874	1,825
GEKS-L	1,768	0	0,483	0,023	0,023	1,135	0,665	1,240	1,357
GEKS-GL	1,630	0,483	0	0,495	0,488	0,914	0,612	1,244	1,225
GEKS-AQU	1,769	0,023	0,495	0	0,023	1,144	0,672	1,240	1,361
GEKS-AQI	1,755	0,023	0,488	0,023	0	1,137	0,665	1,233	1,353
SPQ	1,738	1,135	0,914	1,144	1,137	0	0,618	0,730	0,660
CCDI	1,607	0,665	0,612	0,672	0,665	0,618	0	0,693	0,724
TPD	1,874	1,240	1,244	1,240	1,233	0,730	0,693	0	0,264
GK	1,825	1,357	1,225	1,361	1,353	0,660	0,724	0,264	0

Źródło: opracowanie własne w R.

Znacznie większe różnice można zaobserwować dla wyników indeksów multilateralnych dla danych o owocach (wykres 47). Różnica między indeksem GEKS-J a innymi indeksami multilateralnymi wynosi od 6 pkt. proc. (GEKS-AQU) do 14 pkt. proc. (SPQ). Bardzo wysokie różnice w porównaniu do innych indeksów wykazuje indeks SPQ (od 12,2 pkt. proc. dla indeksu GEKS-AQU do 19,5 pkt. proc. dla indeksu GEKS-L). Może to wynikać z różnicy idei indeksu SPQ, który w przeciwieństwie do pozostałych indeksów nie działa na oknie czasowym wykorzystując odległość cenowo-ilościową.

Wykres 47. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.

Tabela 27. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży owoców (w pkt proc)

	GEKS-J	GEKS-L	GEKS-GL	GEKS-AQU	GEKS-AQI	SPQ	CCDI	TPD	GK
GEKS-J	0	7,619	7,223	6,001	7,066	14,076	6,691	9,957	9,627
GEKS-L	7,619	0	0,723	8,839	0,713	19,587	1,856	9,418	9,452
GEKS-GL	7,223	0,723	0	8,488	0,832	19,073	1,389	9,370	9,352
GEKS-AQU	6,001	8,839	8,488	0	8,473	12,225	7,836	8,964	9,063
GEKS-AQI	7,066	0,713	0,832	8,473	0	19,176	1,586	9,035	9,040
SPQ	14,076	19,587	19,073	12,225	19,176	0	18,43	14,574	14,409
CCDI	6,691	1,856	1,389	7,836	1,586	18,430	0	8,423	8,345
TPD	9,957	9,418	9,370	8,964	9,035	14,574	8,423	0	0,592
GK	9,627	9,452	9,352	9,063	9,040	14,409	8,345	0,592	0

Źródło: opracowanie własne w R.

### 5.3. Analiza metod rozszerzeń indeksów multilateralnych

W poniższym rozdziale oceniono metody rozszerzania okna dla 3 zbiorów danych – kawy, mleka i owoców. Ze względu na zbyt krótki szereg czasowych danych dla mleka w analizie indeksów obliczanych na tym zbiorze pominięto metodę *Fixed Based Moving Window* (FBMW).

W przypadku indeksu GEKS-J można zaobserwować duże różnice między indeksem nierozszerzonym a indeksami, przy kalkulacji których wykorzystano metody rozszerzenia okna

obliczeń. Dla każdego z 3 zbiorów danych w tym przypadku największą różnicą w stosunku do nierozszerzonego indeksu charakteryzuje się indeks rozszerzony metodą FBEW. W dwóch z trzech przypadków indesem, która wykazywała najmniejsze różnice w porównaniu do nierozszerzonego indeksu był indeks rozszerzony metodą *mean splice* (tabela 28).

Tabela 28. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-J dla poszczególnych zestawów danych (w pkt. proc.)

Metoda rozszerzenia okna	Kawa	Owoce	Mleko
window splice	0,683	1,102	0,234
half splice	1,017	1,161	0,278
movement splice	0,787	1,079	0,237
mean splice	0,898	1,016	0,222
GEKS-J	0	0	0
FBEW	1,084	3,078	0,379
FBMW	0,842	1,293	x

Źródło: opracowanie własne w R.

Dla indeksu GEKS-L, podobnie jak dla indeksu GEKS-J, dla wszystkich 3 zbiorów danych największą różnicą w stosunku do wartości nierozszerzonego indeksu odznaczał się indeks rozszerzony metodą FBEW. Wyniki indeksów rozszerzonych metodami *window*, *half*, *movement* i *mean splice* wykazują z kolei dość zbliżone wartości odchylenia od nierozszerzonej wersji indeksu (tabela 29).

Tabela 29. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-L dla poszczególnych zestawów danych (w pkt. proc.)

Metoda rozszerzenia okna	Kawa	Owoce	Mleko
window splice	0,290	1,433	0,103
half splice	0,255	1,321	0,168
movement splice	0,472	1,589	0,096
mean splice	0,351	1,194	0,129
GEKS-L	0	0	0
FBEW	0,514	3,382	0,274
FBMW	0,417	2,079	x

Źródło: opracowanie własne w R.

Tak jak w poprzednich 2 przypadkach indeks rozszerzony metodą FBEW generował największe różnice w stosunku do indeksu nierozszerzonego dla wszystkich 3 zbiorów danych (tabela 30).

Tabela 30. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-GL dla poszczególnych zestawów danych (w pkt. proc.)

<b>Metoda rozszerzenia okna</b>	<b>Kawa</b>	<b>Owoce</b>	<b>Mleko</b>
window splice	0,290	1,372	0,097
half splice	0,264	1,248	0,149
movement splice	0,507	1,538	0,079
mean splice	0,334	1,136	0,110
GEKS-GL	0	0	0
FBEW	0,442	3,120	0,256
FBMW	0,400	1,701	x

Źródło: opracowanie własne w R.

Dla indeksu GEKS-AQI sytuacja przedstawia się w sposób analogiczny do poprzednich indeksów. Różnice wartości indeksu rozszerzonego metodą FBEW w stosunku do indeksu nierozszerzonego są nawet 3-krotnie wyższe niż w przypadku innych metod rozszerzenia indeksu (tabela 31).

Tabela 31. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-AQI dla poszczególnych zestawów danych (w pkt. proc.)

<b>Metoda rozszerzenia okna</b>	<b>Kawa</b>	<b>Owoce</b>	<b>Mleko</b>
window splice	0,296	1,317	0,105
half splice	0,266	1,323	0,168
movement splice	0,472	1,495	0,099
mean splice	0,379	1,135	0,132
GEKS-AQI	0	0	0
FBEW	0,564	3,596	0,277
FBMW	0,431	2,183	x

Źródło: opracowanie własne w R.

Dla indeksu GEKS-AQU różnice w stosunku do wartości generowanych przez indeks niepotraktowany żadną metodą rozszerzenia okna, są dla wszystkich indeksów podobne jak w przypadku indeksu GEKS-AQI. Tak jak w poprzednich indeksach dla wszystkich 3 zbiorów danych indeks rozszerzony metodą FBEW wykazywał największe różnice w stosunku do nierozszerzonej wersji indeksu (tabela 32).

Tabela 32. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-AQU dla poszczególnych zestawów danych (w pkt. proc.)

<b>Metoda rozszerzenia okna</b>	<b>Kawa</b>	<b>Owoce</b>	<b>Mleko</b>
window splice	0,289	1,003	0,103
half splice	0,245	1,441	0,17
movement splice	0,453	0,98	0,098
mean splice	0,335	0,919	0,131
GEKS-AQU	0	0	0
FBEW	0,502	3,386	0,277
FBMW	0,407	2,261	x

Źródło: opracowanie własne w R.

Analogicznie jak w poprzednich przypadkach prezentują się wyniki dla indeksu CCDI. Dla każdego z 3 zbiorów danych indeks rozszerzony metodą FBEW wykazuje największe różnice w stosunku do nierozszerzonej wersji (tabela 33).

Tabela 33. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu CCDI dla poszczególnych zestawów danych (w pkt. proc.)

<b>Metoda rozszerzenia okna</b>	<b>Kawa</b>	<b>Owoce</b>	<b>Mleko</b>
window splice	0,158	1,475	0,061
half splice	0,496	1,386	0,093
movement splice	0,216	1,709	0,059
mean splice	0,316	1,325	0,075
CCDI	0	0	0
FBEW	0,559	3,918	0,147
FBMW	0,412	1,519	x

Źródło: opracowanie własne w R.

Dla indeksu Geary'ego-Khamisa także indeks rozszerzony metodą FBEW wykazuje największe różnice w stosunku do nierozszerzonej wersji indeksu. Dla każdego z 3 zbiorów danych indeks rozszerzony metodą *mean splice* dawał wyniki najbliższe nierozszerzonej wersji indeksu Geary'ego-Khamisa (tabela 34).

Tabela 34. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu Gearego-Khamisa dla poszczególnych zestawów danych (w pkt. proc.)

Metoda rozszerzenia okna	Kawa	Owoce	Mleko
window splice	0,250	2,277	0,156
half splice	0,502	2,554	0,136
movement splice	0,245	2,79	0,146
mean splice	0,243	1,977	0,130
Geary-Khamis	0	0	0
FBEW	0,887	5,966	0,380
FBMW	0,471	2,632	x

Źródło: opracowanie własne w R.

Tak samo jak dla poprzednich indeksów indeks rozszerzony metodą FBEW wykazuje znaczące różnice w stosunku do pozostałych metod rozszerzania indeksów (tabela 35).

Tabela 35. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu TPD dla poszczególnych zestawów danych (w pkt. proc.)

Metoda rozszerzenia okna	Kawa	Owoce	Mleko
window splice	0,260	1,985	0,154
half splice	0,503	2,523	0,134
movement splice	0,219	2,761	0,150
mean splice	0,231	2,025	0,118
TPD	0	0	0
FBEW	0,775	6,021	0,297
FBMW	0,426	2,701	x

Źródło: opracowanie własne w R.

Dla każdego z analizowanych indeksów na każdym z 3 zbiorów danych wyniki dla metod rozszerzenia indeksu wykazywały podobne tendencje. Najbardziej zauważalne są znaczne różnice wartości indeksów rozszerzanych metodą FBEW w stosunku do indeksów rozszerzanych pozostałymi metodami. Indeksy rozszerzane metodami *mean splice*, *half splice*, *movement splice* i *window splice* wykazują wyniki stosunkowo zbliżone do siebie. Dla większości analizowanych przypadków indeksy rozszerzane metodą FBMW charakteryzują się wyższymi różnicami od indeksów w wersjach nierozszerzanych niż indeksy rozszerzane metodami splice. Mimo to wyniki indeksów rozszerzonych metodą FBMW wykazują mniejsze różnice w stosunku do wartości indeksów rozszerzanych metodami splice niż rozszerzanych metodą FBEW. Dokładniejsze tabele wyników (uwzględniające semi-indeksy powyżej i poniżej wartości indeksu referencyjnego) i wykresy zostały umieszczone w aneksie.



#### 5.4. Ocena wpływu filtrowania na końcowy wskaźnik cen

W przypadkach analiz indeksów cen, nietypowe wartości (tzw. outliery) mogą mieć negatywny wpływ na analizę (np. zawyżając lub zaniżając ostateczny wynik). W celu sprawdzenia jak wysoki wpływ na wartości omawianych indeksów mogły mieć wartości nietypowe, dane poddano działaniom 4 filtrów:

- filtr 1 – usunięcie produktów o najmniejszej i największej zmianie cen (1 i 99 percentyl zmiany ceny);
- filtr 2 – usunięcie produktów, których cena spadła poniżej 50% pierwotnej wartości lub wzrosła bardziej niż dwukrotnie;
- filtr 3 – usunięcie produktów których sprzedana liczba z miesiąca na miesiąc spada 4-krotnie lub rośnie ponad 2-krotnie;
- filtr 4 – połączenie filtru 1 i 3 oraz filtra, który odcina produkty dla których 2-krotnie spadła lub wzrosła wartość sprzedaży.

W przypadku mleka, filtry 1 i 2 wykazują niewielkie obniżenie liczby dostępnych produktów dla dwóch skrajnych okresów analizy. Z kolei filtry 3 i 4 obcinają liczbę produktów dostępnych do analizy blisko 3-krotnie, czyli z 44 produktów do zaledwie 16 (tabela 36).

Tabela 36. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla mleka

	Bez filtra	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty	62	60	60	18	18
Produkty dostępne w obu okresach	44	41	43	16	16
Nowe produkty	9	10	10	1	1
Znikające produkty	9	9	7	1	1
Liczba rekordów	4386	4218	4251	1747	1737

Źródło: opracowanie własne w R.

Podobną zależność można zauważyć w przypadku danych o sprzedaży kawy. Obniżenie liczby produktów dostępnych do analizy w obu okresach dla filtra 3 i 4 spada z 68 do 22 produktów (tabela 37).

Tabela 37. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla kawy

	Bez filtra	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty	78	77	78	36	35
Produkty dostępne w obu okresach	68	60	63	22	22
Nowe produkty	6	8	7	9	8
Znikające produkty	4	9	8	5	5
Liczba rekordów	42561	42182	42471	21833	21435

Źródło: opracowanie własne w R.

Duże obniżenie liczby dostępnych produktów dla filtrów 1, 3 i 4 można zauważyć dla danych o owocach (tabela 38). Co znaczące – w tym przypadku ze względu na wysoką sezonowość produktów odcięcie części produktów spowodowało uniemożliwienie policzenia indeksów cen – w przypadku niektórych miesięcy brakuje produktów które powtarzałyby się w analizowanej grupie miesiąc do miesiąca. W efekcie w poniższym rozdziale omawiane są wyniki jedynie dla zbiorów kawy i mleka (wykresy dla danych o owocach dla filtrów 1 i 2 zostały zamieszczone w aneksie)<sup>152</sup>.

Tabela 38. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla owoców


	Bez filtra	Filtr 1	Filtr 2	Filtr 3	Filtr 4
Wszystkie produkty	7	7	7	4	4
Produkty dostępne w obu okresach	7	5	7	4	3
Nowe produkty	0	9	0	0	0
Znikające produkty	0	2	0	0	1
Liczba rekordów	557	383	460	266	213

Źródło: opracowanie własne w R.

Dla indeksu Fishera różnice widoczne są zwłaszcza w przypadku danych poddanych filtrowi 4. Wyniki dla mleka wykazują duże różnice w stosunku pozostałych wyników, zwłaszcza w okresach wzrostów cen (nawet 5 pkt. proc., wykres 49). Pewne różnice od pozostałych indeksów wykazuje też filtr 1 choć są one znacznie mniejsze (maksymalnie ok. 1 pkt. proc.).

<sup>152</sup> Ze względu na wysoki odsetek braków danych zrezygnowano z imputacji danych ze względu na możliwość dużego obciążenia wyników.


Wykres 48. Porównanie metod filtrowania dla indeksu Fishera wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Z kolei dla zbioru danych dotyczących sprzedaży mleka, indeks oparty o dane poddane działaniu filtra 4 wykazuje największe różnice w stosunku do indeksu opartego na danych niefiltrowanych w okresach spadku cen (ok 1,5 pkt. proc.). Nie jest jednak jedynym wykazującym duże różnice. W okresie od 12-2019 do 02-2020 najniższymi wartościami charakteryzuje się indeksy obliczone na danych poddanych filtrowi 3 (wykres 50).


Wykres 49. Porównanie metod filtrowania dla indeksu Fishera wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku indeksu Jevonsa, różnice jakie otrzymano dla różnych wariantów filtru są znacznie większe, aniżeli analogiczne różnice uzyskane w przypadku indeksu Fishera, co może wskazywać na większą wrażliwość indeksów nieważonych na filtrowanie (wykres 51). Różnice widoczne są zwłaszcza w przypadku wartości indeksu opartego o dane z zastosowanym filtrem 4 (nawet blisko 10 pkt. proc.), ale można zauważyć też wysokie różnice wartości indeksów z narzuconym filtrem 2 i 3 w stosunku do wyników na danych bez filtrów (3-4 pkt. proc.).


Wykres 50. Porównanie metod filtrowania dla indeksu Jevonsa wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

W przypadku indeksu Jevonsa dla zbioru danych dotyczącego sprzedaży mleka różnice między indeksami także są widoczne, choć nieco niższe niż w przypadku kawy (do ok 5 pkt. proc., wykres 52).


Wykres 51. Porównanie metod filtrowania dla indeksu Jevonsa wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla indeksu Laspeyresa wyniki wszystkich formuł opartych na danych filtrowanych poza filtrem 4 wykazują wartości wysoce zbliżone do danych nie poddanych filtracji. Różnice dla indeksu opartego o dane z zastosowaniem filtra 4 w stosunku do reszty sięgają ok 5 pkt. proc. (wykres 53).


Wykres 52. Porównanie metod filtrowania dla indeksu Laspeyresa wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Wyniki dla indeksu Laspeyresa dla danych dotyczących sprzedaży mleka wykazują zauważalne różnice między poszczególnymi metodami filtrowania. Warto jednak zwrócić uwagę, że różnice te, także dla wyników indeksu z zastosowaniem filtra 4, wynoszą maksymalnie ok 1 pkt. proc. (wykres 54).


Wykres 53. Porównanie metod filtrowania dla indeksu Laspeyresa wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Indeks Paaschego wykazuje się także dość wysokim zróżnicowaniem wyników dla poszczególnych metod filtracji danych. Największe różnice w stosunku do indeksu niefiltrowanego można zauważyć w przypadku indeksów opartych o dane z zastosowaniem filtra 1 i 4 (wykres 55).


Wykres 54. Porównanie metod filtrowania dla indeksu Paaschego wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku indeksu Sato-Vartia, podobnie jak w przypadku części z poprzednio analizowanych przypadków indeksów cen, wszystkie indeksy poza indeksem z zastosowanym filtrem 4 wykazują stosunkowo zbliżone wyniki. Różnice dla wartości indeksu obliczonego z zastosowaniem filtra 4 wynoszą nawet powyżej 5 pkt. proc. w porównaniu do innych wartości (wykres 56).


Wykres 55. Porównanie metod filtrowania dla indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Dla danych o mleku metody filtrowania wykazują zróżnicowanie sięgające 4 pkt. proc. Co istotne, w tym przypadku wyniki oparte o filtr 4 wykazuje niższe różnice niż w przypadku kawy i przez większość okresów charakteryzuje się stosunkowo zbliżonymi wartościami do reszty indeksów (wykres 57).

Wykres 56. Porównanie metod filtrowania dla indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Dla indeksu Törnqvista większość filtrów wykazuje zbliżone wartości do danych niepoddanych filtracji (wykres 58). Podobnie jak dotychczas, największą fluktuację wartości indeksów obserwujemy po zastosowaniu filtra 4 (do ok .4 pkt. proc.)




Wykres 57. Porównanie metod filtrowania dla indeksu Törnqvista wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Wyniki dla indeksu Törnqvista dla danych dotyczących sprzedaży mleka, podobnie jak w przypadku indeksu Sato-Vartia, wykazują niższe różnice. Największą różnicę między indeksami można zaobserwować w styczniu 2020 r. – sięgała ona blisko 3 pkt. proc. między wynikami dla indeksu policzonego na bazie danych z użyciem filtra 3 a wynikami dla indeksu policzonego na bazie danych z użyciem filtra 1 (wykres 59).


Wykres 58. Porównanie metod filtrowania dla indeksu Törnqvista wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku indeksu Walsha wyniki, podobnie jak w przypadku poprzednich indeksów jednopodstawowych, charakteryzują się zbliżonymi wartościami poza indeksem z zastosowanym filtrem 4 (wykres 60).


Wykres 59. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Wyniki indeksu Walsha dla danych dotyczących sprzedaży kawy ponownie wykazują najwyższe różnice w styczniu 2020 r. (niecałe 3 pkt. proc.) między danymi z zastosowanym filtrem 3 a filtrem 1 (wykres 61).


Wykres 60. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla łańcuchowego indeksu Fishera różnice pomiędzy poszczególnymi wynikami indeksów poddanych poszczególnym filtrom wynoszą nawet 10 pkt. proc. Dla większości okresów najniższe wyniki uzyskiwano dla indeksu obliczonego w oparciu o dane z zastosowaniem filtra 4, a najwyższe – dla indeksu w oparciu o filtr 3. Jedynie wyniki dla indeksu z zastosowaniem filtra 2 wykazują bardzo duże podobieństwo do wyników indeksu nie poddanego filtracji (wykres 62). Wyższe różnice niż w przypadku indeksów bilateralnych wskazują, że mogą być one bardziej podatne na nawet niewielkie zmiany próby niż indeksy bilateralne


Wykres 61. Porównanie metod filtrowania dla łańcuchowego indeksu Fishera wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

W przypadku danych o mleku zróżnicowanie wartości indeksów poddanych filtracji jest ponad 3-krotnie mniejsze i sięga maksymalnie 3 pkt. proc. (wykres 63).


Wykres 62. Porównanie metod filtrowania dla łańcuchowego indeksu Fishera wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku łańcuchowego indeksu Jevonsa największą różnicą w stosunku do reszty wyników charakteryzował się indeks oparty o filtr 3. Widoczne jest to zwłaszcza w okresie od października 2010 r., w którym różnice między indeksami z zastosowaniem filtra 3 i filtra 4 wynoszą 6-7 pkt. proc., a między indeksem z zastosowanym filtrem 3 a danymi niepoddanymi filtracji – nawet 12-13 pkt. proc. (wykres 64).


Wykres 63. Porównanie metod filtrowania dla łańcuchowego indeksu Jevonsa wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Łańcuchowy indeks Jevonsa dla danych o sprzedaży mleka także wykazuje wysokie różnice wyników w zależności od stosowanej metody filtracji. Co interesujące, tym razem to indeks oparty o filtr 2 wykazuje największe różnice w porównaniu do indeksu obliczonego na bazie danych niefiltrowanych (do ok. 5 pkt. proc.) i jako jedyny pokazuje wartości spadkowe w pierwszych miesiącach analizy (wykres 65).


Wykres 64. Porównanie metod filtrowania dla łańcuchowego indeksu Jevonsa wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla indeksu Laspeyresa różnice, które generują poszczególne metody filtrowania są bardzo wysokie. W ostatnim okresie analizy indeks policzony w oparciu o dane z filtrem 3 wykazuje blisko wartości dwukrotnie wyższe niż indeks nie poddany filtracji. Widoczny jest tu też bardzo wyraźny efekt dryfu łańcuchowego (wykres 66).


Wykres 65. Porównanie metod filtrowania dla łańcuchowego indeksu Laspeyresa wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

W przypadku łańcuchowego indeksu Laspeyresa dla danych dotyczących sprzedaży mleka różnice te są znacząco niższe, jednak nadal pozostają wysokie – indeksy dla filtra 3 w ostatnim okresie analizy wykazują wyniki wyższe o ok. 5 pkt .proc. od danych niefiltrowanych i ok.. 8 pkt proc. wyższe niż dla indeksów z użyciem filtra 1. Co interesujące, w tym przypadku wartości najbardziej zbliżone dla danych niefiltrowanych uzyskano dla indeksów z użyciem filtra 3 (wykres 67).


Wykres 66. Porównanie metod filtrowania dla łańcuchowego indeksu Laspeyresa wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla łańcuchowego indeksu Sato-Vartia największe różnice w stosunku do danych niefiltrowanych wykazują indeksy oparte o filtry 3 i 4. Oba w ostatnim miesiącu analizy wykazują różnice w stosunku do wyników indeksu nie poddanego filtracji o ok. 3 pkt. proc. Duża zbieżność z wynikami dla danych niefiltrowanych wykazuje indeks oparty o filtr 2 (wykres 68).


Wykres 67. Porównanie metod filtrowania dla łańcuchowego indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Łańcuchowy indeks Sato-Vartia dla mleka wykazuje podobnie jak indeksy jednopodstawowe wysokie różnice wartości zwłaszcza w styczniu 2020 r. – między indeksami z zastosowanymi filtrami 3 i 1 sięgają w tym okresie blisko 3 pkt. proc. (wykres 69).


Wykres 68. Porównanie metod filtrowania dla łańcuchowego indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla łańcuchowego indeksu Törnqvista, podobnie jak w przypadku indeksu Sato-Vartia dla danych o sprzedaży kawy, najwyższe różnice w stosunku do indeksu niefiltrowanego wykazuje indeks z narzuconymi filtrami 3 i 4. Oba filtry w ostatnim okresie różnią się od wyniku dla danych niefiltrowanych o niespełna 4 pkt. proc. Ponownie najbliższe wartości do wyników opartych o dane niefiltrowane wykazuje indeks oparty o filtr 2 (wykres 70).

Wykres 69. Porównanie metod filtrowania dla łańcuchowego indeksu Törnqvista wyznaczonego dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.



Łańcuchowy indeks Törnqvista wykazuje wartości bardzo zbliżone do wartości łańcuchowego indeksu Sato-Vartia (wykres 71).


Wykres 70. Porównanie metod filtrowania dla łańcuchowego indeksu Törnqvista wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Łańcuchowy indeks Walsha dla kawy wykazuje podobne tendencje jak w przypadku łańcuchowych indeksów Sato-Vartia i Törnqvista – ponownie najwyższe różnice w stosunku do indeksu opartego na danych niefiltrowanych wykazują indeksy z zastosowaniem filtrów 3 i 4 (wykres 72).

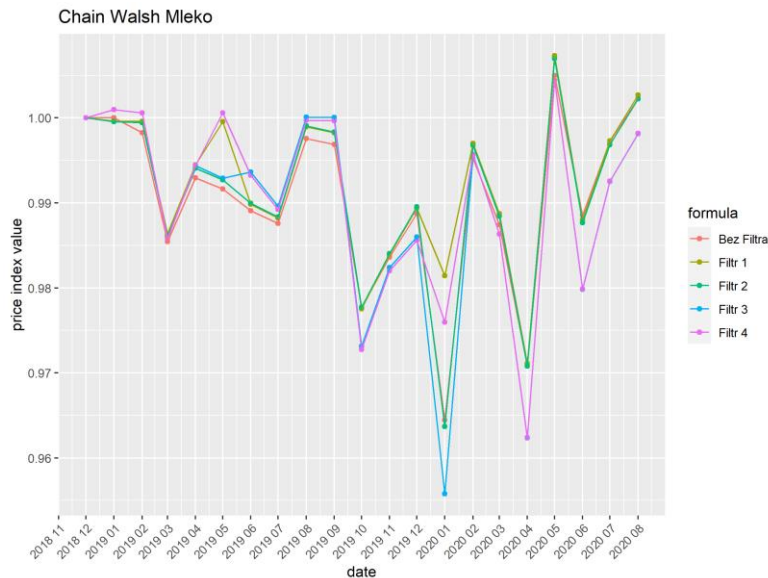
Wykres 71. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Wyniki łańcuchowego indeksu Walsha dla danych o sprzedaży mleka wykazują podobne tendencje w zależności od zastosowanego filtra jak wersje łańcuchowe indeksów Törnqvista i Sato-Vartia (wykres 73).


Wykres 72. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku indeksu CCDI dla kawy najwyższymi różnicami w stosunku do wersji niefiltrowanej charakteryzują się indeksy oparte o filtry 3 i 4 (do ok. 4 pkt. proc.). W przeciwieństwie do indeksów łańcuchowych indeksy te wykazują bardzo zbliżone wyniki w stosunku do siebie (wykres 74).


Wykres 73. Porównanie metod filtrowania dla indeksu CCDI wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Podobną tendencję można zaobserwować w przypadku indeksu CCDI dla danych o sprzedaży mleka. Przez część analizowanych okresów wyniki dla indeksu 3 i 4 wykazują wysoce zbliżone do siebie wartości. Jednak w niektórych okresach (np. styczeń 2020) różnica między nimi znacząco wzrasta (do 2 pkt. proc., wykres 75)


Wykres 74. Porównanie metod filtrowania dla indeksu CCDI wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

W przypadku indeksu Geary'ego-Khamisa bardzo bliskie wartości dla indeksu w wersji niefiltrowanej wykazują indeksy z użyciem filtrów 2 i 1. Większe różnice można zauważyć w przypadku indeksów opartych na filtrach 3 i 4 (do ok. 4 pkt. proc., wykres 76).


Wykres 75. Porównanie metod filtrowania dla indeksu Geary'ego-Khamisa wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Dla indeksu Geary'ego-Khamisa dla mleka najbardziej zbliżone wartości do danych niefiltrowanych wykazują indeksy oparte o filtry 1 i 2. Największe różnice w stosunku do indeksów liczonych na danych niefiltrowanych wykazują indeksy oparte o filtry 4 i 3 (ten drugi do 2 pkt. proc. w styczniu 2020 r., wykres 77)


Wykres 76. Porównanie metod filtrowania dla indeksu Geary'ego - Khamisa wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla indeksu TPD ponownie widoczny jest podział na 2 stosunkowo zbliżone do siebie grupy. Indeksy oparte o filtry 1 i 2 wykazują wyniki stosunkowo zbliżone do wyników opartych o dane niefiltrowane. Z kolei indeksy oparte o filtry 3 i 4 wykazują podobne wyniki do siebie różniąc się od drugiej grupy do 4-5 pkt. proc. (wykres 78).


Wykres 77. Porównanie metod filtrowania dla indeksu TPD wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Bardzo podobnymi wynikami charakteryzują się także wyniki metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI (wykres 79).


Wykres 78. Porównanie metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

Dla mleka indeks TPD wykazuje większe różnice między poszczególnymi filtrami. Najbliższe wartości w stosunku do indeksu opartego o dane niefiltrowane wykazuje filtr 1. Pozostałe indeksy wykazują istotne różnice w poszczególnych okresach – przykładowo w maju 2019 r. różnica między indeksem z narzuconym filtrem 1 a indeksem opartym o dane bez filtra wyniosła ok. 1 pkt. proc., a w przypadku filtra 4 – ok. 1,5 pkt. proc. (wykres 80).





Wykres 79. Porównanie metod filtrowania dla indeksu TPD wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Bardzo podobnymi wynikami charakteryzują się także wyniki metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI (wykres 81).

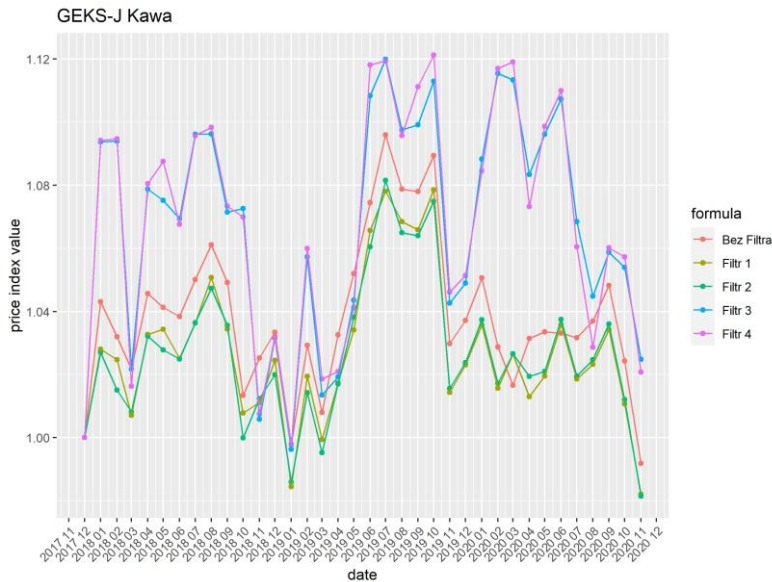
Wykres 80. Porównanie metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Dla indeksu GEKS-J dla kawy żaden z indeksów z narzuconymi filtrami nie wykazuje zbliżonych wartości do indeksu z zastosowaniem danych niefiltrowanych (wykres 82). Największymi różnicami w stosunku do niefiltrowanego indeksu charakteryzują się indeksy 3 i 4 (do ok. 10 pkt. proc.).


Wykres 81. Porównanie metod filtrowania dla indeksu GEKS-J wyznaczonego dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.

W przypadku indeksu GEKS-J dla danych o sprzedaży mleka ponownie żadna metoda filtrowania nie wykazuje zbliżonych wyników do danych niefiltrowanych. Największymi różnicami wykazują ponownie indeksy oparte o filtry 3 i 4 (wykres 83).

Wykres 82. Porównanie metod filtrowania dla indeksu GEKS-J wyznaczonego dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.

Podsumowując, na podstawie dla danych o sprzedaży mleka i kawy należy stwierdzić, że:

- filtry cenowe usuwają znacząco mniejszą liczbę produktów niż filtry oparte na kryteriach sprzedanej ilości i wartości;
- ważone indeksy bilateralne wykazują niewielką wrażliwość na poszczególne filtry – poza filtrem 4. Wyjątkiem są okresy dużych spadków cen. Indeks Jevonsa wykazuje z kolei wyższą wrażliwość na wszystkie rodzaje filtracji;
- indeksy łańcuchowe wykazują znacząco wyższą wrażliwość na działanie filtrów niż indeksy bilateralne. Nawet w przypadku filtrów usuwających niewielki odsetek próby widoczne są różnice w wyników indeksów w stosunku do niefiltrowanych danych;
- w przypadku wystąpienia dryfu łańcuchowego filtracja danych potrafi zmienić finalna wartość indeksu nawet o 100%;
- indeksy multilateralne wykazują większą wrażliwość na filtry oparte na zmianach ilości i wartości niż o filtry oparte wyłącznie na zmianie ceny.

#### 5.5. Wpływ metod agregacji na indeksy cen

Dla danych dotyczących sprzedaży kawy i mleka zastosowano także różne metody agregacji:

- Brak agregacji;
- Agregację podgrup (w tym wypadku ID produktu) za pomocą indeksów Fishera, Laspeyresa i Paaschego;
- Agregację indeksów liczonych dla poszczególnych outletów w jeden indeks;
- Łączoną agregację po podgrupach produktów i po outletach (punktach sprzedaży) za pomocą formuły Fishera, Laspeyresa lub Pascheego.

Za indeks referencyjny (tj. do którego porównujemy wyniki) uznano indeks z zastosowaną agregacją po ID produktów wyznaczony za pomocą formuły Fishera i z dodatkową agregacją po outletach.

W przypadku indeksu Jevonsa możemy zobaczyć bardzo wysoką różnicę między danymi z niezastosowaną żadną metodą agregacji, a wynikami dla indeksów, w których zastosowano przynajmniej jedną metodę agregacji. W stosunku do indeksów z zastosowaniem podwójnej agregacji (na poziomie sklepów i indeksem Fishera na poziomie agregacji podgrup w grupy), najmniejszy poziom odchylenia wykazują indeksy z zastosowaniem metody podwójnej agregacji opartej na innych indeksach (Laspeyrera i Paaschego, tabela 39)



Tabela 39. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu Jevonsa

Metoda agregacji	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	0,48	0,09	0,39
Laspeyres	0,53	0,03	0,50
Paasche	0,31	0,00	0,31
Fisher	0,42	0,02	0,40
Outlets	0,17	0,07	0,10
Outlets+Laspeyres	0,10	0,02	0,08
Outlets+Paasche	0,10	0,08	0,02
Outlets+Fisher	0	0	0

Źródło: opracowanie własne w R.

Dla indeksu Törnqvista najniższe różnice od indeksu policzonego z zastosowaniem podwójnej agregacji opartej na metodzie Fishera wykazuje indeks z zastosowaniem pojedyncza agregacja po sklepach. Najbardziej różnią się wyniki dla indeksu opartego wyłącznie o agregację za pomocą metody Laspeyresa (tabela 40).

Tabela 40. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu Törnqvista

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	0,12	0,02	0,10
Laspeyres	0,33	0,03	0,31
Paasche	0,14	0,13	0,02
Fisher	0,15	0,03	0,12
Outlets	0,06	0,02	0,04
Outlets+Laspeyres	0,27	0,00	0,27
Outlets+Paasche	0,27	0,27	0,00
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

Dla łańcuchowego indeksu Jevonsa wyniki znacząco różnią się zwłaszcza w stosunku do braku jakiegokolwiek metody agregacji. Najbardziej zbliżone wyniki do indeksu referencyjnego wykazują indeksy z zastosowaniem podwójnej metody agregacji opartej o indeks Paascheego lub Laspeyresa (tabela 41).

Tabela 41. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą łańcuchowego indeksu Jevonsa

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	0,82	0,78	0,04
Laspeyres	0,41	0,25	0,16
Paasche	0,36	0,25	0,11
Fisher	0,39	0,25	0,14
Outlets	0,28	0,26	0,02
Outlets+Laspeyres	0,10	0,01	0,09
Outlets+Paasche	0,10	0,09	0,01
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

Dla indeksu GEKS-J, podobnie jak w przypadku indeksu łańcuchowego, wyniki najbliższe do indeksu referencyjnego wykazują pozostałe indeksy z zastosowaniem metody podwójnej agregacji (0,1 pkt. proc.). Stosunkowo niewielka w stosunku do indeksu referencyjnego jest jednak także różnica indeksu z zastosowaniem agregacji względem outletów (0,16 pkt. proc., tabela 42).

Tabela 42. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu GEKS-J

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	0,61	0,16	0,45
Laspeyres	0,59	0,06	0,53
Paasche	0,40	0,03	0,37
Fisher	0,49	0,04	0,43
Outlets	0,16	0,06	0,10
Outlets+Laspeyres	0,10	0,02	0,08
Outlets+Paasche	0,10	0,08	0,02
Outlets+Fisher	0	0	0

Źródło: opracowanie własne w R.

W przypadku indeksu CCDI najniższym odchyleniem od indeksu referencyjnego wykazuje się indeks z zastosowaniem agregacji względem podgrup w grupy indeksem Fishera i indeks z zastosowaniem agregacji po outletach. Co interesujące, w tym wypadku znacznie większe odchylenie od braku metody agregacji wykazuje agregacja podgrup w grupy z wykorzystaniem indeksów Laspeyresa i Paaschego (tabela 43).

Tabela 43. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu CCDI

Indeks	Średni błąd	Średnia różnica powyżej wartości	Średnia różnica powyżej wartości
Bez agregacji	0,05	0,03	0,02
Laspeyres	0,14	0,01	0,13
Paasche	0,15	0,14	0,01
Fisher	0,03	0,02	0,01
Outlets	0,05	0,03	0,02
Outlets+Laspeyres	0,15	0,01	0,14
Outlets+Paasche	0,15	0,14	0,01
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

Dla jednopodstawowego indeksu Jevonsa dla danych o sprzedaży mleka różnice indeksów obliczonych bez agregacji i indeksów z zastosowaną agregacją wyłącznie za pomocą podgrup w grupy wykazują średnie różnice w stosunku do indeksu referencyjnego wahające się od 2,48 pkt. proc. do 3,63 pkt. proc. Znacznie niższymi różnicami charakteryzują się indeksy oparte o metody, które uwzględniają agregację po sklepach (tabela 44).

Tabela 44. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu Jevonsa

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	2,48	0,00	2,48
Laspeyres	3,63	0,00	3,63
Paasche	3,36	0,00	3,36
Fisher	3,50	0,00	3,50
Outlets	0,53	0,09	0,45
Outlets+Laspeyres	0,27	0,00	0,27
Outlets+Paasche	0,27	0,27	0,00
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

W przypadku indeksu Törnqvista dla mleka podobnie jak w przypadku kawy najniższą różnicą charakteryzują się indeksy zagregowane metodą Fishera względem podgrup kawy (0,03 pkt. proc.) i względem outletów (0,05 pkt. proc., tabela 45).

Tabela 45. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu Törnqvista

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	0,06	0,04	0,02
Laspeyres	0,14	0,01	0,13
Paasche	0,15	0,14	0,01
Fisher	0,03	0,02	0,01
Outlets	0,05	0,03	0,02
Outlets+Laspeyres	0,15	0,01	0,14
Outlets+Paasche	0,15	0,14	0,01
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

Dla indeksu łańcuchowego Jevonsa i indeksu GEKS-J w przypadku danych o sprzedaży mleka ponownie najwyższymi różnicami charakteryzują się indeksy z zastosowaniem metody nieuwzględniające agregacji względem outletów (tabele 46 i 47).

Tabela 46. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą łańcuchowego indeksu Jevonsa

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	2,48	0,00	2,48
Laspeyres	3,12	0,01	3,11
Paasche	3,00	0,00	3,00
Fisher	3,06	0,01	3,05
Outlets	0,63	0,04	0,59
Outlets+Laspeyres	0,31	0,00	0,31
Outlets+Paasche	0,31	0,31	0,00
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

Tabela 47. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu GEKS-J

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
Bez agregacji	2,47	0,00	2,47
Laspeyres	3,58	0,00	3,58
Paasche	3,43	0,00	3,43
Fisher	3,51	0,00	3,51
Outlets	0,38	0,02	0,37
Outlets+Laspeyres	0,21	0,00	0,21
Outlets+Paasche	0,21	0,21	0,00
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.

W przypadku indeksu CCDI podobnie jak w jednopodstawowej wersji indeksu Törnqvista można zauważyć, że najniższymi różnicami w stosunku do wersji indeksu z zastosowaną z podwójną agregacją z wykorzystaniem indeksu Fishera charakteryzuje się indeks z zastosowaną agregacją względem outletów (tabela 48).

Tabela 48. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu CCDI

Indeks	Średni błąd	Średnia różnica powyżej wartości	Średnia różnica powyżej wartości
Bez agregacji	0,18	0,15	0,03
Laspeyres	0,25	0,12	0,13
Paasche	0,30	0,30	0,01
Fisher	0,20	0,17	0,03
Outlets	0,07	0,03	0,04
Outlets+Laspeyres	0,23	0,00	0,23
Outlets+Paasche	0,23	0,23	0,00
Outlets+Fisher	0,00	0,00	0,00

Źródło: opracowanie własne w R.


Istotnym czynnikiem wyboru danej metody agregacji jest także szybkość kalkulacji, ponieważ w praktyce urzędy statystyczne operują na bardzo dużych zbiorach danych skanowanych. Za pomocą pakietu *microbenchmark* 20-krotnie dokonano pomiaru szybkości kalkulacji indeksów dla każdej z metod agregacji.

Dla każdego z analizowanych indeksów wyniki dawały podobne rezultaty. Najniższym dodatkowym czasem kalkulacji w stosunku indeksów nieważonych dla danych o sprzedaży


kawy charakteryzowały się indeksem z użyciem agregacji względem podgrup. Kilukrotnie wyższym czasem kalkulacji, choć ciągle znacząco niższym od indeksów z użyciem podwójnej agregacji charakteryzowały się indeksy poddane agregacji względem outletów (wykresy 84 i 86) W przypadku danych o sprzedaży mleka czas kalkulacji względem outletów jest z kolei na nieco niższym poziomie niż dla kalkulacji względem podgrup (wykresy 85 i 87). Wynika to z różnicy między poszczególnymi zestawami danych – w przypadku danych o sprzedaży kawy pochodzą one z 20 outletów, podczas gdy dane o sprzedaży mleka z 5. Wyniki kalkulacji dla indeksu Törnqvista, Jevonsa i GEKS-J charakteryzują się podobnymi tendencjami i zostały dołączone w Aneksie.

Ocena metod agregacji indeksów wskazuje na stosunkowo niewielkie różnice między podwójną agregacją a agregacją wyłącznie względem outletów. Jednocześnie przy stosunkowo niewielkiej liczbie outletów ten sposób agregacji może być szybszy nie tylko od podwójnej agregacji, ale i agregacji wyłącznie po podgrupach produktów. Z tego względu wydaje się, że agregacja względem outletów może być rozsądnym kompromisem między dokładnością metod agregacji, a czasem, o który wydłużają one obliczenia.

Wykres 83. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu CCDI dla danych o sprzedaży mleka




Wykres 84. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu CCDI dla danych o sprzedaży kawy




Źródło: opracowanie własne.

Wykres 85. Czas kalkulacji dla poszczególnych metod agregacji danych dla łańcuchowego indeksu Jevonsa dla danych o sprzedaży mleka



Źródło: opracowanie własne.

Wykres 86. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży kawy



## 6. Porównanie formuł indeksowych na bazie sztucznych zbiorów danych skanowanych

W poniższym rozdziale omówiono wyniki obliczeń na zbiorach danych skanowanych wygenerowanych w pakiecie *PriceIndices*, na podstawie zróżnicowanych parametrów zmienności cen i ilości ustalonych na bazie rozkładu lognormalnego<sup>153154</sup>. W podrozdziale 6.1. omówiono charakterystykę wygenerowanych zestawów danych. W podrozdziale 6.2. dokonano oceny różnic między indeksami cen w zależności od zmienności cen i ilości składników generowanego koszyka inflacyjnego. W podrozdziale 6.3. porównano czas kalkulacji poszczególnych indeksów w zależności od wielkości analizowanego zestawu danych. W ostatnim, czwartym podrozdziale, przeprowadzono analizę zmienności (i tym samym precyzji) wybranych indeksów cen na rotację produktów w próbie za pomocą metody *jackknife*.

### 6.1. Charakterystyka generowanych zbiorów danych

Wygenerowano 7 sztucznych zbiorów danych skanowanych na bazie lognormalnego rozkładu cen i ilości, według następujących (zadanych z góry) parametrów (wektorów) wartości oczekiwanych dla odpowiednio procesów cen i ilości w kolejnych 13 miesiącach, gdzie poszczególne warianty różnią się poziomami zmienności ilości i cen opisanymi w tabeli 49:

$$\mu_p = (1,02;1,03;1,07;1,13;1,2;1,27;1,35;1,31;1,28;1,25;1,18;1,12;1,07);$$

$$\mu_q^i = \frac{6}{\mu_p^i} : i \in \{1,2, \dots, 13\}$$

gdzie:  $\mu_p$  i  $\mu_q$  to wartości parametru  $\mu$  dla cen i ilości.

Zależność między wektorami cen i ilości ma obrazować ujemną zależność między cenami i ilościami generowanych produktów

Do stworzenia poszczególnych zbiorów danych zastosowano następujące parametry odchylenia standardowego cen ( $\sigma_p$ ) i odchylenia standardowego ilości ( $\sigma_q$ ).

---

<sup>153</sup> Szerszy opis rozkładu lognormalnego można znaleźć w: Galton F. (1879), The geometric mean, in vital and social statistics. Proceedings of the Royal Society. 29: 365–367. Współczesne wykorzystanie w badaniach nowych źródeł danych do pomiaru inflacji można znaleźć z kolei w: Biątek, J., Sulewski P. (2022), *Probability Distribution Modeling of Scanner Prices and Relative Prices*, *Statistika*, 102(3): 282-298

<sup>154</sup> <https://www.sciencedirect.com/topics/engineering/lognormal-distribution> [dostęp: 19.04.2023].



Tabela 49. Porównanie wygenerowanych zestawów danych

Zbiór danych	Odchylenie standardowe cen ( $\sigma_p$ )	Odchylenie standardowe ilości ( $\sigma_q$ )
1	0,01	0,01
2	0,01	0,1
3	0,1	0,01
4	0,1	0,1
5	0,01	0,3
6	0,3	0,01
7	0,3	0,3

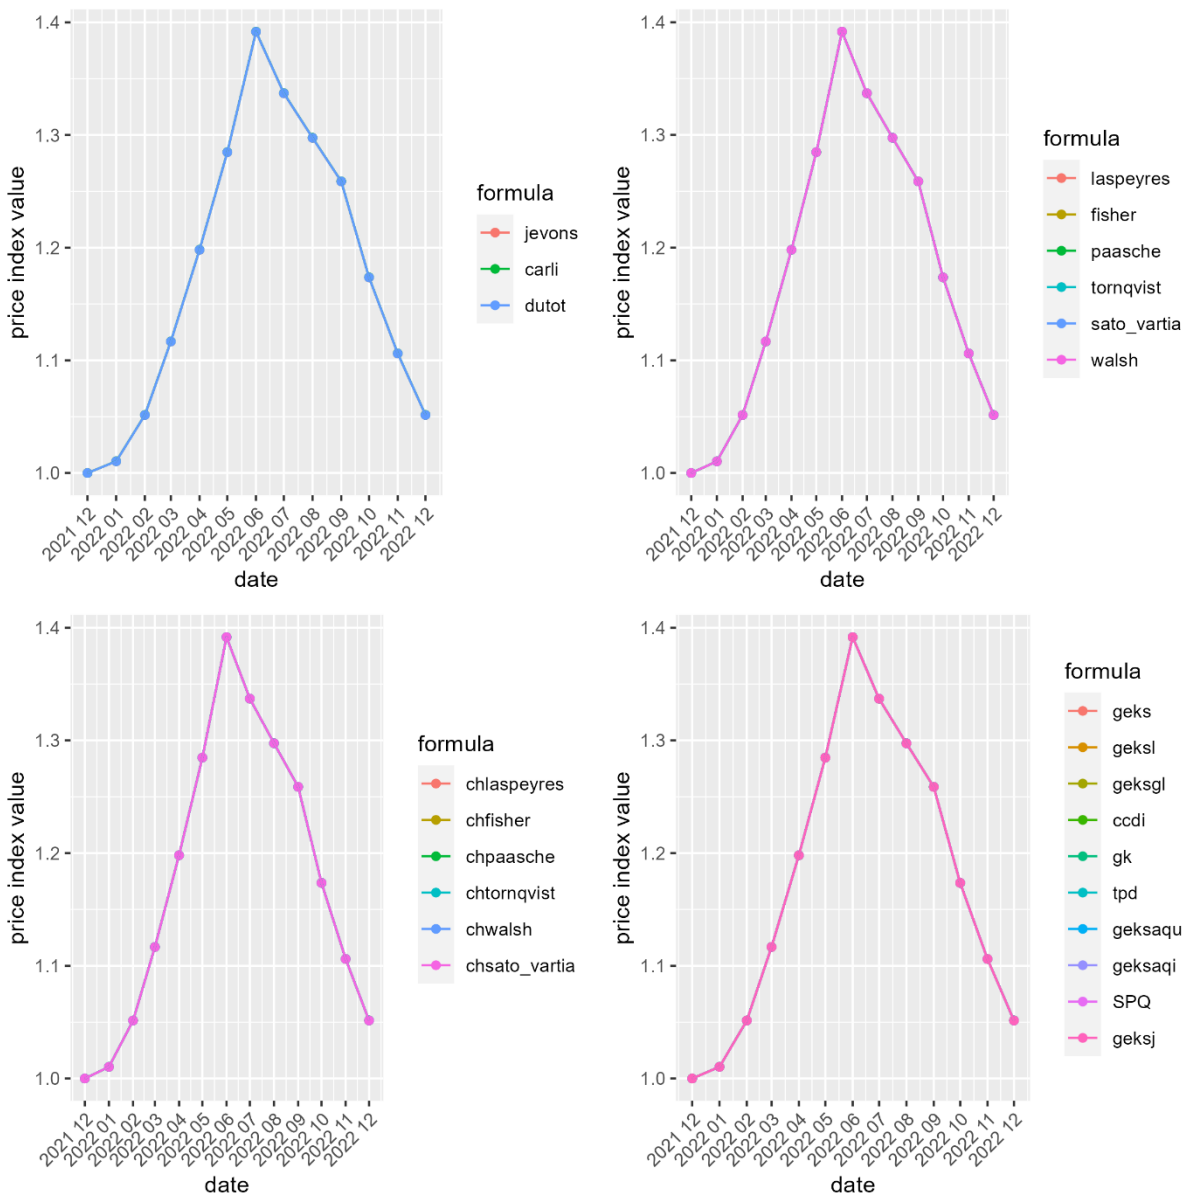
Źródło: opracowanie własne.

Nie zastosowano różnicowania pod kątem sklepów, tj. przyjęto, iż każdy zestaw danych dotyczy pojedynczego outletu. We wszystkich przypadkach generowana liczba produktów wynosiła 1000.

## 6.2. Ocena wpływu zmienności cen i ilości na różnice pomiędzy indeksami cen

Bardzo niska zmienność zarówno cen i ilości przekłada się na bardzo niskie zróżnicowanie wyników poszczególnych indeksów - w większości omawianych okresów poniżej 0,1 pkt. proc. (wykres 88).

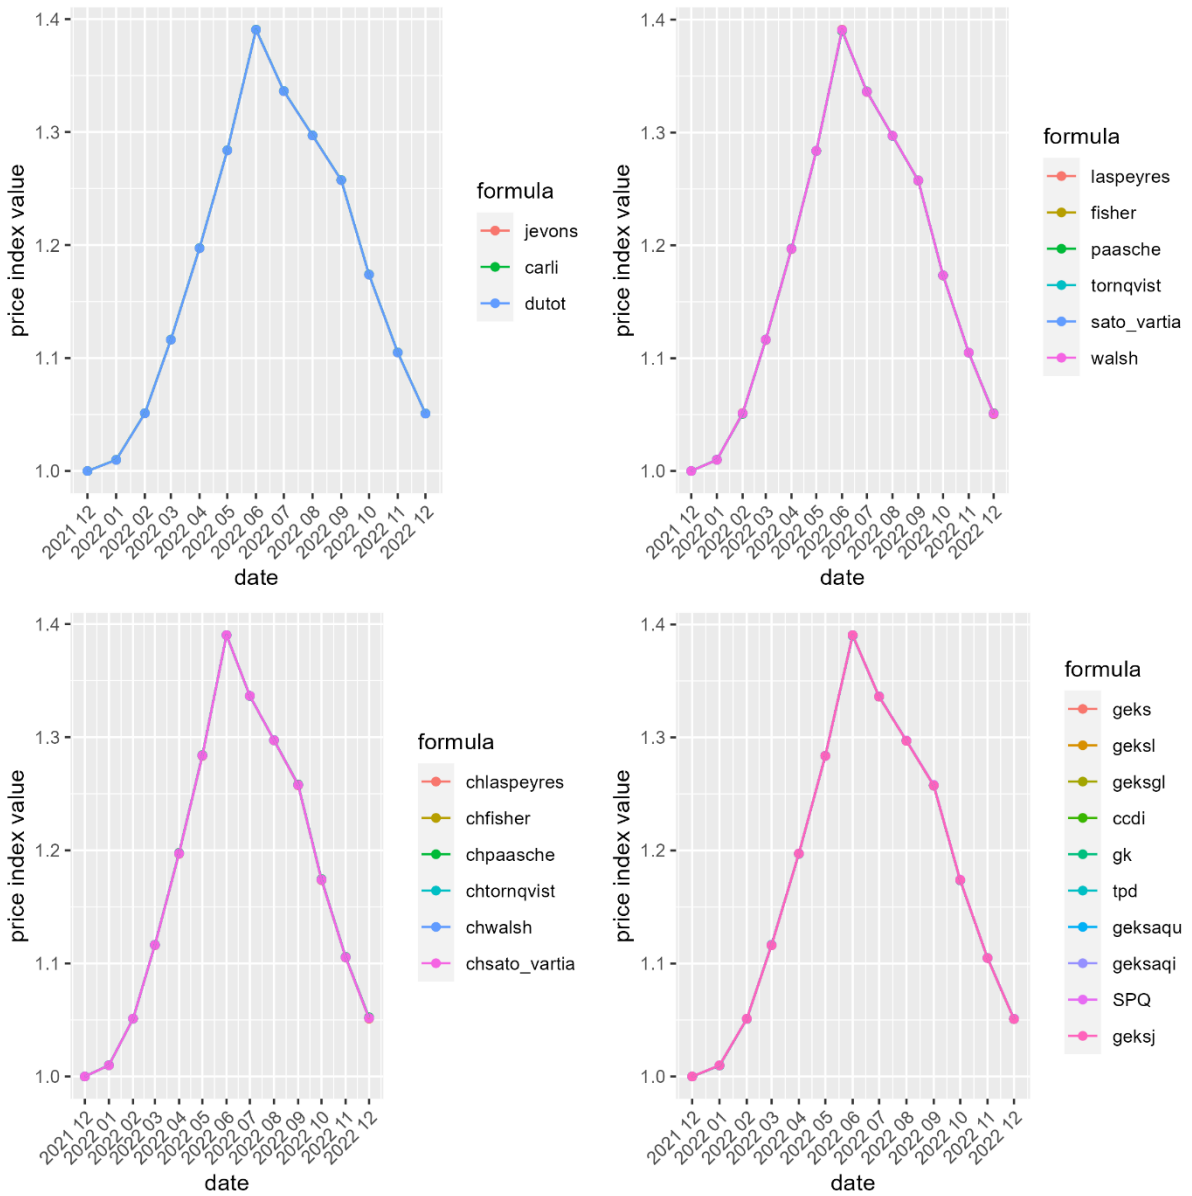
Wykres 87. Porównanie wyników zmienności dla wybranych indeksów dla pierwszego zestawu danych



Źródło: opracowanie własne.

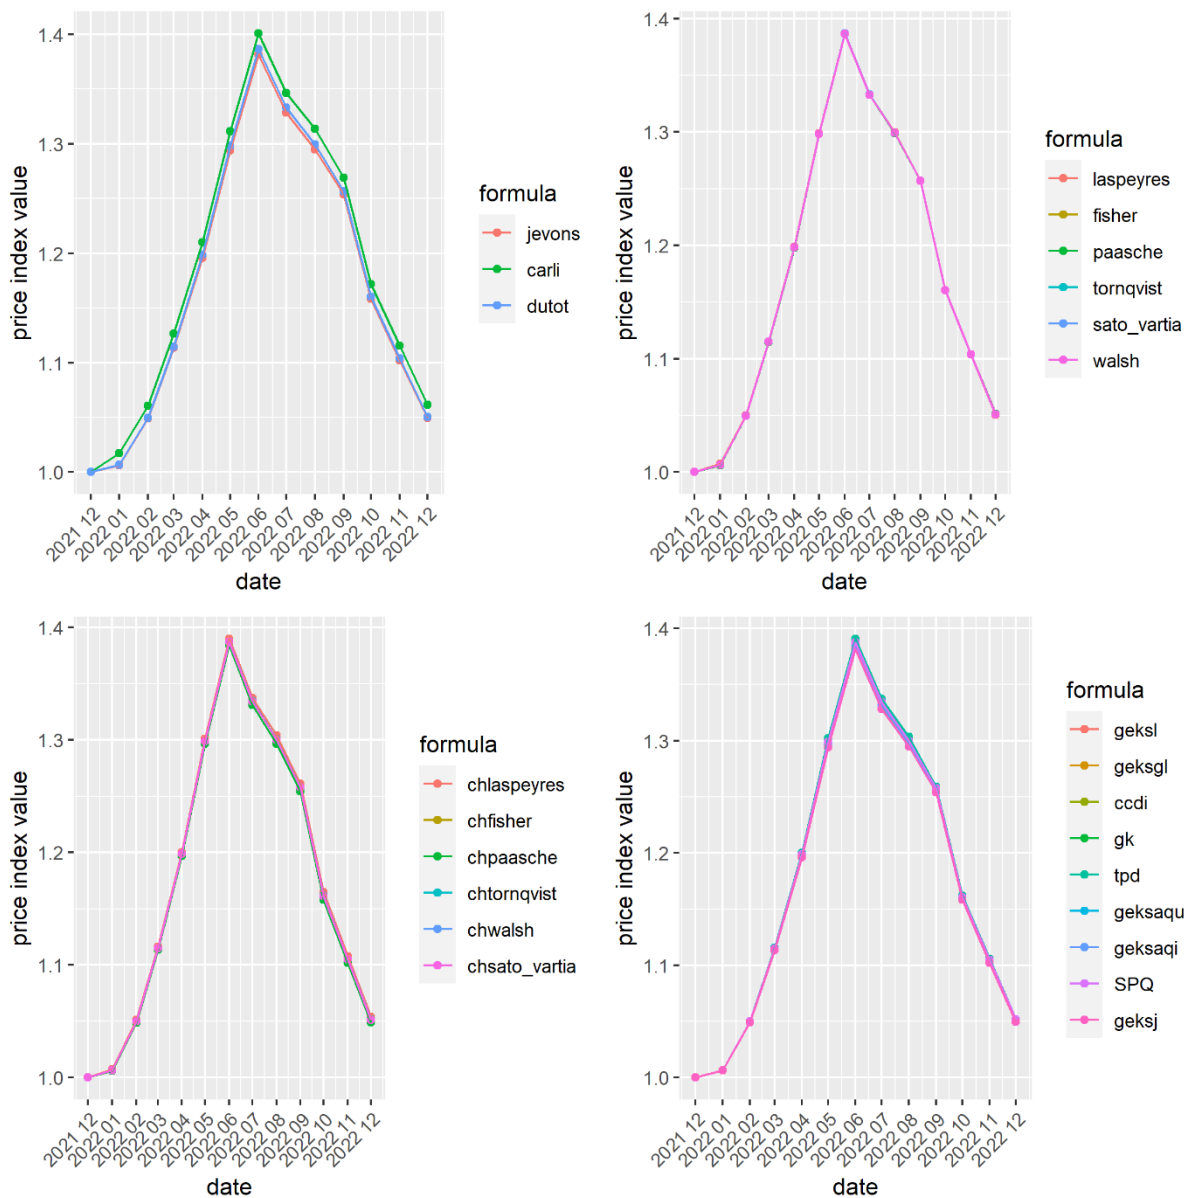
Bardzo niskie różnice między wynikami poszczególnych indeksów widoczne są także w przypadku umiarkowanej zmienności ilości i niskiej zmienności cen (wykres 89). Z kolei niska zmienność ilości (0,01) i umiarkowana zmienność cen (0,1) wpływają na niewielką, choć już zauważalną różnicę między wynikami indeksów (wykres 90).

Wykres 88. Porównanie wyników zmienności dla wybranych indeksów dla drugiego zestawu danych



Źródło: opracowanie własne.

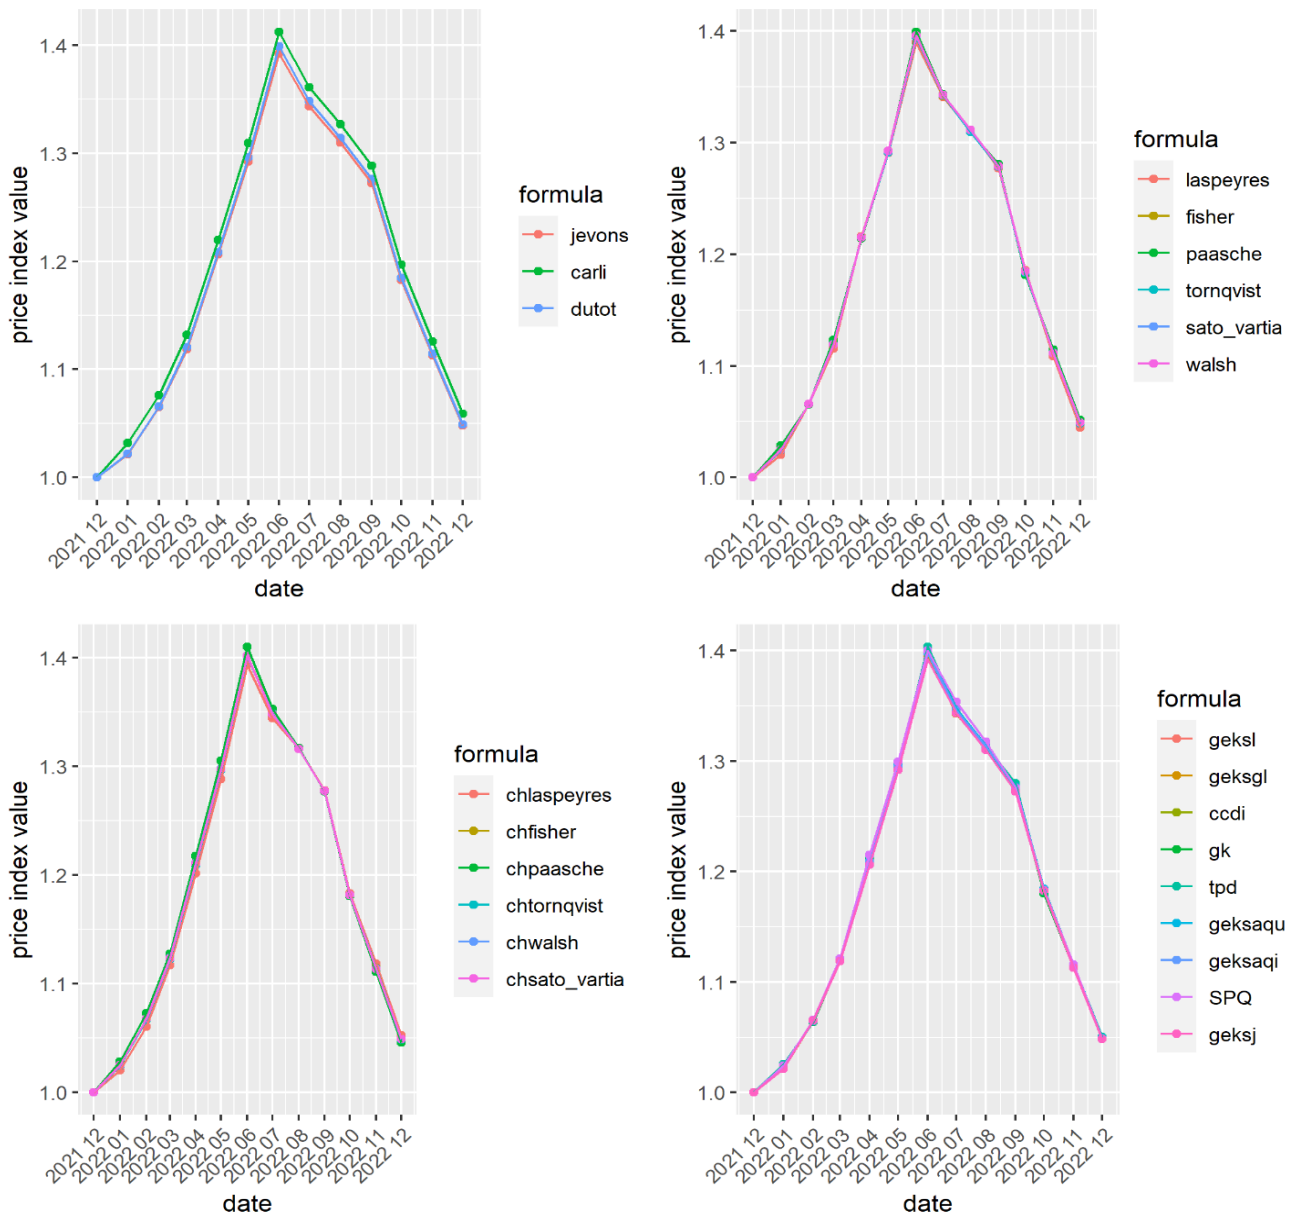
Wykres 89.. Porównanie wyników zmienności dla wybranych indeksów dla trzeciego zestawu danych



Źródło: opracowanie własne.

Umiarkowana zmienność cen i ilości (zbiór 4) nie doprowadziła do wygenerowania istotnych różnic pomiędzy poszczególnymi indeksami. Dla większości analizowanych przypadków wynoszą one poniżej 1 pkt. proc. Wyjątkiem są indeksy nieważone, gdzie różnice w okresie od czerwca do września 2022 r. sięgały nawet 2 pkt. proc. (wykres 91).

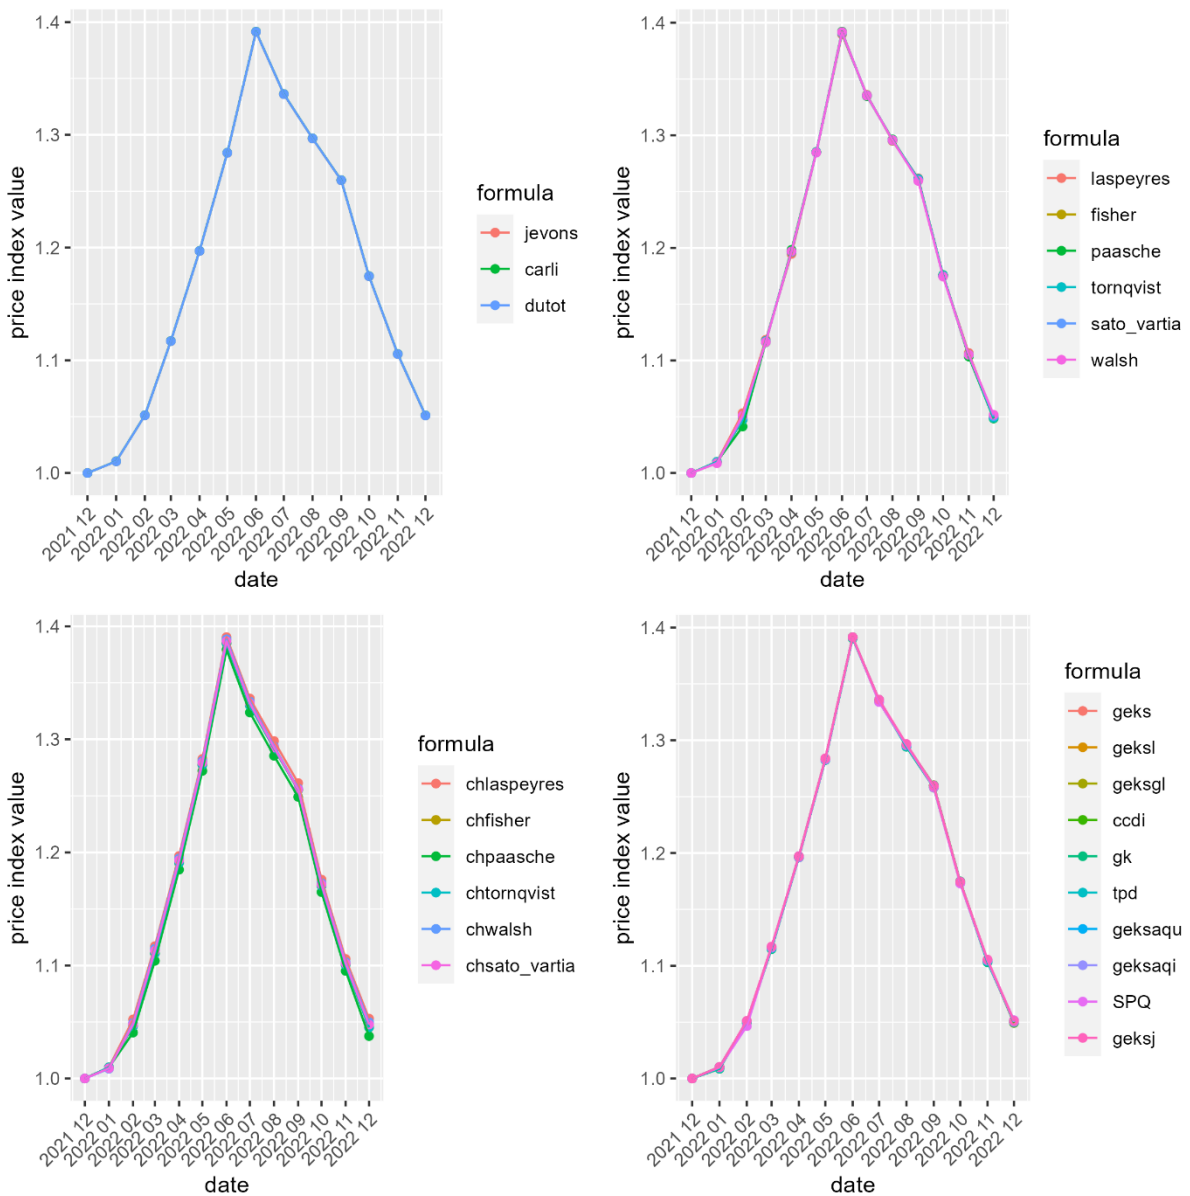
Wykres 90. Porównanie wyników zmienności dla wybranych indeksów dla czwartego zestawu danych



Źródło: opracowanie własne.

W przypadku bardzo niskiej zmienności cen i wysokiej zmienności ilości różnice między indeksami nieważonymi i multilateralnymi pozostają na bardzo niskim poziomie (wykres 92). Zauważalne, choć niskie różnice pojawiają się w przypadku indeksów łańcuchowych i bilateralnych (do 2 pkt. proc.)

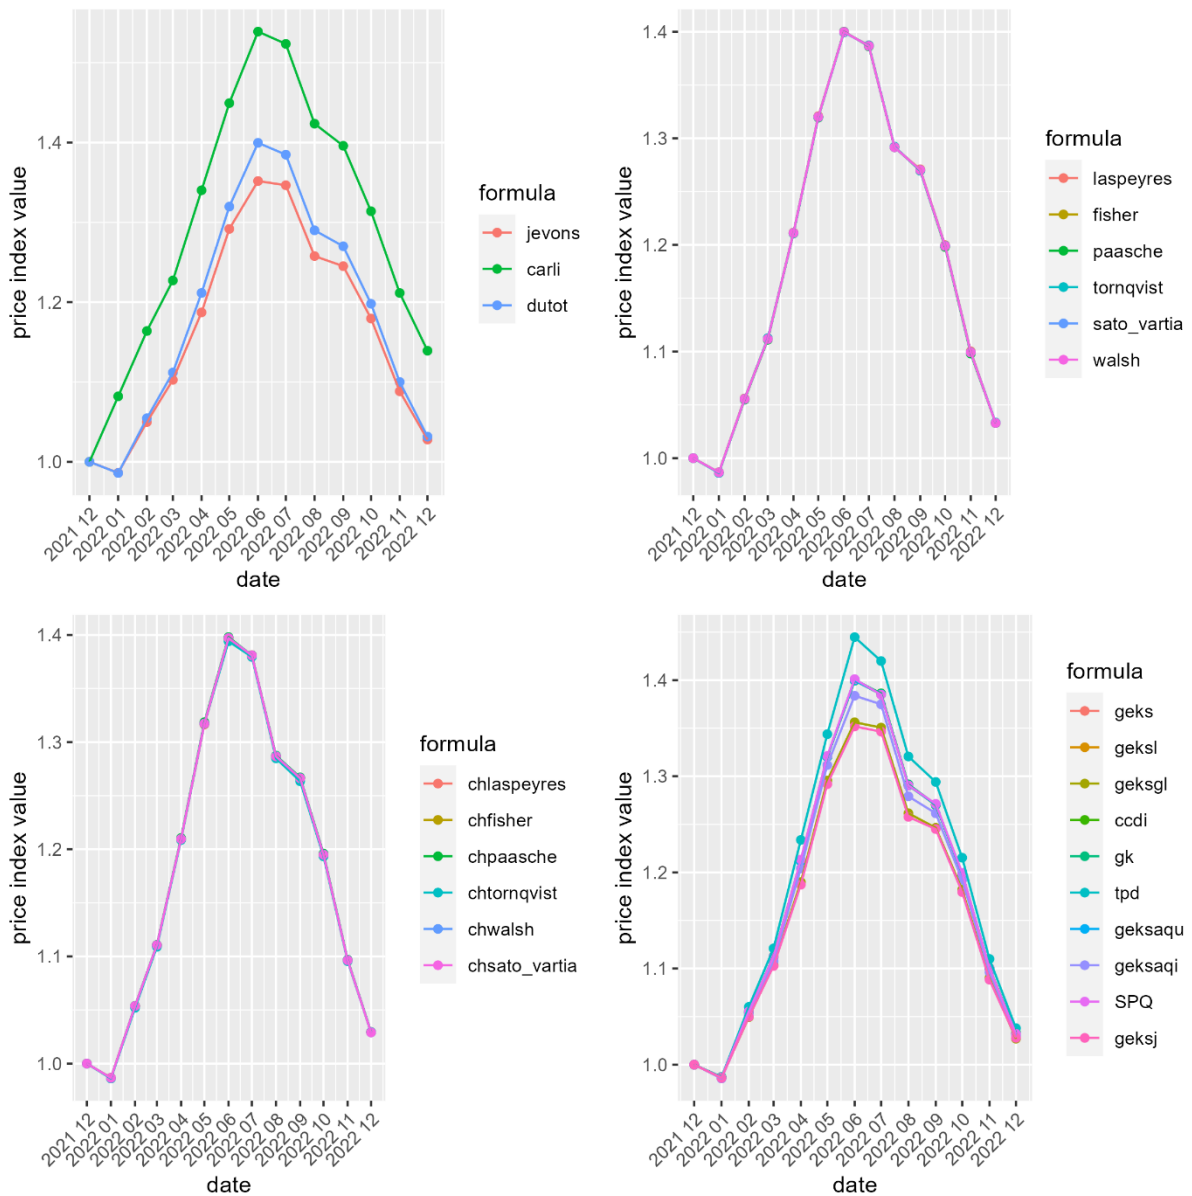
Wykres 91.. Porównanie wyników zmienności dla wybranych indeksów dla piątego zestawu danych



Źródło: opracowanie własne.

W przypadku bardzo wysokiej zmienności cen (0,3) i bardzo niskiej zmienności ilości (0,01) widoczne są bardzo wysokie różnice między indeksami nieważonymi i stosunkowo wysokie różnice między indeksami multilateralnymi. Na niskim poziomie (poniżej 0,5 pkt. proc.) są natomiast różnice dla indeksów ważonych bilateralnych i indeksów łańcuchowych (wykres 93).

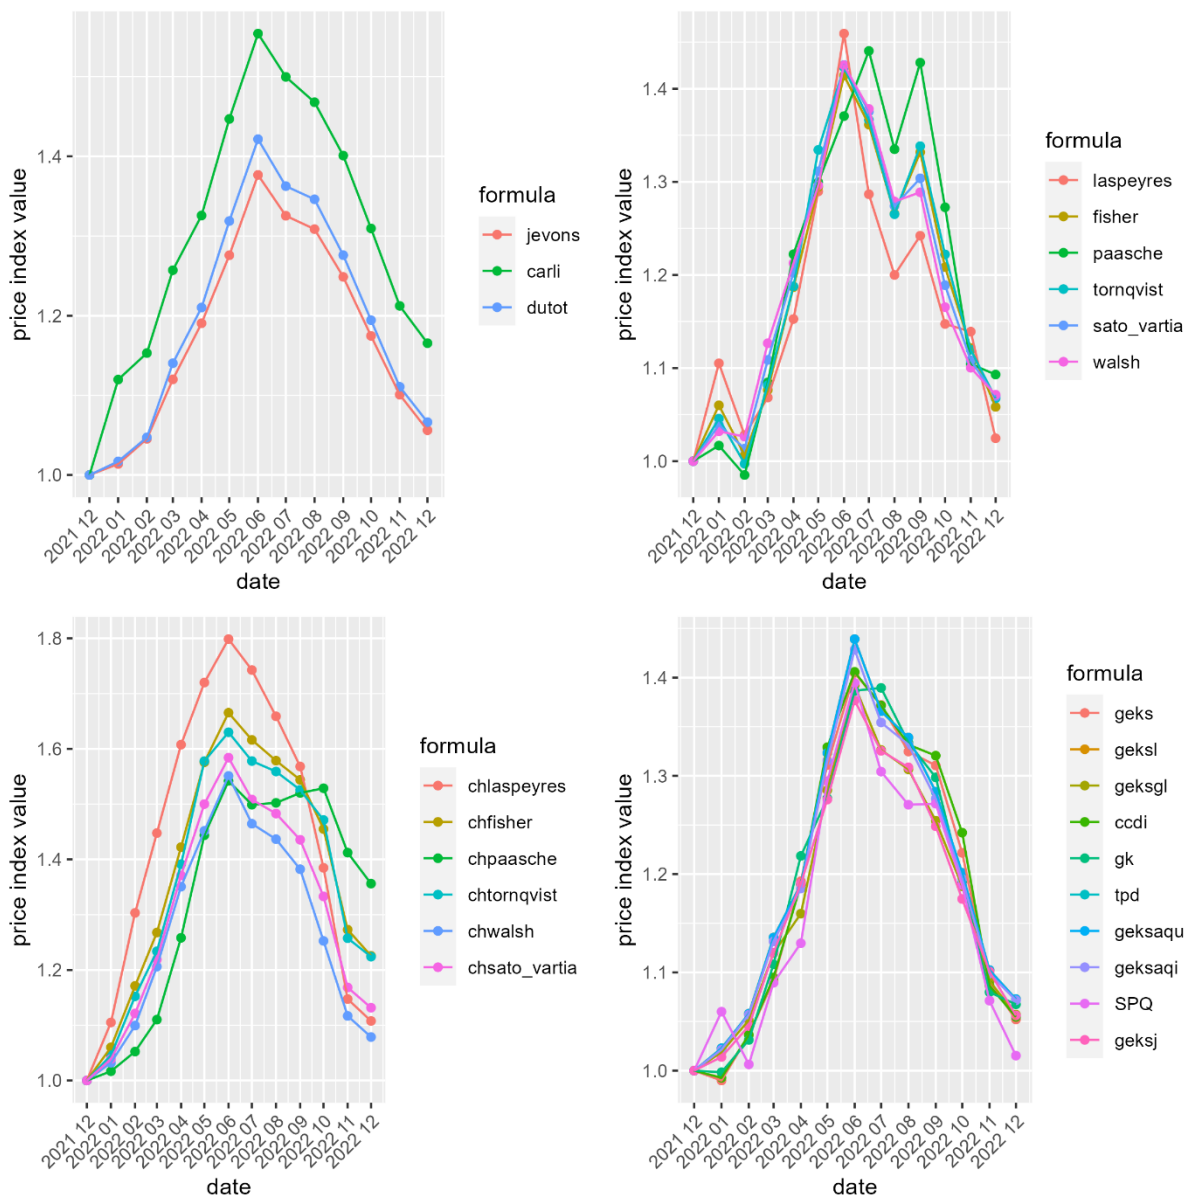
Wykres 92. Porównanie wyników zmienności dla wybranych indeksów dla szóstego zestawu danych



Źródło: opracowanie własne.

Wysoka zmienność cen i ilości (0,3) przekłada się na bardzo wysokie różnice między poszczególnymi indeksami, które sięgają nawet niemal 20 pkt. proc. w przypadku indeksów nieważonych i powyżej 20 pkt. proc. dla indeksów łańcuchowych. Niższe, choć nadal bardzo wysokie różnice można zaobserwować w przypadku indeksów multilateralnych (od 2 pkt. proc. do 8 pkt. proc. w zależności od analizowanego okresu, wykres 94)

Wykres 93. Porównanie wyników zmienności dla wybranych indeksów dla siódmego zestawu danych



Źródło: opracowanie własne.

Z powyższych symulacji można wnioskować, że:

- wysoka zmienność ilości w bardzo mało istotny sposób przekłada się na różnice między indeksami;
- wysoka zmienność cen w istotny sposób przekłada się na różnice między indeksami nieważonymi i multilateralnymi;
- w przypadku indeksów łańcuchowych i indeksów bilateralnych sama zmienność cen nie powoduje istotnych różnic między indeksami, jeżeli występuje niska zmienność ilości;




- przy wysokiej zmienności cen i ilości indeksy multilateralne wydają się być mniej wrażliwe na wahania cen niż pozostałe typy indeksów.

### 6.3. Porównanie indeksów cenowych ze względu na czas ich kalkulacji

Istotnym czynnikiem wyboru danego indeksu jest także szybkość kalkulacji, ponieważ w praktyce urzędy statystyczne operują na bardzo dużych zbiorach danych skanowanych. W ramach tego podrozdziału dokonano porównania szybkości obliczeń wybranych indeksów cenowych dla trzech wygenerowanych zbiorów o różnej liczebności (tj. odpowiednio 10, 100 i 1000 produktów). Każdy indeks został policzony 100 razy dla każdego zbioru danych, by zminimalizować wpływ innych procesów systemowych działających w tle na czas obliczeń.

Dla 10 produktów większość z analizowanych indeksów cen charakteryzuje się średnim czasem obliczeń niższym niż 1 sekunda. Kalkulacja indeksami GEKS-AQI i GEKS-AQU średnio zajmowały nieco powyżej 1 sekundy (odpowiednio 1,27 i 1,02 sekundy). Obliczenia dokonywane za pomocą indeksu Geary’ego- Khamisa zajmowały już ponad 2 sekundy. Najdłużej zajmowały kalkulacje indeksem SPQ – średnio aż 7,17 sekundy (wykres 95).


Wykres 94. Średni czas obliczeń wybranych indeksów dla 10 produktów (w sekundach)



Źródło: opracowanie własne.

Dla 100 produktów większość indeksów zachowuje niewiele wyższy czas kalkulacji niż w przypadku 10 produktów. Znaczącą różnicę widać w przypadku indeksu TPD – średni czas kalkulacji rośnie tu 11-krotnie z 0,07 do 0,78 sekundy (wykres 96).


Wykres 95. Średni czas obliczeń wybranych indeksów dla 100 produktów (w sekundach)



Źródło: opracowanie własne.

Dla 1000 produktów widać znaczący wzrost czasu potrzebnego do kalkulacji poszczególnych indeksów. Dla indeksu SPQ rośnie on z 7,5 do 13 sekund. Istotne różnice widać także w przypadku indeksu Geary’ego- Khamisa (z 2,3 do 4,5 sekundy), GEKS-AQU (1,4 do 2,5 sekundy) i GEKS-AQI (z 1 do 1,6 sekundy, wykresy 97 i 98).


Wykres 96. Średni czas obliczeń wybranych indeksów dla 1000 produktów z wyłączeniem indeksu TPD (w sekundach)



Źródło: opracowanie własne.

Nieproporcjonalnie wzrósł czas potrzebny na kalkulację indeksu TPD. Ze względu na konstrukcję indeksu, która bazuje na odwracaniu macierzy o rozmiarze proporcjonalnym do liczby produktów, czas potrzebny na obliczenia wyraźnie wzrósł z 0,78 sekundy do średnio 382 sekund (wykres 98). Wskazuje to na znacząco niższą praktyczną przydatność indeksu TPD do kalkulacji indeksów cen opartych na dużych zbiorach danych niż w przypadku pozostałych indeksów.

Wykres 97. Średni czas obliczeń wybranych indeksów dla 1000 produktów (w sekundach)



Źródło: opracowanie własne.

#### 6.4. Porównanie zmienności indeksów cen metodą *jackknife*

Metoda *jackknife*, zaprojektowana przez Quenouilla w 1949 r.<sup>155</sup>, pierwotnie służyła do redukcji obciążenia estymatorów. W 1958 r. Tukey wskazał na możliwości wykorzystania metody *jackknife* do oceny wariancji i błędu średniokwadratowego estymatora<sup>156</sup>. Metoda ta jest wykorzystywana w procesie walidacji wyników CPI uzyskanych dla danych skanowanych m.in. w Szwecji<sup>157</sup>. W przypadku indeksów cen można ją wykorzystać nie tylko do oceny obciążenia estymatora (w stosunku do wartości w populacji), ale także do zbadania odporności wybranych indeksów na obciążenie pomiaru wynikające z rotacji produktów wewnątrz próby. W poniższym rozdziale skupimy się właśnie na tym wykorzystaniu metody *jackknife*.

<sup>155</sup> Quenouille, M. (1949), Approximations tests of correlations in time series, "Journal of the Royal Statistical Society", Series B, No. 11, s. 533-538.

<sup>156</sup> Tukey, J. (1958), Bias and confidence in not quite large samples, "Annals of Mathematical Statistics", No. 29, s. 614.

<sup>157</sup> Tongur, C. (2019), Inflation Measurement with Scanner Data and an Ever Changing Fixed Basket, "Economie et Statistique / Economics and Statistics", No. 509, s. 31-47, doi: 10.24187/ecostat.2019.509.1982.

Z  $n$ -elementowego zbioru produktów usuwany jest jeden produkt i na otrzymanym podzbiorze dokonywane są obliczenia indeksu. Procedura ta powtarzana jest  $n$  razy dla kolejnych podzbiorów, które za każdym razem powstają poprzez redukcję oryginalnego zbioru produktów o kolejny, jeden produkt. Następnie wyliczana jest średnia i odchylenie standardowe z uzyskanych w ten sposób wyników.

Przyjęto, że im niższe odchylenie standardowe i mniejsza różnica między średnią wyników uzyskanych metodą *jackknife* a wynikiem policzonym na pełnej próbie, tym badany indeks wykazuje wyższą odporność na dobór próby produktów z populacji i występowanie wartości nietypowych.

Powyższe obliczenia zostały zastosowane dla grupy 7 symulowanych zbiorów danych (patrz tabela 1) – jednak ze względu na szybkość obliczeń ograniczono liczbę produktów do  $n = 100$ .

Dla grupy o bardzo niskiej zmienności cen i ilości odchylenie standardowe wyników metody *jackknife* wyniki poszczególnych indeksów za bardzo zbliżone do siebie (różnica ok. 0,01 pkt. proc.). Współczynnik zmienności wartości indeksów wyliczanych metodą *jackknife* we wszystkich przypadkach jest na poziomie 0,01% (tabela 50).

Tabela 50. Wyniki kalkulacji indeksów metoda *jackknife* dla pierwszego zestawu danych

<b>Indeks</b>	<b>Wynik indeksu (całość produktów)</b>	<b>Średnia z wartości indeksów (<i>jackknife</i>)</b>	<b>Odchylenie standardowe wartości indeksów (<i>jackknife</i>)</b>	<b>Współczynnik zmienności wartości indeksów (<i>jackknife</i>)</b>
Jevons	1,0516	1,0516	0,00014	0,01356%
Chain Jevons	1,0516	1,0516	0,00014	0,01356%
Fisher	1,0517	1,0517	0,00014	0,01352%
Chain Fisher	1,0517	1,0517	0,00014	0,01378%
GEKS-J	1,0516	1,0516	0,00014	0,01356%
GEKS-L	1,0517	1,0517	0,00014	0,01359%
GEKS-GL	1,0516	1,0516	0,00014	0,01357%
GEKS-AQU	1,0517	1,0517	0,00014	0,01359%
GEKS-AQI	1,0517	1,0517	0,00014	0,01359%
SPQ	1,0517	1,0517	0,00014	0,01352%
TPD	1,0517	1,0517	0,00014	0,01353%
Geary-Khamis	1,0517	1,0517	0,00014	0,01350%
CCDI	1,0517	1,0517	0,00014	0,01354%

Źródło: opracowanie własne.

W przypadku drugiego zestawu danych wyniki indeksu liczonego ze wszystkich produktów w próbie i indeksów liczonych z użyciem metody *jackknife* są na podobnym poziomie. Współczynnik zmienności wartości indeksów wyliczanych metodą *jackknife* najwyższe wartości przyjmuje dla indeksu SPQ (0,029%) i łańcuchowego indeksu Fishera (0,024%) w porównaniu do wartości 0,014-0,016% dla pozostałych indeksów (tabela 51).

Tabela 51. Wyniki kalkulacji indeksów metoda *jackknife* dla drugiego zestawu danych

<b>Indeks</b>	<b>Wynik indeksu (całość produktów)</b>	<b>Średnia z wartości indeksów (<i>jackknife</i>)</b>	<b>Odchylenie standardowe wartości indeksów (<i>jackknife</i>)</b>	<b>Współczynnik zmienności wartości indeksów (<i>jackknife</i>)</b>
Jevons	1,05035	1,05035	0,00015	0,01395%
Chain Jevons	1,05035	1,05035	0,00015	0,01395%
Fisher	1,05079	1,05079	0,00016	0,01538%
Chain Fisher	1,05215	1,05215	0,00025	0,02415%
GEKS-J	1,05035	1,05035	0,00015	0,01395%
GEKS-L	1,05041	1,05041	0,00015	0,01418%
GEKS-GL	1,05040	1,05040	0,00015	0,01418%
GEKS-AQU	1,05041	1,05041	0,00015	0,01418%
GEKS-AQI	1,05044	1,05044	0,00015	0,01417%
SPQ	1,05032	1,05030	0,00031	0,02907%
TPD	1,05075	1,05075	0,00017	0,01575%
Geary-Khamis	1,05062	1,05062	0,00016	0,01548%
CCDI	1,05064	1,05064	0,00016	0,01486%

Źródło: opracowanie własne.

Dla trzeciego zestawu danych (umiarkowana zmienność cen, niska zmienność ilości) widoczne są niewielkie różnice między wynikami indeksu liczonego na pełnym zestawie danych i średnią indeksów liczonych z wykorzystaniem metody *jackknife*. Najwyższa jest ona dla indeksu SPQ (0,03 pkt. proc.). Współczynniki zmienności są na podobnym poziomie dla wszystkich indeksów liczonych metodą *jackknife* (0,16%, tabela 52).

Tabela 52. Wyniki kalkulacji indeksów metoda jackknife dla trzeciego zestawu danych

Indeks	Wynik indeksu (całość produktów)	Średnia z wartości indeksów (jackknife)	Odchylenie standardowe wartości indeksów (jackknife)	Współczynnik zmienności wartości indeksów (jackknife)
Jevons	1,01703	1,01704	0,00159	0,15659%
Chain Jevons	1,01703	1,01704	0,00159	0,15659%
Fisher	1,01899	1,01899	0,00161	0,15757%
Chain Fisher	1,01948	1,01948	0,00161	0,15786%
GEKS-J	1,01703	1,01704	0,00159	0,15659%
GEKS-L	1,01973	1,01973	0,00161	0,15766%
GEKS-GL	1,01691	1,01691	0,00159	0,15665%
GEKS-AQU	1,01973	1,01973	0,00161	0,15766%
GEKS-AQI	1,01967	1,01967	0,00161	0,15809%
SPQ	1,01787	1,01790	0,00160	0,15754%
TPD	1,02113	1,02113	0,00162	0,15893%
Geary-Khamis	1,01841	1,01841	0,00160	0,15733%
CCDI	1,01907	1,01907	0,00160	0,15726%

Źródło: opracowanie własne.

W przypadku umiarkowanej zmienności cen i ilości najwyższą różnicę między indeksem liczonym na całej próbie i średnią indeksów liczonych metodą *jackknife* można zauważyć dla indeksu SPQ (0,05 pkt. proc.). Współczynniki zmienności ponownie są najwyższe dla indeksów SPQ (0,26%) i łańcuchowego indeksu Fishera (0,23%, tabela 53).

Tabela 53. Wyniki kalkulacji indeksów metoda jackknife dla czwartego zestawu danych

Indeks	Wynik indeksu (całość produktów)	Średnia z wartości indeksów (jackknife)	Odchylenie standardowe wartości indeksów (jackknife)	Współczynnik zmienności wartości indeksów (jackknife)
Jevons	1,04440	1,04440	0,00155	0,14839%
Chain Jevons	1,04440	1,04440	0,00155	0,14839%
Fisher	1,04177	1,04177	0,00174	0,16690%
Chain Fisher	1,05857	1,05857	0,00241	0,22771%
GEKS-J	1,04440	1,04440	0,00155	0,14839%
GEKS-L	1,04683	1,04683	0,00157	0,15013%
GEKS-GL	1,04803	1,04803	0,00156	0,14856%
GEKS-AQU	1,04683	1,04683	0,00157	0,15013%
GEKS-AQI	1,04602	1,04602	0,00157	0,14979%
SPQ	1,04259	1,04305	0,00273	0,26187%

TPD	1,03756	1,03756	0,00185	0,17797%
Geary-Khamis	1,03972	1,03972	0,00186	0,17853%
CCDI	1,04317	1,04317	0,00166	0,15899%

Źródło: opracowanie własne.

W przypadku niskiej zmienności cen i wysokiej zmienności ilości można zauważyć, że najwyższa różnica między indeksem liczonym dla pełnej próby i średnią indeksów liczonych metodą *jackknife* występuje dla indeksu SPQ. Najwyższe współczynniki zmienności wartości indeksów liczonych metodą *jackknife* są obserwowane dla indeksu łańcuchowego Fishera (0,051%), indeksu SPQ (0,049%) i indeksu Fishera (0,029%, tabela 54).

Tabela 54. Wyniki kalkulacji indeksów metoda *jackknife* dla piątego zestawu danych

Indeks	Wynik indeksu (całość produktów)	Średnia z wartości indeksów ( <i>jackknife</i> )	Odchylenie standardowe wartości indeksów ( <i>jackknife</i> )	Współczynnik zmienności wartości indeksów <i>jackknife</i>
Jevons	1,04984	1,04984	0,00014	0,01347%
Chain Jevons	1,04984	1,04984	0,00014	0,01347%
Fisher	1,04840	1,04840	0,00031	0,02931%
Chain Fisher	1,04697	1,04698	0,00053	0,05092%
GEKS-J	1,04984	1,04984	0,00014	0,01347%
GEKS-L	1,04968	1,04968	0,00019	0,01769%
GEKS-GL	1,04967	1,04967	0,00019	0,01765%
GEKS-AQU	1,04968	1,04968	0,00019	0,01769%
GEKS-AQI	1,04975	1,04975	0,00018	0,01749%
SPQ	1,04710	1,04716	0,00052	0,04942%
Geary-Khamis	1,04674	1,04672	0,00045	0,04283%
CCDI	1,05049	1,05049	0,00032	0,03073%

Źródło: opracowanie własne.

Dla danych o wysokiej zmienności cen i niskiej zmienności ilości można zaobserwować znacznie wyższe współczynniki zmienności niż dla piątego zestawu danych (0,43-0,53% vs 0,01-0,05%). Najwyższe różnice między indeksem liczonym na pełnej próbie i średnią z metody *jackknife* widoczne są dla indeksu SPQ (0,014 pkt. proc.). Najwyższy współczynnik zmienności można zaobserwować dla indeksu TPD (0,58%), a najniższe dla indeksów opartych na formule Jevonsa (0,44%, tabela 55).



Tabela 55. Wyniki kalkulacji indeksów metoda *jackknife* dla szóstego zestawu danych

Indeks	Wynik indeksu (całość produktów)	Średnia z wartości indeksów ( <i>jackknife</i> )	Odchylenie standardowe wartości indeksów ( <i>jackknife</i> )	Współczynnik zmienności wartości indeksów ( <i>jackknife</i> )
Jevons	1,09548	1,09549	0,00478	0,43671%
Chain Jevons	1,09548	1,09549	0,00478	0,43671%
Fisher	1,09817	1,09819	0,00553	0,50332%
Chain Fisher	1,10624	1,10625	0,00562	0,50809%
GEKS-J	1,09548	1,09549	0,00478	0,43671%
GEKS-L	1,09971	1,09973	0,00557	0,50694%
GEKS-GL	1,10321	1,10322	0,00502	0,45492%
GEKS-AQU	1,09971	1,09973	0,00557	0,50694%
GEKS-AQI	1,09743	1,09744	0,00578	0,52656%
SPQ	1,09323	1,09337	0,00551	0,50387%
TPD	1,09342	1,09343	0,00631	0,57669%
Geary-Khamis	1,09518	1,09519	0,00552	0,50445%
CCDI	1,09852	1,09853	0,00560	0,51015%

Źródło: opracowanie własne.

W przypadku danych o wysokiej zmienności cen i ilości (zestaw siódmy) różnice między indeksami policzonymi na pełnym zestawie danych i średnią indeksów policzonych z wykorzystaniem metody *jackknife* sięgają nawet powyżej 2 pkt. proc. (SPQ). Wysokie różnice można zauważyć także dla indeksu łańcuchowego Fishera (0,2 pkt. proc.). W przypadku tych dwóch indeksów widoczne są także znacznie wyższe współczynniki zmienności dla kalkulacji za pomocą metody *jackknife* (4,3% dla SPQ i 3,2% dla łańcuchowego indeksu Fishera, tabela 56).

Tabela 56. Wyniki kalkulacji indeksów metoda *jackknife* dla siódmego zestawu danych

Indeks	Wynik indeksu (całość produktów)	Średnia z wartości indeksów ( <i>jackknife</i> )	Odchylenie standardowe wartości indeksów ( <i>jackknife</i> )	Współczynnik zmienności wartości indeksów ( <i>jackknife</i> )
Jevons	1,00857	1,00858	0,00450	0,44648%
Chain Jevons	1,00857	1,00858	0,00450	0,44648%
Fisher	1,11851	1,11831	0,00944	0,84409%
Chain Fisher	1,65151	1,64961	0,05237	3,17444%
GEKS-J	1,00857	1,00858	0,00450	0,44648%

GEKS-L	0,97105	0,97120	0,00647	0,66645%
GEKS-GL	0,95901	0,95924	0,00714	0,74402%
GEKS-AQU	0,97105	0,97120	0,00647	0,66645%
GEKS-AQI	0,96278	0,96292	0,00629	0,65372%
SPQ	1,09443	1,07378	0,04643	4,32380%
TPD	0,92086	0,92087	0,00609	0,66143%
Geary-Khamis	0,88532	0,88542	0,00662	0,74730%
CCDI	0,95723	0,95738	0,00768	0,80221%

Źródło: opracowanie własne.

Wyniki porównania zmienności indeksów cen metodą *jackknife* wskazują na wysoką odporność indeksów opartych na formule GEKS i indeksach bilateralnych na obciążenie pomiaru wynikające ze zmian wewnątrz próby. Największym odchyleniem standardowym wyników uzyskanych metodą *jackknife* oraz największymi różnicami między średnią z tych wyników i wynikiem pozyskanym dla pełnej próby charakteryzują się: łańcuchowy indeks Fishera oraz indeks SPQ

## Podsumowanie

W swojej pracy autor dokonał szerokiego przeglądu metodologii dotyczącej wykorzystania danych skanowanych i skrapowanych w pomiarze inflacji. Autor przeprowadził także analiz dotyczących ponad dwudziestu wybranych formuł indeksowych wraz z dodatkowymi analizami metod agregacji, metod rozszerzania okna czasowego, wpływu filtrów na formuły indeksowe oraz czasu kalkulacji indeksów cen. W swojej analizie autor nie ograniczał się wyłącznie do formuł o ugruntowanej pozycji ale sprawdził też najnowsze propozycje, które pojawiły się w literaturze w ciągu ostatnich 2-3 lat. Za dodatkowy atut pracy można także uznać propozycję indeksu GEKS opartego na formule Dutot, a także niespotkane wcześniej w literaturze wykorzystanie metody jackknife do empirycznego sprawdzenia wrażliwości indeksów cen na obciążenie wynikające ze zmian wewnątrz próby. Zdaniem autora praca wnosi istotną wartość dodaną do literatury zwłaszcza w kontekście przydatności metod mających na celu zmniejszenie obciążenia pomiaru inflacji bazującego na danych skanowanych i skrapowanych, zatem cel postawiony na początku pracy można uznać za osiągnięty.

Analiza zbioru danych pochodzącego z *web-scrapingu* i dotyczącego cen odzieży i obuwia potwierdza problem dużej rotacji produktów, który w odniesieniu do tego segmentu opisywano w badaniach brytyjskiego urzędu statystycznego. Dla całego zbioru danych odsetek kodów ID powtarzających się w pierwszym i ostatnim miesiącu analizy wynosił jedynie 2,63%, a w żadnej podkategorii odzieży i obuwia nie przekraczał 10%. Tak wysoka rotacja produktów w praktyce utrudnia dopasowanie produktów w czasie zwłaszcza, jeżeli bazuje ono wyłącznie na kodzie produktu. Przy wykorzystaniu danych do celów innych niż testowe wymagane byłoby zastosowanie dodatkowych metod dopasowania produktów bazując na opisach produktów lub dokonywania obliczeń na już zagregowanych grupach produktów.

Warte zauważenia są stosunkowo niskie różnice między wynikami dla indeksów bilateralnych, zwłaszcza między indeksami Jevonsa i Dutot. Bardzo wysokie zróżnicowanie wyników występuje, gdy porównamy je do indeksów łańcuchowych i indeksów multilateralnych – UTPD i GEKS-J. Różnice wynoszące nawet powyżej 25 pkt. proc. wskazują na bardzo duże obciążenie pomiaru wiążące się z obliczeniami na grupie niehomogenicznych produktów.

Analiza bilateralnych formuł indeksowych oparta na 3 zbiorach danych skanowanych wykazała, że najmniejszymi różnicami w stosunku do formuły Fishera charakteryzuje się indeks Törnqvista. Niewielkie różnice w porównaniu do indeksu Fishera charakteryzowały

także indeks Walsha i Sato-Vartia. Podobne tendencje można zaobserwować także w przypadku łańcuchowych wersji tych formuł. Łańcuchowe indeksy Laspeyresa i Paaschego wykazują z kolei bardzo wysoką tendencję do dryfu łańcuchowego.

W przypadku formuł multilateralnych można zaobserwować bardzo zbliżone wartości indeksów TPD i Geary'ego-Khamisa. Także indeksy oparte na formule GEKS, z wyłączeniem indeksu GEKS-J, charakteryzują się niewielkimi różnicami względem siebie w przypadku dwóch spośród trzech analizowanych zestawów danych (dotyczy to zwłaszcza indeksów GEKS-AQU i GEKS-AQI). Dla trzeciego zestawu danych o wysokich wahań sezonowych różnice między formułami indeksów są już znacznie wyższe sięgając kilkunastu punktów procentowych, co wskazuje na podatność części formuł multilateralnych na dużą zmienność i/lub sezonowość cen. Wniosek ten znajduje potwierdzenie w rozdziale symulacyjnym, w którym pokazano, że wysoka zmienność cen wpływa na zróżnicowanie wyników indeksów multilateralnych, nawet jeśli zmienność ilości jest na bardzo niskim poziomie.

Dla obu źródeł danych, zarówno skrapowanych, jak i skanowanych, zweryfikowane metody filtracji wskazały na dobre wyniki indeksów z nałożonym filtrem cenowym (1 i 99 percentyl). Eliminował on z badanych grup produktów bardzo niewielką liczbę obserwacji jednocześnie wpływając na zmniejszenie wysokich wahań cen dla części indeksów (np. GEKS-J) wynikających z wpływu wartości nietypowych. Pozytywne efekty można zaobserwować też w przypadku indeksów z nałożonym filtrem cenowym eliminującym produkty, których cena wzrosła bardziej niż dwukrotnie lub spadła poniżej 50% wartości ceny z poprzedniego miesiąca. Filtry oparte na zmienności ilości lub wartości sprzedaży należy w kontekście tej analizy ocenić mniej pozytywnie, głównie ze względu na znacznie większą ingerencję w próbę. Po ich zastosowaniu odsetek unikatowych produktów w analizie zmniejszył się nawet o 50%.

Analiza metod rozszerzania formuł multilateralnych, zarówno w przypadku danych skanowanych, jak i danych skrapowanych wykazała dużą różnicę pomiędzy metodą FBEW a innymi metodami rozszerzania okna obliczeń. Metody typu *splice* wykazywały w większości analizowanych przypadków umiarkowanie zbliżone wartości. Metoda FBMW dawała rezultaty bardziej zbliżone to metod *splice* niż metoda FBEW.

Ocena metod agregacji indeksów wykazała, że występują istotne różnice między podwójną metodą agregacji (względem podgrup i względem outletów formułą Fishera), a agregacją wyłącznie względem podgrup (z tą samą formułą agregującą). Znacznie niższe różnice można zaobserwować w porównaniu do agregacji wyłącznie względem outletów. Biorąc pod uwagę

kilkukrotnie niższy czas obliczeń indeksów cen w przypadku agregacji względem outletów w porównaniu do podwójnej metody filtracji na podstawie analizowanych danych można postawić wniosek, że dla większych zestawów danych pochodzących ze stosunkowo niewielkiej liczby sklepów wybór tej formuły agregacji może być najlepszym kompromisem między poprawą dokładności obliczeń a czasem potrzebnym na ich sfinalizowanie.

Czas kalkulacji jest także istotnym czynnikiem przy wyborze samych formuł indeksowych. Jak wynika z symulacji przeprowadzonej na wygenerowanych zbiorach danych, już w przypadku 1000 produktów widać znaczące różnice w czasie kalkulacji rozważanych indeksów cen. Wśród formuł multilateralnych niskim czasem kalkulacji charakteryzują się formuły GEKS, zwłaszcza indeks CCDI i indeksy GEKS-L, GEKS-GL i GEKS-J. Obliczenia za pomocą formuły Geary'ego-Khamisa zajmowały ok 4-krotnie dłuższy czas, a za pomocą indeksu SPQ – 12-krotnie (indeks ten charakteryzował się też najniższą odpornością na zmiany wewnątrz próby). Relatywnie najgorzej wypadł indeks TPD, który ze względu na formułę opierającą się na obliczeniach dokonywanych na macierzach odwrotnych potrzebował średnio blisko 400-krotnie więcej czasu obliczeniowego niż np. indeks CCDI.

Podsumowując, wydaje się, iż wybór indeksu cenowego, a wcześniej metody filtracji danych, dopasowania produktów w czasie czy na końcu agregacji wyników cząstkowych, pozostają nadal kwestiami otwartymi. Jedną z przyczyn tego stanu rzeczy jest fakt, iż efektywność wymienionych etapów procedowania danych skanowanych czy skrapowanych w dużej mierze zależy od ich rozmiaru, stopnia szczegółowości, stopnia homogeniczności oraz innych cech, takich jak sezonowość sprzedaży czy poziom zmienności cen i ilości. Bazując jednak na wynikach z przeprowadzonych badań autor skłania się ku stwierdzeniu, że spośród analizowanych indeksów najlepiej wypadły indeksy oparte na formule GEKS. Wniosek ten jednak oparty jest na analizie tylko kilku grup produktów oraz analizie sztucznych, generowanych w pakiecie *PriceIndices* zbiorów danych. W przyszłych badaniach analizę należałoby rozszerzyć o porównanie skupiające się na znacznie szerszym zakresie kategorii dóbr i usług. Niemniej jednak, autor pracy wyraża głęboką nadzieję, iż uzyskane przez niego wyniki oraz poczynione obserwacje i spostrzeżenia będą cenne zarówno dla akademików, jak i praktyków zajmujących się problematyką alternatywnych źródeł danych w pomiarze inflacji.

## Literatura

1. Abe, N. (2019), *Multilateral Sato-Vartia Index for International Comparisons of Prices and Real Expenditures*, "RCESR Discussion Paper Series", No. DP19-1.
2. Auer, J., Boettcher, I. (2017), *From price collection to price data analytics. How new large data sources require price statisticians to re-think their index compilation procedures. Experiences from web-skraped and scanner data*, Praca opublikowana w ramach spotkania Grupy Ottawskiej.
3. Bertolotto, M., Cavallo, A., Rigobon, R. (2014), *Using Online Prices to Anticipate Official CPI Inflation*, UTokyo Price Project Working Paper Series 031, University of Tokyo, Graduate School of Economics, Tokyo.
4. Bernholtz, P.(2003), *Monetary Regimes and Inflation: History, Economic and Political Relationships*, Edward Elgar Publishing Ltd, London.
5. Białek, J. (2012), *Propozycja indeksu cen*, „Wiadomości Statystyczne”, nr 7, , s. 13-24.
6. Białek, J. (2019), *Metodologia pomiaru inflacji: stan Obecny i wyzwania*, [https://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/6375/2/1/1/pomiar\\_inflacji\\_stan\\_obecny\\_i\\_wyzwania.pdf](https://stat.gov.pl/files/gfx/portalinformacyjny/pl/defaultaktualnosci/6375/2/1/1/pomiar_inflacji_stan_obecny_i_wyzwania.pdf) [dostęp: 19.04.2023].
7. Białek, J., Bobel, A. (2019), *Comparison of Price Index Methods for CPI Measurement Using Scanner Data*, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.
8. Białek, J. (2020), *Remarks on Price Index Methods for the CPI Measurement Using Scanner Data*, "Statistika - Statistics and Economy Journal", No. 100(1).
9. Białek, J. (2020), *Wykorzystanie danych skanowanych do pomiaru inflacji – doświadczenia międzynarodowe i wyzwania metodologiczne*, „Wiadomości Statystyczne”, Vol. 65(1), s. 9-33.
10. Białek, J., Beresewicz, M. (2020), *Scanner data in inflation measurement: from raw data to price indices*, <https://arxiv.org/abs/2005.11233> [dostęp: 19.04.2023].
11. Białek, J. (2022), *Improving quality of the scanner CPI: proposition of new multilateral methods*, "Quality & Quantity", doi: 10.1007/s11135-022-01506-6.
12. Białek, J.(2022), *The general class of multilateral indices and its two special cases*, 17th Meeting of the Ottawa Group, 7-10 June, Rome.
13. Białek, J., Kłopotek, M., Panek, T. (red.) (2022), *Nowoczesne technologie i nowe źródła danych w pomiarze inflacji*, Główny Urząd Statystyczny, Warszawa.

14. Białek, J., Sulewski P. (2022), *Probability Distribution Modeling of Scanner Prices and Relative Prices*, *Statistika*, 102(3): 282-298
15. BLS (2020), *Handbook of methods*, <https://www.bls.gov/opub/hom/cpi/pdf/cpi.pdf> [dostęp: 19.04.2023].
16. Bosch, O. (n.d.), *Uses of web skraping for official statistics ESTP course on Big Data Sources – Web, Social Media and Text Analytics*, [https://circabc.europa.eu/sd/a/5e250346-44a9-471b-87f1-5b5ddb59aa77/1\\_Big%20Data%20Sources%20part3-Day%201-A%20Use.pdf](https://circabc.europa.eu/sd/a/5e250346-44a9-471b-87f1-5b5ddb59aa77/1_Big%20Data%20Sources%20part3-Day%201-A%20Use.pdf) [dostęp: 19.04.2023].
17. Boskin, M.J., Dulberger, E., Gordon, R., Griliches, Z., Jorgenson, D. (1996), *Toward a More Accurate Measure of the Cost of Living*, Final Report to the Senate Finance Committee, (w:) *Getting Prices Right*, Roulledge, London.
18. Cavallo, A. (2020), *Inflation with Covid consumption baskets*, Working Paper 27352 <http://www.nber.org/papers/w27352> [dostęp: 19.04.2023].
19. Chessa, A.G. (2016), *A new methodology for processing scanner data in the Dutch CPI*, “Eurostat Review of National Accounts and Macroeconomic Indicators”, No. 1, <https://ec.europa.eu/eurostat/documents/3217494/7556543/KS-GP-16-001-EN-N.pdf/70e246de-734c-42ba-bee2-bc0b3dd97faa> [dostęp: 19.04.2023].
20. Chessa, A.G. (2019), *A comparison of index extension methods for multilateral methods*, 16th Meeting of the Ottawa Group on Price Indices, Rio de Janeiro.
21. Chessa, A.G., Griffioen, R. (2019), *Comparing Price Indices of Clothing and Footwear for Scanner Data and Web Skraped Data*, “Economie et Statistique / Economics and Statistics”, No. 509, s. 49-68, doi:10.24187/ecostat.2019.509.1984.
22. Chuanyang, F., Lee Wen Hao, J. (2016), *Experiences with the Use of Online Prices in Consumer Price Index*, Statistics Singapore Newsletter, Singapore.
23. Claeys, G., Guetta-Jeanrenaud, L. (2021), *How has COVID-19 affected inflation measurement in the euro area?*, Bruegel Blog, 24 March.
24. Crawford, A. (1998), *Measurement Biases in the Canadian CPI: An Update*, “Bank of Canada Review”, Spring, s. 38-56.
25. Dalen, J. (2017), *Unit values in scanner data and some operational issues*. Paper presented at the fifteenth Ottawa Group Meeting. Eltville am Rhein, Germany.
26. Diewert, W. (1976), *Exact and superlative index numbers*, “Journal of Econometrics”, No. 4, issue 2, s. 115-145,

- <https://EconPapers.repec.org/RePEc:eee:econom:v:4:y:1976:i:2:p:115-145> [dostęp: 19.04.2023].
27. Diewert, W.E. (2020), *The chain drift problem and multilateral indexes. Technical Report*, Discussion Paper 20-07, Vancouver School of Economics, Vancouver.
  28. Drudi, I. (2003), *The treatment of substitution bias in consumer price index: an alternative approach*, "Statistical Methods&Applications", No. 11, s. 397-398.
  29. Dubois, P., Griffith, R., O'Connell, M. (2022), *The Use of Scanner Data for Economics Research*, [https://pierredubois.github.io/DGO\\_ScannerData.pdf](https://pierredubois.github.io/DGO_ScannerData.pdf) [dostęp: 19.04.2023].
  30. Durcharme, L.M. (2000), The canadian CPI and the bias issue: present and future outlooks, "ESTADÍSTICA ESPAÑOLA", Vol. 42, Núm. 145, s. 29-30.
  31. Dutot, C. (1738), *Reflexions Politiques sur les Finances et le Commerce*, La Haye, Chez les Freres Vaillant & Nicolas Prevost.
  32. Eltető, Ö., Köves, P. (1964), *Egy nemzetközi összehasonlításoknál fellépő indexszámítási problémáról*, "Statisztikai Szemle", No. 42(10), s. 507–518, [https://www.ksh.hu/statszemle\\_archive/all/1964/1964\\_05/1964\\_05\\_0507\\_0518.pdf](https://www.ksh.hu/statszemle_archive/all/1964/1964_05/1964_05_0507_0518.pdf) [dostęp: 19.04.2023].
  33. Eurostat (2017), *Europejski Kodeks Praktyk Statystycznych dla krajowych organów statystycznych i Eurostatu (organu statystycznego UE)*, Luksemburg, doi: 10.2785/319604.
  34. Eurostat (2018), *Harmonised Index of Consumer Prices (HICP) Methodological Manual*, <https://ec.europa.eu/eurostat/documents/3859598/9479325/KS-GQ-17-015-EN-N.pdf/d5e63427-c588-479f-9b19-f4b4d698f2a2> [dostęp: 19.04.2023].
  35. Eurostat (2020), *Practical guidelines on web scraping for the HICP*, <https://ec.europa.eu/eurostat/documents/272892/12032198/Guidelines-web-scraping-HICP-11-2020.pdf/> [dostęp: 17.04.2023].
  36. Eurostat (2022), *Guide on Multilateral Methods in the Harmonised Index of Consumer Prices*, <https://ec.europa.eu/eurostat/documents/3859598/14503841/KS-GQ-21-020-EN-N.pdf/243796c9-f5ad-2155-e546-c94e17d9a7eb?t=1649074284236> [dostęp: 19.04.2023].
  37. Filer, R.K., Hanousek, J. (2003), *Inflationary bias in middle to late transition Czech Republic*, "Economic Systems", No. 27, s. 367-376.
  38. Galton F. (1879), *The geometric mean, in vital and social statistics*, "Proceedings of the Royal Society", 29: 365–367
  39. Gini, C. (1931), *On the circular test of index numbers*, "Metron", No. 9(9), s. 3-24.



40. Gordon, R.J., van Goethem, T. (2005), *A Century of Housing Shelter Prices: Is There a Downward Bias in the CPI?*, NBER Working Paper 11776.
41. Greenlees, J.S., McClelland, R. (2008), *New Evidence on Outlet Substitution Effects in Consumer Price Index Data*, BLS WORKING PAPERS 421.
42. GUS (2013), Systemy ważenia w badaniach cen towarów i usług konsumpcyjnych, [https://stat.gov.pl/gfx/portalinformacyjny/userfiles/public/wyniki\\_wstepne/coicop\\_12\\_2013.pdf](https://stat.gov.pl/gfx/portalinformacyjny/userfiles/public/wyniki_wstepne/coicop_12_2013.pdf) [dostęp: 19.04.2023].
43. GUS (2018), *Zeszyt metodologiczny. Badanie Budżetów Gospodarstw Domowych*, Warszawa.
44. de Haan, J., van der Grient, H.A. (2011), *Eliminating chain drift in price indexes based on scanner data*, "Journal of Econometrics", No. 161(1), s. 36–46. doi: 10.1016/j.jeconom.2010.09.004.
45. de Haan, J. (2015), *A Framework for Large Scale Use of Scanner Data in the Dutch CPI*, Paper presented at the fourteenth Ottawa Group Meeting, 20-22 May, Tokyo.
46. de Haan, J., Willenborg, L., Chessa, A.G. (2016), *An Overview of Price Index Methods for Scanner Data*, Paper presented at the Meeting of the Group of Experts on Consumer Price Indices, 2-4 May, Geneva.
47. Hałka, A., Leszczyńska, A. (2011), *Wady i zalety wskaźnika cen towarów i usług konsumpcyjnych – szacunki obciążenia dla Polski*, „Gospodarka Narodowa”, nr 9, s. 60-61.
48. IMF (2004), *Consumer Price Index Manual*, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms\\_331153.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/presentation/wcms_331153.pdf) [dostęp: 19.04.2023].
49. IMF (2020), *Consumer Price Index Manual Concepts and Methods*, [https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms\\_761444.pdf](https://www.ilo.org/wcmsp5/groups/public/---dgreports/---stat/documents/publication/wcms_761444.pdf) [dostęp: 19.04.2023].
50. Ivanic, L. (2005), *Can scanner data be used to reduce substitution bias in the CPI? : A review of the issues and evidence*, Centre for applied economic research, Working Paper 01.
51. Ivanic, L., Diewert, E.W., Fox, K. (2011), *Scanner data, time aggregation and the construction of price indexes*, "Journal of Econometrics", Vol. 161(1), s. 24-35.
52. Juszczak, A. (2018), *Pomiar i redukcja obciążenia wskaźnika cen dóbr i usług konsumpcyjnych (CPI)*, Praca Magisterska, Uniwersytet Łódzki, Łódź.

53. Juszczyk A. (2020), *Estimation of the Optimal Parameter of Delay in Young and Lowe Indices in the Fisher Index Approximation*, *Statistika: Statistics and Economy Journal* - No. 1/2020
54. Juszczyk A. (2021), *Zastosowanie danych scrapowanych w pomiarze dynamiki cen*, „Acta Universitatis Lodzianensis. Folia Oeconomica”, nr 1(352), s. 25-37.
55. Juszczyk, A. (2021), *Usage of skraped data in price dynamic measurement*, „Acta Universitatis Lodzianensis. Folia Oeconomica”, nr 1(352), s. 25-37, doi: 10.18778/0208-6018.352.02.
56. Juszczyk, A. (2023), *The use of web-scraped data to analyze the dynamics of clothing and footwear prices*, *Wiadomości Statystyczne* (praca zaakceptowana do druku)
57. Krsinich, F. (2014), *The FEWS index: fixed effects with a window splice – non-revisable qualityadjusted price indexes with no characteristic information*, Meeting of the Group of Experts on Consumer Price Indices, Geneva.
58. Lamboray, C. (2017), *The Geary Khamis index and the Lehr index: how much do they differ?*, 15th meeting of the Ottawa Group, Eltville.
59. Lamboray, C. (2021), *Index Compilation Techniques for Scanner Data*, [https://unece.org/sites/default/files/2021-05/Session\\_1\\_Eurostat\\_Paper.pdf](https://unece.org/sites/default/files/2021-05/Session_1_Eurostat_Paper.pdf) [dostęp: 17.04.2023].
60. Lequiller, F. (1997), *L'indice des prix à la consommation surestime-t-il l'inflation?*, „Economie et statistique”, No. 303, s. 3-32.
61. Levell, P. (2015), *Is the Carli index flawed?: assessing the case for the new retail price index RPIJ*. “Journal of Royal Statistical Society”, No. 178(2), s. 303-336, doi: 10.1111/rssa.12061.
62. Macias, P., Stelmasiak, D. (2018), *Food Inflation nowcasting with web skraped data*, “NBP Working Paper”, No. 302.
63. Marini, G., Piergallini, A., Scaramozzino, P. (2007), *Inflation bias after the Euro: evidence from the UK and Italy*, “Applied Economics”, Vol. 39, No. 4, s. 461-470.
64. Nahm, D. (2015), *The Effects of New Goods and Substitution on the Korean CPI as a Measure of Cost of Living*, “International Economic Journal”, Vol. 29, No. 1 s. 59.
65. Ngasamiaku, A., Mkenda, W. (2009), *An Analysis of Alternative Weighting System on the National Price Index in Tanzania: The Implication to Poverty Analysis*, “Botswana Journal of Economics”, Vol. 6, No. 10, s. 50-70.
66. Nordhaus, W.D. (1998), *Quality Change in Price Indexes*, “Journal of Economic Perspectives”, Vol. 12, s. 59-68.

67. O'Neill, R., Ralph, J., Smith, P. (2018), *The Rise and Rise of Inflation*, "Significance", Vol. 15, Iss. 2, s. 32-37, doi: 10.1111/j.1740-9713.2018.01129.x.
68. Quenouille, M. (1949), *Approximations tests of correlations in time series*, "Journal of the Royal Statistical Society", Series B, No. 11, s. 533-538.
69. Polidoro, F., Giannini, R., Lo Conte, R., Mosca, S., Rosetti, F. (2015), *Web scraping techniques to collect data on consumer electronics and airfares for Italian HICP compilation*, "Statistical Journal of the IAOS", No. 31(2), s. 165-176, doi: 10.3233/sji-150901
70. Rada Europy (1995), Regulacja nr 2494/95, <https://eur-lex.europa.eu/legal-content/PL/ALL/?uri=CELEX%3A31995R2494> [dostęp: 19.04.2023].
71. Radzikowski, B., Smietanka, A. (2016), *Online CASE CPI, Proceedings of the 1st International Conference on Advanced Research Methods and Analytics*, Universitat Politècnica de València, Valencia,
72. Ruiz-Castillo, J., Ley, E., Izquierdo, M. (2002), *The Laspeyres bias in the Spanish consumer price index*, "Applied Economics", Vol. 34, Nro.18, s. 2267-76.
73. Szulc, B. (1964), *Indices for multiregional comparisons*, "Przegląd Statystyczny", nr 3, s. 239-254.
74. Tongur, C. (2019), *Inflation Measurement with Scanner Data and an Ever-Changing Fixed Basket*, "Economie et Statistique / Economics and Statistics", No. 509, s. 31-47, doi: 10.24187/ecostat.2019.509.1982.
75. Tukey, J. (1958), *Bias and confidence in not quite large samples*, "Annals of Mathematical Statistics", No. 29, s. 614.
76. Unayama, T. (2004), *Upward bias in the consumer price index under the zero-inflation economy*, "Economic Letters", No. 85, s. 139-144.
77. Unayama, T. (2008), *Measuring the substitution bias in Japan: the demand system approach and a superlative index*, "Applied Economics", No. 40, s. 1795–1806.
78. von der Lippe, Peter (2012), *Covariances and relationships between price indices: Notes on a theorem of Ladislaus von Bortkiewicz on linear index functions*, <https://mpra.ub.uni-muenchen.de/38566/> [dostęp: 19.04.2023].
79. Van Loon, K., Roels, D. (2018), *Integrating big data in the Belgian CPI*, Meeting of the Group of Experts on Consumer Price Indices, Geneva.
80. Watanabe, K., Watanabe T. (2014), *Estimating Daily Inflation Using Scanner Data: A progress report, Understanding Persistent Deflation in Japan*, "Working Paper Series", No. 037

81. Wells, J., Restieaux, A. (2014), *Review of Hedonic Quality Adjustment in UK Consumer Price Statistics and Internationally*, ONS, <https://www.data.gov.uk/dataset/9f837ab0-4508-4f91-bd14-92b7b9674f1a/review-of-hedonic-quality-adjustment-in-uk-consumer-price-statistics-and-internationally> [dostęp: 19.04.2023].
82. Zhang, L. (2020), *Proxy expenditure weights for Consumer Price Index: audit sampling inference for big-data statistics*, "Journal of the Royal Statistical Society", Series A, <https://rss.onlinelibrary.wiley.com/doi/epdf/10.1111/rssa.12632> [dostęp: 19.04.2023].


## Źródła internetowe

1. [https://ec.europa.eu/eurostat/cache/metadata/en/prc\\_hicp\\_esmshi\\_pl.htm](https://ec.europa.eu/eurostat/cache/metadata/en/prc_hicp_esmshi_pl.htm) [dostęp: 19.04.2023].
2. [https://ec.europa.eu/eurostat/cache/metadata/EN/prc\\_hicp\\_esmshi\\_lt.htm](https://ec.europa.eu/eurostat/cache/metadata/EN/prc_hicp_esmshi_lt.htm) [dostęp: 19.04.2023].
3. <https://forsal.pl/artykuly/1456807,bialek-metoda-pomiaru-inflacji-ewoluuje-i-jej-zmiany-sa-konieczne-wywiad.html> [dostęp: 19.04.2023].
4. <https://eur-lex.europa.eu/eli/reg/2010/1114/oj> [dostęp: 19.04.2023].
5. <https://eur-lex.europa.eu/eli/reg/2013/93/oj> [dostęp: 19.04.2023].
6. <https://www.rba.gov.au/education/resources/explainers/inflation-and-its-measurement.html> [dostęp: 19.04.2023].
7. <https://stat.gov.pl/metainformacje/slownik-pojec/pojecia-stosowane-w-statystyce-publicznej/422,pojecie.html> [dostęp: 19.04.2023].
8. <https://stat.gov.pl/dla-mediow/komunikaty-prasowe/wskaznik-cen-towarow-i-uslug-konsumpcyjnych-pot-inflacja,100,1.html> [dostęp: 19.04.2023].
9. <https://www.bls.gov/cpi/quality-adjustment/questions-and-answers.htm> [dostęp: 19.04.2023].
10. <https://eu.usatoday.com/story/tech/news/2019/03/12/world-wide-web-turns-30-berners-lee-contract-thoughts-internet/3137726002/> [dostęp: 19.04.2023].
11. <https://eu.usatoday.com/story/tech/news/2019/03/12/world-wide-web-turns-30-berners-lee-contract-thoughts-internet/3137726002/> [dostęp: 19.04.2023].
12. <http://www.inflacionverdadera.com/argentina/english/> [dostęp: 19.04.2023].
13. <https://www.pricestats.com/inflation-series> [dostęp: 19.04.2023].

14. [https://www.unescap.org/sites/default/files/incorporating\\_non\\_traditional\\_sources\\_CP\\_I.pdf](https://www.unescap.org/sites/default/files/incorporating_non_traditional_sources_CP_I.pdf) [dostęp: 19.04.2023].
15. [https://konferencja230.stat.gov.pl/K230/Content/File/presentation\\_JBialekABobel.pdf](https://konferencja230.stat.gov.pl/K230/Content/File/presentation_JBialekABobel.pdf) [dostęp: 19.04.2023].
16. <https://stat.gov.pl/statystyki-eksperymentalne/gospostrateg/instatceny/> [dostęp: 19.04.2023].
17. <https://www.efta.int/Statistics/news/Transaction-data-consumer-price-index-518411> [dostęp: 19.04.2023].
18. [https://www.jef.or.jp/journal/pdf/191st\\_cover2-03.pdf](https://www.jef.or.jp/journal/pdf/191st_cover2-03.pdf) [dostęp: 19.04.2023].
19. <https://www.imf.org/-/media/Files/Data/CPI/chapter-10-scanner-data.ashx> [dostęp: 19.04.2023].
20. <https://circabc.europa.eu/sd/a/8e1333df-ca16-40fc-bc6a-1ce1be37247c/Practical-Guide-Supermarket-Scanner-Data-September-2017.pdf> [dostęp: 19.04.2023].
21. <https://www.sciencedirect.com/topics/engineering/lognormal-distribution>
22. <https://unctad.org/news/covid-19-has-changed-online-shopping-forever-survey-shows> [dostęp: 19.04.2023]

# Aneks

Wykres 98. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 57. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,683	0,65	0,033
half splice	1,017	0,984	0,033
movement splice	0,787	0,754	0,033
mean splice	0,898	0,865	0,033
GEKS-J	0	0	0
FBEW	1,084	1,039	0,045
FBMW	0,842	0,807	0,035

Źródło: opracowanie własne w R.

Wykres 99. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 58. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,234	0,002	0,232
half splice	0,278	0	0,278
movement splice	0,237	0,002	0,236
mean splice	0,222	0,003	0,219
GEKS-J	0	0	0
FBEW	0,379	0,01	0,369

Źródło: opracowanie własne w R.

Wykres 100. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.


Tabela 59. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,102	0,713	0,389
half splice	1,161	0,257	0,904
movement splice	1,079	0,363	0,716
mean splice	1,016	0,168	0,848
GEKS-J	0	0	0
FBEW	3,078	1,759	1,319
FBMW	1,293	0,59	0,703

Źródło: opracowanie własne w R.



Wykres 101. Analiza metod rozszerzania okna indeksu GEKS-L dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 60. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,29	0,113	0,177
half splice	0,255	0,208	0,047
movement splice	0,472	0,458	0,014
mean splice	0,351	0,337	0,014
GEKS-L	0	0	0
FBEW	0,514	0,456	0,058
FBMW	0,417	0,374	0,043

Źródło: opracowanie własne w R.

Wykres 102. Analiza metod rozszerzeń okna indeksu GEKS-L dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 61. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,103	0,025	0,079
half splice	0,168	0,022	0,146
movement splice	0,096	0,03	0,066
mean splice	0,129	0,025	0,104
GEKS-L	0	0	0
FBEW	0,274	0,041	0,234

Źródło: opracowanie własne w R.

Wykres 103. Analiza metod rozszerzeń okna indeksu GEKS-L dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 62. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,433	0,824	0,609
half splice	1,321	0,55	0,772
movement splice	1,589	0,709	0,88
mean splice	1,194	0,083	1,111
GEKS-GL	0	0	0
FBEW	3,382	1,374	2,008
FBMW	2,079	1,035	1,044

Źródło: opracowanie własne w R.

Wykres 104. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 63. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,29	0,086	0,203
half splice	0,264	0,222	0,042
movement splice	0,507	0,477	0,03
mean splice	0,334	0,305	0,03
GEKS-GL	0	0	0
FBEW	0,442	0,399	0,044
FBMW	0,4	0,356	0,044

Źródło: opracowanie własne w R.

Wykres 105. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży mleka




Źródło: opracowanie własne w R

Wykres 106. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,097	0,02	0,077
half splice	0,149	0,019	0,129
movement splice	0,079	0,036	0,044
mean splice	0,11	0,021	0,089
GEKS-GL	0	0	0
FBEW	0,256	0,026	0,23

Źródło: opracowanie własne w R.

Wykres 107. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 64. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,372	0,748	0,623
half splice	1,248	0,499	0,749
movement splice	1,538	0,77	0,768
mean splice	1,136	0,085	1,051
GEKS-GL	0	0	0
FBEW	3,12	1,366	1,754
FBMW	1,701	1,006	0,695

Źródło: opracowanie własne w R.

Wykres 108. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 65. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,296	0,123	0,173
half splice	0,266	0,229	0,037
movement splice	0,472	0,46	0,012
mean splice	0,379	0,367	0,012
GEKS-AQI	0	0	0
FBEW	0,564	0,52	0,045
FBMW	0,431	0,394	0,036

Źródło: opracowanie własne w R.

Wykres 109. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży mleka



Źródło: opracowanie własne w R.


Tabela 66. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,105	0,027	0,078
half splice	0,168	0,024	0,144
movement splice	0,099	0,031	0,068
mean splice	0,132	0,026	0,105
GEKS-AQI	0	0	0
FBEW	0,277	0,048	0,228

Źródło: opracowanie własne w R.



Wykres 110. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 67. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,317	0,807	0,51
half splice	1,323	0,586	0,737
movement splice	1,495	0,732	0,762
mean splice	1,135	0,104	1,031
GEKS-AQI	0	0	0
FBEW	3,596	1,328	2,268
FBMW	2,183	1,026	1,157

Źródło: opracowanie własne w R.

Wykres 111. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 68. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,289	0,107	0,183
half splice	0,245	0,195	0,05
movement splice	0,453	0,437	0,016
mean splice	0,335	0,32	0,016
CCDI	0	0	0
FBEW	0,502	0,44	0,062
FBMW	0,407	0,357	0,05

Źródło: opracowanie własne w R.

Wykres 112. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 69. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,103	0,025	0,078
half splice	0,17	0,022	0,148
movement splice	0,098	0,029	0,069
mean splice	0,131	0,025	0,107
CCDI	0	0	0
FBEW	0,277	0,04	0,237

Źródło: opracowanie własne w R.

Wykres 113. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 70. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,003	0,335	0,668
half splice	1,441	1,147	0,294
movement splice	0,98	0,462	0,519
mean splice	0,919	0,291	0,627
CCDI	0	0	0
FBEW	3,386	1,505	1,881
FBMW	2,261	1,064	1,198

Źródło: opracowanie własne w R.

Wykres 114. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 71. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,158	0,131	0,027
half splice	0,496	0,484	0,012
movement splice	0,216	0,201	0,014
mean splice	0,316	0,304	0,012
CCDI	0	0	0
FBEW	0,559	0,489	0,07
FBMW	0,412	0,302	0,11

Źródło: opracowanie własne w R.

Wykres 115. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 72. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,061	0,03	0,03
half splice	0,093	0,024	0,07
movement splice	0,059	0,027	0,032
mean splice	0,075	0,023	0,052
CCDI	0	0	0
FBEW	0,147	0,013	0,134

Źródło: opracowanie własne w R.

Wykres 116. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 73. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,475	0,66	0,815
half splice	1,386	0,456	0,93
movement splice	1,709	0,609	1,1
mean splice	1,325	0,059	1,265
CCDI	0	0	0
FBEW	3,918	1,475	2,444
FBMW	1,519	0,629	0,89

Źródło: opracowanie własne w R.

Wykres 117. Analiza metod rozszerzeń okna indeksu Geary'ego-Khamisa dla danych o sprzedaży kawy



Źródło: opracowanie własne w R.


Tabela 74. Średnia różnica między metodami rozszerzania okna a indeksem Geary'ego-Khamisa dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,25	0,178	0,072
half splice	0,502	0,468	0,033
movement splice	0,245	0,178	0,067
mean splice	0,243	0,199	0,044
CCDI	0	0	0
FBEW	0,887	0,655	0,232
FBMW	0,471	0,303	0,168

Źródło: opracowanie własne w R.



Wykres 118. Analiza metod rozszerzeń okna indeksu Geary'ego-Khamisa dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 75. Średnia różnica między metodami rozszerzania okna a indeksem Geary'ego-Khamisa dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,156	0,115	0,042
half splice	0,136	0,066	0,07
movement splice	0,146	0,068	0,078
mean splice	0,13	0,075	0,055
CCDI	0	0	0
FBEW	0,38	0,206	0,174

Źródło: opracowanie własne w R.

Wykres 119. Analiza metod rozszerzeń okna indeksu Geary-Khamisa dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Tabela 76. Średnia różnica między metodami rozszerzania okna a indeksem Gearego-Khamisa dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	2,277	1,601	0,676
half splice	2,554	0,861	1,693
movement splice	2,79	2,057	0,733
mean splice	1,977	0,479	1,498
CCDI	0	0	0
FBEW	5,966	2,538	3,428
FBMW	2,632	1,592	1,04

Źródło: opracowanie własne w R.

Wykres 120. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży kawy




Źródło: opracowanie własne w R.

Tabela 77. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży kawy

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,26	0,21	0,051
half splice	0,503	0,477	0,026
movement splice	0,21	0,157	0,053
mean splice	0,231	0,2	0,03
CCDI	0	0	0
FBEW	0,775	0,543	0,232
FBMW	0.426	0.283	0.143

Źródło: opracowanie własne w R.

Wykres 121. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży mleka




Źródło: opracowanie własne w R.

Tabela 78. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży mleka

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	0,154	0,112	0,042
half splice	0,134	0,054	0,08
movement splice	0,15	0,054	0,096
mean splice	0,118	0,059	0,058
CCDI	0	0	0
FBEW	0,297	0,161	0,136

Źródło: opracowanie własne w R.

Wykres 122. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży owoców



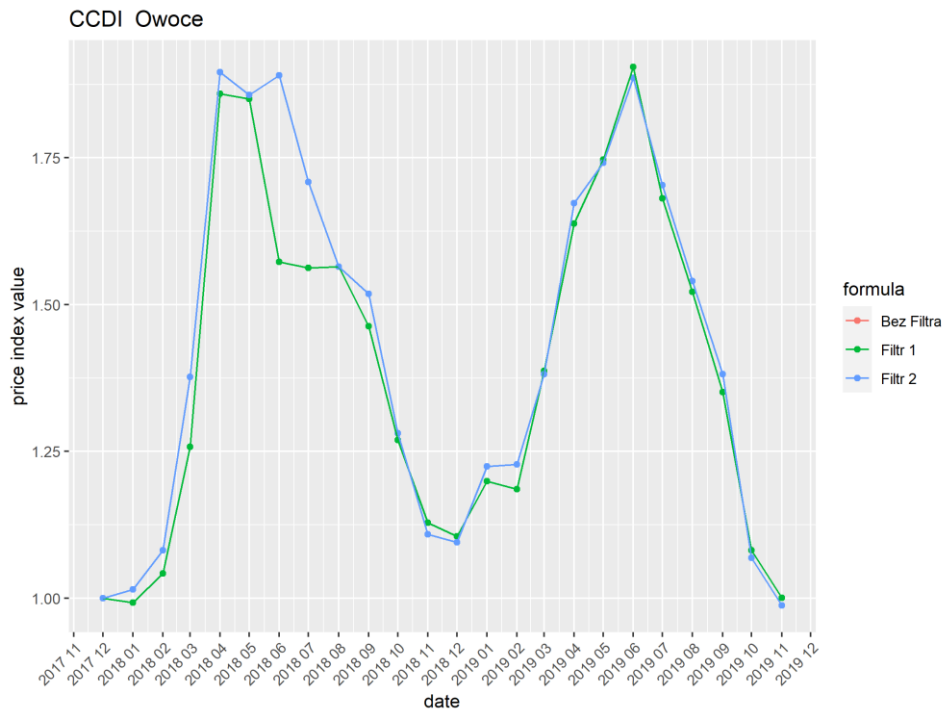
Źródło: opracowanie własne w R.

Tabela 79. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży owoców

Indeks	Średni błąd absolutny	Średnia absolutna różnica wartości poniżej indeksu referencyjnego	Średnia absolutna różnica wartości powyżej indeksu referencyjnego
window splice	1,985	1,197	0,788
half splice	2,523	0,81	1,713
movement splice	2,761	1,843	0,918
mean splice	2,025	0,391	1,634
CCDI	0	0	0
FBEW	6,021	2,463	3,558
FBMW	2.701	1.503	1.198


Źródło: opracowanie własne w R.

Wykres 123. Porównanie metod filtrowania indeksu CCDI dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 124. Porównanie metod filtrowania indeksu Geary'ego-Khamisa dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 125. Porównanie metod filtrowania indeksu TPD dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 126. Porównanie metod filtrowania indeksu GEKS-GL dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 127. Porównanie metod filtrowania indeksu GEKS-AQI dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.


Wykres 128. Porównanie metod filtrowania indeksu GEKS-AQU dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.




Wykres 129. Porównanie metod filtrowania indeksu GEKS-J dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 130. Porównanie metod filtrowania indeksu Sato-Vartia dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 131. Porównanie metod filtrowania łańcuchowego indeksu Sato Vartia dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 132. Porównanie metod filtrowania dla łańcuchowego indeksu Walsh dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 133. Porównanie metod filtrowania indeksu Walsha dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 134. Porównanie metod filtrowania indeksu Törnqvista dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 135. Porównanie metod filtrowania łańcuchowego indeksu Paaschego dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 136. Porównanie metod filtrowania łańcuchowego indeksu Laspeyresa dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 137. Porównanie metod filtrowania łańcuchowego indeksu Fishera dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 138. Porównanie metod filtrowania łańcuchowego indeksu Jevonsa dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 139. Porównanie metod filtrowania indeksu Törnqvista dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 140. Porównanie metod filtrowania indeksu Paaschego dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 141. Porównanie metod filtrowania indeksu Laspeyresa dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 142. Porównanie metod filtrowania indeksu Fishera dla danych o sprzedaży owoców




Źródło: opracowanie własne w R.

Wykres 143. Porównanie metod filtrowania indeksu Jevonsa dla danych o sprzedaży owoców



Źródło: opracowanie własne w R.


Wykres 144. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Törnqvista dla danych o sprzedaży mleka (w sekundach)



Źródło: opracowanie własne.




Wykres 145. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Törnqvista dla danych o sprzedaży kawy (w sekundach)




Źródło: opracowanie własne.

Wykres 146. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży mleka (w sekundach)




Źródło: opracowanie własne.

Wykres 147. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży kawy (w sekundach)




Źródło: opracowanie własne.

Wykres 148. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu GEKS-J dla danych o sprzedaży mleka (w sekundach)



Źródło: opracowanie własne.

Wykres 149. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu GEKS-J dla danych o sprzedaży kawy (w sekundach)



Źródło: opracowanie własne.

## Spis tabel i wykresów

Wykres 1. Porównanie wartości indeksów HICP i CPI w okresie I 2021 - VIII 2022.....	14
Wykres 2. Porównanie zmian udziału 12 głównych kategorii COICOP w koszyku inflacyjnym w UE-27 .....	25
Wykres 3. Porównanie zmian udziału 12 głównych kategorii COICOP w koszyku inflacyjnym w Polsce .....	25
Wykres 4. Odsetek osób, które dokonały przynajmniej jednego zakupu przez internet w 2021 r.....	30
Wykres 5. Różnice między dynamiką cen transportu liczoną metodą tradycyjną i z udziałem danym skrapowanych (w pkt. proc.) .....	37
Wykres 6. Odsetek obecności produktów w kolejnych miesiącach analizy .....	70
Wykres 7. Odsetek obecności produktów z kategorii kobiece obuwie w kolejnych miesiącach analizy .....	71
Wykres 8. Odsetek obecności produktów z kategorii męskie obuwie w kolejnych miesiącach analizy	71
Wykres 9. Odsetek obecności produktów z kategorii odzież damska w kolejnych miesiącach analizy	71
Wykres 10. Odsetek obecności produktów z kategorii odzież męska w kolejnych miesiącach analizy	71
Wykres 11. Porównanie wartości dla jednopodstawowych indeksów bilateralnych. ....	73
Wykres 12. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla damskiego obuwia.....	74
Wykres 13. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla obuwia męskiego .....	74
Wykres 14. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla damskiej odzieży.....	74
Wykres 15. Porównanie wartości dla jednopodstawowych indeksów bilateralnych dla męskiej odzieży .....	74
Wykres 16. Porównanie wartości dla indeksów łańcuchowych.....	76

Wykres 17. Porównanie wartości dla indeksów łańcuchowych dla damskiego obuwia.....	77
Wykres 18. Porównanie wartości dla indeksów łańcuchowych dla męskiego obuwia.....	77
Wykres 19. Porównanie wartości dla indeksów łańcuchowych dla damskiej odzieży.....	77
Wykres 20. Porównanie wartości dla indeksów łańcuchowych dla męskiej odzieży.....	77
Wykres 21. Porównanie wartości dla formuł bazujących na indeksie Jevonsa i nieważonego indeksu TPD dla mokasynów .....	80
Wykres 22. Porównanie metod rozszerzeń okna indeksu GEKS-J dla pełnego zestawu danych.....	81
Wykres 23. Porównanie metod rozszerzeń okna indeksu GEKS-J dla kategorii Mokasyny .....	83
Wykres 24. Porównanie metod rozszerzeń okna nieważonego indeksu TPD dla kategorii Mokasyny	84
Wykres 25. Porównanie wyników filtrowania danych dla indeksu Jevonsa dla pełnego zestawu danych .....	89
Wykres 26. Porównanie wyników filtrowania danych dla indeksu Dutot dla pełnego zestawu danych .....	89
Wykres 27. Porównanie wyników filtrowania danych dla indeksu Carliego dla pełnego zestawu danych .....	90
Wykres 28. Porównanie wyników filtrowania danych dla indeksu Jevonsa dla kategorii Mokasyny...	91
Wykres 29. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Jevonsa dla pełnego zestawu danych.....	92
Wykres 30. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Dutot dla pełnego zestawu danych.....	92
Wykres 31. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Carliego dla pełnego zestawu danych.....	93
Wykres 32. Porównanie wyników filtrowania danych dla łańcuchowego indeksu Jevonsa dla kategorii Mokasyny .....	93
Wykres 33. Porównanie wyników filtrowania danych dla indeksu GEKS-J dla pełnego zestawu danych .....	94
Wykres 34. Porównanie wyników filtrowania danych dla indeksu GEKS-J dla kategorii Mokasyny.....	95
Wykres 35. Porównanie wyników filtrowania danych dla nieważonego indeksu TPD dla kategorii Mokasyny .....	95
Wykres 36. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży kawy .....	99
Wykres 37. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży mleka.....	100
Wykres 38. Odsetek produktów z pierwszego okresu obecnych w kolejnych okresach analizy dla danych o sprzedaży owoców.....	100
Wykres 39. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży mleka .....	101
Wykres 40. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży kawy	102
Wykres 41. Porównanie wartości dla indeksów jednopodstawowych dla danych o sprzedaży owoców .....	103
Wykres 42. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży mleka.....	103
Wykres 43. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży kawy .....	104
Wykres 44. Porównanie wartości dla indeksów łańcuchowych dla danych o sprzedaży owoców .....	105
Wykres 45. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży kawy.....	106
Wykres 46. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży mleka .....	107
Wykres 47. Porównanie wartości dla indeksów multilateralnych dla danych o sprzedaży owoców .	108
Wykres 49. Porównanie metod filtrowania dla indeksu Fishera wyznaczonego dla danych o sprzedaży kawy.....	115

Wykres 50. Porównanie metod filtrowania dla indeksu Fishera wyznaczonego dla danych o sprzedaży mleka.....	115
Wykres 51. Porównanie metod filtrowania dla indeksu Jevonsa wyznaczonego dla danych o sprzedaży kawy.....	116
Wykres 52. Porównanie metod filtrowania dla indeksu Jevonsa wyznaczonego dla danych o sprzedaży mleka.....	117
Wykres 53. Porównanie metod filtrowania dla indeksu Laspeyresa wyznaczonego dla danych o sprzedaży kawy .....	117
Wykres 54. Porównanie metod filtrowania dla indeksu Laspeyresa wyznaczonego dla danych o sprzedaży mleka.....	118
Wykres 55. Porównanie metod filtrowania dla indeksu Paaschego wyznaczonego dla danych o sprzedaży mleka.....	119
Wykres 56. Porównanie metod filtrowania dla indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży kawy .....	119
Wykres 57. Porównanie metod filtrowania dla indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży mleka.....	120
Wykres 58. Porównanie metod filtrowania dla indeksu Törnqvista wyznaczonego dla danych o sprzedaży kawy .....	121
Wykres 59. Porównanie metod filtrowania dla indeksu Törnqvista wyznaczonego dla danych o sprzedaży mleka.....	121
Wykres 60. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży kawy .....	122
Wykres 61. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży mleka.....	122
Wykres 62. Porównanie metod filtrowania dla łańcuchowego indeksu Fishera wyznaczonego dla danych o sprzedaży kawy .....	123
Wykres 63. Porównanie metod filtrowania dla łańcuchowego indeksu Fishera wyznaczonego dla danych o sprzedaży mleka.....	124
Wykres 64. Porównanie metod filtrowania dla łańcuchowego indeksu Jevonsa wyznaczonego dla danych o sprzedaży kawy .....	124
Wykres 65. Porównanie metod filtrowania dla łańcuchowego indeksu Jevonsa wyznaczonego dla danych o sprzedaży mleka.....	125
Wykres 66. Porównanie metod filtrowania dla łańcuchowego indeksu Laspeyresa wyznaczonego dla danych o sprzedaży kawy .....	126
Wykres 67. Porównanie metod filtrowania dla łańcuchowego indeksu Laspeyresa wyznaczonego dla danych o sprzedaży mleka.....	126
Wykres 68. Porównanie metod filtrowania dla łańcuchowego indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży kawy .....	127
Wykres 69. Porównanie metod filtrowania dla łańcuchowego indeksu Sato-Vartia wyznaczonego dla danych o sprzedaży mleka.....	128
Wykres 70. Porównanie metod filtrowania dla łańcuchowego indeksu Törnqvista wyznaczonego dla danych o sprzedaży kawy .....	128

Wykres 71. Porównanie metod filtrowania dla łańcuchowego indeksu Törnqvista wyznaczonego dla danych o sprzedaży mleka.....	129
Wykres 72. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży kawy .....	129
Wykres 73. Porównanie metod filtrowania dla indeksu Walsha wyznaczonego dla danych o sprzedaży mleka.....	130
Wykres 74. Porównanie metod filtrowania dla indeksu CCDI wyznaczonego dla danych o sprzedaży kawy .....	130
Wykres 75. Porównanie metod filtrowania dla indeksu CCDI wyznaczonego dla danych o sprzedaży mleka.....	131
Wykres 76. Porównanie metod filtrowania dla indeksu Geary'ego-Khamisa wyznaczonego dla danych o sprzedaży kawy .....	131
Wykres 77. Porównanie metod filtrowania dla indeksu Geary'ego - Khamisa wyznaczonego dla danych o sprzedaży mleka.....	132
Wykres 78. Porównanie metod filtrowania dla indeksu TPD wyznaczonego dla danych o sprzedaży kawy .....	132
Wykres 79. Porównanie metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI wyznaczonego dla danych o sprzedaży kawy.....	133
Wykres 80. Porównanie metod filtrowania dla indeksu TPD wyznaczonego dla danych o sprzedaży mleka .....	134
Wykres 81. Porównanie metod filtrowania dla indeksów GEKS-L, GEKS-GL, GEKS-AQU i GEKS-AQI wyznaczonego dla danych o sprzedaży mleka .....	134
Wykres 82. Porównanie metod filtrowania dla indeksu GEKS-J wyznaczonego dla danych o sprzedaży kawy .....	135
Wykres 83. Porównanie metod filtrowania dla indeksu GEKS-J wyznaczonego dla danych o sprzedaży mleka.....	135
Wykres 84. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu CCDI dla danych o sprzedaży mleka .....	142
Wykres 85. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu CCDI dla danych o sprzedaży kawy.....	142
Wykres 86. Czas kalkulacji dla poszczególnych metod agregacji danych dla łańcuchowego indeksu Jevonsa dla danych o sprzedaży mleka .....	143
Wykres 87. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży kawy .....	143
Wykres 88. Porównanie wyników zmienności dla wybranych indeksów dla pierwszego zestawu danych .....	146
Wykres 89. Porównanie wyników zmienności dla wybranych indeksów dla drugiego zestawu danych .....	147
Wykres 90.. Porównanie wyników zmienności dla wybranych indeksów dla trzeciego zestawu danych .....	148
Wykres 91. Porównanie wyników zmienności dla wybranych indeksów dla czwartego zestawu danych .....	149
Wykres 92.. Porównanie wyników zmienności dla wybranych indeksów dla piątego zestawu danych .....	150
Wykres 93. Porównanie wyników zmienności dla wybranych indeksów dla szóstego zestawu danych .....	151

Wykres 94. Porównanie wyników zmienności dla wybranych indeksów dla siódmego zestawu danych .....	152
Wykres 95. Średni czas obliczeń wybranych indeksów dla 10 produktów (w sekundach) .....	153
Wykres 96. Średni czas obliczeń wybranych indeksów dla 100 produktów (w sekundach) .....	154
Wykres 97. Średni czas obliczeń wybranych indeksów dla 1000 produktów z wyłączeniem indeksu TPD (w sekundach) .....	155
Wykres 98. Średni czas obliczeń wybranych indeksów dla 1000 produktów (w sekundach) .....	156
Wykres 99. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży kawy .....	174
Wykres 100. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży mleka .....	175
Wykres 101. Analiza metod rozszerzania okna indeksu GEKS-J dla danych o sprzedaży owoców .....	176
Wykres 102. Analiza metod rozszerzania okna indeksu GEKS-L dla danych o sprzedaży kawy .....	177
Wykres 103. Analiza metod rozszerzeń okna indeksu GEKS-L dla danych o sprzedaży mleka .....	178
Wykres 104. Analiza metod rozszerzeń okna indeksu GEKS-L dla danych o sprzedaży owoców .....	179
Wykres 105. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży kawy .....	180
Wykres 106. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży mleka .....	181
Wykres 107. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży mleka .....	181
Wykres 108. Analiza metod rozszerzeń okna indeksu GEKS-GL dla danych o sprzedaży owoców .....	182
Wykres 109. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży kawy .....	183
Wykres 110. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży mleka .....	184
Wykres 111. Analiza metod rozszerzeń okna indeksu GEKS-AQI dla danych o sprzedaży owoców .....	185
Wykres 112. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży kawy .....	186
Wykres 113. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży mleka .....	187
Wykres 114. Analiza metod rozszerzeń okna indeksu GEKS-AQU dla danych o sprzedaży owoców .....	188
Wykres 115. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży kawy .....	189
Wykres 116. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży mleka .....	190
Wykres 117. Analiza metod rozszerzeń okna indeksu CCDI dla danych o sprzedaży owoców .....	191
Wykres 118. Analiza metod rozszerzeń okna indeksu Geary'ego-Khamisa dla danych o sprzedaży kawy .....	192
Wykres 119. Analiza metod rozszerzeń okna indeksu Geary'ego-Khamisa dla danych o sprzedaży mleka .....	193
Wykres 120. Analiza metod rozszerzeń okna indeksu Geary'ego-Khamisa dla danych o sprzedaży owoców .....	194
Wykres 121. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży kawy .....	195
Wykres 122. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży mleka .....	196
Wykres 123. Analiza metod rozszerzeń okna indeksu TPD dla danych o sprzedaży owoców .....	197
Wykres 124. Porównanie metod filtrowania indeksu CCDI dla danych o sprzedaży owoców .....	198
Wykres 125. Porównanie metod filtrowania indeksu Geary'ego-Khamisa dla danych o sprzedaży owoców .....	198
Wykres 126. Porównanie metod filtrowania indeksu TPD dla danych o sprzedaży owoców .....	199
Wykres 127. Porównanie metod filtrowania indeksu GEKS-GL dla danych o sprzedaży owoców .....	199
Wykres 128. Porównanie metod filtrowania indeksu GEKS-AQI dla danych o sprzedaży owoców .....	200
Wykres 129. Porównanie metod filtrowania indeksu GEKS-AQU dla danych o sprzedaży owoców .....	200
Wykres 130. Porównanie metod filtrowania indeksu GEKS-J dla danych o sprzedaży owoców .....	201
Wykres 131. Porównanie metod filtrowania indeksu Sato-Vartia dla danych o sprzedaży owoców .....	201
Wykres 132. Porównanie metod filtrowania łańcuchowego indeksu Sato Varyia dla danych o sprzedaży owoców .....	202

Wykres 133. Porównanie metod filtrowania dla łańcuchowego indeksu Walsha dla danych o sprzedaży owoców .....	202
Wykres 134. Porównanie metod filtrowania indeksu Walsha dla danych o sprzedaży owoców .....	203
Wykres 135. Porównanie metod filtrowania indeksu Törnqvista dla danych o sprzedaży owoców ..	203
Wykres 136. Porównanie metod filtrowania łańcuchowego indeksu Paaschego dla danych o sprzedaży owoców .....	204
Wykres 137. Porównanie metod filtrowania łańcuchowego indeksu Laspeyresa dla danych o sprzedaży owoców .....	204
Wykres 138. Porównanie metod filtrowania łańcuchowego indeksu Fishera dla danych o sprzedaży owoców .....	205
Wykres 139. Porównanie metod filtrowania łańcuchowego indeksu Jevonsa dla danych o sprzedaży owoców .....	205
Wykres 140. Porównanie metod filtrowania indeksu Törnqvista dla danych o sprzedaży owoców ..	206
Wykres 141. Porównanie metod filtrowania indeksu Paaschego dla danych o sprzedaży owoców ..	206
Wykres 142. Porównanie metod filtrowania indeksu Laspeyresa dla danych o sprzedaży owoców .	207
Wykres 143. Porównanie metod filtrowania indeksu Fishera dla danych o sprzedaży owoców .....	207
Wykres 144. Porównanie metod filtrowania indeksu Jevonsa dla danych o sprzedaży owoców .....	208
Wykres 145. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Törnqvista dla danych o sprzedaży mleka (w sekundach) .....	208
Wykres 146. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Törnqvista dla danych o sprzedaży kawy (w sekundach).....	209
Wykres 147. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży mleka (w sekundach) .....	209
Wykres 148. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu Jevonsa dla danych o sprzedaży kawy (w sekundach).....	210
Wykres 149. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu GEKS-J dla danych o sprzedaży mleka (w sekundach) .....	210
Wykres 150. Czas kalkulacji dla poszczególnych metod agregacji danych dla indeksu GEKS-J dla danych o sprzedaży kawy (w sekundach).....	211

Tabela 1. Główne założenia budowy systemu wag do obliczania CPI w Polsce.....	12
Tabela 2. Przegląd badań nad obciążeniem wskaźników cen konsumenta .....	23
Tabela 3. Porównanie CPI i Covid CPI w wybranych krajach.....	27
Tabela 4. Przykładowa tabela mapująca używana do skrapowania lotów za pomocą Amadeus API...	33
Tabela 5. Cechy danych skrapowanych i informacji pozyskanych z pomocą tradycyjnego procesu z udziałem ankieterów .....	38
Tabela 6. Przegląd rozwiązań stosowanych przy włączaniu danych skanowanych przez urzędy statystyczne w wybranych krajach Europy.....	57
Tabela 7. Odsetek produktów występujących jednocześnie w pierwszym i ostatnim miesiącu analizy .....	69
Tabela 8. Porównanie wartości dla jednopodstawowych indeksów bilateralnych .....	72
Tabela 9. Średnia różnica między wartościami jednopodstawowych indeksów bilateralnych (w pkt proc.) .....	72
Tabela 10. Średnia różnica między indeksami Carliego i Dutot w porównaniu do indeksu Jevonsa (w pkt. proc.) .....	73
Tabela 11. Porównanie wartości dla indeksów łańcuchowych .....	75
Tabela 12. Średnia różnica między wartościami indeksów łańcuchowych (w pkt proc.).....	76



Tabela 13. Średnia różnica między łańcuchowymi indeksami Carliego i Dutot w porównaniu do łańcuchowego indeksu Jevonsa (w pkt. proc.).....	77
Tabela 14. Porównanie wartości dla formuł bazujących na indeksie Jevonsa oraz nieważonego indeksu TPD dla mokasynów .....	79
Tabela 15. Porównanie metod rozszerzeń okna indeksu GEKS-J dla pełnego zestawu danych .....	81
Tabela 16. Porównanie metod rozszerzeń okna indeksu GEKS-J dla kategorii Mokasyny.....	82
Tabela 17. Porównanie metod rozszerzeń okna nieważonego indeksu TPD dla kategorii Mokasyny..	83
Tabela 18. Odsetek produktów z pierwszego miesiąca analizy występujący w ostatnim miesiącu analizy.....	85
Tabela 19. Liczba rekordów w poszczególnych kategoriach w zależności od zastosowanego sposobu filtracji danych .....	86
Tabela 20. Odsetek rekordów pozostałych w próbie po użyciu poszczególnych z analizowanych filtrów .....	87
Tabela 21. Liczba unikatowych produktów w próbie w zależności od zastosowanego filtra .....	88
Tabela 22. Odsetek unikatowych produktów pozostały w próbie po użyciu poszczególnych filtrów ..	88
Tabela 23. Charakterystyka wykorzystanych zbiorów danych.....	98
Tabela 24. Powtarzalność produktów dla analizowanych zestawów danych.....	99
Tabela 25. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży kawy (w pkt proc) .....	106
Tabela 26. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży mleka (w pkt proc).....	107
Tabela 27. Średnie absolutne różnice pomiędzy indeksami multilateralnymi dla danych o sprzedaży owoców (w pkt proc).....	108
Tabela 28. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-J dla poszczególnych zestawów danych (w pkt. proc.).....	109
Tabela 29. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-L dla poszczególnych zestawów danych (w pkt. proc.).....	109
Tabela 30. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-GL dla poszczególnych zestawów danych (w pkt. proc.).....	110
Tabela 31. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-AQI dla poszczególnych zestawów danych (w pkt. proc.).....	110
Tabela 32. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu GEKS-AQU dla poszczególnych zestawów danych (w pkt. proc.) .....	111
Tabela 33. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu CCDI dla poszczególnych zestawów danych (w pkt. proc.).....	111
Tabela 34. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu Gearego-Khamisa dla poszczególnych zestawów danych (w pkt. proc.) .....	112
Tabela 35. Średnie odchylenie absolutne metod rozszerzenia indeksu w stosunku do indeksu TPD dla poszczególnych zestawów danych (w pkt. proc.).....	112
Tabela 36. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla mleka.....	113
Tabela 37. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla kawy .....	114
Tabela 38. Liczba unikatowych produktów w pierwszym i ostatnim okresie analizy dla owoców.....	114
Tabela 39. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu Jevonsa .....	137
Tabela 40. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu Törnqvista .....	137

Tabela 41. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą łańcuchowego indeksu Jevonsa .....	138
Tabela 42. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu GEKS-J .....	138
Tabela 43. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży kawy kalkulowanych za pomocą indeksu CCDI .....	139
Tabela 44. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu Jevonsa .....	139
Tabela 45. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu Törnqvista .....	140
Tabela 46. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą łańcuchowego indeksu Jevonsa .....	140
Tabela 47. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu GEKS-J.....	141
Tabela 48. Porównanie różnic między poszczególnymi metodami agregacji w porównaniu do podwójnej agregacji (według podgrup w oparciu o indeks Fishera i według outletów) dla danych o sprzedaży mleka kalkulowanych za pomocą indeksu CCDI.....	141
Tabela 49. Porównanie wygenerowanych zestawów danych.....	145
Tabela 50. Wyniki kalkulacji indeksów metoda jackknife dla pierwszego zestawu danych .....	157
Tabela 51. Wyniki kalkulacji indeksów metoda jackknife dla drugiego zestawu danych .....	158
Tabela 52. Wyniki kalkulacji indeksów metoda jackknife dla trzeciego zestawu danych .....	159
Tabela 53. Wyniki kalkulacji indeksów metoda jackknife dla czwartego zestawu danych .....	159
Tabela 54. Wyniki kalkulacji indeksów metoda jackknife dla piątego zestawu danych.....	160
Tabela 55. Wyniki kalkulacji indeksów metoda jackknife dla szóstego zestawu danych.....	161
Tabela 56. Wyniki kalkulacji indeksów metoda jackknife dla siódmego zestawu danych .....	161
Tabela 57. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży kawy.....	174
Tabela 58. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży mleka .....	175
Tabela 59. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-J dla danych o sprzedaży owoców .....	176
Tabela 60. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży kawy.....	177
Tabela 61. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży mleka .....	178
Tabela 62. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-L dla danych o sprzedaży owoców .....	179
Tabela 63. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży kawy.....	180
Tabela 64. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-GL dla danych o sprzedaży owoców .....	182

Tabela 65. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży kawy.....	183
Tabela 66. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży mleka .....	184
Tabela 67. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQI dla danych o sprzedaży owoców .....	185
Tabela 68. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży kawy.....	186
Tabela 69. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży mleka .....	187
Tabela 70. Średnia różnica między metodami rozszerzania okna a indeksem GEKS-AQU dla danych o sprzedaży owoców .....	188
Tabela 71. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży kawy.....	189
Tabela 72. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży mleka .....	190
Tabela 73. Średnia różnica między metodami rozszerzania okna a indeksem CCDI dla danych o sprzedaży owoców .....	191
Tabela 74. Średnia różnica między metodami rozszerzania okna a indeksem Geary'ego-Khamisa dla danych o sprzedaży kawy .....	192
Tabela 75. Średnia różnica między metodami rozszerzania okna a indeksem Geary'ego-Khamisa dla danych o sprzedaży mleka.....	193
Tabela 76. Średnia różnica między metodami rozszerzania okna a indeksem Gearego-Khamisa dla danych o sprzedaży owoców.....	194
Tabela 77. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży kawy.....	195
Tabela 78. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży mleka .....	196
Tabela 79. Średnia różnica między metodami rozszerzania okna a indeksem TPD dla danych o sprzedaży owoców .....	197
Rysunek 1. Kod strony internetowej Obi wraz z zaznaczonymi elementami kodu odpowiadającymi za nazwę kategorii, nazwę produktu oraz jego cenę.....	35
Rysunek 2. Produkty widoczne na stronie sklepu internetowego Obi.....	36
Rysunek 3. Przykładowy wygląd surowych danych z jednego dnia analizy .....	66
Rysunek 4. Kod w programie R odpowiedzialny za połączenie plików z danymi z poszczególnych dni analizy w jeden plik dostosowany do dalszych analiz .....	67
Rysunek 5. Struktura ramki danych po zastosowaniu procedury z rys nr. 4.....	68
Rysunek 6. Procedura filtracji danych po kategoriach i ich agregacji .....	68
Rysunek 7. Wygląd ramki danych po procedurze agregacji.....	69
Rysunek 8. Przykładowa ramka ze zbioru danych Consumer Price Index Manual przed przetworzeniem danych.....	97
Rysunek 9. Przykładowa ramka ze zbioru danych Consumer Price Index Manual po przetworzeniu danych .....	98