



UNIwersYTET WARSZAWSKI
Wydział Nauk Ekonomicznych




Piotr Jutkiewicz, Norbert Kołos

4CFuture

Model Wielkości Sprzedaży Napojów

Opis wyników badania.



Marzec 2008

„Polski rynek napojów gazowanych stanowi największą część rynku napojów bezalkoholowych i jest rynkiem charakteryzującym się trendem wzrostowym. Od roku 1992 obserwuje się wzrost sprzedaży napojów gazowanych od ok. 600 mln litrów do ok. 1330 mln litrów w 2002 r.



Szacuje się, że w następnych latach będzie kontynuowana tendencja rosnąca. Potwierdzeniem możliwości utrzymania się trendu wzrostowego może być średnia konsumpcja napojów gazowanych, wynosząca w Polsce ok. 36l na osobę rocznie w porównaniu z 72l w krajach Europy Zachodniej oraz 203 l na osobę w Ameryce Północnej.”¹

Cel modelu

Celem niniejszego modelu jest otrzymanie wiarygodnych i przydatnych w praktyce prognoz dotyczących wielkości sprzedaży napojów. Do opisu zmiennej zależnej użyto rozmaitych czynników – zarówno kontrolowanych przez firmę, jak i takich, na które nie ma ona wpływu.

Źródła danych

- Dane zebrane przez ABG Polska,
- Instytut Meteorologii i Gospodarki Wodnej;
<http://www.imgw.pl/wl/internet/meteo/sredmiestemp.html>

¹ AC Nielsen Polska

Spis Treści



Opis hipotez badawczych.....	4
Opis bazy danych	6
Interpretacja wyników.....	7
Wnioski	16
Bibliografia.....	17
Aneksy.....	17

Opis hipotez badawczych

Zmienna zależna:

Wielkość sprzedaży w litrach na miesiąc.



Zmienne niezależne:

- Nakłady na reklamę (suma wszystkich wydatków reklamowych związanych z danym produktem). Wpływ tej zmiennej powinien być dodatni zgodnie ze starym prawidłem, że „reklama dźwignią handlu”.
- Nakłady na reklamę poczynione przez konkurencję (wyrażone jako suma nakładów istotnych konkurentów). Wpływ tej zmiennej będzie ujemny. Wzrost wydatków reklamowych konkurencji przyczyni się do ich wzrostu sprzedaży (zgodnie z prawem z punktu poprzedniego), ceteris paribus nasza sprzedaż musi spaść, gdyż rynek jest względnie ograniczony.
- Pogoda (mierzona średnią temperaturą, odsetkiem dni słonecznych). Zmienna ta będzie wpływać i ujemnie i dodatnio, w zależności czy pogoda będzie odchyłać się od normy dla danego okresu im plus czy im minus. Trudno doszukiwać się teorii ekonomicznych wyjaśniających to zjawisko. Jest ono bardziej zagnieżdżone w biologii: w dni gorące i suche wydalamy znacznie większą ilość wody z organizmu, ergo wzrasta zapotrzebowanie na uzupełnienie niedoboru płynów i popyt na napoje rośnie. W czasie pogody wilgotnej vice versa.
- Cena produktu (jako cena litra napoju). Zmienna jak najbardziej ujemnie wpływająca. Zgodnie z ekonomiczną ujemną zależnością popytu względem ceny.
- Cena produktów konkurencji (wyrażona jako średnia cena litra napoju u istotnych konkurentów). Dodatnia, jako że im wyższa, tym bardziej obniża relatywnie cenę produktu naszej firmy. Im wyższa cena konkurencji, tym popyt na jej produkty maleje.
- Roczny całkowity popyt dla gałęzi (mierzony rocznie, aby pominąć problem sezonowości uwzględnionej w zmiennej pogodowej, równy całkowitej sprzedaży gałęzi – rynek nie jest w żaden sposób regulowany, aby nie można było przyjąć takiego założenia). Wpływ dodatni zgodnie z prawem popytu i podaży.

- Dostępność towaru dla klienta (mierzona np. odsetkiem sklepów oferujących dany towar). Wpływ dodatni. Im towar bardziej dostępny tym sprzedaż większa. Zgodnie z marketingowym prawem o użyteczności miejsca i czasu.
- Dostępność towaru konkurencji dla klienta (mierzona jw.). Wpływ ujemny (odwrotność sytuacji wyżej).

Uważamy, że opisane powyżej czynniki powinny być wystarczające do stworzenia wiarygodnego modelu sprzedaży napojów. Wydaje nam się, że uwzględniliśmy wszystkie zmienne mogące mieć istotny wpływ na ilość napojów owej firmy kupowanego przez konsumentów. Wpływ większości czynników na zmienną zależną daje się uzasadnić bezpośrednio teorią ekonomii.

Opis bazy danych

Dane wraz z ich etykietami z programu Stata9:

- *svX* – ilość sprzedanego napoju w 10 000 litrów/miesiąc (zmienna zależna)
- *svtotal* – całkowita sprzedaż gałęzi (10000 l/m-c)
- *svA*, *svB*, *svC* – całkowita sprzedaż napoju u konkurentów A, B, C
- *avptotal* – średnia cena litra napoju dla rynku w PLN
- *avpX* – średnia cena litra napoju analizowanej firmy
- *avpA*, *avpB*, *avpC* – średnia cena litra u poszczególnych firm konkurencji
- *nhdtotal* – dostępność napojów całej gałęzi (odsetek sklepów)
- *nhdX* – dostępność napojów Firmy X
- *nhdA*, *nhdB*, *nhdC* – dostępność napojów poszczególnych firm konkurencji
- *pogoda* – średnia miesięczna temperatura w kraju
- *atlX* – wydatki reklamowe (ATL) w PLN Firmy X
- *atlA*, *atlB*, *atlC* – wydatki reklamowe konkurencji

Pozostałe używane przez nas zmienne są przekształceniami powyższych. Np. zmienna *atlX_2d* jest dyskretnym zapisem zmiennej *atlX*, gdzie wydatki określono jako 0 – brak wydatków, 1 – małe wydatki, 2 – duże wydatki. Ponadto, nakłady na marketing są tu przesunięte o jeden miesiąc w stosunku do oryginalnych danych, aby odzwierciedlić fakt opóźnionego działania reklamy. Więcej informacji na ten temat znajduje się w dalszej części opisu wyników badania.

Interpretacja wyników

Podstawowe równanie regresji, od którego wyszliśmy sugerując się rozmaitymi założeniami teoretycznymi przedstawia się następująco:

xi: reg svX avpB avpA avpC avpX nhdA nhdB nhdC nhdX pogoda atlA atlB atlC i.atlX_2d i.atlX_2d _Iatlx_2d_0-2 (naturally coded; _Iatlx_2d_0 omitted)

Otrzymane wyniki wyglądały mało zachęcająco:

Source	SS	df	MS			
Model	18277.5008	14	1305.53577	Number of obs =	22	
Residual	1392.31968	7	198.902811	F(14, 7) =	6.56	
Total	19669.8205	21	936.658118	Prob > F =	0.0091	
				R-squared =	0.9292	
				Adj R-squared =	0.7876	
				Root MSE =	14.103	

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
avpB	-83.15098	54.5673	-1.52	0.171	-212.1821	45.88017
avpA	-206.4259	208.5161	-0.99	0.355	-699.488	286.6363
avpC	-58.65361	158.3338	-0.37	0.722	-433.0537	315.7464
avpX	98.48104	314.4572	0.31	0.763	-645.092	842.0541
nhdA	16.26338	17.89864	0.91	0.394	-26.06018	58.58694
nhdB	-2.393929	6.70648	-0.36	0.732	-18.25223	13.46438
nhdC	5.542546	6.532106	0.85	0.424	-9.903431	20.98852
nhdX	.7313055	3.524868	0.21	0.842	-7.603683	9.066294
pogoda	7.629307	2.34039	3.26	0.014	2.095163	13.16345
atlA	7.57e-06	8.16e-06	0.93	0.385	-.0000117	.0000269
atlB	-.0000129	7.97e-06	-1.62	0.149	-.0000318	5.94e-06
atlC	.0000167	.0000192	0.87	0.413	-.0000286	.0000619
_Iatlx_2d_1	43.61019	46.42378	0.94	0.379	-66.1646	153.385
_Iatlx_2d_2	-14.36422	8.345885	-1.72	0.129	-34.0991	5.370666
_cons	-294.2006	894.8602	-0.33	0.752	-2410.209	1821.808

Jak widać, wszystkie zmienne poza pogodą wykazują brak istotności, mimo że wydawały się one sensowne i znajdowały uzasadnienie w teorii ekonomii. Możemy jednak domyślać się, że niektóre działania konkurencji nie mają większego wpływu na sprzedaż Firmy X. Ponadto, przy tak dużej ilości zmiennych należałoby dysponować większą ilością obserwacji, jednak dane z wcześniejszych okresów nie nadają się do estymacji (inne sposoby zliczania, zestawienie w okresach 2 miesięcznych, itp). Współczynnik determinacji R^2 wynosi tu 0,93 jednak jest to spowodowane przede wszystkim dużą ilością zmiennych objaśniających w stosunku do liczby obserwacji.

Usuwając najbardziej nieistotne zmienne przeprowadziliśmy następującą regresję:

xi: reg svX avpB avpA avpX nhdA nhdX pogoda atlA atlB i.atlX_2d

i.atlX_2d _Iatlx_2d_0-2 (naturally coded; _Iatlx_2d_0 omitted)

Otrzymane wyniki:

Source	SS	df	MS			
Model	17673.3496	10	1767.33496	Number of obs =	22	
Residual	1996.47085	11	181.49735	F(10, 11) =	9.74	
Total	19669.8205	21	936.658118	Prob > F =	0.0004	
				R-squared =	0.8985	
				Adj R-squared =	0.8062	
				Root MSE =	13.472	

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
avpB	-89.61924	35.33506	-2.54	0.028	-167.3912	-11.84729
avpA	-202.0065	81.05099	-2.49	0.030	-380.3985	-23.61446
avpX	15.78952	94.23073	0.17	0.870	-191.6109	223.19
nhdA	12.26687	5.500014	2.23	0.047	.1614204	24.37232
nhdX	.5212098	2.755556	0.19	0.853	-5.543728	6.586148
pogoda	8.721199	1.722891	5.06	0.000	4.929141	12.51326
atlA	.0000109	6.33e-06	1.71	0.115	-3.09e-06	.0000248
atlB	-.0000121	4.67e-06	-2.59	0.025	-.0000224	-1.83e-06
_Iatlx_2d_1	44.96411	19.77143	2.27	0.044	1.447491	88.48073
_Iatlx_2d_2	-10.40828	7.13548	-1.46	0.173	-26.11337	5.296802
_cons	-7.233101	281.8372	-0.03	0.980	-627.5527	613.0865

Tak skonstruowany model zawiera zdecydowanie więcej istotnych zmiennych. Mimo tego, wciąż jest daleki od ideału: jedna z najważniejszych zmiennych (cena naszego napoju - avpX) uznana jest za całkowicie nieistotną, co jest ewidentnym błędem.

Ponieważ powyższe wyniki wciąż nas nie satysfakcjonowały, szukaliśmy kolejnych rozwiązań. W efekcie stworzyliśmy dwie nowe zmienne:

avpAvsX oraz *avpBvsX* – wyrażające różnicę między średnią ceną litra napoju oferowanego przez Firmę X, a ceną oferowaną przez dwóch największych konkurentów.

Zmuszeni byliśmy również zrezygnować z wyrażania nakładów w formie dyskretnej i powróciliśmy do wyjściowej formy *atlX* – zmiennej ciągłej.

Jedną z regresji, jakie udało się nam w wyniku wielu prób osiągnąć jest:

reg svX avpX avpAvsX avpBvsX nhdX atlX pogoda

Source	SS	df	MS			
Model	16751.5777	6	2791.92961	Number of obs =	22	
Residual	2918.24281	15	194.549521	F(6, 15) =	14.35	
Total	19669.8205	21	936.658118	Prob > F =	0.0000	
				R-squared =	0.8516	
				Adj R-squared =	0.7923	
				Root MSE =	13.948	

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
avpX	-139.8864	65.45334	-2.14	0.049	-279.3968	-.3758587
avpAvsX	-31.9142	52.76206	-0.60	0.554	-144.3739	80.54547
avpBvsX	-94.8757	35.97245	-2.64	0.019	-171.5492	-18.20223
nhdX	6.061627	2.021363	3.00	0.009	1.753194	10.37006
atlX	-4.96e-06	2.02e-06	-2.46	0.027	-9.27e-06	-6.54e-07
pogoda	4.904097	.9385057	5.23	0.000	2.903719	6.904474
_cons	358.9415	144.3117	2.49	0.025	51.34853	666.5345

A zatem równanie opisujące ilość napoju sprzedanego przez Firmę X w 10 000 litrów/miesiąc miałyby postać:

$$svX = 358.9415 - 139.8864avpX - 31.9142avpAvsX - 94.8757avpBvsX + 6.061627nhdX - 4.96 \cdot 10^{-06}atlX + 4.904097pogoda$$

Zmienna *avpAvsX* jest według wskazań programu nieistotna, lecz wyrzucenie jej znacznie pogarsza istotność pozostałych zmiennych. Zastanawia ujemny znak przy zmiennej *atlX* – czyżby zwiększanie nakładów na marketing zmniejszyło ilość sprzedawanego napoju? Być może byłoby to możliwe w przypadku wyjątkowo nieudanych kampanii reklamowych, jednak trudno jest nam zaakceptować takie wytłumaczenie. Będziemy musieli poświęcić temu zagadnieniu więcej czasu. Być może lepsze rezultaty dałoby porównanie nakładów na marketing Firmy X z nakładami konkurencji w tym samym przedziale czasowym.

Stosunek zmienności całkowitej do zmienności opisywanej przez model wynosi tu 0.85. Suma kwadratów wyjaśniana modelem (ESS) wynosi ponad 16751, zaś niewyjaśniona modelem (RSS) w przybliżeniu 2918. Hipoteza o łącznej nieistotności współczynników regresji jest odrzucana, ponieważ $0.0000 \ll 5\%$.

W czasie dalszych prac analizowaliśmy m.in. takie zmienne jak:

- $avpXvsT$ – wyrażające różnicę między średnią ceną litra napoju oferowanego przez Firmę X, a średnią ceną tego napoju na rynku,
- $atlxvsA$, $atlxvsB$, $atlxvsC$, – różnica wydatków na reklamę w firmie X i u konkurencji, w wariantach: przesunięcia miesięczne, potęgi, pierwiastki,
- $avpXsq$, $avpX2$ – cena napoju Firmy X w pierwiastku, potędze,
- $atlxsq$, $atlx2$, $atlxsqP$ – wydatki reklamowe Firmy X w pierwiastku, potędze, z różnymi wariantami przesunięć miesięcznych,

W efekcie udało się nam uzyskać poniższą regresję. Ostateczne równanie ma postać:

$$svX = 566.38 - 213.25avpX - 158.21avpBxX + 6.80nhdX + 1.27atlxPsm2 + 3.47pogoda$$

```
. reg svX avpX avpBxX nhdX atlxPsm2 pogoda
```

Source	SS	df	MS			
Model	17323.2215	5	3464.64431	Number of obs =	22	
Residual	2346.59893	16	146.662433	F(5, 16) =	23.62	
Total	19669.8205	21	936.658118	Prob > F =	0.0000	
				R-squared =	0.8807	
				Adj R-squared =	0.8434	
				Root MSE =	12.11	

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
avpX	-213.2511	58.41606	-3.65	0.002	-337.0876	-89.41455
avpBxX	-158.2069	48.3714	-3.27	0.005	-260.7497	-55.66406
nhdX	6.797936	1.781107	3.82	0.002	3.022157	10.57372
atlxPsm2	1.270545	.3552408	3.58	0.003	.5174677	2.023621
pogoda	3.469877	.7013968	4.95	0.000	1.982982	4.956772
_cons	566.3774	135.7311	4.17	0.001	278.6404	854.1145

Zatem w końcowym modelu użyto następujących zmiennych:

- svX – ilość sprzedanego napoju w 10 000 litrów/miesiąc (zmienna zależna),
- $avpX$ – średnia cena litra napoju analizowanej firmy w PLN ,
- $nhdX$ – dostępność napojów Firmy X wyrażona w procentach,
- $pogoda$ – średnia miesięczna temperatura w kraju, w stopniach Celsjusza,
- $atlxPsm2$ – wydatki reklamowe (ATL) Firmy X, przesunięte o 2 miesiące, wyrażone w milionach PLN, podniesione do kwadratu,
- $avpBxX$ – stosunek ceny napoju konkurenta B do ceny napoju Firmy X.

Przewyciężone zostały problemy braku istotności ceny produktu Firmy X, czy ujemnego współczynnika wydatków marketingowych. Udało nam się także poprawić stosunek zmienności całkowitej do zmienności opisywanej przez model do ponad 88%.

Jak widać wszystkie zmienne są istotne indywidualnie ($P > |t|$ wyraźnie poniżej 0.010) oraz istotne łącznie (statystyka $F = 23.62$, $\text{Prob} > F = 0.0000$).

Znaki przy współczynnikach pozostałych zmiennych niezależnych są zgodne z postawionymi przez nas hipotezami.

Interpretacja wielkości parametrów jest następująca:

- Zwiększenie ceny napoju o złotówkę powoduje spadek miesięcznej sprzedaży o 2 132 511 litrów,
- Kiedy stosunek ceny napoju konkurenta B do ceny napoju Firmy X zwiększy się o jednostkę, miesięczna sprzedaż spadnie o 1 582 069 litrów,
- Zwiększenie dostępności napoju w sklepach o 1 pkt procentowy powoduje wzrost sprzedaży o 67 979 litrów,
- Zwiększenie kwadratu wydatków reklamowych (liczonych w mln PLN) o 1 jednostkę daje wzrost sprzedaży o 12 705 litrów dwa miesiące później,
- Jednostopniowe ocieplenie powiększa sprzedaż o 34 698 litrów.

Model pozytywnie przechodzi testy założeń Klasycznego Modelu Regresji liniowej.

1) Test RESET pozytywnie weryfikuje przyjętą formę liniową modelu.

```
. ovtest, rhs
```

```
Ramsey RESET test using powers of the independent variables
Ho: model has no omitted variables
F(15, 1) = 1.42
Prob > F = 0.5849
```

2) Składnik losowy ma rozkład normalny:

```
. sktest e
```

Skewness/kurtosis tests for Normality				
variable	Pr(Skewness)	Pr(Kurtosis)	adj chi2(2)	joint Prob>chi2
e	0.129	0.592	2.91	0.2332

3) Składnik losowy modelu nie podlega autokorelacji żadnego rzędu:

```
. bgodfrey, lags(1 2 3)
```

```
Breusch-Godfrey LM test for autocorrelation
```

lags(p)	chi2	df	Prob > chi2
1	2.346	1	0.1256
2	2.400	2	0.3012
3	3.775	3	0.2868

H0: no serial correlation

4) Składnik losowy modelu jest homoskedastyczny:

```
. imtest, white
```

```
white's test for Ho: homoskedasticity
against Ha: unrestricted heteroskedasticity

chi2(20) = 20.77
Prob > chi2 = 0.4105
```

```
. hettest, rhs
```

```
Breusch-Pagan / Cook-Weisberg test for heteroskedasticity
```

```
Ho: Constant variance
Variables: avpX avpBX nhdX atlXpsm2 pogoda

chi2(5) = 4.75
Prob > chi2 = 0.4475
```

```
.
```

5) Współczynniki regresji w różnych grupach obserwacji są takie same (złamanie między 11 a 12 obserwacją):

```
. reg svX avpX avpBXX nhdX atlXPsm2 pogoda d dx1 dx2 dx3 dx4 dx5
```

Source	SS	df	MS			
Model	18026.4668	11	1638.76971	Number of obs =	22	
Residual	1643.35367	10	164.335367	F(11, 10) =	9.97	
Total	19669.8205	21	936.658118	Prob > F =	0.0005	
				R-squared =	0.9165	
				Adj R-squared =	0.8246	
				Root MSE =	12.819	

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
avpX	-151.1309	77.23729	-1.96	0.079	-323.2263	20.96453
avpBXX	-148.6326	128.8381	-1.15	0.275	-435.7018	138.4365
nhdX	12.56653	5.577468	2.25	0.048	.139162	24.99391
atlXPsm2	1.891339	.6771317	2.79	0.019	.3825956	3.400082
pogoda	.3683204	2.360844	0.16	0.879	-4.891968	5.628609
d	505.422	469.7241	1.08	0.307	-541.1886	1552.033
dx1	-100.1738	191.4677	-0.52	0.612	-526.7903	326.4428
dx2	7.786933	197.4662	0.04	0.969	-432.1951	447.769
dx3	-8.464297	9.391961	-0.90	0.389	-29.39089	12.4623
dx4	-.9415598	.9055207	-1.04	0.323	-2.959186	1.076066
dx5	4.026549	2.582042	1.56	0.150	-1.726598	9.779696
_cons	215.5736	389.9201	0.55	0.592	-653.2226	1084.37

```
. test (d=0) (dx1=0) (dx2=0) (dx3=0) (dx4=0) (dx5=0)
```

```
( 1) d = 0
( 2) dx1 = 0
( 3) dx2 = 0
( 4) dx3 = 0
( 5) dx4 = 0
( 6) dx5 = 0
```

```
F( 6, 10) = 0.71
Prob > F = 0.6478
```

6) W modelu nie występuje silna współliniowość między zmiennymi (statystyka VIF < 10).

```
. estat vif
```

variable	VIF	1/VIF
pogoda	3.67	0.272811
nhdX	2.71	0.369584
avpBXX	2.10	0.476101
avpX	1.98	0.505741
atlXPsm2	1.26	0.795366
Mean VIF	2.34	

Prognozy wewnątrz próby (fitted values), w związku z wysokim R^2 , wypadają bardzo dobrze. Oto prognoza na podstawie danych empirycznych z pierwszego okresu. Rzeczywista ilość sprzedanego napoju wyniosła 2 396 889 litrów (239.6889 dziesiątków tysięcy litrów).

```
. lincm 1.6*avpX +40*nhdX +1.575*avpBxX -3*pogoda +2.365502*at1XPsm2 + _cons
(1) 1.6 avpX + 1.575 avpBxX + 40 nhdX + 2.365502 at1XPsm2 - 3 pogoda + _cons = 0
```

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	240.5132	6.428923	37.41	0.000	226.8845	254.1419

Tabela poniżej przedstawia prognozę dla okresu z rzeczywistą sprzedażą 3 209 186.

```
. lincm 1.78*avpX +46*nhdX +1.758427*avpBxX +17*pogoda +33.365284*at1XPsm2 + _cons
(1) 1.78 avpX + 1.758427 avpBxX + 46 nhdX + 33.36528 at1XPsm2 + 17 pogoda + _cons = 0
```

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	322.6804	9.871329	32.69	0.000	301.7541	343.6067

A oto przykładowe prognozy poza próbą:

o Pierwszy scenariusz zakłada, że cena napoju konkurenta B spada z 3,13 do 3 PLN. Wartości pozostałych zmiennych niezależnych pozostają na tym samym poziomie co w prognozie powyżej. Nowa wartość zmiennej avpBxX wyniesie $3,00/1,78=1.685393$. Prognoza dla tej wartości tego współczynnika wygląda następująco:

```
. lincm 1.78*avpX +46*nhdX +1.685393*avpBxX +17*pogoda +33.365284*at1XPsm2 + _cons
(1) 1.78 avpX + 1.685393 avpBxX + 46 nhdX + 33.36528 at1XPsm2 + 17 pogoda + _cons = 0
```

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	334.2349	10.1837	32.82	0.000	312.6464	355.8233

Aby wielkość sprzedaży pozostała na poprzednim poziomie (322.6804), należałoby zmienić cenę napoju firmy X do ok. 1.93 PLN.

lincom 1.93*avpX +46*nhdX +1.5544*avpBXX +17*pogoda +33.365284*at1XPsm2 + _cons

(1) 1.93 avpX + 1.5544 avpBXX + 46 nhdX + 33.36528 at1XPsm2 + 17 pogoda + _cons = 0

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	322.9712	14.02105	23.03	0.000	293.2479	352.6945

o W drugim scenariuszu, prognozy meteorologiczne wskazują, iż średnia temperatura w lipcu wyniesie 17 stopni. Firma zakładała, że będzie 20 stopni. Co należy zrobić, aby móc zrealizować plan sprzedaży? Pozostałe dane przyjmujemy na poziomie tym samym, co w poprzednim przykładzie.

Gdyby temperatura wyniosła 20 stopni, firma mogłaby liczyć na sprzedaż wielkości 344.6445:

. lincom 1.78*avpX +46*nhdX +1.685393*avpBXX +20*pogoda +33.365284*at1XPsm2 + _cons

(1) 1.78 avpX + 1.685393 avpBXX + 46 nhdX + 33.36528 at1XPsm2 + 20 pogoda + _cons = 0

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	344.6445	10.56835	32.61	0.000	322.2406	367.0484

Gdyby temperatura wyniosła tylko 17 stopni, wówczas sprzedaż będzie o ponad 100 000 litrów mniejsza (334.2349). Załóżmy, że firmie zależy na zrealizowaniu planu sprzedaży i zamierza w tym celu podnieść dostępność towaru w sklepach. Obecny poziom współczynnika nhdX to 46%. Aby zwiększyć sprzedaż o 100 000 litrów, nhdX musiałoby zostać podniesione w przybliżeniu o 1.5 punkta procentowego w skali kraju (do poziomu 47.53129%).

. lincom 1.78*avpX +47.53129*nhdX +1.685393*avpBXX +17*pogoda +33.365284*at1XPsm2 + _cons

(1) 1.78 avpX + 1.685393 avpBXX + 47.53129 nhdX + 33.36528 at1XPsm2 + 17 pogoda + _cons = 0

svX	Coef.	Std. Err.	t	P> t	[95% Conf. Interval]	
(1)	344.6445	10.79621	31.92	0.000	321.7575	367.5314

Wnioski

W badaniu pokazano, jakie czynniki mają istotny wpływ na sprzedaż produktów w danym przedsiębiorstwie. Model sprzedaży napojów może posłużyć do weryfikacji teorii mikroekonomicznych empirycznymi danymi. Pokazuje istotność wpływu ceny oraz działań konkurenta na naszą sprzedaż. Z drugiej strony, nie każdy konkurent jest dla firmy na tyle groźny na ile mogłoby się wydawać.

Większość postawionych na wstępie hipotez badawczych została potwierdzona. Wybrane przez nas zmienne okazały się wystarczające do stworzenia modelu umożliwiającego dość precyzyjne prognozowanie sprzedaży. Wpływ poszczególnych zmiennych okazał się zgodny z przewidywaniami. Jedynym zaskoczeniem okazał się ujemny współczynnik przy zmiennej $avpBxX$. Wynika on ze skomplikowanej sytuacji między konkurentami na rynku i postrzegania cen przez konsumentów w odniesieniu do towarów konkurencji. Problem ten pozostawia miejsce na dalszą analizę.

Bibliografia

- K.Kuhl, M. Kurcewicz, G. Ogonek, P. Strawiński, J. Tyrowicz, *Materiały do nauki STAT'y*, 2005
- Greene, *Econometric Analysis*, Prentice Hall 2003
- Chow, *Ekonometria*, PWN 1995
- Hal R. Varian, *Intermediate Microeconomics – A Modern Approach*, Fifth Edition , March 1999
- Ph. Kotler: *Marketing: Analiza, Planowanie, wdrażanie, i kontrola*, Warszawa 1999
- Gazeta.pl – *Raport o rynku napojów gazowanych*;
<http://gospodarka.gazeta.pl/gospodarka/1,33203,665373.html>
- Gazeta.pl – *Rozmowa z Thomasem Krennbauerem, szefem Coca-Cola Poland Services*; <http://gospodarka.gazeta.pl/gospodarka/1,33203,665368.html>

Aneksy

- Dane, na których przeprowadzono badanie, w formacie STAT'y – plik *jutkiewicz_kolos_dane.dta* w załączniku
- Plik wsadowy z programu STATA z komendami, które zostały użyte w trakcie badania – plik *jutkiewicz_kolos_dofile.do* w załączniku