

**Tomasz Bartłomowicz**

Uniwersytet Ekonomiczny we Wrocławiu

e-mail: tomasz.bartlomowicz@ue.wroc.pl

---

## PROGNOZOWANIE SZEREGÓW CZASOWYCH ZE SKŁADOWĄ PERIODYCZNĄ Z WYKORZYSTANIEM PAKIETU TSPREDICTION PROGRAMU R

---

**Streszczenie:** Celem artykułu jest prezentacja autorskiego pakietu TSprediction opracowanego dla środowiska R, które należy obecnie do najważniejszych niekomercyjnych platform obliczeniowych (oferowanych na zasadach licencji GNU GPL). W artykule przedstawione zostały funkcje umożliwiające prognozowanie szeregów czasowych, w których występuje składowa periodyczna w postaci wahań sezonowych. Pakiet zawiera implementację najpopularniejszych metod prognozowania szeregów czasowych ze składową periodyczną, w tym addytywnych oraz multiplikatywnych odmian metody wskaźników, metody Wintersa, a także implementację metody Kleina. Działanie wybranych funkcji pakietu TSprediction odpowiedzialnych za metody prognozowania oraz wyznaczanie błędów prognoz zaprezentowano na przykładach.

**Słowa kluczowe:** prognozowanie, szeregi czasowe, pakiet TSprediction, program R.

DOI: 10.15611/ekt.2014.4.17

### 1. Wstęp

W sytuacji, gdy zadaniem prognozowania jest przewidywanie, a nie wyjaśnianie tego, co się zdarzy, tudzież prognozowane zjawisko jest zbyt złożone, zastosowanie znajdują metody prognostyczne oparte na modelach szeregów czasowych [Cieślak 1997; Dittmann 2003; Nowak (red.) 1998]. Metody te zostały szeroko oprogramowane w mniej lub bardziej komercyjnych aplikacjach, brakuje jednak kompleksowego oprogramowania, umożliwiającego prognozowanie szeregów czasowych, udostępnianego na zasadach licencji GNU GPL, a więc bezpłatnego i z dostępem do kodu źródłowego. Odpowiedzią na powyższy stan rzeczy jest autorski pakiet TSprediction [Bartłomowicz 2011] opracowany dla programu R, który spośród dostępnych narzędzi statystyczno-ekonometrycznych należy obecnie do najważniejszych

niekomercyjnych programów obliczeniowych. Celem artykułu jest prezentacja pakietu *TSprediction* oraz weryfikacja hipotezy o przydatności ww. oprogramowania dla użytkowników środowiska R.

W pakiecie *TSprediction* zaimplementowane zostały najważniejsze metody prognozowania oparte na modelach szeregów czasowych. W artykule przedstawione zostały te funkcje pakietu, które odpowiadają metodom prognozowania zjawisk opisanych za pomocą szeregów czasowych ze składową periodyczną w postaci wahań sezonowych. Tym samym pierwszą część artykułu stanowi opis funkcji pakietu *TSprediction* wraz z listą ich argumentów, wykorzystywanych w prognozowaniu zjawisk ze składową sezonową w postaci addytywnych oraz multiplikatywnych odmian metody wskaźników, metody Wintersa oraz metody Kleina. Podsumowaniem tej części jest opis funkcji odpowiedzialnych za wyznaczanie błędów *ex post* (średniego błędu *ex post* – ME, średniego absolutnego błędu *ex post* – MAE, średniego kwadratowego błędu *ex post* – MSE, pierwiastka średniego kwadratowego błędu *ex post* – RMSE, średniego procentowego błędu *ex post* – MPE, średniego absolutnego błędu procentowego *ex post* – MAPE) prognoz wygasłych. W części drugiej artykułu w ramach prezentacji zastosowania wybranych funkcji w prognozowaniu zawarto przykłady ich wywołania w programie R.

## 2. Funkcje składowej periodycznej pakietu *TSprediction* środowiska R

Pakiet *TSprediction* to autorskie [Bartłomowicz 2011] rozszerzenie programu R, zawierające implementację wybranych metod prognozowania szeregów czasowych. Dostępność, instalacja oraz działanie pakietu realizuje się na podobieństwo około 6000 pakietów programu R bezpłatnie rozpowszechnianych w Internecie. Wymagania środowiskowe to zainstalowany w wersji min 2.0.0 program R [R Development Core Team 2013]. Pakiet można bezpłatnie pobrać oraz zainstalować ze strony internetowej Katedry Ekonometrii i Informatyki Uniwersytetu Ekonomicznego we Wrocławiu<sup>1</sup> (<http://keii.ue.wroc.pl/TSprediction>).

W wersji bieżącej pakietu (1.64) znajdują się funkcje metod prognozowania odpowiedzialne za konstrukcję prognoz szeregów czasowych oraz funkcje błędów prognoz umożliwiające weryfikację *ex post* jakości uzyskiwanych prognoz. Funkcje metod realizują obliczenia według wybranych metod prognozowania szeregów czasowych z grupy metod naiwnych, tendencji rozwojowej, metod adaptacyjnych, a także metod średnich ruchomych oraz najpowszechniejszych metod autoregresyjnych. Osobną kategorię tworzą funkcje bazujące na modelach addytywnych oraz multiplikatywnych wybranych metod uwzględniających w modelu składową periodyczną w postaci wahań sezonowych. Oznacza to, iż wśród metod prognozowania występujących w pakiecie *TSprediction* wymienić należy addytywne oraz multi-

<sup>1</sup> Docelowo przewiduje się umieszczenie pakietu w repozytorium CRAN na stronie <http://cran.r-project.org/>.

plikatywnie odmiany metody wskaźników (por. tab. 1) oraz metody Wintersa (por. tab. 2), a także stosowaną w prognozowaniu szeregów czasowych ze składową periodyczną metodę Kleina (por. tab. 3) [Radzikowska (red.) 1999; Zeliaś i in. 2003].

**Tabela 1.** Funkcje implementujące metodę wskaźników w pakiecie `TSprediction`

Funkcje pakietu <code>TSprediction</code>	
<code>addRatio(x, r, horizon)</code> – funkcja zwraca wektor prognoz na podstawie addytywnego modelu metody wskaźników <code>mulRatio(x, r, horizon)</code> – funkcja zwraca wektor prognoz na podstawie multiplikatywnego modelu metody wskaźników:	
Argumenty funkcji	
<code>x</code>	wektor obserwacji (danych empirycznych) szeregu czasowego
<code>r</code>	długość cyklu sezonowego (liczba faz cyklu, domyślnie <code>r=4</code> )
<code>horizon</code>	horyzont prognozy (argument opcjonalny, domyślnie <code>horizon=3</code> )
Przykłady wywołania funkcji w programie R	
<pre>&gt; addRatio(x=data, r=4, horizon=4) &gt; addRatio(data, 4, 2) &gt; addRatio(data,, 2)</pre>	
<pre>&gt; mulRatio(data, 4) &gt; mulRatio(data, 4,) &gt; mulRatio(data)</pre>	

Źródło: opracowanie własne.

**Tabela 2.** Funkcje implementujące metodę Wintersa w pakiecie `TSprediction`

Funkcje pakietu <code>TSprediction</code>	
<code>addWinters(x, r, alfa, beta, gamma, typeF, typeS, typeC)</code> – funkcja zwraca wektor prognoz na podstawie addytywnego modelu Wintersa <code>mulWinters(x, r, alfa, beta, gamma, typeF, typeS, typeC)</code> – funkcja zwraca wektor prognoz na podstawie multiplikatywnego modelu Wintersa:	
Argumenty funkcji	
<code>x</code>	wektor obserwacji (danych empirycznych) szeregu czasowego
<code>r</code>	długość cyklu sezonowego (liczba faz cyklu, domyślnie <code>r=4</code> )
<code>horizon</code>	horyzont prognozy (argument opcjonalny, domyślnie <code>horizon=3</code> )
<code>alfa</code>	parametr $\alpha$ (argument opcjonalny, domyślnie do automatycznego ustalenia*)
<code>beta</code>	parametr $\beta$ (argument opcjonalny, domyślnie do automatycznego ustalenia*)
<code>gamma</code>	parametr $\gamma$ (argument opcjonalny, domyślnie do automatycznego ustalenia*)
<code>typeF</code>	rodzaj argumentu F (argument opcjonalny, domyślnie <code>typeF="first"</code> oznacza przyjęcie za $F_r$ pierwszego wyrazu drugiego cyklu szeregu czasowego; <code>typeF="mean"</code> oznacza przyjęcie za $F_r$ średniej z wyrazów pierwszego cyklu szeregu czasowego)

Tabela 2, cd.

typeS	rodzaj argumentu S (argument opcjonalny, domyślnie typeS="difference" oznacza przyjęcie za Sr różnicy średnich wartości z drugiego i pierwszego cyklu szeregu czasowego; typeS="zero" oznacza przyjęcie za Sr wartości zero)
typeC	rodzaj argumentu C (argument opcjonalny, domyślnie typeC="ratio" oznacza przyjęcie za Cr (w poszczególnych fazach pierwszego cyklu) ilorazów wartości rzeczywistych z pierwszego cyklu szeregu czasowego w odniesieniu do średniej wartości wyrazów w pierwszym cyklu; typeC="one" oznacza przyjęcie za Cr wartości jeden)
<b>Przykłady wywołania funkcji w programie R</b>	
<pre>&gt; addWinters(x=data, r=4, alfa=0.55, beta=0.95, gamma=0.25, typeF="first", typeS="difference", typeC="ratio") &gt; addWinters(x=data, r=4, alfa=0.55, beta=0.95, gamma=0.25, typeF="mean", typeS="zero", typeC="one") &gt; mulWinters(x=data, r=4, alfa=0.55, beta=0.95, gamma=0.25, typeF="mean", typeS="difference", typeC="ratio") &gt; mulWinters(data, 4, 0.55, 0.95, 0.25) &gt; mulWinters(data, 4) &gt; mulWinters(data, , , , "first", "difference", "one") &gt; mulWinters(data)</pre>	

\* Brak deklaracji wartości parametrów  $\alpha$ ,  $\beta$ ,  $\gamma$  oznacza ich automatyczny dobór przez pakiet TSprediction na optymalnym, tj. generującym najniższą wartość średniego błędu *ex post*, poziomie.

Źródło: opracowanie własne.

Ponadto w pakiecie TSprediction zaimplementowano funkcję Kleina wykorzystywaną w prognozowaniu zjawisk charakteryzujących się wahaniami sezonowymi. Składnię oraz listę argumentów funkcji metody Kleina prezentuje tab. 3.

Tabela 3. Funkcje implementujące metodę Kleina w pakiecie TSprediction

Funkcje pakietu TSprediction	
Klein(x, r, horizon) – funkcja zwraca wektor prognoz na podstawie liniowej funkcji trendu modelu Kleina	
Argumenty funkcji	
x	wektor obserwacji (danych empirycznych) szeregu czasowego
r	długość cyklu sezonowego (liczba faz cyklu, domyślnie r=4)
horizon	horyzont prognozy (argument opcjonalny, domyślnie horizon=3)
Przykłady wywołania funkcji w programie R	
<pre>&gt; Klein(x=data, r=4, horizon=4) &gt; Klein(data, 4, 2) &gt; Klein(data, , 2) &gt; Klein(data)</pre>	

Źródło: opracowanie własne.

Aby możliwy był pomiar błędów prognoz, w pakiecie `TSprediction` oprogramowane zostały funkcje błędów prognoz umożliwiające wyznaczenie najpopularniejszych błędów *ex post* prognoz wygasłych (por. tab. 4) [Cieślak 1997; Dittmann 2003; Pawłowski 1973].

**Tabela 4.** Funkcje błędów *ex post* w pakiecie `TSprediction`

Funkcje pakietu <code>TSprediction</code>	
ME ( $x$ , $y$ ) – funkcja podaje wartość średniego błędu <i>ex post</i> (mean error) prognoz wygasłych	
MAE ( $x$ , $y$ ) – funkcja podaje wartość średniego absolutnego błędu <i>ex post</i> (mean absolute error) prognoz wygasłych:	
MSE ( $x$ , $y$ ) – funkcja podaje wartość średniego kwadratowego błędu <i>ex post</i> (mean squared error) prognoz wygasłych	
RMSE ( $x$ , $y$ ) – funkcja podaje wartość pierwiastka średniego kwadratowego błędu <i>ex post</i> (root mean squared error) prognoz wygasłych	
MPE ( $x$ , $y$ ) – funkcja podaje wartość średniego procentowego błędu <i>ex post</i> (mean percentage error) prognoz wygasłych	
MAPE ( $x$ , $y$ ) – funkcja podaje wartość średniego absolutnego błędu procentowego <i>ex post</i> (mean absolute percentage error) prognoz wygasłych	
Argumenty funkcji	
$x$	wektor obserwacji (danych empirycznych) szeregu czasowego
$y$	Wektor prognoz
Przykłady wywołania funkcji w programie R	
<code>&gt; ME(x=data, y=addratio)</code>	
<code>&gt; MAE(data, addratio)</code>	
<code>&gt; MSE(data, mulratio)</code>	
<code>&gt; RMSE(data, addWinters(data, 12, 0.55, 0.95, 0.25))</code>	
<code>&gt; MPE(data, Holt(data, , , "first", "zero"))</code>	
<code>&gt; MAPE(data, mulWinters(data, r=12))</code>	

Źródło: opracowanie własne.

Szczegółowa charakterystyka wszystkich funkcji oraz przykłady realizujące prognozowanie szeregów czasowych ze składową periodyczną dostępne są w dokumentacji pakietu `TSprediction` (<http://keii.ue.wroc.pl/TSprediction/>).

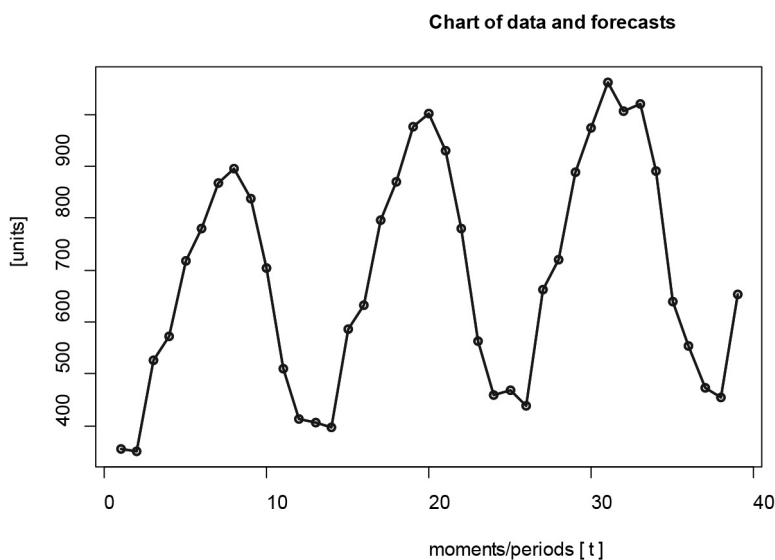
### 3. Przykład zastosowania wybranych funkcji pakietu `TSprediction` w prognozowaniu

Na potrzeby prezentacji działania funkcji pakietu `TSprediction`, umożliwiających prognozowanie szeregów czasowych ze składową w postaci wahań sezonowych, w artykule wykorzystano wyniki badania Głównego Urzędu Statystycznego, które obrazują wykorzystanie bazy noclegowej zbiorowego zakwaterowania w Polsce

w latach 2010-2013. Ostatecznie za źródło danych posłużył szereg czasowy prezentujący liczbę noclegów udzielonych turystom zagranicznym w obiektach hotelowych od stycznia 2010 do marca 2013 r. [GUS 2010; 2012; GUS 2013a; GUS 2013b]. Tym samym wywołaniu pakietu TSprediction towarzyszy następujący wektor danych:

```
> library(TSprediction)
> data=c(356, 350, 526, 573, 718, 781, 869, 896, 839, 703, 511, 413,
407, 396, 586, 633, 796, 870, 977, 1002, 930, 780, 562, 459, 468, 438,
662, 720, 889, 975, 1063, 1006, 1020, 891, 639, 554, 473, 454, 654)
```

Wektor *data* odpowiada kolejnym wyrazom jednowymiarowego szeregu czasowego będącego podstawą budowy prognoz. W przykładzie, bazuje się na znajomości realizacji zjawiska w momentach/okresach:  $t_1, t_2, t_3, \dots, t_{39}$  (por. rys. 1) oraz zakłada się potrzebę budowy prognoz na kolejne 12 miesięcy, tj. na momenty/okresy  $T_{40}, T_{41}, T_{42}, \dots, T_{51}$ .



**Rys. 1.** Liczba noclegów udzielonych turystom zagranicznym w obiektach hotelowych (styczeń 2010-marzec 2013)

Źródło: opracowanie własne z wykorzystaniem pakietu TSprediction.

W pierwszej kolejności do budowy prognoz wykorzystano metodę wskaźników, uzyskując następujący wektor prognoz oraz średni absolutny błąd procentowy *ex post* prognoz wygasłych (MAPE) dla modelu addytywnego:

```

> addratio=addRatio(data, r=12, horizon=12)
Call:
lm(formula = em ~ tt)
Residuals:
    Min       1Q   Median       3Q      Max
-310.08 -221.46  -38.31  193.73  328.44
Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  603.843     69.630   8.672 1.92e-10 ***
tt           4.217       3.034   1.390  0.173
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
Residual standard error: 213.3 on 37 degrees of freedom
Multiple R-squared:  0.04961,    Adjusted R-squared:  0.02393
F-statistic: 1.932 on 1 and 37 DF,  p-value: 0.1729

> print(round(addratio, 2))
 [1] 332.82 316.32 513.82 574.12 733.12 807.45 901.79 900.12
 [9] 861.79 723.45 502.79 407.45 383.42 366.92 564.42 624.72
[17] 783.72 858.05 952.39 950.72 912.39 774.05 553.39 458.05
[25] 434.02 417.52 615.02 675.32 834.32 908.66 1002.99 1001.32
[33] 962.99 824.66 603.99 508.66 484.62 468.12 665.62 725.92
[41] 884.92 959.26 1053.59 1051.92 1013.59 875.26 654.59 559.26
[49] 535.23 518.73 716.23

> MAPE(data, addratio)
[1] 3.804321%

```

W przypadku multiplikatywnego modelu metody wskaźników uzyskano następujące zestawienie prognoz wraz z ich średnim absolutnym błędem procentowym *ex post* prognoz wygasłych (MAPE):

```

> mulratio=mulRatio(data, r=12, horizon=12)
> print(round(mulratio,2))
 [1] 368.70 355.04 527.14 578.08 721.88 789.09 875.00 875.74
 [9] 839.82 714.46 515.64 428.96 399.38 384.38 570.41 625.21
[17] 780.33 852.56 944.91 945.24 906.04 770.42 555.76 462.12
[25] 430.06 413.72 613.68 672.33 838.78 916.03 1014.82 1014.74
[33] 972.25 826.39 595.89 495.29 460.75 443.06 656.94 719.46
[41] 897.23 979.49 1084.73 1084.24 1038.47 882.35 636.02 528.46
[49] 491.43 472.40 700.21

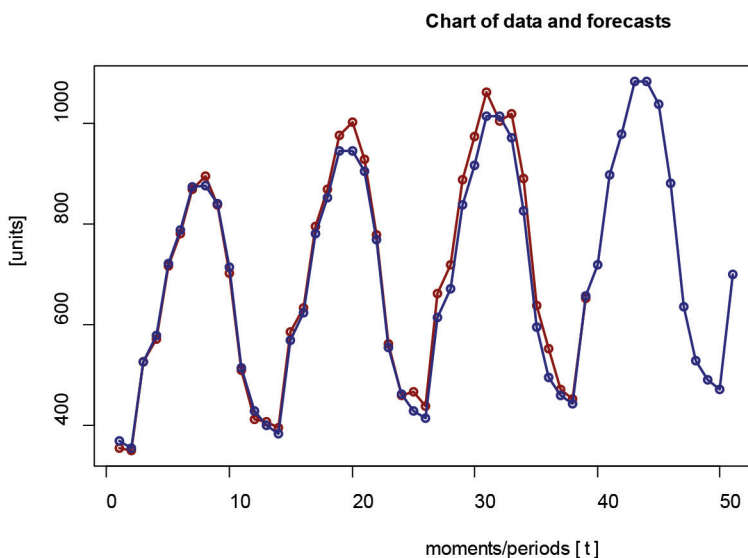
> MAPE(data, mulratio)
[1] 3.173036%

```

W obu przypadkach wartość uzyskanego błędu jest na podobnie niskim poziomie ze wskazaniem na multiplikatywną postać metody wskaźników. Sugeruje to występowanie w prognozowanym zjawisku względnie stałych wahań sezonowych. Wykres prognoz z uwzględnieniem postaci multiplikatywnej prezentuje rys. 2.

W przypadku metody Wintersa należy zauważyć, iż wywołanie w pakiecie TSprediction funkcji `addWinters()` oraz `mulWinters()` może odbywać się bez deklaracji wartości parametrów:  $\alpha$ ,  $\beta$ ,  $\gamma$ . W tej sytuacji dobór wartości tych parametrów przez pakiet TSprediction odbywa się w sposób automatyczny na optymalnym (tj. generującym najniższą wartość błędu *ex post*) poziomie. W odniesieniu do obu ww. funkcji oznacza to następujące (z pominięciem atrybutów alfa, beta, gamma) wywołanie metody Wintersa na przykładzie modelu addytywnego:

```
> addwinters=addWinters(data, r=12,,, typeF="first", typeS="difference", typeC="ratio")
[1] Optimal combination of parameters:
[1] alfa: 0.85
[1] beta: 0.95
[1] gamma: 0.95
> MAPE(data, addwinters)
[1] 14.18091%
```



**Rys. 2.** Wykres liczby noclegów udzielonych turystom zagranicznym w obiektach hotelowych (styczeń 2010-marzec 2013) oraz ich prognoz uzyskanych metodą wskaźników

Źródło: opracowanie własne z wykorzystaniem pakietu TSprediction.

Uzasadnieniem wywołania funkcji bez podania wartości parametrów  $\alpha$ ,  $\beta$ ,  $\gamma$  jest „korzystniejsza” wartość błędów *ex post*, niż ma to miejsce w przypadku dowolnej, innej niż ustalana przez program kombinacji wartości tych parametrów. Potwierdzają to wskazania niższych wartości błędów ME, MAE, MSE, RMSE, MPE oraz MAPE dla optymalnej kombinacji wartości parametrów  $\alpha$ ,  $\beta$ ,  $\gamma$ :



```
> x=data; y=addWinters(data, r=12)
> print(paste(ME(x, y), MAE(x, y), MSE(x, y), RMSE(x, y), MPE(x, y),
MAPE(x, y)), quote=FALSE)
[1] 2.59 89.75 10773.65 103.79 2.34 14.18
```

w relacji do następujących przykładowych wartości tych parametrów zadeklarowanych „z góry”:

```
> x=data; y=mulWinters(data, r=12, alfa=0.2, beta=0.5, gamma=0.8)
> print(paste(ME(x, y), MAE(x, y), MSE(x, y), RMSE(x, y), MPE(x, y),
MAPE(x, y)), quote=FALSE)
[1] -55.58 154.37 33245.13 182.33 -8.91 22.15
```

Jak nie trudno zauważyć, w prezentowanych przykładzie lepiej sprawdza się multiplikatywna postać szeregu czasowego potwierdzająca, iż w zjawisku występują względnie stałe wahania sezonowe. Potwierdza to, podobnie jak miało to miejsce w przypadku metody wskaźników, niższa wartość błędu MAPE dla modelu multiplikatywnego (na tle modelu addytywnego) metody Wintersa:


```
> mulwinters=mulWinters(data, r=12,,, typeF="first", typeS="difference",
typeC="ratio")
[1] Optimal combination of parameters:
[1] alfa: 0.95
[1] beta: 0.35
[1] gamma: 0.05
> MAPE(data, mulwinters)
[1] 6.515019%
```

Uzyskany wynik dla metody mulWinters() uprawnia do otrzymania wektora prognoz (wygasłych oraz właściwych) w zadanym horyzoncie czasowym, który w prezentowanym przykładzie odpowiada długości cyklu sezonowego ( $r = 12$ ). Ponieważ zakłada się, iż długość cyklu sezonowego wynosi 12 obserwacji, stąd jako wynik prognozowania otrzymuje się prognozy na 12 kolejnych okresów. W konsekwencji oznacza to wektor wyników o  $r$  elementów dłuższy niż wektor danych. Należy w tym miejscu zauważyć, iż brak wartości (NA) dla momentów/okresów od  $t_1$  do  $t_{12}$  jest przy przyjętych założeniach ( $r = 12$ ) cechą charakterystyczną wywołanej metody:

```
> print(round(mulwinters, 2))
[1]      NA      NA      NA      NA      NA      NA      NA      NA
[9]      NA      NA      NA      NA      NA     266.95    710.17    736.03
[17]  870.62  920.12 1008.15 1036.78  955.10  786.06  569.91  454.61
[25]  411.94  459.86  676.56  735.88  914.09  971.07 1089.07 1092.92
[33]  914.87  853.43  657.63  521.41  507.89  451.49  685.09  707.16
[41]  877.40  944.92 1040.67 1061.79  984.39  816.07  586.78  469.29
[49]  415.39  389.28  577.73
```

Wobec tego poszukiwane prognozy to w przypadku metody Wintersa 12 ostatnich wartości otrzymanego wektora (w przeciwieństwie do pozostałych wartości odpowiadających prognozom wygasłym).

Wzajemną zależność danych oraz otrzymanych prognoz, jako efekt wywołania funkcji chart(), prezentuje rys. 3.



**Rys. 3.** Wykres liczby noclegów udzielonych turystom zagranicznym w obiektach hotelowych (styczeń 2010-marzec 2013) oraz ich prognoz uzyskanych metodą Wintersa

Źródło: opracowanie własne z wykorzystaniem pakietu TSprediction.

Porównanie obu uzyskanych wykresów prognoz (rys. 2 i 3) pozwala domniemywać, iż bez względu na postać (addytywną lub multiplikatywną) lepszych jakościowo prognoz w prezentowanym zjawisku dostarcza metoda wskaźników. Potwierdza to najniższa uzyskana wartość błędu MAPE na poziomie 3,17% dla multiplikatywnej metody wskaźników. Tym samym za ostateczne prognozy należy (w prezentowanym przykładzie) przyjąć następujące wartości:

$$\begin{array}{ll}
 y_{40}^* = 719,46 \text{ [jedn.]}, & y_{41}^* = 897,23 \text{ [jedn.]}, \\
 y_{42}^* = 979,49 \text{ [jedn.]}, & y_{43}^* = 1084,73 \text{ [jedn.]}, \\
 y_{44}^* = 1084,24 \text{ [jedn.]}, & y_{45}^* = 1038,47 \text{ [jedn.]}, \\
 y_{46}^* = 882,35 \text{ [jedn.]}, & y_{47}^* = 636,02 \text{ [jedn.]}, \\
 y_{48}^* = 528,46 \text{ [jedn.]}, & y_{49}^* = 491,43 \text{ [jedn.]}, \\
 y_{50}^* = 472,40 \text{ [jedn.]}, & y_{51}^* = 700,21 \text{ [jedn.]}.
 \end{array}$$

## 4. Zakończenie

Przedstawiony w artykule autorski pakiet TSPrediction to implementacja metod prognozowania szeregów czasowych w postaci modułu znanego i cenionego wśród statystyków, ekonometryków i prognostów środowiska R. Zaletą zarówno pakietu, jak i całego środowiska jest możliwość użytkowania go na zasadzie darmowej licencji. Oznacza to alternatywę względem oprogramowania komercyjnego. Przykład zastosowania wybranych funkcji pakietu TSPrediction w prognozowaniu pozwala, w opinii autora, zweryfikować pozytywnie hipotezę o przydatności tego typu oprogramowania dla użytkowników środowiska R. Choć istnieją pakiety programu R o bardziej rozbudowanych funkcjach i zadaniach, zaletą prezentowanego pakietu jest koncentracja na elementarnych technikach prognozowania szeregów czasowych.

W chwili obecnej szczególną pozycję w pakiecie TSPrediction zajmują metody szeregów czasowych umożliwiające prognozowanie zjawisk ze składową periodyczną w postaci wahań sezonowych. Składnia oraz argumenty funkcji implementujące metodę wskaźników, metodę Wintersa oraz metodę Kleina zostały wraz z przykładami zaprezentowane w artykule. Przewiduje się rozbudowę pakietu o kolejne funkcje, umożliwiające prognozowanie z wykorzystaniem mniej znanych metod prognozowania szeregów czasowych, co daje szansę szerszego zainteresowania pakietem TSPrediction w przyszłości.

## Literatura

- Bartłomowicz T., 2011, *TSPrediction – Time Series prediction package for R program*, <http://keii.ue.wroc.pl/TSPrediction/>.
- Cieślak M., 1997, *Prognozowanie gospodarcze. Metody i zastosowania*, PWN, Warszawa.
- Dittmann P., 2003, *Prognozowanie w przedsiębiorstwie. Metody i ich zastosowanie*, Oficyna Ekonomiczna, Kraków.
- GUS, 2010, *Materiał na konferencję prasową w dniu 23 kwietnia 2010 r. Baza noclegowa i jej wykorzystanie w 2009 roku*, Warszawa.
- GUS, 2012, *Informacje i opracowania statystyczne. Turystyka w 2011 r.*, Warszawa.
- GUS, 2013a, *Informacje i opracowania statystyczne. Turystyka w 2012 r.*, Warszawa.
- GUS, 2013b, *Informacje i opracowania statystyczne. Turystyka w I kwartale w 2013 r.*, Warszawa.
- Hyndman R., 2009, *forecast: Forecasting functions for time series and linear models*, <http://cran.r-project.org/web/packages/forecast/>.
- Nowak E. (red.), 1998, *Prognozowanie gospodarcze. Metody, modele, zastosowania, przykłady*, Placet, Warszawa.
- Pawłowski Z., 1973, *Prognozy ekonometryczne*, PWN, Warszawa.
- R Development Core Team, 2013, *R: A Language and Environment for Statistical Computing*, R Foundation for Statistical Computing, URL: <http://cran.r-project.org/>.
- Radzikowska B. (red.), 1999, *Metody prognozowania. Zbiór zadań*, AE, Wrocław.
- Zeliaś A., Pawełek B., Wanat S., 2003, *Prognozowanie ekonomiczne*, PWN, Warszawa.

## FORECASTING TIME SERIES WITH PERIODIC COMPONENT USING TSPREDICTION R PACKAGE

**Summary:** The main aim of the paper is to present selected features of TSprediction package developed for R environment, which now is one of the most important commercial computing platforms (offered under the GNU GPL license). The article presents the features of the TSprediction package enabling the prediction of time series where there is a periodic component in the form of seasonal fluctuations. The package includes an implementation of the most popular time series methods of forecasting with a periodic component in the additive and multiplicative variety of ratio and Winters and Klein methods. The effects of selected forecasting functions and ex-post forecasting errors of TSprediction R package are presented in the examples.

**Keywords:** forecasting, time-series methods, TSprediction package, R program.