

Dominika Morawska

e-mail: 169946@student.ue.wroc.pl

Uniwersytet Ekonomiczny we Wrocławiu

## Ślad ekologiczny a produkt krajowy brutto

JEL Classification: C5, Q01, O13

DOI: 10.15611/2022.17.6.05

**Streszczenie:** W artykule zaprezentowano wyniki badania, dla którego określono następujące cele: sprawdzenie, czy wielkość produktu krajowego brutto *per capita* istotnie wpływa na kształtowanie się śladu ekologicznego *per capita*, a także predykcję wartości śladu ekologicznego w kolejnych latach. Do realizacji pierwszego z celów zastosowano klasyczny model regresji liniowej dla zmiennych zlogarytmowanych. Wyniki pokazują, że PKB *per capita* istotnie wpływa na wielkość śladu ekologicznego *per capita* i jest to zależność stabilna w czasie. Do realizacji drugiego celu badawczego wykorzystano model liniowy Holta. Zaprognozowano wartości śladu ekologicznego *per capita* na lata 2018–2022. Na podstawie błędów *ex post* prognoz wygasłych wnioskuje się, że prognozy są dopuszczalne.

**Słowa kluczowe:** ślad ekologiczny, wzrost gospodarczy, produkt krajowy brutto, zrównoważony rozwój, zielona gospodarka, model ekonometryczny, prognozowanie gospodarcze, model liniowy Holta.

### 1. Wstęp

Artykuł traktuje o problemie nadmiernej eksploatacji dostępnych zasobów naturalnych przez gospodarki krajów całego świata. Tematyka ta jest ważna z punktu widzenia rozwoju gospodarczego, jak również rozwoju cywilizacji. W każdym procesie produkcji wykorzystywane są zasoby naturalne, których z roku na rok ubywa i coraz więcej czasu potrzeba na ich odtworzenie. Jest to związane ze zjawiskiem degradacji środowiska poprzez jego zanieczyszczenie oraz nadmierne wykorzystywanie. Jednym z mierników popytu na zasoby naturalne jest ślad ekologiczny, określający zapotrzebowanie na produktywnie biologicznie obszary biosfery m.in. w celu pozyskania czynników produkcji (Wackernagel i Beyers, 2019).

Za cele badania obrano sprawdzenie, czy wielkość produktu krajowego brutto *per capita* wpływa istotnie na wielkość śladu ekologicznego *per capita*, a także predykcję wartości śladu ekologicznego *per capita* w kolejnych latach. Zbadanie związku między wspomnianymi zjawiskami może być pomocne w procesie wdrażania założeń zielonej gospodarki. Jednocześnie prognoza wielkości śladu ekologicznego ma pokazać, jak będzie kształtować się badane zjawisko oraz czy podjęto odpowiednie kroki w celu ograniczenia degradacji środowiska. Rozważania zawarte w niniejszym artykule są próbą odpowiedzi na trzy pytania badawcze.

Czy wielkość PKB wpływa na kształtowanie się śladu ekologicznego? Czy występuje stabilność tego wpływu? Jak będzie się kształtować wielkość śladu ekologicznego *per capita* w kolejnych latach?

Za obszar badawczy przyjęto kraje świata – 171 – w podziale terytorialnym z 2017 r. Do analizy wpływu PKB *per capita* na wielkość śladu ekologicznego *per capita* wybrano dane z 2017 r. Do zbadania stabilności tej zależności w czasie wykorzystano dane z lat 1965, 1970, 1980, 1990, 2000 i 2010. Prognozowanie natomiast oparto na danych dla świata w latach 1961–2017. Dane do badań pochodzą z bazy danych Global Footprint Network (2021). Analizy danych przekrojowych dokonano za pomocą modelowania ekonometrycznego opartego na budowie modelu regresji liniowej. W celu wyznaczenia prognozy wielkości śladu ekologicznego posłużono się modelem wygładzania wykładniczego Holta.

## 2. Koncepcja śladu ekologicznego w kontekście zielonej gospodarki

Pojęcie zielonej gospodarki (*green economy*) pojawiło się po raz pierwszy w raporcie *Blueprint for green economy* przygotowanym w 1989 r. na zlecenie brytyjskiego rządu. Zagadnienie wtedy nie zostało szerzej omówione, a autorzy skupili się na rozważaniach dotyczących koncepcji rozwoju zrównoważonego i trwałego oraz roli ekonomii w kontekście wzmacniania polityki ekologicznej. Przez pojęcie zrównoważonego i trwałego rozwoju (*sustainable development*) rozumie się rozwój, który pozwala zaspokoić potrzeby i aspiracje obecnych pokoleń, nie odbierając kolejnym pokoleniom możliwości zaspokojenia ich własnych potrzeb (Brundtland, 1987).

W kolejnych latach pojęcie zielonej gospodarki wróciło jako odrębna koncepcja dotycząca nowego podejścia do zarządzania produkcją. United Nations Environment Programme (Fedrigo-Fazio i ten Brink, 2012) definiuje zieloną gospodarkę jako gospodarkę polepszającą dobrobyt człowieka i budującą równość społeczną, przy jednoczesnej redukcji niedoborów ekologicznych i ryzyka dla środowiska naturalnego. Szyja (2015) charakteryzuje koncepcję zielonej gospodarki za pomocą trzech atrybutów: niskiej emisyjności, wydajności surowcowej i włączenia społecznego.

Pochylając się nad dorobkiem współczesnej ekonomii w kontekście rozważania problemu ekologii, można wyróżnić dwa paradygmaty (Fiedor, 2002):

- 1) paradygmat ekonomizacji środowiska,
- 2) ekologiczny paradygmat ekonomii.

Pierwszy z nich odnosi się do ekonomii neoklasycznej i opiera się na stwierdzeniu, że optymalizacja procesu gospodarowania jest społecznie użyteczną metodą radzenia sobie z problemem ograniczoności zasobów i zanieczyszczenia środowiska. Drugi zaś jest krytyką podejścia neoklasycznego i sprowadza się do przekonania, że wartość środowiska naturalnego i rozwoju gospodarczego jest bezwzględnie ważniejsza od celów ekonomicznych (Fiedor, 2002).

Jednym z narzędzi proponowanych do pomiaru gospodarki w kontekście zrównoważonego rozwoju i zielonej gospodarki jest ślad ekologiczny (*ecological footprint*). Pierwsze systematyczne próby liczenia śladu ekologicznego zostały podjęte w 1997 r. (Wackernagel i in., 1997, za: Borucke i in., 2013). Na ich podstawie w 2003 r. Global Footprint Network zainicjowało powstanie programu National Footprint Accounts (NFA) (później National Footprint and Biocapacity Accounts). W ramach NFA Global Footprint Network każdego roku publikuje bazę danych oraz przewodnik zawierający szczegółowe informacje dotyczące dwóch kluczowych dla środowiska wskaźników. Są nimi ślad ekologiczny oraz potencjał biologiczny (*biocapacity*). Ślad ekologiczny określa wielkość popytu na zasoby biosfery w danym roku, biorąc pod uwagę dominującą technologię oraz zarządzanie zasobami w tymże roku (Borucke i in., 2013). Natomiast potencjał biologiczny mierzony jest jako suma produktywnych biologicznie obszarów lądowych i morskich dostępnych w celu dostarczenia zasobów naturalnych oraz pochłonięcia wyemitowanego dwutlenku węgla w danym roku (Borucke i in., 2013). Oba wskaźniki wyrażane są za pomocą globalnych hektarów (gha), tj. wzajemnie wykluczających się jednostek powierzchni niezbędnych do corocznego zapewnienia (lub regeneracji) zasobów naturalnych.

Zgodnie z założeniami wolnego rynku głównym celem gospodarki jest dobrobyt. Ten zaś może zostać osiągnięty jedynie przez wzrost gospodarczy, którego miarą jest PKB (produkt krajowy brutto) (*Gross Domestic Product – GDP*). PKB z punktu widzenia ekonomii jest definiowany jako „wartość rynkowa wszystkich finalnych dóbr i usług, wytworzonych w kraju w danym okresie” (Mankiw i Taylor, 2009). Tak definiowany (w sposób monetarny) wzrost gospodarczy nie uwzględnia szkód środowiskowych (Ostasiewicz, 2016).

Ostasiewicz (2017, s. 239) określa gospodarowanie jako „pobieranie materii ze środowiska naturalnego, czynienie z niej produktów użytecznych człowiekowi i wydalanie do środowiska resztek z takiej transformacji materii”. Materia jest intuicyjnie rozumiana jako „wszystko to, co jest rozciągle i zajmuje miejsce w przestrzeni” (Ostasiewicz, 2017, s. 240). Nową metodologię pomiaru procesów produkcji, czyli metabolizmu gospodarczego, Ostasiewicz (2016) nazywa metabometrią.

Próby wyrażenia wielkości gospodarki za pomocą energii i materii zostały podjęte już w latach 80. XIX w. W 1886 r. Boltzmann sformułował tezę, że życie jest „rywalizacją o użyteczne formy energii” (Fiedor, 2002, s. 14). Według fizyków tamtego okresu, energia i materia powinny być głównym przedmiotem uwagi ekonomistów, gdyż każda aktywność, której podejmuje się człowiek, podporządkowana jest pierwszemu i drugiemu prawu termodynamiki.

Jednym z narzędzi pomiaru gospodarki opartych na zasadach termodynamiki jest analiza bilansu masy (*mass-balance approach*). Bazuje ona na tezie mówiącej o tym, że suma całkowita energii i materii pobieranych ze środowiska naturalnego pod postacią zasobów, musi być równa sumie energii powracającej do środowiska jako wszelkie dobra kapitałowe i konsumpcyjne, a także odpady i rozproszona energia. Jednocześnie taka analiza gospodarki napotyka problemy metodologiczne

ne i statystyczno-numeryczne. W głównej mierze związane są one z trudnymi do zmierzenia procesami chemicznymi i fizycznymi. Nie ulega jednak wątpliwości, że bilansowanie masy ma dużo większe możliwości w kwestii kontrolowania i mierzenia gospodarki (w kontekście zużycia zasobów naturalnych) niż obecnie stosowany produkt krajowy brutto (Fiedor, 2002).

### 3. Metoda analizy

#### 3.1. Charakterystyka danych

W celu przeprowadzenia analizy ekonometrycznej badanego zjawiska zgromadzone dane przekrojowe z 2017 r. dla 171 państw świata. Do analizy zostały wybrane następujące zmienne:

- wielkość śladu ekologicznego konsumpcji *per capita* w globalnych hektarach na osobę,
- wielkość produktu krajowego brutto *per capita* w dolarach amerykańskich według cen bazowych 2010.

Do wyznaczenia prognoz wielkości śladu ekologicznego *per capita* wykorzystano dane w postaci szeregu czasowego dla świata ogółem w latach 1961–2017 (dane roczne).

Wszystkie zgromadzone dane zostały pobrane z bazy danych Global Footprint Network (2021).

#### 3.2. Modelowanie ekonometryczne

Wpływ wielkości PKB *per capita* na wielkość śladu ekologicznego *per capita* zbadano za pomocą modelu ekonometrycznego będącego podstawowym narzędziem modelowania ekonometrycznego. Istotą modelowania ekonometrycznego jest opisywanie teorii ekonomicznych za pomocą równań lub układów równań (czyli modeli ekonometrycznych), przekształcanie ich i dochodzenie do wniosków mniej intuicyjnych i oczywistych niż wysnuwane na początku (Gruszczyński, Kuszewski i Podgórska, 2009).

W pracy wykorzystano klasyczny model regresji liniowej dla danych przekrojowych, który dla zależności zmiennej  $Y$  od  $X$  można opisać wzorem (Ampuła, 2014):

$$y_i = \alpha_0 + \alpha_1 \cdot x_i + \varepsilon_i, i = 1, 2, \dots, n,$$

gdzie:  $y_i$  – wartość zmiennej zależnej dla  $i$ -tej obserwacji;  $x_i$  – wartości zmiennej niezależnej dla  $i$ -tej obserwacji;  $\alpha_0, \alpha_1$  – parametry strukturalne;  $\varepsilon_i$  – składnik losowy dla  $i$ -tej obserwacji.

Jedną z najpopularniejszych metod szacowania parametrów modelu liniowego jest (klasyczna) metoda najmniejszych kwadratów (MNK lub KMNK). Zgodnie z twierdzeniem Gaussa-Markowa estymator  $\hat{\alpha}$  wyznaczony MNK jest estymatorem

zgodnym, nieobciążonym i najefektywniejszym w klasie liniowych estymatorów wektora parametrów  $\mathbf{a}$  w modelu regresji liniowej (Gruszczynski i in., 2009). Opisane własności są prawdziwe, gdy model spełnia założenia:

$$(Z1) \text{rz}(\mathbf{X}) = k+1 \leq n$$

(Z2) zmienne objaśniające  $X_i$  są nielosowe, tzn. niezależne od składnika losowego  $\boldsymbol{\varepsilon}$ ,

$$(Z3) E(\boldsymbol{\varepsilon}) = 0$$

$$(Z4) \mathbf{D}^2(\boldsymbol{\varepsilon}) = E(\boldsymbol{\varepsilon}\boldsymbol{\varepsilon}^T) = \sigma^2\mathbf{I} \text{ dla } \sigma^2 < \infty,$$

$$(Z5) \varepsilon_i \sim N(0, \sigma^2), i = 1, 2, \dots, n.$$

gdzie:  $\text{rz}(\mathbf{X})$  – rząd macierzy zaobserwowanych wartości zmiennych objaśniających ( $\mathbf{X}$ );  $\boldsymbol{\varepsilon}$  – wektor składnika losowego;  $E(\boldsymbol{\varepsilon})$  – wartość oczekiwana składnika losowego;  $\mathbf{D}^2(\boldsymbol{\varepsilon})$  – macierz kowariancji składnika losowego;  $\sigma^2$  – wariancja składnika losowego;  $\mathbf{I}$  – macierz jednostkowa.

Założenie (Z5) nie jest warunkiem koniecznym, by estymator spełniał twierdzenie Gaussa-Markowa, jednak ułatwia weryfikację modelu, pozwalając na przeprowadzenie testów statystycznych.

Wartości zmiennej zależnej otrzymane dla ocen parametrów  $\hat{\mathbf{a}}$  nazywane są wartościami teoretycznymi modelu i oznaczane przez  $\hat{y}_i$  (Dziechciarz, 2012; Gruszczynski i in., 2009):

$$\hat{y}_i = \hat{\alpha}_0 + \hat{\alpha}_1 \cdot y_i, \quad i = 1, 2, \dots, n,$$

gdzie:  $\hat{y}_i$  – wartość teoretyczna zmiennej objaśnianej dla  $i$ -tej obserwacji;  $\hat{\alpha}_0, \hat{\alpha}_1$  – oceny parametrów strukturalnych modelu;  $y_i$  – wartość zmiennej niezależnej dla  $i$ -tej obserwacji.

Ideą KMNK jest znalezienie takiego estymatora  $\hat{\mathbf{a}}$  wektora parametrów  $\mathbf{a}$ , dla którego suma kwadratów reszt modelu osiąga minimum. Estymator ten jest postaci

$$\hat{\mathbf{a}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y},$$

gdzie:  $\mathbf{X}$  – macierz zaobserwowanych wartości zmiennych objaśniających (w badanym przypadku  $k = 1$ );  $\mathbf{y}$  – wektor obserwacji zmiennej objaśnianej, a jego macierz kowariancji ma postać:

$$\mathbf{D}^2(\hat{\mathbf{a}}) = \sigma^2 (\mathbf{X}^T \mathbf{X})^{-1}.$$

Estymatorem – nieobciążonym i zgodnym – wariancji składnika losowego  $\sigma^2$  jest

$$S^2 = \frac{\mathbf{e}^T \mathbf{e}}{n - (k + 1)},$$

gdzie:  $\mathbf{e}$  – wektor reszt modelu postaci  $e_i = y_i - \hat{y}_i$  dla  $i$ -tej obserwacji;  $n$  – liczba obserwacji;  $k$  – liczba zmiennych objaśniających (w badanym przypadku  $k = 1$ ).

Nieobciążony i zgodny estymator macierzy kowariancji ma postać:

$$\hat{\mathbf{D}}^2(\hat{\mathbf{a}}) = S^2(\mathbf{X}^T \mathbf{X})^{-1}.$$

Pierwiastki kwadratowe z elementów znajdujących się na głównej przekątnej ( $S(\hat{\alpha}_j)$ ) estymatora macierzy kowariancji nazywane są błędami szacunku parametrów i informują o przeciętnym odchyleniu wartości oceny  $\hat{\alpha}_j$  od rzeczywistej wartości parametru  $\alpha_j$  (Gruszczyński i in., 2009).

Kolejnym krokiem – po oszacowaniu parametrów modelu – jest weryfikacja merytoryczna modelu, polegająca na ocenie sensu ekonomicznego oszacowań parametrów modelu oraz weryfikacja statystyczna. Ta ostatnia sprowadza się do oceny dobroci dopasowania modelu do danych empirycznych oraz sprawdzenia czy zbudowany model spełnia założenia Gaussa-Markowa (Gruszczyński i in., 2009).

Jedną z głównych miar dopasowania modelu do danych empirycznych jest współczynnik determinacji ( $R^2$ ). Jego wartość interpretuje się jako frakcję zmienności zmiennej zależnej wyjaśnionej przez zbudowany model (Dziechciarz, 2012).

Do weryfikacji istotności statystycznej oszacowanych parametrów modelu używa się uogólnionego testu Walda opartego na rozkładzie  $F$ -Snedecora (badającego łączną istotność wszystkich parametrów modelu) oraz testu istotności na podstawie rozkładu  $t$ -Studenta (badającego istotność poszczególnych parametrów modelu). Test Walda sprowadza się do weryfikacji hipotezy zerowej postaci:

$$H_0: \alpha_1 = \alpha_2 = \dots = \alpha_k = 0.$$

Statystyka testowa wyrażana jest wzorem:

$$F = \frac{n-k-1}{k} \cdot \frac{R^2}{1-R^2},$$

ma rozkład  $F$ -Snedecora z  $n_1 = k$  oraz  $n_2 = n - k - 1$  stopniami swobody. Wartość statystyki testowej porównuje się z wartością krytyczną  $F^*$  odczytaną z tablic  $F$ -Snedecora dla danego poziomu istotności  $\alpha$  oraz  $n_1 = k$  i  $n_2 = n - k - 1$  stopniami swobody.

Hipotezę zerową dwustronnego testu istotności opartego na rozkładzie  $t$ -Studenta postaci:

$$H_0: \alpha_j = 0$$

weryfikuje się przez porównanie wartości statystyki testowej:

$$t_j = \frac{\hat{\alpha}_j}{S_j},$$

z wartością krytyczną  $t^*$  odczytaną z tablic rozkładu  $t$ -Studenta o  $n - k - 1$  stopniach swobody przy zadanym poziomie istotności  $\alpha$  (Dziechciarz, 2012).

Do weryfikacji założenia o homoskedastyczności składnika losowego służy m.in. test Breusha-Pagana. Przy założeniu, że  $V(\varepsilon_i) = \sigma_i^2$ , jeżeli istnieją zmienne  $z_1, z_2, \dots, z_k$ , które mają wpływ na wariancję składnika losowego w badanym modelu, oraz jeżeli  $\sigma_i^2 = f(\beta_0 + \beta_1 \cdot z_{1i} + \beta_2 \cdot z_{2i} + \dots + \beta_r \cdot z_{ri})$ , to test Breusha-Pagana polega na weryfikacji hipotezy zerowej:

$$H_0 : \beta_1 = \beta_2 = \dots = \beta_r = 0.$$

Statystyka testowa postaci:

$$\lambda = \frac{ESS}{2\hat{\sigma}^4},$$

gdzie:  $ESS$  – wyjaśniona suma kwadratów z regresji  $e_i^2$  względem  $z_1, z_2, \dots, z_r$ , wyrażona wzorem:

$$ESS = R^2 \cdot \sum_{i=1}^n (e_i^2)^2 - n \cdot (\bar{e^2})^2,$$

$\hat{\sigma}^2$  – ocena wariancji błędu w całej próbie:

$$\hat{\sigma}^2 = \sum_{i=1}^n \frac{e_i^2}{n}$$

ma asymptotyczny rozkład  $\chi^2$  o  $r$  stopniach swobody. Wartość krytyczna odczytana pochodzi z tablic rozkładu  $\chi^2$  z  $r$  stopniami swobody na zadanym poziomie istotności  $\alpha$  (Maddala, 2006).

Do weryfikacji założenia (Z5) stosuje się powszechnie test Jarque'a-Bery. Hipoteza zerowa traktuje o normalności rozkładu składnika losowego. Konstrukcja testu opiera się na porównaniu trzeciego i czwartego momentu rozkładu składnika losowego modelu z trzecim i czwartym momentem znanym dla rozkładu normalnego (Gruszczyński i in., 2009). Niech  $w$  – współczynnik skośności oraz  $k$  – współczynnik kurtozy, określone wzorami:

$$w = \frac{\sum_{i=1}^n e_i^3}{S^3}$$

oraz

$$k = \frac{\sum_{i=1}^n e_i^4}{S^4},$$

gdzie:  $S$  – odchylenie standardowe reszt modelu postaci:

$$S = \sqrt{\frac{1}{n} \sum_{i=1}^n e_i^2}.$$

Wówczas statystyka testowa ma postać:

$$JB = n \left( \frac{w^2}{6} + \frac{(k-3)^2}{24} \right)$$

i pochodzi z rozkładu  $\chi^2$  z dwoma stopniami swobody. Wartość krytyczną odczytuje się z rozkładu  $\chi^2$  z dwoma stopniami swobody na zadanym poziomie istotności  $\alpha$  (Maddala, 2006).

Kolejnym elementem do weryfikacji jest losowość reszt modelu. Jej testowanie związane jest z postacią analityczną modelu. W teście serii Walda-Wolfowitza stawiana jest hipoteza zerowa traktująca o losowym rozkładzie reszt  $e_t$ . Na początku porządkuje się reszty modelu w sposób chronologiczny lub według rosnących wartości zmiennej objaśniającej, a następnie wyznacza się liczbę serii  $L$  reszt o tych samych znakach. Dla dużej próby rozkład liczby serii ma rozkład normalny (Gładysz i Mercik, 2007):

$$N \left( \frac{2m(n-m)}{n} + 1, \sqrt{\frac{2m(n-m)(2m(n-m)-n)}{n^2(n-1)}} \right),$$

gdzie:  $m$  – liczba serii jednego rodzaju (reszty dodatnie);  $n - m$  – liczba serii drugiego rodzaju (reszty ujemne).

### 3.3. Model liniowy Holta

Model liniowy Holta jest jednym z wielu znanych w literaturze modeli wygładzania wykładniczego. Istotą wygładzania wykładniczego jest wyrównanie szeregu czasowego za pomocą ważonej średniej ruchomej, gdzie wagi określane są według prawa wykładniczego. Model liniowy Holta stosuje się w przypadku występowania w szeregu czasowym zarówno tendencji rozwojowej, jak i wahań przypadkowych (Cieślak, 2005). Równania tego modelu mają postać (I. Dittmann, P. Dittmann, Szabela-Pasierbińska i Szpulak, 2011):

$$F_{t-1} = \alpha y_{t-1} + (1 - \alpha)(F_{t-2} + S_{t-2})$$

oraz

$$S_{t-1} = \beta(F_{t-1} - F_{t-2}) + (1 - \beta) S_{t-2},$$

gdzie:  $F_{t-1}$  – wygładzona wartość zmiennej prognozowanej na moment lub okres  $t - 1$ ;  $S_{t-1}$  – wygładzona wartość przyrostu trendu na moment lub okres  $t - 1$ ;  $\alpha$ ,  $\beta$  – parametry modelu o wartościach z przedziału  $[0,1]$ .



Równanie prognozy na okres  $t > n$  przybiera postać:

$$y_t^* = F_n + (t - n)S_n,$$

gdzie:  $y_t^*$  – prognoza wyznaczona na moment lub okres  $t$ ;  $F_n$  – wygładzona wartość zmiennej prognozowanej na okres  $n$ ;  $S_n$  – wygładzona wartość przyrostu trendu w okresie  $n$ ;  $n$  – liczba wyrazów szeregu czasowego zmiennej prognozowanej.

Wartości parametrów wygładzania –  $\alpha$  oraz  $\beta$  – wyznacza się zazwyczaj eksperymentalnie, tak aby w efekcie zminimalizować średni kwadratowy błąd prognoz wygasłych (Cieślak, 2005). Jednym z nich jest średni kwadratowy błąd prognozy *ex post* (*Mean Squared Error* – MSE) w przedziale weryfikacji:

$$s^{*2} = \frac{1}{n-2} \sum_{t=3}^n (y_t - y_t^*)^2,$$

gdzie:  $y_t$  – realizacja zmiennej  $Y$  w czasie  $t$ ;  $y_t^*$  – prognoza zmiennej  $Y$  na czas  $t$  otrzymana z danej metody.

Korzystając z optymalnych wartości parametrów  $\alpha$  oraz  $\beta$ , konstruuje się ostateczny model oraz wyznacza prognozę na zadany moment lub okres.

Po wyznaczeniu prognozy należy określić stopień jej niepewności (dopuszczalność). Jednymi z najpopularniejszych metod oceny dopuszczalności prognozy są błąd prognozy *ex ante* oraz prawdopodobieństwo realizacji prognozy. Jednak modele wygładzania wykładniczego nie pozwalają na znalezienie tych mierników. Dla modelu Holta do oceny dopuszczalności prognozy można zastosować m.in. błędy *ex post* prognoz wygasłych, wyznaczonych według tej samej metody co oceniana prognoza. Prognozy wygasłe definiuje się jako prognozy skonstruowane na taki czas  $t$ , dla którego znane są rzeczywiste wartości zmiennej prognozowanej (Cieślak, 2005; Dittmann i in., 2011).

W artykule wykorzystano dwie formuły błędów *ex post*: bezwzględny błąd prognozy w czasie  $t$ :

$$q_t = y_t - y_t^*, \quad t > n$$

oraz względny błąd prognozy *ex post* w czasie  $t$ :

$$\Psi_t = \frac{y_t - y_t^*}{y_t} \cdot 100, \quad t > n,$$

gdzie dla obu błędów:  $y_t$  – realizacja zmiennej  $Y$  w czasie  $t > n$ ;  $y_t^*$  – prognoza zmiennej  $Y$  na czas  $t > n$  otrzymana z danej metody.

Prognoza, dla której wartość błędu *ex post* prognoz wygasłych jest co najwyżej równa z góry zadanej wartości, jest prognozą dopuszczalną i może być wykorzystana do ustalonego celu. Najdalszy moment lub okres w przyszłości, dla którego prognoza jest dopuszczalna, nazywany jest maksymalnym horyzontem prognozy (Cieślak, 2005).

Do oceny trafności zastosowanej prognozy używa się błędów *ex post*. Prognozę uważa się za trafną, jeśli wartość obliczonego błędu *ex post* nie przekracza wielkości progowej ustalonej podczas formułowania wymagań dotyczących dopuszczalności prognozy. W przypadku gdy trafność prognozy okazała się wystarczająca oraz nie zmieniły się wymagania dotyczące prognozy, wybraną metodę prognozowania można użyć do wyznaczenia kolejnych prognoz. W przeciwnym wypadku przed wyznaczeniem kolejnej prognozy, warto powrócić do poprzednich etapów procesu prognostycznego (Dittmann i in., 2011).

## 4. Rezultaty badań

### 4.1. Modelowanie ekonometryczne – ślad ekologiczny a PKB

W pierwszym etapie badań przeprowadzono wstępną analizę danych odnoszących się do badanego problemu. Zastosowano następujące oznaczenia zmiennych:

- PKB – wielkość produktu krajowego brutto *per capita* w dolarach amerykańskich według cen w roku bazowym 2010,
- ŚladEko – wielkość śladu ekologicznego *per capita* w globalnych hektarach na osobę.

Na początku zbadano kształtowanie się wielkości śladu ekologicznego *per capita*. W tabeli 1 przedstawiono wartości statystyk opisowych badanej zmiennej.

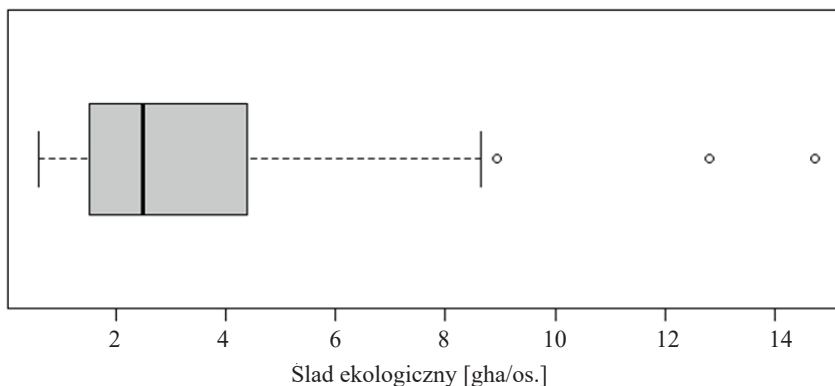
**Tabela 1.** Podstawowe statystyki opisowe zmiennej ślad ekologiczny ( $n = 171$ )

Statystyka	Wartość statystyki dla zmiennej <i>ŚladEko</i> [gha/os.]
Średnia arytmetyczna	3,19
Odchylenie standardowe	2,32
Mediana	2,50
Kwartył pierwszy	1,51
Kwartył trzeci	4,39

Źródło: obliczenia własne z wykorzystaniem pakietu *base* w programie R.

Analizując średnią arytmetyczną zmiennej objaśnianej *ŚladEko*, można wnioskować, że przeciętnie w krajach świata generowany jest ślad ekologiczny na poziomie 3,19 globalnych hektarów na osobę. Wartość mediany jest niższa niż wartość średniej arytmetycznej, co sugeruje istnienie prawostronnej, czyli dodatniej asymetrii. W zbiorowości występuje przewaga jednostek (państw) o relatywnie niskiej średniej wartości śladu ekologicznego. Spośród wszystkich obserwacji, 67% znajduje się w przedziale od 0,87 gha/os. do 5,51 gha/os. W 25% państw zaobserwowano wartość śladu ekologicznego niższą lub równą 1,51 gha/os., natomiast w pozostałych 75% państw ta wartość była wyższa lub równa 1,51 gha/os. W 75% państw wartość śladu ekologicznego nie przekroczyła 4,39 gha/os., a w 25% wartość badanej cechy była wyższa lub równa 4,39 gha/os.

Na rysunku 1 przedstawiono wykres pudełkowy analizowanej zmiennej. Dla zmiennej ślad ekologiczny można zauważyć trzy obserwacje odstające, które na wykresie zostały przedstawione za pomocą kropek. Są to: Katar (14,7 gha/os.), Luksemburg (12,8 gha/os.) oraz Zjednoczone Emiraty Arabskie (8,9 gha/os.). Przeważający udział w śladzie ekologicznym *per capita* ma ślad węglowy definiowany jako obszar gruntów leśnych wymagany do pochłonięcia wyemitowanego dwutlenku węgla. Global Footprint Network oblicza ślad emisji dwutlenku węgla przy użyciu kilku parametrów, w tym krajowego spalania paliw kopalnych i zużycia energii elektrycznej, węgla zawartego w przedmiotach handlowych i energii elektrycznej, udziału danego kraju w globalnych emisjach z transportu międzynarodowego oraz źródeł paliw innych niż kopalne. Całkowita ilość dwutlenku węgla przydzielona do każdego kraju jest przeliczana na globalne hektary w oparciu o intensywność śladu węglowego (Lin i in., 2019). Dla Kataru, Luksemburga i Zjednoczonych Emiratów Arabskich ślad węglowy stanowi odpowiednio 91,4, 75,8 i 76,8% śladu ekologicznego *per capita*.




**Rys. 1.** Wykres pudełkowy realizacji zmiennej  $\dot{S}ladEko$  [gha/os.] ( $n = 171$ )

Źródło: opracowanie własne z wykorzystaniem pakietu *graphics* w programie R.

Kolejnym krokiem była analiza powiązań zmiennej PKB *per capita* ze zmienną objaśnianą. Obie zmienne zlogarytmowano, ponieważ badając wykresu rozrzutu zmiennych niezlogarytmowanych, nie zauważono zależności liniowej, lecz nieliniową. W kolejnych częściach analizy zastosowano oznaczenia zmiennych odpowiednio  $\ln(PKB)$  oraz  $\ln(\dot{S}ladEko)$ .

W celu wstępnej oceny zależności między zmiennymi, stworzono wykres rozrzutu (rys. 2). Z wykresu można wnioskować, że zmienna  $\ln(PKB)$  jest liniowo skorelowana ze zmienną  $\ln(\dot{S}ladEko)$ .



Rys. 2. Wykres rozrzutu badanych zmiennych ( $n = 171$ )

Źródło: opracowanie własne z wykorzystaniem pakietu *graphics* w programie R.

Zbudowano model ekonometryczny postaci:

$$\ln(\dot{S}ladEko)_i = \alpha_0 + \alpha_1 \cdot \ln(PKB)_i + \varepsilon_i, \quad i = 1, 2, \dots, 171.$$

W tabeli 2 zostały zawarte wartości parametrów strukturalnych modelu oszacowane klasyczną metodą najmniejszych kwadratów i błędy szacunku parametrów oraz wartości statystyk testowych i wartości  $p$ -value dla przeprowadzonych testów statystycznych.

Tabela 2. Wartości parametrów strukturalnych oszacowanych KMNK i błędy szacunku parametrów oraz wartości statystyk testowych i wartości  $p$ -value dla testów  $t$ -Studenta, Walda, Breuscha-Pagana, Jarque'a-Bery i Walda-Wolfowitza

Nazwa testu statystycznego	Wartość statystyki testowej	Wartość $p$ -value dla testu	Wartość oszacowanego parametru strukturalnego	Wartość błędu szacunku parametru
Test $t$ -Studenta dla $\alpha_0$	-16,94	< 0,001	-2,689	0,159
Test $t$ -Studenta dla $\alpha_1$	23,06	< 0,001	0,419	0,018
Test Walda	531,6	< 0,001	nie dotyczy	
Test Breuscha-Pagana	1,62	0,203	nie dotyczy	
Test Jarque'a-Bery	9,29	0,016	nie dotyczy	
Test Walda-Wolfowitza	-2,15	0,031	nie dotyczy	

Źródło: obliczenia własne z wykorzystaniem pakietów *stats*, *broom*, *lmtest*, *randtests* w programie R.

Zbadano istotność parametrów, przeprowadzając test Walda oraz testy  $t$ -Studenta. W przypadku testu Walda można wnioskować, że co najmniej jeden z parametrów modelu jest istotnie różny od zera ( $p$ -value < 0,01). Dla testów  $t$ -Studenta wnioskuje się, że parametry  $\alpha_0$  oraz  $\alpha_1$  są istotnie różne od zera ( $p$ -value < 0,01). Zatem wielkość PKB ma istotny wpływ na kształtowanie się wielkości śladu ekologicznego.

Ocena jakości modelu polega m.in. na sprawdzeniu, czy zbudowany model spełnia założenia MNK wynikające z twierdzenia Gaussa-Markowa. Najpierw poddano badaniu jednorodność wariancji. Do tego celu użyto testu Breuscha-Pagana. Stwierdzono, że w modelu występuje homoskedastyczność ( $p\text{-value} > 0,01$ ). Kolejnym warunkiem, który postuluje się dla modeli szacowanych metodą najmniejszych kwadratów, jest normalność rozkładu składnika losowego. Do weryfikacji tego zagadnienia skorzystano z testu Jarque'a-Bery. Wnioskuje się, że składnik losowy ma rozkład normalny ( $p\text{-value} > 0,01$ ). Ostatnim krokiem weryfikacji poprawności doboru metody szacowania parametrów jest badanie losowości reszt modelu. W tym celu przeprowadzono test serii Walda-Wolfowitza. Można wnioskować, że reszty modelu są losowe ( $p\text{-value} > 0,01$ ).

Zbudowany model spełnił wszystkie założenia metody najmniejszych kwadratów. Oznacza to, że metoda estymacji parametrów modelu została dobrana prawidłowo. Dla skonstruowanego modelu obliczono współczynnik determinacji  $R^2$ . Jego wartość kształtuje się na poziomie 0,757. Wnioskuje się, że 75,7% zmienności objaśnianej zmiennej jest wyjaśniane przez model, zaś 24,3% zmienności badanej zmiennej model nie wyjaśnia. Przyjmuje się, że osiągnięty poziom współczynnika determinacji jest zadowalający i wskazuje na dobre dopasowanie modelu do danych. Model log-liniowy zależności śladu ekologicznego *per capita* od PKB *per capita* został skonstruowany poprawnie. Wzrost PKB *per capita* o 1% prowadzi do wzrostu śladu ekologicznego *per capita* o 0,419%.

Celem potwierdzenia stabilności występowania zależności między wielkością PKB *per capita* a wielkością śladu ekologicznego *per capita*, zbudowano analogiczne modele liniowe dla badanych zmiennych we wcześniejszych latach, tj. 1965, 1970, 1980, 1990, 2000 i 2010. W tabeli 3 zestawiono wartości oszacowanych parametrów, błędy szacunku parametrów oraz wyniki przeprowadzonych testów statystycznych – wartości statystyk testowych i  $p\text{-value}$  – dla analizowanych modeli. Modele zbudowane na podstawie danych z lat 1965, 1970, 1990 i 2000 spełniają wszystkie założenia klasycznej metody najmniejszych kwadratów. W modelach wykorzystujących dane z lat 1980 i 2000 składniki losowe nie mają rozkładu normalnego. Mimo to twierdzenia Gaussa-Markowa są nadal spełnione. We wszystkich modelach współczynnik determinacji równy jest co najmniej 0,65. Wnioskuje się, że modele zostały skonstruowane poprawnie i są dobrze dopasowane do danych. Uznaje się, że zależność log-liniowa śladu ekologicznego *per capita* od PKB *per capita* jest stabilna – utrzymuje się niezależnie od analizowanego roku.

**Tabela 3.** Wartości parametrów strukturalnych oszacowanych KMNK i błędy szacunku parametrów oraz wartości statystyk testowych i wartości *p-value* dla testów weryfikujących założenia Gaussa-Markowa modeli na podstawie danych z lat 1965, 1970, 1980, 1990, 2000 i 2010


Nazwa testu / symbol parametru	Nazwa prezentowanego elementu	Wartość w analizowanym roku					
		1965	1970	1980	1990	2000	2010
Test <i>t</i> -Studenta dla $\alpha_0$	statystyka testowa	-9,74	-11,28	-12,41	-15,82	-18,25	-18,46
	<i>p-value</i>	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
Test <i>t</i> -Studenta dla $\alpha_1$	statystyka testowa	12,25	14,71	16,37	20,80	24,29	25,06
	<i>p-value</i>	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
Test Walda	statystyka testowa	150,0	216,5	267,9	432,6	589,7	628,1
	<i>p-value</i>	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001	< 0,001
Test Bruscha-Pagana	statystyka testowa	1,296	1,268	0,005	0,004	0,030	0,003
	<i>p-value</i>	0,255	0,260	0,944	0,950	0,862	0,956
Test Jarque'a-Bery	statystyka testowa	1,739	8,246	37,72	5,215	15,096	5,406
	<i>p-value</i>	0,315	0,019	< 0,001	0,062	0,0045	0,049
Test Walda-Wolfowitza	statystyka testowa	1,576	-0,616	-1,664	0,746	0	0,308
	<i>p-value</i>	0,115	0,538	0,096	0,456	1	0,758
Parametr strukturalny $\alpha_0$	estymacja MNK	-2,641	-2,616	-2,642	-2,731	-2,703	-2,730
	błąd szacunku	0,271	0,232	0,213	0,173	0,148	0,148
Parametr strukturalny $\alpha_1$	estymacja MNK	0,423	0,424	0,422	0,430	0,426	0,430
	błąd szacunku	0,035	0,028	0,026	0,021	0,018	0,017

Źródło: obliczenia własne z wykorzystaniem pakietów *stats*, *broom*, *lmtest*, *randtests* w programie R.

#### 4.2. Prognozowanie wielkości śladu ekologicznego *per capita*

Na początku badania dokonano wstępnej analizy wykorzystanej zmiennej. Użyto tych samych oznaczeń, co poprzednio. Na rysunku 3 przedstawiono kształtowanie się zmiennej *ŚladEko*.

Wielkość śladu ekologicznego *per capita* zmieniała się w badanym przedziale czasu. Przez pierwsze lata stale rosła, osiągając najwyższą wartość w 1973 r. (2,85 gha/os.). W latach 80. i 90. wielkość śladu ekologicznego kształtowała się na poziomie 2,5–2,65 gha/os. Po 2002 r. obserwowano gwałtowny wzrost wielkości badanego zjawiska – od 2006 r. wahała się w granicach 2,75–2,85 gha/os.



**Rys. 3.** Kształtowanie się wielkości śladu ekologicznego *per capita* [gha/os.] dla świata w latach 1961–2017

Źródło: opracowanie własne z wykorzystaniem pakietu *ggplot2* w programie R.

Jako metodę prognozowania zastosowano model liniowy Holta. Parametry  $\alpha$  oraz  $\beta$  modelu oszacowano przy użyciu pakietu *stats* w programie R, optymalizując błąd średniokwadratowy prognoz wygasłych (dla wartości początkowych  $\alpha = 0,2$  i  $\beta = 0,1$ ). Oszacowane parametry są równe:


$$\begin{cases} \hat{\alpha} = 1 \\ \hat{\beta} = 0,132532476 \end{cases}$$

Na rysunku 4 przedstawiono wartości teoretyczne i rzeczywiste dla badanego modelu.

Błąd średniokwadratowy dla tak zbudowanego modelu wynosi 0,0023. Pierwiastek kwadratowy MSE równy jest 0,048. Oznacza to, że wartości teoretyczne odchylają się od wartości rzeczywistych średnio o 0,048 gha/os.

Wyznaczono prognozę wielkości śladu ekologicznego *per capita* na kolejny rok (2018). Jej wartość równa jest 2,7766 gha/os.

Kolejne cztery wartości (na lata 2019–2022) zaprognozowano dla nowych modeli wyznaczonych w sposób rekurencyjny (tab. 4). Aby wyznaczyć prognozę na 2019 r., do pierwotnego szeregu czasowego wartości rzeczywistych dodano wartość prognozowaną na 2018 r. Dla takiego zbioru danych utworzono model Holta i oszacowano parametry  $\alpha$  oraz  $\beta$ , minimalizując błąd średniokwadratowy prognoz. Ze zbudowanego modelu wyznaczono prognozę na jeden okres. Dla każdego kolejnego roku procedurę powtórzono. Wyznaczone prognozy wskazują na wzrost śladu ekologicznego *per capita* na świecie do 2022 r.



**Rys. 4.** Kształtowanie się wartości rzeczywistych (krzywa czarna) i wartości teoretycznych (krzywa szara) śladu ekologicznego *per capita* [gha/os.]

Źródło: opracowanie własne z wykorzystaniem pakietu *graphics* w programie R.

**Tabela 4.** Parametry modeli Holta oraz wartości prognoz wielkości śladu ekologicznego *per capita* na lata 2019–2022

Wartość parametru $\alpha$	Wartość parametru $\beta$	Rok, na który wyznaczono prognozę	Prognozowana wartość [gha/os.]
1	0,1325324833	2019	2,7816
1	0,1325326172	2020	2,7866
1	0,1325326144	2021	2,7917
1	0,1325326138	2022	2,7967

Źródło: obliczenia własne z wykorzystaniem pakietu *stats* w programie R.

Oceniono dopuszczalność prognoz na podstawie błędów *ex post* prognoz wygasłych. Dla poprzednich lat, tj. 2013–2017, zbudowano w sposób rekurencyjny modele Holta, jak przy wyznaczaniu prognoz za lata 2018–2022. Dla każdej prognozy obliczono bezwzględne i względne błędy prognoz wygasłych *ex post*. Wyniki przedstawiono w tab. 5.

Do oceny dopuszczalności przyjęto progową wartość względnego miernika predykcji na poziomie 5%. Jako że nie ma możliwości wyznaczenia błędów *ex ante* ani prawdopodobieństwa realizacji prognozy, wykorzystano błędy prognoz wygasłych. Prognozy wygasłe wyznaczono w taki sam sposób, z którego skorzystano podczas wyznaczania prognoz na lata 2018–2022. W każdym z badanych lat 2013–2017 wartość błędu jest niższa niż zadana wartość progowa. Można zatem wnioskować,



że prognozy na lata 2018–2022 wyznaczono prawidłowo, a okres prognozy nie przekracza maksymalnego horyzontu prognozy.

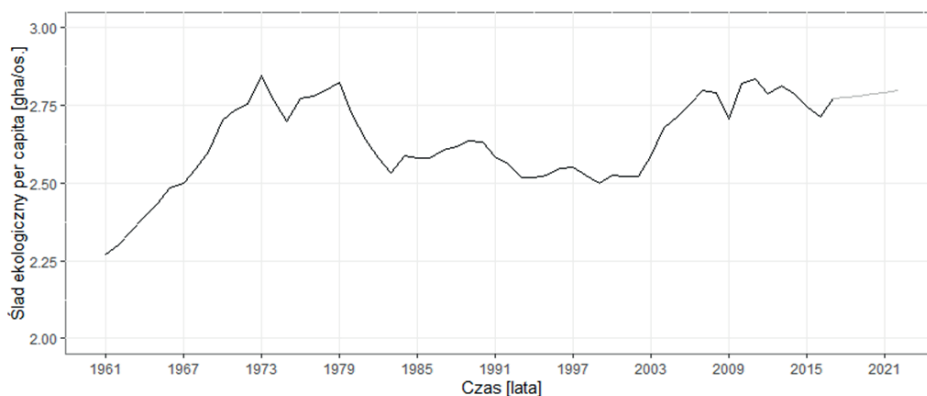
**Tabela 5.** Wartości bezwzględnych i względnych błędów prognoz wygasłych *ex post* w latach 2013–2017

Rok	Wartość bezwzględnego błędu prognozy w czasie $t$	Wartość względnego błędu prognozy w czasie $t$ [%]
2013	0,015	0,5
2014	0,022	0,8
2015	0,074	2,7
2016	0,120	4,4
2017	0,080	2,9

Źródło: obliczenia własne.

Global Footprint Network do obliczeń wielkości śladu ekologicznego wykorzystuje dane z oficjalnych zbiorów danych Organizacji Narodów Zjednoczonych (UNdata), które uzupełniane są z opóźnieniem, dlatego najnowsze dane dotyczące śladu ekologicznego wydawane są z około czteroletnim opóźnieniem (Lin, Wambersie i Wackernagel, 2021). W związku z tym rzeczywiste wartości śladu ekologicznego *per capita* za lata 2018–2022 nie są dostępne, a zatem nie można zweryfikować trafności wyznaczonych prognoz.


Na rysunku 5 przedstawiono kształtowanie się śladu ekologicznego *per capita* w latach 1961–2017 wraz z prognozą na lata 2018–2022. Wartości prognoz wskazują na niewielki wzrost wartości badanego zjawiska w kolejnych latach. Warto nadmienić, że prognoza nie uwzględnia ani wahań w latach 2020–2022 spowodowanych pandemią COVID-19, podczas której funkcjonowanie wielu gospodarek było zaburzone, ani skutków wojny w Ukrainie.



**Rys. 5.** Kształtowanie się śladu ekologicznego *per capita* w latach 1961–2017 (krzywa czarna) z prognozą na lata 2018–2022 (krzywa szara)

Źródło: opracowanie własne z wykorzystaniem pakietu *ggplot2* w programie R.

Celem oceny, czy prognozowane wartości badanej zmiennej są obiektywnie wysokie, czy niskie, na rys. 6 przedstawiono kształtowanie się śladu ekologicznego *per capita* oraz potencjału biologicznego *per capita* (*biocapacity*), definiowanego jako ilość produktywnych biologicznie obszarów lądowych i morskich (*per capita*) dostępnych w celu zapewnienia zasobów, które ludność konsumuje, jak również wchłonięcia swoich odpadów, biorąc pod uwagę obecne technologie i praktyki zarządzania (Lin i in., 2019).



**Rys. 6.** Kształtowanie się śladu ekologicznego [gha/os.] (krzywa szara) i potencjału biologicznego *per capita* [gha/os.] (krzywa czarna) w latach 1961–2017

Źródło: opracowanie własne z wykorzystaniem pakietu *ggplot2* w programie R.

Jak można zauważyć na rys. 6, wielkość potencjału biologicznego *per capita* z roku na rok maleje, co się wiąże z nadmierną eksploatacją środowiska naturalnego. W 1970 r. wartość śladu ekologicznego na osobę przekroczyła możliwości produkcyjne i regeneracyjne planety, a od 1984 r. różnica ta stale się pogłębia. Utrzymywanie się obecnego trendu degradacji środowiska z dużym prawdopodobieństwem będzie skutkowało w przyszłości problemami z dostępnością surowców. Zatem zmniejszenie poboru zasobów naturalnych jest kluczowe z punktu widzenia wzrostu gospodarczego, który jest uzależniony od możliwości produkcyjnych środowiska.

## 5. Zakończenie

Celem niniejszego badania było sprawdzenie, czy wielkość produktu krajowego brutto *per capita* istotnie wpływa na kształtowanie się śladu ekologicznego *per capita*, a także predykcja wartości śladu ekologicznego w kolejnych latach. Do realizacji pierwszego z celów wykorzystano analizę ekonometryczną. Zbudowano klasyczny model regresji liniowej, rozpatrując jako potencjalną zmienną objaśniającą

wielkość PKB *per capita*. Ze względu na występowanie zależności nieliniowej między badanymi zjawiskami obie zmienne zlogarytmowano. Zbudowany model spełniał wszystkie założenia dotyczące metody najmniejszych kwadratów. Przeprowadzona analiza pozwala stwierdzić, że PKB *per capita* determinuje wielkość śladu ekologicznego *per capita*. Zmienność śladu ekologicznego została wyjaśniona w zadowalającym stopniu przez oszacowany model log-liniowy. Otrzymane rezultaty wskazują, że wzrost PKB *per capita* o 1% prowadzi do wzrostu śladu ekologicznego *per capita* o 0,419%. Celem potwierdzenia stabilności badanej zależności w czasie, przeprowadzono analogiczne analizy dla wcześniejszych lat. Ich wyniki dają twierdzącą odpowiedź na postawione pytanie badawcze o występowaniu stabilności wpływu PKB na kształtowanie się śladu ekologicznego.

Do realizacji drugiego celu badawczego wykorzystano model liniowy Holta. Parametry wygładzania otrzymano, minimalizując błąd średniokwadratowy prognoz wygasłych. Wyznaczono prognozy na kolejne pięć lat (2018–2022). Dopuszczalność prognoz oceniono na podstawie błędów *ex post* prognoz wygasłych (2013–2017), wyznaczonych tą samą metodą co prognozowane wartości. W każdym z badanych lat wartość błędu była niższa od zadanej wartości progowej, co oznacza, że prognozy na lata 2018–2022 zostały wyznaczone prawidłowo. Prognozowany jest wzrost śladu ekologicznego *per capita* na świecie, jakoś wyznaczonych prognoz należy uznać za dobrą. Ze względu na złożoność procesu gromadzenia i przetwarzania danych nie zostały jeszcze opublikowane rzeczywiste wartości śladu ekologicznego *per capita* dotyczące okresu prognozy, a zatem trafność prognoz nie została oceniona.

W ostatniej części pracy zwrócono uwagę na problem nadmiernej eksploatacji środowiska naturalnego. Aby wzrost gospodarczy w kolejnych latach był możliwy, konieczne jest zmniejszenie poboru zasobów naturalnych. W pracy nie rozwinięto dogłębnie problemu ograniczoności zasobów, więc analiza sposobów redukcji zużycia surowców i miar wzrostu gospodarczego, innych niż PKB, może być przedmiotem dalszych rozważań.

## Literatura

- Ampuła, D. (2014). Regresja jako metoda procesu predykcji. *Problemy Techniki Uzbrojenia*, 43(130), 67–78.
- Borucke, M., Moore, D., Cranston, G., Gracey, K., Iha, K., Larson, ... Galli, A. (2013). Accounting for demand and supply of the biosphere's regenerative capacity: The National Footprint Accounts' underlying methodology and framework. *Ecological Indicators*, 24, 518–533.
- Brundtland, G. H. (1987). Our common future. W: M. K. Tolba, i A. K. Biswas, (red.), *Earth and us: population – resources – environment – development*. Oxford: Butterworth-Heinemann.
- Cieślak, M. (red.). (2005). *Prognozowanie gospodarcze: metody i zastosowania*. Warszawa: Wydawnictwo Naukowe PWN.
- Dittmann, I., Dittmann, P., Szabela-Pasierbińska, E. i Szpulak, A. (2011). *Prognozowanie w zarządzaniu sprzedażą i finansami przedsiębiorstwa*. Warszawa: Wolters Kluwer.

- Dziechciarz, J. (red.). (2012). *Ekonometria. Metody, przykłady, zadania*. Wrocław: Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu.
- Fedrigo-Fazio, D. i ten Brink, P. (2012). *Green economy: what do we mean by green economy?* Pobrane z <https://wedocs.unep.org>
- Fiedor, B. (red.). (2002). *Podstawy ekonomii środowiska i zasobów naturalnych*. Warszawa: C.H. Beck.
- Global Footprint Network. (2021). *National footprint and biocapacity accounts, 2021 edition*. Pobrane z <https://data.footprintnetwork.org/>
- Gładysz, B. i Mercik, J. (2007). *Modelowanie ekonometryczne. Studium przypadku* (wyd. II). Wrocław: Oficyna Wydawnicza Politechniki Wrocławskiej.
- Gruszczyński, M., Kuszewski, T. i Podgórska, M. (red.). (2009). *Ekonometria i badania operacyjne: podręcznik dla studiów licencjackich*. Warszawa: Wydawnictwo Naukowe PWN.
- Lin, D., Hanscom, L., Martindill, J., Borucke, M., Cohen, L., Galli, ... Wackernagel, M. (2019). *Working guidebook to the national footprint accounts, 2019 edition*. Oakland: Global Footprint Network.
- Lin, D., Wambersie, L. i Wackernagel, M. (2021). *Estimating the date of earth overshoot day 2021*. Pobrane z <https://www.overshootday.org>
- Maddala, G. S. (2006). *Ekonometria*. Warszawa: Wydawnictwo Naukowe PWN.
- Mankiw, N. G. i Taylor, M. P. (2009). *Makroekonomia*. Warszawa: Polskie Wydawnictwo Ekonomiczne.
- Ostasiewicz, W. (2016). *Metabometria. Śląski Przegląd Statystyczny, 14(20)*, 145–184. doi: 10.15611/sps.2016.14.09
- Ostasiewicz, W. (2017). *Ekosocjonomia: nauka o gospodarowaniu. Śląski Przegląd Statystyczny, 15(21)*, 233–250. doi: 10.15611/sps.2017.15.12
- Szyja, P. (2015). *Pojęcie, tworzenie i pomiar zielonej gospodarki. Gospodarka w Praktyce i Teorii, 2(39)*, 21–38. doi: 10.18778/1429-3730.39.02
- Wackernagel, M. i Beyers, B. (2019). *Ecological footprint: Managing our biocapacity budget*. Gabriola Island, BC: New Society Publishers.

## Ecological Footprint versus GDP

**Abstract:** The article presents the results of the study for which the following objectives were set: to check whether the size of the Gross Domestic Product *per capita* significantly influences the ecological footprint *per capita*, as well as the prediction of the ecological footprint for subsequent years. To achieve the first of the objectives, the author has applied the OLS method of the log-transformed variables. The results show that GDP *per capita* significantly influences the ecological footprint *per capita* and it is a time-stable relationship. To achieve the second research objective, the author has used Holt's linear model and predicted ecological footprint *per capita* values for the period of 2018–2022. Basing on the *ex post* errors of expired forecasts, it is concluded that the levels of forecast accuracy are acceptable.

**Keywords:** ecological footprint, economic growth, Gross Domestic Product, sustainable development, green economy, econometric model, economic forecasting, Holt's linear model.