

Patrycja ŻEGLEŃ\*  
Małgorzata STEC\*\*  
Anna BERWIŃSKA-MAŁAJOWICZ\*\*\*

## RAZVOJ FUNKCIJE TURIZMA U ZEMLJAMA EU: MJERENJE I STATISTIČKA EVALUACIJA

### TOURIST FUNCTION DEVELOPMENT IN EU COUNTRIES: MEASUREMENT AND STATISTICAL EVALUATION

---

**SAŽETAK:** Iako su zemlje Europske unije (EU) među najvažnijim turističkim destinacijama na svijetu, njihov je razvoj funkcije turizma različit. Stoga nam se čini interesantnim usporediti razinu razvoja funkcije turizma u zemljama EU-a. U ovom se članku pokušava odrediti vrijednost sintetičke mjere razina razvoja funkcije turizma zemalja EU-a, uzimajući u obzir osam najčešće korištenih indikatora. U istraživanju se koristila *Mjera opće udaljenosti* (MOU) prema M. Walesiaku gdje je normalizacija varijabli provedena za razdoblje od 2007. do 2016. godine korištenjem formule temeljene na medijanu. Empirijsko istraživanje provedeno je za prosječne podatke i vremenske nizove, što je omogućilo usporedbu promjena u vremenskoj dimenziji analiziranih pojava. Na osnovu rezultata autori su rangirali zemlje EU-a prema stupnjevima razvoja funkcije turizma i klasificirali ih u tri skupine. Prema razini razvoja 2016. godine vodila je Malta. Srednje visok stupanj razvoja funkcije turizma zabilježen je u skupini zapadno-europskih zemalja dok su na srednje niskom stupnju razvoja bile srednjoeuropske i skandinavske zemlje te neke u Zapadnoj Europi. Dobiveni bi rezultati mogli poslužiti kao osnova za ispravnije upravljanje turizmom u zemljama EU-a i kompetentnije odlučivanje o alokaciji europskih sredstava.

**KLJUČNE RIJEČI:** destinacija, indeksi funkcije turizma, sintetički indikator funkcije turizma

**ABSTRACT:** European Union countries are the most significant tourist destinations around the world. However, the level of development of tourist function is not the same in all European Union countries. It seems interesting to compare the level of tourist function development of European Union countries. The article attempts to determine the value of the synthetic measure of levels of development of the tourist function of European Union countries, taking into consideration the eight most frequently utilised indicators. The study applies M. Walesiak's General Distance Measure (GDM), where the normalisation of variables was undertaken during 2007-2016 with the application of a median-based formula. The empirical research was conducted, using the dynamic approach (for cross-sectional and tidal data) thus, enabling the comparison of changes observed in the analysed phenomenon tidally. The research findings enabled the authors to rank EU countries in terms of their tourist function development levels and to classify them into three groups. In 2016, the leader regarding the level of development of tourist function was Malta. The majority of Western European countries have medium-high levels of development of in tourist function, whereas the group of countries with medium-low levels included countries from East-Central Europe, Scandinavian countries and several Western Europe countries. The obtained results can lay the foundation for the proper management of tourism in EU countries and for proper decision-making regarding the allocation of EU funds.

**KEY WORDS:** destination, tourist function indexes, synthetic tourist function indicator

---

\* Patrycja Żegleń, PhD, University of Rzeszów, Faculty of Economics, Poland, e-mail: [pzeglen@ur.edu.pl](mailto:pzeglen@ur.edu.pl)

\*\* Małgorzata Stec, PhD, University of Rzeszów, Faculty of Economics, Poland

\*\*\* Professor Anna Barwińska-Małajowicz, University of Rzeszów, Faculty of Economics, Poland

## 1. UVOD

Turizam je od vitalne važnosti za globalnu ekonomiju. Vrijedi napomenuti da je značaj turizma u stalnom usponu, a njegovi rezultati utječu na svjetsku ekonomiju. Međutim, taj rast ovisi o stupnju razvoja zemlje kao i o njezinom primarnom potencijalu. Zahvaljujući rastu prihoda od turizma, razvijenije europske zemlje doživjele su veliki porast udjela turizma u BDP-u (Gburopa, Matusikova i Benkova, 2015) u zadnjim desetljećima. Svjetsko vijeće za putovanja i turizam (WTTC) ([www.wttc.org](http://www.wttc.org)) procjenjuje da su u 2018. godini putovanja i turizam direktno ili indirektno zaslužni za generiranje 11,3% svjetskog BDP-a i 269 milijuna radnih mjesta diljem svjetskog gospodarstva. Za velik broj zemalja turizam je najveći izvozni proizvod, a u mnogim drugima uvršten je u tri glavne industrije. Nesumnjivo je da je ubrzanim rastom turizam postao glavna društvena i gospodarska snaga na svijetu. Na toj premisi temelji se istraživanje ovog sustava, naročito na području zemalja EU-a.

Sljedeća je hipoteza postavljena na propitivanje: Zemlje EU-a spadaju u skupinu zemalja visokog ili srednjeg stupnja razvoja funkcije turizma. Procjena stupnja razvoja funkcije turizma za neko područje nije jednostavan zadatak budući da se radi o složenom fenomenu<sup>1</sup>, na kojeg utječu brojni čimbenici. U dostupnoj literaturi iz područja turizma ne postoji opće prihvaćena mjera kojom bi se procijenio stupanj razvoja funkcije turizma za bilo koje posebno područje, naročito za zemlje EU-a. Neki izvori predlažu mjerenje funkcije turizma u nekom području putem indikatora na osnovu broja smještaj-

<sup>1</sup> Složeni ekonomski fenomeni nisu pogodni za složena izravna mjerenja, npr. socio-ekonomski razvoj zemalja, regija, itd., stupanj standarda života stanovništva, stanje na tržištu rada, financijska situacija u društvima, bankama, itd. (Pawełek 2008:19).

## 1. INTRODUCTION

The importance of tourism to the global economy is invaluable. The significance of tourism is continuously rising and its performance is reflected in the world's economy. However, this growth depends on the level of the country's development as well as on its primary potential. Thanks to tourism, more developed European countries have a high share in GDP's creation (Gburopa, Matusikova and Benkova, 2015). Its contribution has risen dramatically over recent decades. The World Travel and Tourism Council (WTTC) ([www.wttc.org](http://www.wttc.org)) estimates that tourism generated 11.3 % of world GDP in 2018 and 269 million jobs across the world. Tourism is the largest commodity in international trade for many countries being one of three most important industries. Without doubt, tourism and its meaning constitutes the premise for the empirical research in this field of study, especially in EU countries.

The following research hypothesis was submitted for verification: European Union countries belong to the group of high or medium levels of tourist function development. The evaluation of the level of development of tourist function for a given area seems a difficult task as it is a complex phenomenon,<sup>1</sup> influenced by many factors. Available specialist literature, lacks a universally accepted measure which could be used to evaluate and measure level of development of tourist function for any specific area, especially amongst EU countries. Some sources suggest measuring the tourist function of an area by means of indicators based on the number of accommodation facilities, the intensity of touristic traffic

<sup>1</sup> Complex economic phenomena are not subjected to direct measurement e.g. the socio-economic development of countries, regions etc., the level of living standards of population, situation on the job market, financial situation of companies, banks etc. (Pawełek 2008:19).

nih jedinica, intenziteta turističkog prometa i obima zapošljavanja u turizmu (Szromek, 2013; Walasek, 2014). Ovi indikatori, ako se posebno računaju i analiziraju, ne mogu dati potpunu sliku stupnja razvoja funkcije turizma u nekom području. Čini se da se taksonomske metode, uključujući metode linearnog poretka, mogu primijeniti u mjerenju stupnja razvoja funkcije turizma u nekom području. Zahvaljujući takvim metodama moguće je formirati tzv. sintetsku mjeru temeljenu na djelomičnim informacijama koje su uključene u određene varijable.

Treba naglasiti da su autori konstatirali nedostatak empirijskih radova na temu vrednovanja stupnjeva funkcije turizma u zemljama EU-a uz uporabu multivarijatne analize. Identifikacija stupnjeva razvoja funkcije turizma najčešće je ograničena na analizu određenog područja u zemlji ili na korištenje drugih metoda istraživanja (npr. Arimond i Elfessi, 2001; Blancasa *et al.*, 2010; Bąk i Szczecińska, 2015; Chandra i Menezes, 2001; Cracolici i Nijkamp, 2009; Durbarry, 2004; Dziedzic i Radkowska, 2014; Farrell i Twining-Ward, 2004; Gołembski, 2002; Ko, 2005; Lozano i Gutiérrez, 2011; Ostrowska, 2011; Rapacz, 2004; Song *et al.*, 2012; *The Travel & Tourism Competitiveness Report*, 2015; Zhang *et al.*, 2011). Stoga, multivarijatna analiza stupnja razvoja funkcije turizma u zemljama EU-a kojom su se autori koristili premošćuje ovaj „metodološki jaz“.

Cilj ovog rada je izrada statističke evaluacije stupnja razvoja turizma u EU u razdoblju od 2007. do 2016. godine. Evaluacija se temelji na indikatorima koji određuju stupnjeve razvoja funkcije turizma u zemljama EU-a<sup>2</sup>. Na temelju indikatora za svaku

and the size of employment in the tourist sector (Szromek, 2013; Walasek, 2014). These indicators, if calculated and analysed separately, cannot offer the full picture of the level of development of tourist function of an area. It seems that taxonomic methods, including linear ordering methods can be applied in case of measurements of levels of development of tourist function of an area. Thanks to such methods, it is possible to create the so called synthetic measure based on partial information included in particular variables.

It is worthy of emphasis that the authors observed the lack of empirical work concerning assessment of levels of tourist function development in EU countries, using the multivariate approach. The identification of levels of tourist function development is, most often, restricted to analyzing a given area within a country or using other research methods (e.g. Arimond and Elfessi, 2001; Blancasa *et al.*, 2010; Bąk and Szczecińska, 2015; Chandra and Menezes, 2001; Cracolici and Nijkamp, 2009; Durbarry, 2004; Dziedzic and Radkowska, 2014; Farrell and Twining-Ward, 2004; Gołembski, 2002; Ko, 2005; Lozano and Gutiérrez, 2011; Ostrowska, 2011; Rapacz, 2004; Song *et al.*, 2012; *The Travel & Tourism Competitiveness Report*, 2015; Zhang *et al.*, 2011). Therefore, the multivariate approach in the assessment of the level of tourist function development in EU countries used by the authors completes the “methodological gap”.

The aim of the article is to perform a statistical evaluation of the level of tourism development of European Union countries from 2007 to 2016. The basis for the evaluation are the indicators determining levels of development of tourist function of EU countries<sup>2</sup>.

<sup>2</sup> Tzv. turistička privlačnost destinacija nije uzeta u obzir prilikom istraživanja zbog polisemijske prirode termina. Radi se objektivnim čimbenicima, npr. prirodne atrakcije, spomenici, kao i oni subjektivni, vezuju se s njihovom valorizacijom od strane turista i investitora. O ovim

<sup>2</sup> The so called tourist attractiveness of destinations was not incorporated into the research because the term is polysemic. It concerns objective factors, eg. natural attractions, monuments as well as subjective ones connected with their assessment of tourists or investors. The elements are difficult to opine with the use of quantity indicators.

zemlju su postavljene vrijednosti sintetičkog mjerenja putem *Mjere opće udaljenosti* (MOU). Korištenje dinamičkog pristupa u istraživanju omogućilo je usporedbu promjena u analiziranom fenomenu tijekom cijelog razdoblja<sup>3</sup>. Posljedično, zemlje EU-a mogli smo rangirati i grupirati slične zemlje prema razinama razvoja funkcije turizma. Promjene u razini razvoja funkcije turizma zemalja EU-a uspoređivane su također za 2016. u odnosu na 2007. godinu<sup>4</sup>. U postupku istraživanja provedeno je statističko vrednovanje stupnja razvoja funkcije turizma u zemljama EU-a, a na vrijednosti dobivene sintetičke mjere temelji se klasifikacija europskih zemalja na skupine sličnih stupnjeva razvoja funkcije turizma. Empirijsko istraživanje je provedeno korištenjem programa *R* (proračuni su se bazirali na paketu clusterSim programa *R*).

## 2. ZNAČAJ TURZIMA

Turizam ima važnu ulogu otkako je postao primarno značajan za svjetsku ekonomiju. Na početku trećeg milenija turizam je postao najbrže rastuća ekonomska aktivnost u svijetu čime je nastavio privlačiti sve više pozornosti. Mnoga lokalna gospodarstva uvelike ovise o turizmu i za neka od njih po-

---

se elementima teško može odlučivati uporabom indikatora kvantitete. Analiza turističke atraktivnosti destinacije uglavnom je predmet posebnih istraživanja.

<sup>3</sup> Korištenje ispravnog pristupa važno je zbog korektnosti zaključaka koji se izvode na temelju provedenog istraživanja. Proračun sintetičkih indikatora za svaku zemlju je posebno statički i ne omogućuje uspoređivanje promjena vrijednosti sintetičkih indikatora tijekom vremena.

<sup>4</sup> Kako bi se promatrale promjene stupnja analizirane pojave potreban je protok vremena. Zato su sintetički indikatori stupnja razvoja funkcije turizma bili definirani za sve analizirane godine, dok se šira analiza bavila ekstremnim godinama, 2007. i 2016.

Based on the indicators, values of synthetic measure were established for each country by means of the General Distance Measure (GDM). The use of dynamic approach in the research enabled the comparison of changes in the analysed phenomenon over the entire period of time<sup>3</sup>. As a consequence, it was possible to create a ranking of EU countries and to group similar countries according to levels of development of tourist function. The changes in the level of tourist function of EU countries were also evaluated for the year 2016 in relation to the year 2007<sup>4</sup>. As a result of the application of the research procedure, a statistic evaluation of the level of development in tourist function of EU countries was performed. The values of synthetic measure obtained formed the basis for the classification of European countries into groups of similar levels of development of tourist function. Empirical research was conducted with the use of *R* programme (calculations using clusterSim package of *R* programme).

## 2. SIGNIFICANCE OF TOURISM

Tourism plays an important role since it became the industry of primary importance for the world economy. At beginning of the 3rd millennium, the tourism industry has proved to be one of the fastest growing economic sectors in the world, which has continued to

---

Analysis of tourist attractiveness of destinations is the object of separate research mostly.

<sup>3</sup> The use of proper approach is important in terms of correctness of conclusions drawn on the base of conducted research. Calculation of synthetic indicators for each year separately (in a static way) does not enable to compare changes in values of synthetic indicators tidally.

<sup>4</sup> In order that one can observe changes in the level of the analysed phenomenon it needs a flow of time. Therefore the synthetic indicators of the level of tourist function development were definite for all the analysed years, whereas broader analysis was made for extreme years, i.e. 2007 and 2016.

stao je glavni izvor prihoda i deviza. Pozitivni aspekt turizma jest činjenica da služi kao važan izvor zapošljavanja za različite društvene skupine. Također potiče potrošnju u turističkim destinacijama i stvara dodatnu potražnju za uslugama (Pearce, 1989). Ekonomski utjecaj turizma proistječe iz uravnoteženosti troškova i koristi koje sadrži (Pearce, 1989). Istraživanja ekonomskog udjecaja turizma prvenstveno su se fokusirala na multiplikativne učinke potrošnje i na zapošljavanje proizašlo iz turizma (Butler, 1974; Turner i Witt, 2001; Mason, 2003). Prema Andergassen, Candela and Figini (2017), turističke destinacije razlikuju se po načinima upravljanja i razvoja, a ta činjenica je značajna kada se radi o funkcijama turizma u regijama i destinacijama diljem svijeta.

Još jedan važan aspekt turizma je marketing. Kao i u svakom drugom području, vjernost klijenta je odlučujuće pitanje turističkog marketinga (Middleton, 1994; Buhalis, 2000). Poznata je činjenica da je rentabilnije zadržati klijenta nego tražiti novog. Uspjeh turističke destinacije ovisi najčešće o udjelu lojalnih turista. Danas turizam uključuje gotovo sve aspekte društva i heterogenog je karaktera. Brojni su znanstvenici pokušali definirati turizam iz različitih perspektiva. Kotler i Armstrong (1994) definirali su „usluge“ kao bilo koju djelatnost ili korist koju jedna stranka može ponuditi drugoj, a koja je temeljno nematerijalna i ne dovodi do posjedovanja nečega. Postoji opće slaganje da usluge imaju jedinstvene značajke koje ih razlikuju od roba/dobara, a to povlači i primjenu različitih marketinških strategija u oba slučaja.

Ukratko, putovanja i turizam najveće su svjetske aktivnosti s globalnim ekonomskim doprinosima (izravnim, neizravnim i induciranim) za brojne zemlje, poput Francuske i Sjedinjenih Američkih Država, tradicionalno popularnih turističkih destinacija. Stoga je turistička statistika ključna informacija za gospodarske planere, znanstvenike u turiz-

attract more and more attention. Many local economies heavily depend on tourism and for some countries it has become the main source of income and foreign exchange. One positive aspect of tourism is that it has served as a crucial source of employment for different social groups. It creates and boosts demand and supply in tourist destinations (Pearce, 1989). Research studies delving the economic impact of tourism have previously focused on the multiplier effect of expenditures, and the employment generated as a result of tourism (Butler, 1974; Turner and Witt, 2001; Mason 2003). According to Andergassen, Candela, and Figini (2017), tourist destinations are managed and developed in different ways, which plays a significant role in case of tourist functions of regions and destinations all over the world.

Another important aspect related to tourism is its marketing: as in any other area, customer loyalty is a crucial issue in tourism marketing (Middleton, 1994; Buhalis, 2000). It is a well-known fact that retaining customers is less expensive than seeking for new ones. The success of a tourism destination depends on the ratios of its loyal tourists. Nowadays, tourism involves almost all aspects of the society and has got a heterogeneous character. Many researchers have tried to define tourism from different perspectives. “Services” have been defined by Kotler and Armstrong (1994) as any activity or benefit that can be offered to various people that is essentially intangible and does not result in the ownership of anything. It is known that services have unique character that differentiate them from goods hence there should be different marketing strategies applied for both.

To sum up, the travel and tourism industry is one of the world’s largest industries with a global economic contribution (direct, indirect and induced) for a number of countries, such as France and the United States that are popular tourism destinations ([www.statista.com](http://www.statista.com), available at: 23.06.2019). Therefore, tourism statistics are key information for economic planners, tourism researchers,

mu i sve pružatelje turističkih usluga (Aroca *et al.*, 2017).

Važno pitanje koje se odnosi na ekonomski aspekt turizma je pojam životnog ciklusa nekog receptivnog područja, što može doprinijeti ne samo analizi interakcije između ponude i potražnje nego i promjeni načina razmišljanja o dugoročnim posljedicama razvoja turizma (Cooper *et al.*, 1993). Sljedeća važna značajka je tzv. identitet određenih turističkih regija koje se trude razlikovati od ostalih receptivnih područja (MacCannell, 2001) obavljanjem specifičnih funkcija turizma.

### 3. KONCEPTI I INDIKATORI FUNKCIJE TURIZMA NA ODREĐENIM LOKACIJAMA

Definicije turizma i njegovih funkcija razlikuju se po motivima i izvorima. Jedna od najpopularnijih definicija turizma naglašava njegov ekonomski i društveni značaj, a definira turizam kao zbir odnosa između turista, domaćina, dobavljača, itd. (McIntosh i Goeldner, 1986). Kod predstavljanja pitanja o turističkim funkcijama destinacija mora se naglasiti glavna uloga turizma u gospodarstvu EU-a. Prema Europskoj komisiji radi se o trećoj najvećoj socio-ekonomskoj aktivnosti EU-a (nakon trgovine i distribucije te graditeljstva), koja značajno doprinosi BDP-u EU-u (Paulo, 2000; Juul, 2015). Funkcija turizma najčešće se razumije kao socio-ekonomska djelatnost koju stanovnici određenih krajeva poduzimaju s ciljem pružanja usluga za turistički promet (Matczak, 1989; Kowalczyk, 2000; Kurek i Mika, 2007).

Razvoj funkcije turizma obično je određen pomoću indeksa koji se zasnivaju na broju smještajnih jedinica, intenzitetu turističkog prometa i obimu zapošljavanja u turizmu. Najčešće korišteni indikatori za stupanj funkcije turizma su sljedeći (Szromek, 2012; Szromek, 2013):

and all tourist services providers (Aroca *et al.*, 2017).

A very important issue related to the economic aspect of tourism is the concept of life-cycle of a receptive area, which can contribute not only to the analysis of interaction between supply and demand, but also to the change in ways of thinking about long-term implications resulting from the development of tourism (Cooper *et al.* 1993). Another important aspect is the so called identity of particular tourist regions which endeavour to become distinct from other receptive areas (MacCannell, 2001) by performing specific tourist functions.

### 3. CONCEPTS AND INDICATORS OF THE TOURIST FUNCTION OF GIVEN LOCATION

Definitions of tourism and its functions vary by their motives and sources. One of the most popular definitions of tourism underlines the economic and social value of tourism. It says that tourism is the sum of relationships between tourists, hosts, suppliers, etc. (McIntosh and Goeldner, 1986). The major role of tourism in EU's economy has to be emphasized when presenting issues concerning the tourist function of destinations. According to the European Commission, it is the third largest socio-economic activity in the European Union (after trade and distribution, and construction sectors), and makes an important contribution to the EU's GDP (Paulo, 2000; Juul, 2015). Tourist function is most frequently understood as a socio-economic activity undertaken by a particular area and its inhabitants, aimed at providing services for the tourist traffic (Kowalczyk, 2000; Kurek and Mika, 2007; Matczak, 1989).

The development of tourist function is usually determined by means of indexes based on the number of accommodation facilities, the intensity of tourist traffic and the size of employment in the tourist sector. The most frequently used indicators of the level of tourist function are as follows (Szromek, 2012; Szromek, 2013):



- Beretje i Defertov indeks, kojim se određuje razvoj turističkih kapaciteta, izračunava se kao broj kreveta u odnosu na 1000 stalnih stanovnika na nekom području (broj kreveta/ 1000 stanovnika) (X1),
- Defertov indeks gustoće turističkog prometa koji se izražava omjerom broja turista smještenima po jedinici prostora od 1km<sup>2</sup> (broj smještenih turista na 1 km<sup>2</sup> prostora) (X2),
- Schneiderov indeks, koji određuje inenzitet turističkog prometa izražen brojem turista koji koriste smještaj u odnosu na tisuću stalnih stanovnika koji borave na nekom području (broj smještenih turista/1.000 stanovnika) (X3),
- Charvatov indeks gustoće smještenih turista koji određuje broj noćenja prema smještenim turistima u odnosu na 100 stalnih stanovnika na nekom području (broj noćenja/100 stanovnika) (X4),
- Gustoća smještajnih kapaciteta izražena kao odnos broja turističkih kreveta i područja izraženom u km<sup>2</sup> (X5),
- Indeks smještajnog kapaciteta izražen je brojem kreveta koji se nude u grupnim smještajnim objektima (X6),
- Odnos prihoda i troškova inozemnog turizma (X7),
- Postotak zaposlenih u razvoju turizma i gastronomije u odnosu na ukupan broj zaposlenih (X8).

Turistička satelitska bilanca također je vrlo značajna kod prezentiranja utjecaja turizma na nacionalne ekonomije i razinu turističke funkcije u destinacijama (Frechtling, 2010; Tourism Satellite Account, 2010).

#### 4. METODOLOGIJA

Metode linearnog poretka mogu se svrstati u dvije skupine: s obrascem i bez obrasca. Kod metode bez obrasca sintetska varijabla je funkcija normaliziranih vrijednosti

- Beretje and Defert index, which determines the development of tourist facilities, calculated as the number of tourist bed places in relation to 1000 permanent residents of an area (number of bed places/ 1000 population) (X1),
- Defert index of tourist traffic density, which is expressed by the ratio of the number of tourists who use accommodation in a unit area in 1km<sup>2</sup> (number of accommodated tourists/1 km<sup>2</sup> of area) (X2),
- Schneider index, which determines the intensity of tourist traffic expressed by the number of tourists who use accommodation in relation to 1000 permanent residents of an area (number of accommodated tourists/1000 population) (X3),
- Charvat index of tourist accommodation density, which determines the number of nights spent by accommodated tourists in relation to 100 permanent residents of an area (number of nights spent/100 population) (X4),
- Density of accommodation facilities expressed as a ratio of the number of tourist bed places to the area in km<sup>2</sup> (X5),
- The use of accommodation capacity index is expressed by the number of bed places provided in group accommodation facilities (X6),
- The ratio of incomes and expenses regarding foreign tourism (X7),
- The percentage of employees in tourism development and gastronomy relative to the general number of employees (X8).

Tourism Satellite Account is also of great importance when presenting tourism impact on the national economies and the level of tourist function of destinations (Frechtling, 2010; Tourism Satellite Account, 2010).

#### 4. METHODOLOGY

Generally speaking, linear ordering methods can be categorised into two groups: pat-

ulaznih varijabli. S druge strane, kod metoda s obrascem sintetska varijabla je funkcija normaliziranih vrijednosti ulaznih varijabli, tj. model objekta sa željenim vrijednostima ulaznih varijabli. Sintetska mjera kreira se na osnovu mjerenja distance između istraživog predmeta i obrasca predmeta (Panek, 2009).

U svrhu ocjenjivanja razvoja funkcije turizma u zemljama EU-a, autori predlažu korištenje jedne od metoda s obrascem tj. metodu *Mjere opće udaljenosti* (Walesiak).<sup>5</sup> Metoda se temelji na ideji poopćenog koeficijenta korelacije koji se sastoji od Pearson-ovog koeficijenta korelacije i Kendallovog koeficijenta korelacije. Prednosti i nedostaci ove metode su kako slijedi (Jajuga *et al.*, 2003):

- može se primijeniti kada su objekti opisani varijablama mjerjenima na kvocijentalnoj, intervalnoj, ordinalnoj ili skali omjera
- može poprimiti vrijednosti vrijednosti intervala [0; 1],
- usklađena je sa zahtjevima sintetskih mjerenja,
- ne mijenja vrijednost kao rezultat mapiranih varijabli mapi upotrebom dozvoljenih matematičkih mapa u omjeru.

Postupak linearnog poretka predmeta pomoću izabrane metode uključuje sljedeće faze (Walesiak, 2011:74-76):

- početna točka je podatkovna matrica  $X$  sljedećeg oblika:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

<sup>5</sup> Važno je napomenuti da je ovo jedno od najnovijih metodoloških rješenja; štoviše, njezin računalni postupak je dostupan u programu slobodnog dohvata *R*.

tern and non-pattern methods. The non-pattern method, a synthetic variable, is a function of normalised values of input variables. Pattern methods, in turn, utilise the concept of a pattern object i.e. a model object with desirable values of input variables. Synthetic measure is created on the basis of measuring the distance between the researched object and the pattern object (Panek 2009).

For the purpose of evaluation of the development of tourist function in EU countries, the authors suggest using one of the pattern methods i.e. the method of General Distance Measure by M. Walesiak.<sup>5</sup> The method, in its construction, is based on the idea of the generalised correlation coefficient comprising Pearson's line correlation coefficient and Kendall's tau correlation coefficient. The strengths and weaknesses of GDM method are as follows (Jajuga *et al.*, 2003):

- It can be applied when the objects are described by variables measured on a quotient, interval, ordinal or ratio scale,
- it takes values from the [0; 1] interval,
- it complies with requirements of synthetic measurements,
- it does not change the value as a result of a map's variables with the use of a permissible mathematical map on the scale.

The procedure of linear ordering of objects by means of a selected method involves the following stages (Walesiak, 2011: 74-76):

- the starting point is the  $X$  data matrix in the following form:

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1m} \\ x_{21} & x_{22} & \cdots & x_{2m} \\ \vdots & \vdots & \vdots & \vdots \\ x_{n1} & x_{n2} & \cdots & x_{nm} \end{bmatrix} \quad (1)$$

<sup>5</sup> It has to be emphasized that this method is one of the latest methodological solutions; what is more, its computational procedure is available in the non-commercial package of *R* program.



gdje je:

$x_{ij}$  - vrijednost varijable  $X_j$  ( $j= 1,2,\dots,m$ ) u objektu  $O_i$  ( $i=1,2,\dots, n$ ),

- određuje se tip varijabli (stimulanti, destimulanti),<sup>6</sup>
- kako bi se varijable mogle uspoređivati, primjenjuje se postupak tzv. normalizacije. Ovo istraživanje primjenjuje relativno nov način normalizacije varijable koji se temelji na medijanu. Medijan je visoko otporan na pojavu netipičnih vrijednosti, što je, čini se, izvanredno obilježje, budući da se često može dogoditi da su analizirane zemlje znatno diverzificirane i vrlo asimetrične u pogledu vrijednosti varijabli.

Normalizacija se provodi prema sljedećoj formuli<sup>7</sup> (Walesiak, 2014:364-372; Gryszel, Walesiak, 2018:155):

$$z_{ij} = \frac{x_{ij} - med_j}{\sqrt{\sum_{i=1}^n (x_{ij} - med_j)^2}} \quad (2)$$

gdje je:

$z_{ij}$  - normalizirana vrijednost  $j$ -te varijable za  $i$ -ti objekt

$x_{ij}$  - vrijednost  $j$ -te varijable za  $i$ -ti objekt

$med_j = med_i(x_{ij})$  - medijan  $j$ -te varijable.

<sup>6</sup> Pojam stimulanata i destimulanata uveo je Z. Hellwig (1968:323-326). Stimulanti su značajke čije su visoke vrijednosti poželjne s neke pretpostavljene/zamišljene točke gledišta (npr. stupanj razvoja funkcije turizma na nekom području), dok se njihove niske vrijednosti smatraju nepoželjnim. Destimulanti su značajke čije su niske vrijednosti poželjne s neke točke gledišta, a njihove se visoke vrijednosti smatraju nepoželjnim.

<sup>7</sup> Kod izoliranih opažanja u skupu varijabli (koji je indiciran visokim vrijednostima varijable i koeficijentom asimetrije korištenjem klasičnih metoda) može se doći do netočnih rezultata. U istraživanju u kojem se priprema rangiranje objekata vrijedi primijeniti medijan kako bi se prikazala visoka tolerancija na netipična opažanja.

where:

$x_{ij}$  - the value of the variable  $X_j$  ( $j= 1,2,\dots,m$ ) in the object  $O_i$  ( $i=1,2,\dots, n$ ),

- the type of variables is determined (stimulants, destimulants),<sup>6</sup>
- in order to make the variables comparable, the procedure of the so called normalisation is applied. The study applies a relatively new way of normalisation of variables based on a median. A median is highly resistant to the occurrence of extreme values, which seems to be a remarkably valuable feature, since it might often be the case that the analysed countries are considerably diversified and highly asymmetrical regarding the values of the variables.

Normalisation is conducted according to the following formula<sup>7</sup> (Walesiak, 2014:364-372; Gryszel, Walesiak, 2018:155):

$$z_{ij} = \frac{x_{ij} - med_j}{\sqrt{\sum_{i=1}^n (x_{ij} - med_j)^2}} \quad (2)$$

where:

$z_{ij}$  - normalised value of the  $j$ -th variable for the  $i$ -th object,

$x_{ij}$  - value of the  $j$ -th variable for the  $i$ -th object,

$med_j = med_i(x_{ij})$  - median for the  $j$ -th variable.

<sup>6</sup> The concept of stimulants and destimulants was introduced by Z. Hellwig (1968:323-326). Stimulants are features, the high values of which are a desirable phenomenon from the assumed point of view (e.g. the level of development of tourist function of an area), whereas their low values are considered to be undesirable. Destimulants are features, the low values of which are a desirable phenomenon from a given point of view, while their high values are deemed undesirable.

<sup>7</sup> In case of isolated observations in variables' set (indicated by high values of variable and asymmetry coefficient) the use of classical methods may cause false results then. In the research in which ranking of objects is prepared it is worth to apply median characterising a high tolerance to isolated observations.

Formula normalizacije (2) važna je budući da osigurava različitu varijabilnost normaliziranih vrijednosti varijabli (mjenjenih apsolutnom devijacijom medijana).

- koordinate objekta obrasca (gornja polovica po razvijenosti) pokazuju najpovoljnije vrijednosti varijabli stimulanata i destimulanata,<sup>8</sup>
- razdaljine između određenih objekata i objekta obrasca određuju se putem Mjere opće udaljenosti prema M. Walesiaku za numeričke podatke:

$$d_{ik} = \frac{1}{2} \frac{\sum_{j=1}^m (z_{ij} - z_{kj})(z_{kj} - z_{lj}) + \sum_{\substack{j=1 \\ l \neq i, k}}^n \sum_{l=1}^n (z_{ij} - z_{lj})(z_{kj} - z_{lj})}{2 \left[ \sum_{j=1}^m \sum_{l=1}^n (z_{ij} - z_{lj})^2 \cdot \sum_{j=1}^m \sum_{l=1}^n (z_{kj} - z_{lj})^2 \right]^{\frac{1}{2}}} \quad (3)$$

gdje je:

$i, k, l = 1, \dots, n$ - brojevi objekata,

$j = 1, \dots, m$  – broj varijable,

$m$  – broj varijabli,

$z_{ij}$  ( $z_{kj}$ ,  $z_{lj}$ )- normalizirana vrijednost  $j$ -te varijable za  $i$ -ti ( $k$ -ti,  $l$ -ti) objekt,

- Elementi skupine predmeta slažu se prema npr. rastućim vrijednostima distance GDM (gornja polovica razvijenosti).

Istraživanje će se odvijati na dinamičan način, tzv. pristupom „objektnih razdoblja,” uzimajući u obzir vrijednosti indeksa iz cijelog razdoblja istraživanja, tj. od 2007. to 2016. godine. Standardni parametar (medijan) određen je za svaku varijablu uzimajući u obzir sve analizirane godine (tzv. dinamični pristup).

Utvrđene vrijednosti sintetske mjere trebaju slijediti poredak od najniže do najviše na čemu bi se temeljilo moguće određivanje

The normalization formula (2) is important since it ensures different variability for the normalized variable values (measured by median absolute deviation).

- the coordinates of the pattern object (the upper pole of development) are determined i.e. the most favourable values of stimulant and destimulant variables,<sup>8</sup>
- the distances between the particular objects and the pattern object are determined by means of the General Distance Measure (GDM) by M. Walesiak for metric data:

$$d_{ik} = \frac{1}{2} \frac{\sum_{j=1}^m (z_{ij} - z_{kj})(z_{kj} - z_{lj}) + \sum_{\substack{j=1 \\ l \neq i, k}}^n \sum_{l=1}^n (z_{ij} - z_{lj})(z_{kj} - z_{lj})}{2 \left[ \sum_{j=1}^m \sum_{l=1}^n (z_{ij} - z_{lj})^2 \cdot \sum_{j=1}^m \sum_{l=1}^n (z_{kj} - z_{lj})^2 \right]^{\frac{1}{2}}} \quad (3)$$

where:

$i, k, l = 1, \dots, n$ - numbers of objects,

$j = 1, \dots, m$  - number of a variable,

$m$  - number of variables,

$z_{ij}$  ( $z_{kj}$ ,  $z_{lj}$ )- normalised value of the  $j$ -th variable for the  $i$ -th ( $k$ -th,  $l$ -th) object,

- The elements of the set of objects are put in order according to e.g. the growing values of GDM distances (the upper pole of development).

The research will be conducted in a dynamic way in the so called “object-periods” taking into consideration the values of indexes from the whole researched period i.e. years from 2007 to 2016. Standard parameter (median) was defined for each variable taking all the analysed years into account (the so called dynamic approach).

The determined values of the synthetic measure should be ordered from the lowest

<sup>8</sup> Koordinate objekta obrasca mogu se odrediti i pomoću donje polovice razvijenosti tj. najnepovoljnijim vrijednostima varijabli stimulanata i destimulanata.

<sup>8</sup> The coordinates of the pattern object can also be determined by means of the lower pole of development i.e. the least favourable values of stimulant and destimulant variables.

skupina sličnih objekata u odnosu na istraživanu pojavu. Skupine objekata mogu se odrediti putem dijagrama temeljenog na mjerama lokacije (Wysocki, 2010):

to the highest one, on the bases of which, it will be possible to determine groups of similar objects regarding the researched phenomenon. Groups of objects can be determined by means of a diagram based on measures of location (Wysocki 2010):

skupina I: $GDM_i < med - 2,5 \cdot mad$	visoka razina	
skupina II: $med - 2,5 \cdot mad \leq GDM_i < med$	srednje-visoka razina	
skupina III: $med \leq GDM_i < med + 2,5 \cdot mad$	srednje-niska razina	(4)
skupina IV: $GDM_i \geq med + 2,5 \cdot mad$	niska razina	

group I: $GDM_i < med - 2,5 \cdot mad$	high level	
group II: $med - 2,5 \cdot mad \leq GDM_i < med$	medium-high level	
group III: $med \leq GDM_i < med + 2,5 \cdot mad$	medium-low level	(4)
group IV: $GDM_i \geq med + 2,5 \cdot mad$	low level	

gdje je:

$med$  – medijan,

$mad$  – apsolutna devijacija medijana izračunata iz:

$$mad = med |GDM_i - med|.$$

where:

$med$  – median,

$mad$  – median absolute deviation calculated from:

$$mad = med |GDM_i - med|.$$


## 5. REZULTATI

Prvobitno vrednovanje stupnja razvoja funkcije turizma u zemljama EU-a provedeno je usporedbom vrijednosti indeksa X1-X8 tijekom dviju godina, 2007. i 2016. Slika 1 prikazuje vrijednosti Baretje-Defert-ovog indeksa (X1) za zemlje EU-a.

## 5. RESULTS


The initial evaluation of the level of development of tourist function in EU countries was performed by comparing the values of particular indexes X1-X8, in the two years i.e. in 2007 and in 2016. Figure 1 shows values of Baretje-Defert index (X1) for EU countries.

**Slika 1: Vrijednosti Baretje-Defertovog indeksa (X1) u zemljama EU 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 1: The values of Baretje-Defert index (X1) in EU countries in 2007 and in 2016**



Source: Own research based on Eurostat data


Godine 2016. indeks broja kreveta u odnosu na 1000 stanovnika na području (X1) porastao je u 21 zemlje EU-a (najveći rast zabilježen je u Hrvatskoj, Grčkoj i Sloveniji) u usporedbi s 2007. godinom, dok je u sedam zemalja EU-a (posebice Luksemburg, Cipar i Francuska) pao. Prosječna vrijednost indeksa X1 za sve zemlje EU bila je 59,3 2007. godine, a 2016. je bilo 67,8 turističkih kreveta na 1000 stanovnika. Razlike među zemljama EU-a mjerene koeficijentom varijacije mogu se smatrati umjerenima. Međutim, asimetrija indeksa X1 pokazala je uspon, naročito između 2012. i 2016. godine (indikator asimetrije bio je između 1,2 i 2,15), što znači da je u većini zemalja EU-a indeks turističkih kreveta na 1000 stanovnika na nekom području bio ispod prosjeka.

Malta je neupitni rekorder prema Defertovom indeksu (X2) kojim se izražava odnos između broja turista u smještajnim kapacitetima po jedinici prostora u  $\text{km}^2$ . Njezin je indeks bio na razini 4146,7 2007. godine i 4893,8 2016. godine zbog malog teritorija zemlje i velike frekvencije posjetitelja. U ostalim zemljama EU-a vrijednosti čimbenika X2 znatno su manje. Opća razina Defertovog indeksa za sve zemlje EU-a varira između 248,9 i 295,6 turista koji koriste smještajne objekte na jedinicu površine  $\text{km}^2$  u 2007. odnosno u 2016. godini. Vrijednosti ovoga indeksa također su značajno različite i asimetrične (Slika 2).

In 2016 the index of the number of bed places in relation to 1000 permanent residents of an area (X1) rose in 21 EU countries (the highest growth in Croatia, Greece and Slovenia) in comparison to the year 2007. Seven EU countries witnessed a drop in the value of the factor (especially Luxemburg, Cyprus, France). The average value of the X1 index for all EU countries amounted to 59.3 in 2007 and 67.8 tourist bed places per 1000 permanent residents of an area in 2016. The differences existing between EU countries measured with a coefficient of variation can be considered to be moderate. However, the asymmetry of index X1 witnessed a rise, especially from 2012 to 2016 (the asymmetry indicator is between 1.21-2.15), which means that in most EU countries, the index of tourist bed places per 1000 permanent residents of an area was below its average level.


The unquestionable leader according to Defert index (X2), which is expressed by the ratio of the number of tourists who use accommodation facilities per a unit area in  $\text{km}^2$  is Malta. For this country the index was at the level of 4146.7 in 2007 and 4893.8 in 2016, which is due to the fact that Malta is a country frequently visited by tourists and it has a small territory. In the rest of EU countries, X2 factor's values are definitely lower. The average level of Defert index for all EU countries ranges from 248.9 in 2007 to 295.6 of tourists who use accommodation facilities per a unit area in  $\text{km}^2$  in 2016. The values of this index are also significantly diversified and asymmetrical (Figure 2)

**Slika 2: Vrijednosti Defertovog indeksa (X2) u zemljama EU-a 2007. i 2016. godine**



Izvor: vlastito istraživanje koje se temelji na Eurostatovim podacima

**Figure 2: The values of Defert index (X2) in EU countries in 2007 and in 2016**




Source: Own research based on Eurostat data



Vrijednosti Schneiderovog indeksa (X3), kojim se opisuju intenzitet turističkog prometa u 2007. i 2016. godini vidi se na Slici 3.


The values of the Schneider index (X3), which depicts the intensity of tourist traffic, in 2007 and in 2016 are shown in Figure 3.

**Slika 3: Vrijednosti Schneiderovog indeksa (X3) u zemljama EU-a 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 3: The values of Schneider index (X3) in EU countries in 2007 and in 2016**



Source: Own research based on Eurostat data


Godine 2016. Hrvatska, Malta, Austrija i Cipar zabilježile su najveći broj posjetitelja u smještajnim objektima na 1000 stanovnika

In 2016 the following EU countries, Croatia, Malta, Austria and Cyprus, had the highest number of visitors who use accommoda-

na nekom području (X3 indeks), dok su najniže vrijednosti indeksa X3 bile zabilježene za Rumunjsku, Poljsku, Slovačku i Njemačku. U usporedbi s godinom 2007. Schneiderov je indeks porastao u većini zemalja EU-a, osim na Cipru, u Luksemburgu, Grčkoj, Češkoj, Belgiji i Finskoj (Slika 3). Stupanj diverzifikacije i asimetrije nekih zemalja EU-a prema indeksu X3 može se smatrati umjerenim u razdoblju od 2007. do 2016. godine.


tion facilities per 1000 permanent residents of an area (X3 index) whereas the lowest values of X3 index were found in Romania, Poland, Slovakia and Germany. In comparison to 2007, Schneider index has grown in most EU countries except for Cyprus, Luxembourg, Greece, Czech Republic, Belgium and Finland (Figure 3). The level of diversification and asymmetry of particular EU countries according to X3 index can be considered to be moderate for the period 2007-2016.

**Slika 4: Vrijednosti indeksa Charvat (X4) u zemljama EU-a 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 4: The values of Charvat index (X4) in EU countries in 2007 and in 2016**




Source: Own research based on Eurostat data

Prema Charvatovom indexu (X4), Malta, Hrvatska, Austrija, Cipar, Španjolska i Grčka su zemlje EU-a koje su najviše rangirane u 2016. (Slika 4). Prema odnosu broja noćenja turista na 100 stanovnika na nekom području najniže rangirane zemlje su: Rumunjska, Poljska, Latvija, Litva i Slovačka. U usporedbi s 2007. godinom vrijednost indeksa u 2016. pala je u samo u tri zemlje EU-a: Cipar, Irska i Luksemburg. Vrijednost Charvatovog indeksa u zemljama EU-a vrlo je diverzificirana i asimetrična u cijelom razdoblju od 2007. do 2016. godine (Slika 4; Tablica 1).


According to the Charvat index (X4), Malta, Croatia Austria, Cyprus, Spain and Greece are EU countries ranked highest in 2016 (Figure 4). According to the number of nights spent by accommodated tourists in relation to 100 permanent residents of an area, the last countries in the ranking are: Romania, Poland, Latvia, Lithuania and Slovakia. In comparison to 2007 the value of the researched index in 2016 fell only in case of three EU countries: Cyprus, Ireland and Luxembourg. The value of Charvat index for EU countries was highly diversified and asymmetrical over the entire period, from 2007 to 2016 (Figure 4; Table 1).

**Slika 5: Vrijednosti indeksa gustoće smještajnih kapaciteta (X5)u zemljama EU-a 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 5: Values of the index of density of accommodation facilities (X5) in EU countries in 2007 and in 2016**



Source: Own research based on Eurostat data

Tijekom dvije uspoređene godine, zemlja EU-a koja je postigla najveći uspjeh u omjeru broja kreveta na km<sup>2</sup> (X5) je Malta. Vrijednost indeksa za ovu zemlju četiri je puta viša od drugoplasirane zemlje, Nizozemske. Najnižu poziciju zauzele su Latvija, Finska, Litva, Estonija i Rumunjska (u rasponu od 0,60 do 1,30). S gledišta indeksa gustoće smještaja, zemlje EU-a mogu se smatrati vrlo diverzificiranima te pokazuju visoku desnu asimetriju u razdoblju od 2007. do 2016. godine (Tablica 1).

Na Slici 6 prikazane su vrijednosti korištenja indeksa smještajnih kapaciteta (X6) u zemljama EU-a 2007. i 2016. godine. Prema tom indeksu, u 2016. godini sljedeće su zemlje bile visoko rangirane: Malta, Cipar, Irska, Španjolska i Austrija. Na najnižim pozicijama prema indeksu X6 nalazile su se Luksemburg, Mađarska, Češka, Švedska i Slovačka. Također je vrijedno spomenuti da je vrijednost ovog indeksa u 9 zemalja EU-a pala 2016. godini u usporedbi s 2007.


In the two years compared, the EU country which performed best with regard to the ratio of the number of tourist bed places to the unit area in km<sup>2</sup> (X5) was Malta. The value of the index for this country was over four times higher than that of the country which was ranked second i.e. the Netherlands. The lowest values of the X5 index were obtained by Latvia Finland, Lithuania, Estonia and Romania (within 0.60-1.30). EU countries can, from the perspective of the index of density of tourist accommodation, be considered to be highly diversified and of high right-sided asymmetry for the period 2007-2016 (Table 1).

Figure 6 shows the values of the use of accommodation capacity index (X6) in EU countries in 2007 and 2016. In 2016, according to this index, the following countries prevailed in the ranking: Malta, Cyprus, Ireland, Spain and Austria. The lowest level of the X6 index was found in respect of Luxembourg, Hungary, Czech Republic, Sweden

godinom i to naročito u Latviji, Sloveniji i Ujedinjenom Kraljevstvu.


and Slovakia. Also, it has to be noted that in 9 EU countries the value of the researched index decreased in 2016 in comparison to 2007, especially in Latvia, Slovenia and the United Kingdom.

**Slika 6: Vrijednosti indeksa korištenja smještajnih kapaciteta (X6) u zemljama EU-a 2007. i 2016. godine**




Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 6: Values of the use of accommodation capacity index (X6) in EU countries in 2007 and in 2016**




Source: Own research based on Eurostat data

**Slika 7: Omjer prihoda i troška inozemnog turizma (X7) u zemljama EU-a 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 7: The ratio of incomes to expenses regarding foreign tourism (X7), in EU countries in 2007 and in 2016**



Source: Own research based on Eurostat data




U rangiranju zemalja EU-a, prema omjeru prihoda i troškova u odnosu na inozemni turizam (X7), i u 2007. i 2016. godine neupitni je predvodnik Hrvatska (Slika 7). Slijede ju Grčka, Malta, Španjolska, Portugal i Bugarska. Prihod od inozemnog turizma ne pokriva sve nastale troškove u deset zemalja EU-a (indeks X7 < 1). Prosječna vrijednost indeksa X7 od 2007. do 2016. godine varira između 1,83 i 2,01 (Tablica 1).

Posljednji indeks kojim se može istraživati stupanj razvijenosti funkcije turizma u zemljama EU-a je postotak zaposlenih u razvoju turizma i gastronomije u odnosu na ukupni broj zaposlenih (X8). Te su vrijednosti za godine 2007. i 2016. prikazane na Slici 8. Postotak zaposlenih u turizmu i gastronomiji u općem broju zaposlenih 2007. godine varira između 1,65% (Rumunjska) do 8,07% (Malta), a 2016. godine indeks X8 porastao je od 2,10% (Rumunjska) do 8,40% (Grčka). Prosječna vrijednost tog indeksa u razdoblju od 2007. do 2016. godine bila je preko 4%, što upućuje na zaključak da je raznolikost prema ovom indeksu u zemljama EU-a niska (Tablica 1).

In the ranking of EU countries, according to the ratio of incomes to expenses regarding foreign tourism (X7), both in 2007 and in 2016, the unquestionable leader is Croatia (Figure 7). The subsequent countries in the ranking were Greece, Malta, Spain, Portugal and Bulgaria. The income from foreign tourism does not cover the incurred expenses in case of 10 EU countries (X7 index < 1). The average value of the X7 index from 2007 to 2016 ranges from 1.83 to 2.01 (Table 1).


The last index which can facilitate research on the level of development of tourist function in EU countries is the percentage of employees in tourism development and gastronomy relative to the overall number of employees (X8). Its values in 2007 and 2016 are shown in Figure 8. In 2007 the percentage of employees in tourism development and gastronomy in the general number of employees ranges from 1.65% (Romania) to 8.07% (Malta). In 2016 the value of the X8 index went up ranging from 2.10% (Romania) to 8.40% (Greece). The average value of the index in 2007-2016 amounted to over 4% hence the diversity of EU countries according to this index can be deemed to be low (Table 1).

**Slika 8: Postotak zaposlenih u razvoju turizma i gastronomije u odnosu na ukupan broj zaposlenih (X8) u zemljama EU-a 2007. i 2016. godine**



Izvor: Vlastito istraživanje temeljeno na podacima Eurostata

**Figure 8: The percentage of employees in tourism development and gastronomy relative to overall number of employees (X8) in EU countries in 2007 and in 2016**



Source: Own research based on Eurostat data

Tablica 1 prikazuje osnovne statističke mjere, tj. aritmetičku sredinu, koeficijent varijacije i koeficijent asimetrije, izračunate za indekse kojima se određuje stupanj razvoja funkcije turizma u zemljama EU-a u razdoblju 2007. - 2016.<sup>9</sup> godine.

Table 1 presents the basic statistical measures i.e. the arithmetic mean, coefficient of variation and coefficient of asymmetry calculated for indexes determining the level of development of tourist function in EU countries in 2007 - 2016<sup>9</sup>.

<sup>9</sup> Korištene su sljedeće formule: aritmetič-

ka sredina:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  koeficijent varijacije:

$V_s = \frac{S}{\bar{x}}$  koeficijent asimetrije:  $A = \frac{m_3}{S^3}$  gdje je:

$$m_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3$$

<sup>9</sup> The following formulas were applied: Arith-

metic mean:  $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$  Coefficient of varia-

tion:  $V_s = \frac{S}{\bar{x}}$  Coefficient of asymmetry:  $A = \frac{m_3}{S^3}$

where:  $m_3 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3$

**Tablica 1: Vrijednosti deskriptivnih parametara stupnjeva razvoja funkcije turizma u zemljama EU-A 2007. i 2016.**

Godine	Deskriptivni parametri	X1	X2	X3	X4	X5	X6	X7	X8
2007.	Aritmeička sredina	59,26	248,92	1 024,22	528,47	12,00	92,93	1,83	4,29
	Koeficijent varijacije	0,59	3,04	0,82	0,76	2,07	0,35	0,96	0,37
	Koeficijent asimetrije	0,58	5,17	1,28	1,96	4,69	1,30	3,13	0,68
2008.	Aritmeička sredina	59,62	253,94	1 024,24	528,28	11,95	91,09	1,79	4,29
	Koeficijent varijacije	0,57	3,09	0,83	0,76	2,03	0,35	1,04	0,37
	Koeficijent asimetrije	0,53	5,19	1,30	1,91	4,67	1,47	3,44	0,68
2009.	Aritmeička sredina	60,59	235,43	950,31	499,64	12,00	83,34	1,75	4,42
	Koeficijent varijacije	0,56	3,05	0,82	0,72	2,07	0,35	0,94	0,36
	Koeficijent asimetrije	0,45	5,17	1,21	1,52	4,69	1,27	3,10	0,55
2010.	Aritmeička sredina	59,67	256,72	986,38	520,18	11,95	86,82	1,84	4,43
	Koeficijent varijacije	0,56	3,17	0,83	0,74	2,03	0,38	0,98	0,37
	Koeficijent asimetrije	0,54	5,20	1,32	1,65	4,67	1,41	3,16	0,56
2011.	Aritmeička sredina	59,78	272,62	1 060,20	535,25	12,12	90,29	1,97	4,50
	Koeficijent varijacije	0,55	3,15	0,82	0,72	2,01	0,36	1,00	0,40
	Koeficijent asimetrije	0,49	5,20	1,28	1,66	4,67	1,48	3,21	0,57
2012.	Aritmeička sredina	65,14	279,94	1 088,21	568,54	12,11	88,72	1,99	5,01
	Koeficijent varijacije	0,59	3,13	0,82	0,73	2,02	0,37	0,93	0,42
	Koeficijent asimetrije	1,21	5,19	1,28	1,68	4,65	1,59	2,61	0,76
2013.	Aritmeička sredina	66,58	301,02	1 139,02	582,58	12,07	89,11	2,09	5,17
	Koeficijent varijacije	0,60	3,20	0,81	0,74	1,99	0,36	1,00	0,43
	Koeficijent asimetrije	1,44	5,21	1,30	1,77	4,63	1,62	2,78	0,78
2014.	Aritmeička sredina	66,76	317,05	1 149,11	593,86	12,66	91,01	2,13	5,23
	Koeficijent varijacije	0,61	3,24	0,84	0,73	1,94	0,37	1,06	0,44
	Koeficijent asimetrije	1,61	5,20	1,38	1,80	4,64	1,82	3,00	0,79
2015.	Aritmeička sredina	67,26	285,73	1 055,82	619,18	13,27	93,54	2,13	5,24
	Koeficijent varijacije	0,62	3,04	0,78	0,72	1,99	0,35	1,06	0,45
	Koeficijent asimetrije	1,86	5,16	1,40	1,80	4,64	1,76	3,01	0,80
2016.	Aritmeička sredina	67,83	295,63	1 120,35	648,58	13,10	97,55	2,01	5,25
	Koeficijent varijacije	0,63	3,02	0,78	0,72	1,94	0,36	1,07	0,47
	Koeficijent asimetrije	2,15	5,17	1,38	1,74	4,62	1,67	3,20	0,82

Izvor: Vlastiti izračuni na temelju podataka Eurostata.

**Table 1: Values of Descriptive Parameters of the level of development of tourist function in EU countries in 2007 and in 2016**

Years	Descriptive Parameters	X1	X2	X3	X4	X5	X6	X7	X8
2007	Arithmetic mean	59.26	248.92	1 024.22	528.47	12.00	92.93	1.83	4.29
	Coefficient of variation	0.59	3.04	0.82	0.76	2.07	0.35	0.96	0.37
	Coefficient of asymmetry	0.58	5.17	1.28	1.96	4.69	1.30	3.13	0.68
2008	Arithmetic mean	59.62	253.94	1 024.24	528.28	11.95	91.09	1.79	4.29
	Coefficient of variation	0.57	3.09	0.83	0.76	2.03	0.35	1.04	0.37
	Coefficient of asymmetry	0.53	5.19	1.30	1.91	4.67	1.47	3.44	0.68
2009	Arithmetic mean	60.59	235.43	950.31	499.64	12.00	83.34	1.75	4.42
	Coefficient of variation	0.56	3.05	0.82	0.72	2.07	0.35	0.94	0.36
	Coefficient of asymmetry	0.45	5.17	1.21	1.52	4.69	1.27	3.10	0.55
2010	Arithmetic mean	59.67	256.72	986.38	520.18	11.95	86.82	1.84	4.43
	Coefficient of variation	0.56	3.17	0.83	0.74	2.03	0.38	0.98	0.37
	Coefficient of asymmetry	0.54	5.20	1.32	1.65	4.67	1.41	3.16	0.56
2011	Arithmetic mean	59.78	272.62	1 060.20	535.25	12.12	90.29	1.97	4.50
	Coefficient of variation	0.55	3.15	0.82	0.72	2.01	0.36	1.00	0.40
	Coefficient of asymmetry	0.49	5.20	1.28	1.66	4.67	1.48	3.21	0.57
2012	Arithmetic mean	65.14	279.94	1 088.21	568.54	12.11	88.72	1.99	5.01
	Coefficient of variation	0.59	3.13	0.82	0.73	2.02	0.37	0.93	0.42
	Coefficient of asymmetry	1.21	5.19	1.28	1.68	4.65	1.59	2.61	0.76
2013	Arithmetic mean	66.58	301.02	1 139.02	582.58	12.07	89.11	2.09	5.17
	Coefficient of variation	0.60	3.20	0.81	0.74	1.99	0.36	1.00	0.43
	Coefficient of asymmetry	1.44	5.21	1.30	1.77	4.63	1.62	2.78	0.78
2014	Arithmetic mean	66.76	317.05	1 149.11	593.86	12.66	91.01	2.13	5.23
	Coefficient of variation	0.61	3.24	0.84	0.73	1.94	0.37	1.06	0.44
	Coefficient of asymmetry	1.61	5.20	1.38	1.80	4.64	1.82	3.00	0.79
2015	Arithmetic mean	67.26	285.73	1 055.82	619.18	13.27	93.54	2.13	5.24
	Coefficient of variation	0.62	3.04	0.78	0.72	1.99	0.35	1.06	0.45
	Coefficient of asymmetry	1.86	5.16	1.40	1.80	4.64	1.76	3.01	0.80
2016	Arithmetic mean	67.83	295.63	1 120.35	648.58	13.10	97.55	2.01	5.25
	Coefficient of variation	0.63	3.02	0.78	0.72	1.94	0.36	1.07	0.47
	Coefficient of asymmetry	2.15	5.17	1.38	1.74	4.62	1.67	3.20	0.82

Source: Own elaborations based on Eurostat data

Provedeno preliminarno vrednovanje stupnja razvoja funkcije turizma u zemljama EU-a, temeljeno na vrijednostima indeksa X1-X8, pokazuje koliko je teško s potpunom sigurnošću odlučiti koja zemlja EU-a ima visok, srednji ili nizak stupanj razvoja u tom smislu. Čini se da odlučivanje vrijednosti sintetske mjere putem predložene metode može omogućiti stvaranje objektivnog rangiranja zemalja EU-a i njihovu klasifikaciju prema dosegotom stupnju razvoja funkcije turizma.

Kako bi se postavile vrijednosti sintetske mjere razvoja funkcije turizma za zemlje EU-a, autori su primijenili postupak uzastopnih koraka kod predstavljanja Walesiakove metode Mjere opće udaljenosti (MOU) kako slijedi:

1. za svaku godinu u analiziranom razdoblju (2007.-2016.) pokazatelji koji određuju stupanj razvoja funkcije turizma označeni su (X1-X8) za 28 zemalja EU-a u obliku podatkovne matrice (formula br. 1)
2. svi indikatori stupnja razvoja funkcije turizma su stimulant
3. normalizacija varijabli analizirala se za cijelo razdoblje istovremeno i primijenila prema formuli br. 2
4. koordinate formule su također određene za varijable cijelog analiziranog razdoblja (2007. – 2016.)
5. vrijednosti sintetske mjere su određene prema formuli br. 3.

Tablica 2 prikazuje vrijednosti sintetske mjere zemalja EU-a izračunane putem srednje vrijednosti Walesiakove Mjere opće udaljenosti (MOU) u razdoblju 2007.-2016. godine. Što je niža vrijednost sintetske mjere određene zemlje, to je bliža obrascu objekta i bolja je njezina pozicija među zemljama EU-a.

The preliminary evaluation of the level of development of tourist function in EU countries conducted, based on values of X1-X8 indexes, shows how difficult it is to decide beyond any doubt which EU country has a high, medium or low level of development in this respect. It seems that the determination of the value of synthetic measure by means of the proposed method can facilitate the creation of an objective ranking of EU countries and their classification according to the level of development of tourist function which they have attained.

With the aim of setting values of synthetic measure of tourist function development level for EU countries, the authors used successive stages of procedure discussed when presenting M. Walesiak's GDM method as follows:

1. For each year of the analyzed period (i.e. 2007-2016) indicators determining levels of tourist function development were labeled (X1-X8 indicators) for 28 EU countries in the form of data matrix (formula no. 1).
2. All the indicators of level of tourist function development are stimulants.
3. Variables' normalization for the whole period was analyzed simultaneously and applied according to the formula no 2.
4. Formula's coordinates were also determined for the whole analyzed period variables (i.e. 2007-2017).
5. GDM values of synthetic measure were determined according to the formula no 3.

Table 2 presents the values of synthetic measure of EU countries calculated by means of General Distance Measure (GDM) by M. Walesiak in 2007-2016. The lower the values of synthetic measure obtained by a given country, the closer it is to the pattern object and the better its position among other EU countries.

**Tablica 2: Vrijednosti sintetskih mjera (GDM) za zemlje EU-a 2007. – 2016. godine**

Zemlje	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.
Austrija	0,273	0,267	0,264	0,267	0,281	0,264	0,276	0,287	0,352	0,351
Belgija	0,596	0,595	0,580	0,582	0,588	0,600	0,608	0,611	0,560	0,577
Bugarska	0,593	0,586	0,577	0,559	0,546	0,565	0,569	0,557	0,547	0,536
Hrvatska	0,268	0,255	0,251	0,253	0,236	0,214	0,208	0,203	0,235	0,232
Cipar	0,238	0,248	0,264	0,260	0,266	0,265	0,293	0,297	0,308	0,290
Češka Republika	0,555	0,566	0,550	0,562	0,570	0,557	0,565	0,581	0,592	0,590
Danska	0,522	0,527	0,513	0,517	0,539	0,525	0,535	0,542	0,597	0,593
Estonija	0,545	0,544	0,544	0,521	0,507	0,503	0,512	0,526	0,572	0,564
Finska	0,620	0,612	0,612	0,607	0,609	0,623	0,630	0,639	0,643	0,647
Francuska	0,523	0,527	0,502	0,479	0,490	0,495	0,503	0,522	0,566	0,572
Njemačka	0,589	0,586	0,573	0,575	0,583	0,585	0,592	0,594	0,554	0,554
Grčka	0,357	0,355	0,313	0,334	0,329	0,306	0,302	0,291	0,317	0,335
Mađarska	0,608	0,596	0,582	0,583	0,582	0,586	0,582	0,575	0,578	0,575
Irska	0,380	0,387	0,387	0,376	0,399	0,436	0,448	0,449	0,490	0,484
Italija	0,450	0,460	0,434	0,453	0,465	0,456	0,472	0,488	0,481	0,484
Latvija	0,609	0,616	0,653	0,648	0,639	0,643	0,640	0,625	0,615	0,625
Litva	0,659	0,657	0,676	0,664	0,645	0,654	0,652	0,653	0,637	0,640
Luksemburg	0,439	0,458	0,451	0,479	0,479	0,442	0,457	0,461	0,544	0,557
Malta	0,022	0,031	0,029	0,029	0,032	0,032	0,038	0,044	0,039	0,039
Nizozemska	0,477	0,497	0,464	0,479	0,498	0,502	0,479	0,494	0,486	0,483
Poljska	0,651	0,650	0,640	0,644	0,643	0,660	0,660	0,659	0,625	0,619
Portugal	0,464	0,464	0,467	0,481	0,481	0,491	0,493	0,478	0,425	0,404
Rumunjska	0,691	0,688	0,690	0,699	0,693	0,699	0,703	0,704	0,682	0,672
Slovačka	0,587	0,584	0,601	0,606	0,611	0,614	0,616	0,628	0,628	0,614
Slovenija	0,506	0,500	0,486	0,503	0,495	0,508	0,511	0,520	0,498	0,486
Španjolska	0,321	0,324	0,329	0,342	0,336	0,343	0,357	0,356	0,337	0,329
Švedska	0,595	0,609	0,587	0,594	0,608	0,605	0,608	0,612	0,632	0,630
Ujedinjeno Kraljevstvo	0,558	0,566	0,531	0,561	0,578	0,541	0,571	0,564	0,542	0,544

*Izvor: vlastito istraživanje*



**Table 2: Values of Synthetic Measures (GDM) for EU countries in 2007-2016**

Countries	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016
Austria	0.273	0.267	0.264	0.267	0.281	0.264	0.276	0.287	0.352	0.351
Belgium	0.596	0.595	0.580	0.582	0.588	0.600	0.608	0.611	0.560	0.577
Bulgaria	0.593	0.586	0.577	0.559	0.546	0.565	0.569	0.557	0.547	0.536
Croatia	0.268	0.255	0.251	0.253	0.236	0.214	0.208	0.203	0.235	0.232
Cyprus	0.238	0.248	0.264	0.260	0.266	0.265	0.293	0.297	0.308	0.290
Czech Republic	0.555	0.566	0.550	0.562	0.570	0.557	0.565	0.581	0.592	0.590
Denmark	0.522	0.527	0.513	0.517	0.539	0.525	0.535	0.542	0.597	0.593
Estonia	0.545	0.544	0.544	0.521	0.507	0.503	0.512	0.526	0.572	0.564
Finland	0.620	0.612	0.612	0.607	0.609	0.623	0.630	0.639	0.643	0.647
France	0.523	0.527	0.502	0.479	0.490	0.495	0.503	0.522	0.566	0.572
Germany	0.589	0.586	0.573	0.575	0.583	0.585	0.592	0.594	0.554	0.554
Greece	0.357	0.355	0.313	0.334	0.329	0.306	0.302	0.291	0.317	0.335
Hungary	0.608	0.596	0.582	0.583	0.582	0.586	0.582	0.575	0.578	0.575
Ireland	0.380	0.387	0.387	0.376	0.399	0.436	0.448	0.449	0.490	0.484
Italy	0.450	0.460	0.434	0.453	0.465	0.456	0.472	0.488	0.481	0.484
Latvia	0.609	0.616	0.653	0.648	0.639	0.643	0.640	0.625	0.615	0.625
Lithuania	0.659	0.657	0.676	0.664	0.645	0.654	0.652	0.653	0.637	0.640
Luxembourg	0.439	0.458	0.451	0.479	0.479	0.442	0.457	0.461	0.544	0.557
Malta	0.022	0.031	0.029	0.029	0.032	0.032	0.038	0.044	0.039	0.039
Netherlands	0.477	0.497	0.464	0.479	0.498	0.502	0.479	0.494	0.486	0.483
Poland	0.651	0.650	0.640	0.644	0.643	0.660	0.660	0.659	0.625	0.619
Portugal	0.464	0.464	0.467	0.481	0.481	0.491	0.493	0.478	0.425	0.404
Romania	0.691	0.688	0.690	0.699	0.693	0.699	0.703	0.704	0.682	0.672
Slovakia	0.587	0.584	0.601	0.606	0.611	0.614	0.616	0.628	0.628	0.614
Slovenia	0.506	0.500	0.486	0.503	0.495	0.508	0.511	0.520	0.498	0.486
Spain	0.321	0.324	0.329	0.342	0.336	0.343	0.357	0.356	0.337	0.329
Sweden	0.595	0.609	0.587	0.594	0.608	0.605	0.608	0.612	0.632	0.630
United Kingdom	0.558	0.566	0.531	0.561	0.578	0.541	0.571	0.564	0.542	0.544

Source: Own research

Na temelju podataka iz Tablice 2 može se opaziti da je u razdoblju od 2007. do 2016. godine situacija u zemljama EU-a bila raznovrsna, ali stabilna. Ovaj zaključak potvrđuje rangiranje zemalja EU-a prema vrijednostima sintetske mjere MOU u istom razdoblju (Tablica 3).

Based on the data shown in Table 2 it can be noted that in 2007-2016 EU countries had a diversified but stable situation, regarding the level of development of tourist function. This conclusion is confirmed by the ranking of EU countries according to the values of synthetic measure (GDM) in 2007-2016 (Table 3).

**Tablica 3: Rangiranje zemalja EU-a prema vrijednostima sintetske mjere izračunate srednjim vrijednostima Walesiak-ove Mjere opće udaljenosti MOU 2007. – 2016. godine**

Zemlja	2007.	2008.	2009.	2010.	2011.	2012.	2013.	2014.	2015.	2016.	Promjena mjesta 2016. prema 2007.
Austrija	4	4	3	4	4	3	3	3	6	6	-2
Belgija	22	21	20	20	21	21	22	21	16	19	+3
Bugarska	20	20	19	16	16	18	17	16	14	12	+8
Hrvatska	3	3	2	2	2	2	2	2	2	2	+1
Cipar	2	2	4	3	3	4	4	5	3	3	-1
Češka Republika	16	17	17	18	17	17	16	19	20	20	-4
Danska	13	14	14	14	15	15	15	15	21	21	-8
Estonija	15	15	16	15	14	13	14	14	18	16	-1
Finska	25	24	24	24	23	24	24	25	27	27	-2
Francuska	14	13	13	9	11	11	12	13	17	17	-3
Njemačka	19	19	18	19	20	19	20	20	15	14	+5
Grčka	6	6	5	5	5	5	5	4	4	5	+1
Mađarska	23	22	21	21	19	20	19	18	19	18	+5
Irska	7	7	7	7	7	7	7	7	10	10	-3
Italija	9	9	8	8	8	9	9	10	8	9	0
Latvija	24	25	26	26	25	25	25	23	22	24	0
Litva	27	27	27	27	27	26	26	26	26	26	+1
Luksemburg	8	8	9	10	9	8	8	8	13	15	-7
Malta	1	1	1	1	1	1	1	1	1	1	0
Nizozemska	11	11	10	11	13	12	10	11	9	8	+3
Poljska	26	26	25	25	26	27	27	27	23	23	+3
Portugal	10	10	11	12	10	10	11	9	7	7	+3
Rumunjska	28	28	28	28	28	28	28	28	28	28	0
Slovačka	18	18	23	23	24	23	23	24	24	22	-4
Slovenija	12	12	12	13	12	14	13	12	11	11	+1
Španjolska	5	5	6	6	6	6	6	6	5	4	+1
Švedska	21	23	22	22	22	22	21	22	25	25	-4
Ujedinjeno Kraljevstvo	17	16	15	17	18	16	18	17	12	13	+4

Izvor: Vlastita obrada

**Table 3: Ranking of EU countries according to the values of synthetic measure calculated by means of General Distance Measure (GDM) by M. Walesiak in 2007-2016**

Countries	2007	2008	2009	2010	2011	2012	2013	2014	2015	2016	Change in position in 2016 compared to 2007
Austria	4	4	3	4	4	3	3	3	6	6	-2
Belgium	22	21	20	20	21	21	22	21	16	19	+3
Bulgaria	20	20	19	16	16	18	17	16	14	12	+8
Croatia	3	3	2	2	2	2	2	2	2	2	+1
Cyprus	2	2	4	3	3	4	4	5	3	3	-1
Czech Republic	16	17	17	18	17	17	16	19	20	20	-4
Denmark	13	14	14	14	15	15	15	15	21	21	-8
Estonia	15	15	16	15	14	13	14	14	18	16	-1
Finland	25	24	24	24	23	24	24	25	27	27	-2
France	14	13	13	9	11	11	12	13	17	17	-3
Germany	19	19	18	19	20	19	20	20	15	14	+5
Greece	6	6	5	5	5	5	5	4	4	5	+1
Hungary	23	22	21	21	19	20	19	18	19	18	+5
Ireland	7	7	7	7	7	7	7	7	10	10	-3
Italy	9	9	8	8	8	9	9	10	8	9	0
Latvia	24	25	26	26	25	25	25	23	22	24	0
Lithuania	27	27	27	27	27	26	26	26	26	26	+1
Luxembourg	8	8	9	10	9	8	8	8	13	15	-7
Malta	1	1	1	1	1	1	1	1	1	1	0
Netherlands	11	11	10	11	13	12	10	11	9	8	+3
Poland	26	26	25	25	26	27	27	27	23	23	+3
Portugal	10	10	11	12	10	10	11	9	7	7	+3
Romania	28	28	28	28	28	28	28	28	28	28	0
Slovakia	18	18	23	23	24	23	23	24	24	22	-4
Slovenia	12	12	12	13	12	14	13	12	11	11	+1
Spain	5	5	6	6	6	6	6	6	5	4	+1
Sweden	21	23	22	22	22	22	21	22	25	25	-4
United Kingdom	17	16	15	17	18	16	18	17	12	13	+4

Source: Own research

U pogledu stupnja razvoja funkcije turizma u razdoblju 2007.-2016. godine vodeće zemlje EU-a bile su Malta, Hrvatska, Cipar, Španjolska, Grčka i Austrija, dok su Rumunjska, Finska, Litva, Švedska i Latvija ostale na začelju. Međutim, pozicije 13 zemalja EU-a bolje su u pogledu stupnja razvijenosti

The leading EU countries with regards to the level of development of tourist function in 2007-2016 were Malta, Croatia, Cyprus, Spain, Greece and Austria, whereas the last ones in the ranking were Romania, Finland, Lithuania, Sweden and Latvia. Yet, 13 EU countries improved their position in the

funkcije turizma 2016. u usporedbi s 2007. godinom (najveći skok su doživjele Bugarska – 8 mjesta, Njemačka i Mađarska – 5 mjesta), četiri su zemlje zadržale isti rang, dok ih je 11 palo s ranijih pozicija (najveći pad zabilježile su Danska – za 8 mjesta, Luksemburg – za 7 mjesta i Slovačka – za 4 mjesta).

Na Tablici 4 prikazana je klasifikacija zemalja EU-a u pogledu dosegnutih stupnjeva razvijenosti funkcije turizma 2007. i 2016. godine.

**Tablica 4: Rangiranje i skupina zemalja EU-a na sličnim stupnjevima razvijenosti funkcije turizma 2007. i 2016. godine**

Razina	Godina	
	2007.	2016.
visoka	Malta, Cipar	Malta,
srednje visoka	Hrvatska, Austrija, Španjolska, Grčka, Irska, Luksemburg, Italija, Portugal, Nizozemska, Slovenija, Danska, Francuska	Hrvatska, Cipar, Španjolska, Grčka, Austrija, Portugal, Nizozemska, Italija, Irska, Slovenija, Bugarska, Ujedinjeno Kraljevstvo, Njemačka
srednje niska	Estonija, Republika Češka, Ujedinjeno Kraljevstvo, Slovačka, Njemačka, Bugarska, Švedska, Belgija, Mađarska, Latvija, Finska, Poljska, Litva, Rumunjska	Luksemburg, Estonija, Francuska, Mađarska, Belgija, Republika Češka, Danska, Slovačka, Poljska, Latvija, Švedska, Litva, Finska, Rumunjska
niska		

2007: med = 0,534; mad = 0,111; 2016: med = 0,555; mad = 0,105

Izvor: Vlastita obrada

ranking regarding their level of development of tourist function in 2016 in comparison to 2007 (the biggest improvement were in Bulgaria – by 8 places, Germany and Hungary by 5), 4 countries maintained their rank, while 11 countries fell lower than their earlier positions (the biggest decline were in Denmark by 8 places, Luxembourg by 7 places, Slovakia by 4 places).

The classification of EU countries with regards to their levels of development of tourist function they achieved in 2007 and 2016 is presented in Table 4.

**Table 4: Ranking and groups of EU countries with similar levels of tourist function in 2007 and 2016**

Level	Year	
	2007	2016
high	Malta, Cyprus,	Malta,
medium-high	Croatia, Austria, Spain, Greece, Ireland, Luxembourg, Italy, Portugal, Netherlands, Slovenia, Denmark, France,	Croatia, Cyprus, Spain, Greece, Austria, Portugal, Netherlands, Italy, Ireland, Slovenia, Bulgaria, United Kingdom, Germany,
medium-low	Estonia, Czech Republic, United Kingdom, Slovakia, Germany, Bulgaria, Sweden, Belgium, Hungary, Latvia, Finland, Poland, Lithuania, Romania.	Luxembourg, Estonia, France, Hungary, Belgium, Czech Republic, Denmark, Slovakia, Poland, Latvia, Sweden, Lithuania, Finland, Romania.
low		

2007: med = 0.534; mad = 0.111; 2016: med = 0.555; mad = 0.105

Source: Own elaborations

Malta je 2016. godine imala visok stupanj razvoja funkcije turizma i bila je predvodnik srednjih vrijednosti svih ulaznih varijabli (X1-X8). Međutim, 13 zemalja EU-a svrstano je u skupinu srednje-visoke razine, a to je prilično povezano područje Zapadne Europe i još tri zemlje na raznim stranama kontinenta (Irska, Ujedinjeno Kraljevstvo, Grčka, Bugarska i Cipar). Srednje vrijednosti svih ulaznih varijabli (X1-X8) za zemlje u ovoj skupini manje su od analoških indeksa za zemlje s visokim stupnjem razvoja funkcije turizma, ali su više od indeksa svih zemalja koje su klasificirane kao srednje-niske razine. Većina zemalja (14) je svrstana u skupinu srednje-niskog stupnja razvoja funkcije turizma, a to su uglavnom zemlje Srednje i Istočne Europe, koje su postigle najniže srednje vrijednosti varijabli koje određuju stupanj razvoja funkcije turizma. Važno je napomenuti da niti jedna zemlja EU-a nije svrstana u skupinu zemalja niskog stupnja razvoja funkcije turizma.

U usporedbi s 2007. godinom poredak zemalja EU-a prema stupnju razvoja funkcije turizma ostao je uglavnom nepromijenjen 2016. godine. U pogledu razvoja funkcije turizma opaženi su mali pomaci u poretku nekih zemalja u svim skupine zemalja. U obje komparirane godine Malta je zadržala najvišu poziciju, dok se Cipar 2016. godine svrstao na drugo mjesto (na medijski visok stupanj razvoja funkcije turizma) (Tablica 4; Slika 8).

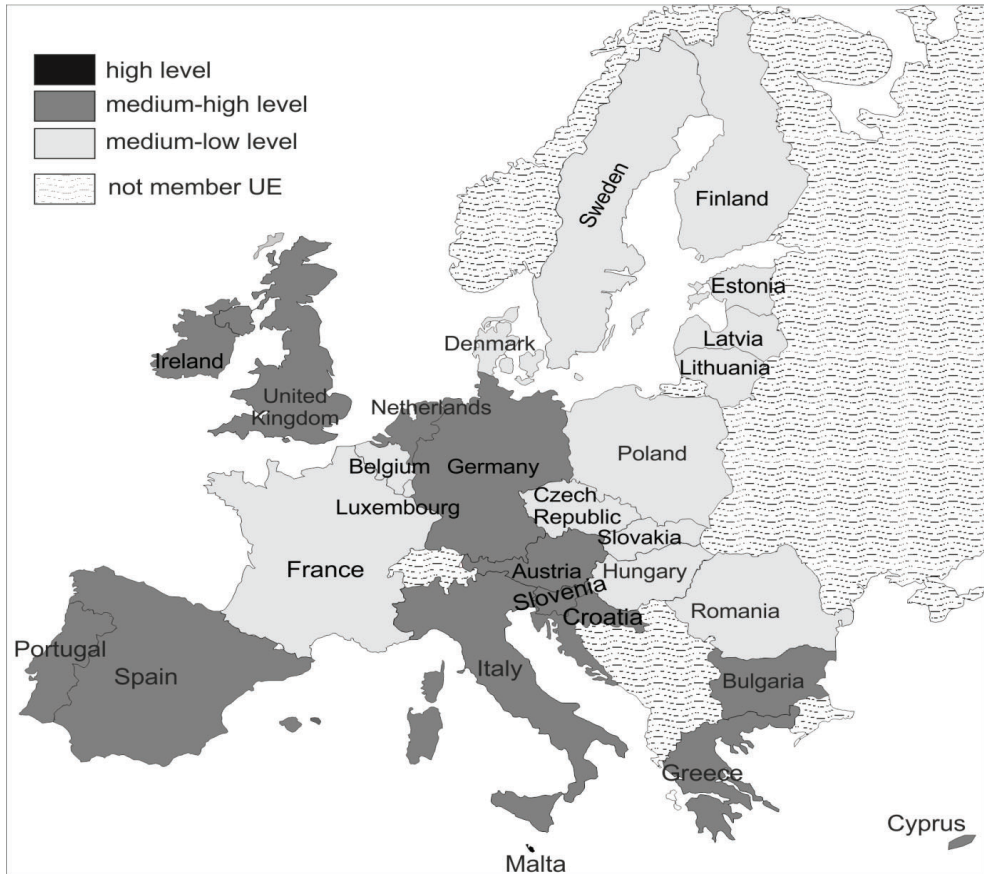
U pogledu stupnjeva razvoja funkcije turizma u 2016. godini rezultati klasifikacije zemalja EU-a prikazani su na Slici 9.

In 2016 Malta had a high level of development of tourist function. The country was the leader in respect of the average values of all input variables (X1-X8), 13 EU countries were placed in the medium-high level group. These countries include a rather cohesive area of Western Europe with three additional countries located in various parts of the continent (Ireland, United Kingdom, Greece, Bulgaria and Cyprus). Average values of all the input variables (X1-X8) for countries qualified into this group are lower than the analogical indexes for countries with a high level of development of tourist function, but higher than the indexes of the countries classified as medium-low. The majority of countries (14) were categorised into the medium-low group regarding the level of development of tourist function. These are mainly countries from Central and Eastern Europe, that achieved the lowest average values of variables determining the level of development of tourist function. It has to be noted that there is no low-level group in the classification of EU countries.

In comparison to 2007, the ranking of EU countries regarding levels of development of tourist function remained mostly unchanged in 2016. Small shifts in the ranks of some countries can be seen in the group of countries in terms of tourist function development level. In both years compared, Malta kept the leading position, whereas Cyprus was qualified in 2016 to the second group of countries (at medianly high level of tourist function development) (Table 4; Figure 8).

The results of the classification of EU countries, regarding levels of development of tourist function in 2016 are shown in Figure 9.

**Slika 9: Klasifikacija zemalja EU-a u odnosu na stupnjeve razvoja funkcije turizma 2016. godine / Figure 9: The classification of EU countries, regarding their levels of development of tourist function in 2016**



Izvor: Vlastita obrada

## 6. ZAKLJUČCI

Istraživanjem je obuhvaćena statistička evaluacija stupnja razvoja funkcije turizma u zemljama EU-a. Preliminarna evaluacija provedena je na temelju predloženih indikatora koji određuju broj smještajnih objekata, intenziteta turističkog prometa i razmjera zaposlenosti u turističkom sektoru (X1-X8). Međutim, vrednovanje zemalja koje su dostigle visok, srednji ili nizak stupanj razvoja funkcije turizma bilo je nepotpuno. Poslje-

## 6. CONCLUSIONS

As a result of the application of the research procedure, a statistic evaluation of the level of development of tourist function of EU countries was performed. A preliminary evaluation of the phenomenon was conducted, based on the proposed indicators which determine the number of accommodation facilities, the intensity of tourist traffic and the size of employment in the tourist sector (X1-X8). However, the evaluation was incon-



dično, linearni poredak zemaja EU-a dobiven je putem *Mjere opće udaljenosti* (MOU) prema metodi M. Walesiaka iz dinamičke perspektive. Vrijedno je napomenuti da je zbog visoke raznolikosti i značajne asimetrije indikatora funkcije turizma za zemlje EU-a kao metoda istraživanja korištena formula standardizacije s medijanom koja je pokazala značajne tolerancije na izolirane vrijednosti varijabli. Korištena metodologija istraživanja može biti jamstvo za rezultate i zaključke prezentirane u članku.

Vrijedosti dobivene sintetske mjere poslužile su za temelj klasifikacije zemalja EU-a prema sličnom stupnju razvoja funkcije turizma. Najviši stupanj razvoja funkcije turizma dosegle su Malta i Hrvatska 2016. godine. Većina zapadnoeuropskih zemalja dosegla je srednje-visok stupanj razvoja funkcije turizma, dok su zemlje srednjoistočne Europe, Skandinavije i nekoliko njih iz Zapadne Europe svrstane u skupinu srednje niskog stupnja. Nije izdvojena niti jedna zemlja s niskim stupnjem razvoja funkcije turizma.

Na temelju rezultata istraživanja potvrđena je postavljena hipoteza. Analiza rezultata pokazala je da zemlje EU-a pripadaju skupini zemalja s visokim i srednjim stupnjem razvoja funkcije turizma. Treba dodati da se rangiranje ovih zemalja u pogledu stupnja razvoja funkcije turizma nije značajno promijenilo između prvog i drugog desetljeća 21. stoljeća. Također je značajno da se Politika EU-a u području turizma ugradi u, među ostalima, Kohezijski fond, strukturne fondove i Europski socijalni fond. Ti su fondovi namijenjeni za investicije u turističku infrastrukturu, podršku malim i srednjim poduzećima te ostalima.

Dobiveni rezultati mogli bi poslužiti kao temelj za donošenje mjerodavnih odluka u djelokrugu politike turizma EU-a, i to najviše za raspodjelu fondova namijenjenih razvoju turističke aktivnosti. Ovo istraživanje kojim su zemlje EU-a rangirane i klasificirane prema stupnju razvoja funkcije turizma

clusive about which countries have a high, medium or low level of development of tourist function. Consequently, linear ordering of EU countries was performed by means of the General Distance Measure (GDM) by M. Walesiak from the dynamic perspective. It is worth emphasizing that because of high diversity and significant asymmetry of tourist function indicators for EU countries, using the applied research method a formula of standardization with median was used, which has indicated a significant tolerance to isolated values of the variables. The research methodology used in the paper may constitute a warranty of results and conclusions presented in the paper.

The values of obtained synthetic measure were the basis for the classification of European countries into groups of similar levels of tourist function development. In 2016 the leaders, regarding the level of development of tourist function, were Malta and Croatia. The majority of Western European countries achieved a medium-high level of development of tourist function, whereas the group of countries with medium-low level included countries from East-Central Europe, Scandinavia and several Western Europe countries. The group of countries of low level tourist function was not sorted out.

Based on the research findings the hypothesis formulated in the introductory section of the paper has been confirmed. The analysis of the results show that EU countries belong to the group of countries with high and medium level of tourist function development. One should add that EU countries' ranking in terms of level of tourist function development did not change significantly between the first and second decades of XX century. It is also important that EU Policy in the field of tourism has been implemented by among others: Cohesion Fund, structural funds and Social Fund. The funds are devoted to investments in tourist infrastructure, support for small and medium enterprises and others.

moglo bi značajno doprinijeti i u donošenju kompetentnih odluka u području turističkog menadžmenta.

Due to complexity of tourism issues, it is necessary to conduct further research in this field, especially concerning sustainable tourism development issues. The application of multivariate approach with the use of few methods should constitute, in the opinion of the authors, a field for further research.

## LITERATURA - REFERENCES

- Arimond, G., Elfessi, A. (2001). A clustering method for categorical data in tourism market segmentation research. *Journal of Travel Research*, Vol. 39, No. 4, pp. 391-397. DOI: <https://doi.org/10.1177/004728750103900405>
- Andergassen, R., Candela, G., Figini, P., (2017). The management of tourist destinations: a policy game, *Tourism Economics*, Vol. 23, No. 1, p. 1. DOI: <https://doi.org/10.5367/te.2015.0496>
- Aroca, P., Brida, J. G., Volo, S., (2017). Tourism statistics: correcting data inadequacy, *Tourism Economics*, Vol. 23, No. 1, p. 1. DOI: <https://doi.org/10.5376/te.2015.0506>
- Bak, I., Szczecińska, B. (2015). Ocena atrakcyjności turystycznej województw w Polsce, *Folia Pomeranae Universitatis Technologiae Stetinensis*, 317 (78)1, pp. 5-16.
- Baretje, R., Defert, P., (1972). *Aspects économiques du tourisme*. Paris.
- Blancasa, F., J., González, M., Lozano-Oyola, M., Pérez F., (2010). The assessment of sustainable tourism: Application to Spanish coastal destinations, *Ecological Indicators*, Vol. 10, No. 2, March, pp. 484-492. DOI: <https://doi.org/10.1016/j.ecolind.2009.08.001>
- Buhalis, D. (2000). Marketing the competitive destination of the future. *Tourism Management*, Vol. 21, pp. 97-116. DOI: [https://doi.org/10.1016/S0261-5177\(99\)00095-3](https://doi.org/10.1016/S0261-5177(99)00095-3)
- Butler, R. W., (1974). The social implications of tourist developments. *Annals of Tourism Research*, Vol. 2, pp. 100-111. DOI: [https://doi.org/10.1016/0160-7383\(74\)90025-3](https://doi.org/10.1016/0160-7383(74)90025-3)
- Chandra, S., Menezes, D. (2001). Applications of multivariate analysis in international tourism research: The marketing strategy perspective of NTOs. *Journal of Economic and Social Research*, Vol. 3, No. 1, pp. 77-98.
- Cooper, C., Fletcher, J., Gilbert, D., Wanhill, S., (1993). *Tourism. Principles & Practice*. Pitman Publishing, United Kingdom.
- Cracolici, M. F., Nijkamp, P. (2009). The Attractiveness and Competitiveness of Tourist Destinations: A Study of Southern Italian Regions, *Tourism Management*, Vol. 30, No. 3, pp. 336-344. DOI: <https://doi.org/10.1016/j.tourman.2008.07.006>
- Crotti R., Misrahi, T. (eds.), (2015). *The Travel & Tourism Competitiveness Report. Growth through Shocks*, World Economic Forum, Geneva.
- Defert, P., (1967). Le Taut de Fonction Touristique: mise au point et critique, (in:) *Les Cahiers du Tourisme*, Aux-en-provence. Centre des Hautes Etudes Touristiques, Berne, p. C-13. cit. after: Szromek, A. R., (2013). Pomiar funkcji turystycznej obszarów za pomocą wskaźników funkcji turystycznej na przykładzie obszarów państw europejskich, *Studia Ekonomiczne*, Uniwersytet Ekonomiczny w Katowicach, T. 132.
- Durbarry, R. (2004). Tourism and economic growth: The case of Mauri-

- tius. *Tourism Economics*, Vol. 10, No. 4, pp. 389-401. DOI: <https://doi.org/10.5367/0000000042430962>
- Dwyer, L., Forsyth, P., Spurr, R. (2004). Evaluating tourism's economic effects: new and old approaches. *Tourism Management*, Vol. 25, pp. 307-317. DOI: [https://doi.org/10.1016/S0261-5177\(03\)00131-6](https://doi.org/10.1016/S0261-5177(03)00131-6)
- Dziedzic, T., Radkowska, B., (2014). *Indeks koniunktury turystycznej. Wielowskażnikowy indeks stanu i zmian w polskiej gospodarce turystycznej*. Vistula Indeks Koniunktury Turystycznej (VIKT), Instytut Turystyki, Szkoła Główna Turystyki i Rekreacji, Warszawa.
- Farrell, B. H., & Twining-Ward, L. (2004). Reconceptualizing Tourism. *Annals of Tourism Research*, Vol. 31, No. 2, pp. 274-295. DOI: <https://doi.org/10.1016/j.annals.2003.12.002>
- Frechtling, D. C. (2010). The tourism satellite account: A primer. *Annals of Tourism Research*, Vol. 37, No. 1, pp. 136-153. DOI: <https://doi.org/10.1016/j.annals.2009.08.003>
- Gbuurova, J., Matusikova, D., Benkova, E., (2015). Perception of tourist destination brand, *Economic Annals – XXI*, 5-6, pp. 20-23.
- Gryszel, P., Walesiak, M., (2018). The application of selected multivariate statistical methods for the evaluation of tourism competitiveness of the Sudety communes. *Argumenta Oeconomica*, Vol. 1, pp.147-166.
- Jajuga, K., Walesiak, M., Bąk, A., (2003). On the General Distance Measure, (in:) *Exploratory Data Analysis in Empirical Research*, M. Schwaiger and O. Opitz (eds), Berlin-Heidelberg: Springer-Verlag, pp. 104-109.
- Juul, M., (2015). *Tourism and the European Union. Recent trends and policy developments*. EPRS European Parliamentary Research Service, European Union, pp. 1-5.
- Ko, T. G. (2005). Development of a tourism sustainability assessment procedure: a conceptual approach. *Tourism Management*, Vol. 26, pp. 431-445. DOI: <https://doi.org/10.1016/j.tourman.2003.12.003>
- Kotler P., Armstrong G., (1994). *Principles of Marketing*, Englewood Cliffs, Prentice Hall International, New York.
- Kowalczyk, A., (2000). *Geografia turystyki*, PWN, Warsaw.
- Kurek, W., Mika, M., (2007). *Turystyka jako przedmiot badań naukowych*, (in:) *Turystyka*, W. Kurek (ed.), PWN, Warszawa.
- Lira, J., Wagner, W., Wysocki, F., (2002). *Mediana w zagadnieniach porządkowania obiektów wielocechowych*, (in:) *Statystyka regionalna w służbie samorządu lokalnego i biznesu*, J. Paradysz (ed.), Internetowa Oficyna Wydawnicza Centrum Statystyki Regionalnej, AE w Poznaniu, Poznań.
- Lozano, S., Gutiérrez, E. (2011). Efficiency analysis of EU-25 member states as tourist destinations. *International Journal of Services Technology and Management*, Vol. 15, No. 1/2, pp. 69-88.
- Gołembski, G. (ed.), (2002). *Metody stymulowania rozwoju turystyki w ujęciu przestrzennym*, Wydawnictwo AE w Poznaniu, Poznań.
- MacCannell, D., (2001). *Remarks on the Commodification of Cultures*, (in:) *Hosts and Guests Revisited: Tourism Issues of the 21<sup>st</sup> Century*, V. L. Smith, M. Brent (eds.) Cognizant Communication Corporation, New York, Sydney, Tokyo, p. 380.
- McIntosh, R. W., Goeldner, C. R., (1986). *Tourism: principles, practices, philosophies*, Wiley, p. 5.
- Mason, P., (2003). *Tourism Impacts, Planning and Management*, Butterworth-Heinemann.
- Matczak, A., (1989). Problemy badania funkcji turystycznej miast Polski, *Turyzm*, No 5, pp. 27-39.

- Middleton, V. (1994). *Marketing in Travel and Tourism*. Oxford, England: Butterworth Heinemann.
- Ostrowska, B., (2011). Konkurencyjność turystyczna krajów Unii Europejskiej. *Państwo i Społeczeństwo*, No. 1, pp. 185-192.
- Panek, T., (2009). *Statystyczne metody wielowymiarowej analizy porównawczej*, SGH, Warsaw.
- Paulo, R., (2000). Tourism in the European Union. *International Journal of Contemporary Hospitality Management*, Vol. 12, No. 7, pp. 434 – 436.
- Pawełek, B., (2008). *Metody normalizacji zmiennych w badaniach porównawczych złożonych zjawisk ekonomicznych*, Wyd. Uniwersytetu Ekonomicznego in Kraków, Kraków.
- Pearce, D., (1989). *Tourist development*, Longman Scientific&Technical.
- Pearce, D., (1996). New directions in tourism for third world development. *Annals of Tourism Research*, Vol. 23, No. 1, 1996, pp. 48–70. DOI: [https://doi.org/10.1016/0160-7383\(95\)00043-7](https://doi.org/10.1016/0160-7383(95)00043-7)
- Rapacz, A., (ed.), (2004). *Współpraca i integracja w turystyce w Euroregionie Nysa w perspektywie członkostwa w Unii Europejskiej*, Wydawnictwo AE we Wrocławiu, Wrocław.
- Smith, V. L., Brent, M. (eds.), (2001). *Hosts and Guests Revisited: Tourism Issues of the 21st Century*. California State University.
- Song, H., Dwyer, L., Li, G., Cao, Z. (2012). Tourism economics research: A review and assessment. *Annals of Tourism Research*, Vol. 39, No. 3, pp. 1653-1682. DOI: <https://doi.org/10.1016/j.annals.2012.05.023>
- Szromek, A. R. (2012). *Wskaźniki funkcji turystycznej. Koncepcja wskaźnika funkcji turystycznej i uzdrowiskowej*, Wyd. Politechniki Śląskiej, Gliwice, pp. 60-74.
- Szromek, A. R. (2013). Pomiar funkcji turystycznej obszarów za pomocą wskaźników funkcji turystycznej na przykładzie obszarów państw europejskich, *Studia Ekonomiczne*, Uniwersytet Ekonomiczny w Katowicach, T. 132, pp. 91-103.
- The European Tourism Indicator System. ETIS toolkit for sustainable destination management*, (2016). Luxembourg: Publications Office of the European Union.
- Tourism Satellite Account: Recommended Methodological Framework 2008, (2010). *Studies in Methods*, Series F, No. 80/Rev. 1, UNWTO, Eurostat, OECD, Luxembourg, Madrid, New York, Paris.
- Turner, L.W., Witt S.F., (2001). Factors influencing demand for international tourism: tourism demand analysis using structural equation modelling, revisited, *Tourism Economics*, Vol. 7, No. 1, pp. 21-38. DOI: <https://doi.org/10.5367/000000001101297711>
- Walasek, J. (2014). *Turystyka w Unii Europejskiej*, Wyd. Difin, Warsaw.
- Walesiak, M. (2011). *Uogólniona miara odległości GDM w statystycznej analizie wielowymiarowej z wykorzystaniem programu R*, Wyd. UE we Wrocławiu, Wrocław.
- Walesiak, M. (2014). Przegląd formuł normalizacji wartości zmiennych oraz ich własności w statystycznej analizie wielowymiarowej, *Przegląd Statystyczny*.
- Walesiak, M., Gatnar, E. (2009). *Statystyczna analiza danych z wykorzystaniem programu R*, PWN, Warsaw.
- Wysocki, F. (2010). *Metody taksonomiczne w rozpoznawaniu typów ekonomicznych rolnictwa i obszarów wiejskich*, Wyd. Uniwersytetu Przyrodniczego w Poznaniu, Poznań.
- Zhang, H., Gu, C., Gu, L., Zhang, Y., (2011). The Evaluation of Tourism Destination Competitiveness by TOPSIS & Informa-

tion Entropy – A Case in the Yangtze River Delta of China. *Tourism Management*, Vol. 32, No. 2, pp. 443-451. DOI: <https://doi.org/10.1016/j.tourman/2010.02.007>

Internet sources:

<http://ec.europa.eu/eurostat/data/database> [accessed at 15.12.2016.]

<https://ec.europa.eu/growth/industry/corporate-social-responsibility> [accessed at 01.07.2019.]

<http://www2.unwto.org> [accessed at 01.07.2019.]

<http://www.eea.europa.eu/publications> [accessed at 01.07.2019.]

[statista.com](http://statista.com) [accessed at 20.12.2016.]

[unwto.org](http://unwto.org) [accessed at 20.12.2016.]

[www.emas.eu](http://www.emas.eu) [accessed at 01.07.2019.]

[wttc.org](http://wttc.org) [accessed at 20.12.2016.]

*Primljeno: 4. travnja 2018. / Submitted: 4 April 2018*

*Prihvaćeno: 18. rujna 2019. / Accepted: 18 September 2019*