

Henryk Kowgier

Uniwersytet Szczeciński
Zachodniopomorska Szkoła Biznesu

Kilka uwag o szacowaniu kosztów całkowitych

Streszczenie

Do tej pory trwają spory wśród ekonomistów co do postaci analitycznej funkcji kosztów całkowitych. W artykule ukazano na przykładach empirycznych użyteczne wykorzystanie metody regresji liniowej do badania postaci analitycznej funkcji kosztów całkowitych w przypadku produkcji jedno – asortymentowej oraz wiele – asortymentowej.

Słowa kluczowe: koszty całkowite, analiza regresji liniowej

Wiadomości wstępne

Liczne opracowania o charakterze teoretycznym jak i empirycznym stwierdzają, że zależność między kosztami całkowitymi a wielkością produkcji może przybierać różne postacie analityczne¹:

$$C = \alpha_1 Q + \alpha_2 + u \quad (1)$$

$$C = \alpha_1 Q^2 + \alpha_2 Q + \alpha_3 + u \quad (2)$$

$$C = \alpha_1 Q^3 + \alpha_2 Q^2 + \alpha_3 Q + \alpha_4 + u \quad (3)$$

$$C = \alpha_1 e^{\alpha_2 Q} e^u \quad (4)$$

$$C = \alpha_1 \log(Q+1) + \alpha_2 + u \quad (\alpha_1 > 0, \alpha_2 > 0 \text{ lub } \alpha_2 < 0) \quad (5)$$

Krzywe kosztów całkowitych w przypadkach (2) i (4) odzwierciedlają sytuację gdy koszty całkowite rosną coraz szybciej a koszty jednostkowe maleją, osiągają minimum a następnie rosną. Krzywą postaci 5 zaobserwowano w przedsiębiorstwie transportowo – samochodowym (Z. Hellwig 1969) – tutaj koszty całkowite rosną coraz wolniej, a koszty jednostkowe maleją².

1 J. Hozer, Mikroekonometria, PWE, Warszawa 1993.

2 J. Hozer, Mikroekonometria, PWE, Warszawa 1993.



Koszty jednostkowe dla kosztów całkowitych postaci (1) –(4) przyjmują postać odpowiednio (6) – (9).

$$C_j = \frac{C}{Q} \text{ - koszty jednostkowe,}$$

$$C_j = \alpha_1 + \frac{\alpha_2}{Q} + \zeta \quad (6)$$

$$C_j = \alpha_1 Q + \alpha_2 + \frac{\alpha_3}{Q} + \zeta \quad (7)$$

$$C_j = \alpha_1 Q^2 + \alpha_2 Q + \alpha_3 + \frac{\alpha_4}{Q} + \zeta \quad (8)$$

$$C_j = \alpha_1 Q^{-1} e^{\alpha_2 Q} e^{\zeta} \quad (9)$$

przy ograniczeniach podanych w pracy³:

$$\alpha_1 > 0, \alpha_2 \geq 0 \text{ - odnośnie funkcji (1),}$$

$$\alpha_1 > 0, \alpha_2 \geq 0, \alpha_3 \geq 0 \text{ - odnośnie funkcji (2),}$$

$$\alpha_1 > 0, \alpha_2 \geq 0, \alpha_3 \geq 0, \alpha_4 \geq 0, \alpha_2^2 \leq 3\alpha_1\alpha_3 \text{ - odnośnie funkcji (3),}$$

$$\alpha_1 > 0, \alpha_2 \geq 0 \text{ - odnośnie funkcji (4) .}$$

Nałożone ograniczenia są jednak dość trudne w realizacji w przypadku (3) wobec istnienia punktu przegięcia wykresu funkcji kosztów całkowitych.

I tak mamy⁴:

$$\begin{aligned} \frac{dC}{dQ} &= 3\alpha_1 Q^2 + 2\alpha_2 Q + \alpha_3, \\ \frac{d^2C}{dQ^2} &= 6\alpha_1 Q + 2\alpha_2 = 0 \Leftrightarrow Q = \frac{-\alpha_2}{3\alpha_1}. \end{aligned}$$

Aby zachodził warunek $Q > 0$ w ostatnim równaniu musi być: $\alpha_1 > 0, \alpha_3 > 0, \alpha_2 < 0$.

Fakt aproksymacji w badaniach empirycznych funkcji kosztów całkowitych krzywymi postaci (1) – (5) wynika z tego, że w praktyce koszty obserwujemy w krótkim czasie w warunkach gospodarki rynkowej i ostatnia faza kształtowania się kosztów oznacza najczęściej bankructwo firmy i stosunkowo rzadko jest obserwowana⁵.

Wykorzystanie analizy regresji liniowej do szacowania kosztów całkowitych w przypadku produkcji jedno – asortymentowej

Aby znaleźć relację między kosztami całkowitymi i wielkością produkcji można niejednokrotnie zastosować analizę regresji.

3 A. Barczak, Ekonometryczne metody badania kosztów produkcji, PWN, Warszawa 1971.

4 J. Hozer, Mikroekonometria, PWE, Warszawa 1993.

5 J. Hozer, Mikroekonometria, PWE, Warszawa 1993.



Polega ona na jak najlepszym dopasowaniu linii kosztów do wszystkich obserwacji oraz określeniu stopnia dopasowania tej linii do tych obserwacji. W tym celu zastosujemy metodę najmniejszych kwadratów. W metodzie tej minimalizujemy wartość wyrażenia:

$$\Gamma = \sum_{i=1}^n (C_i - C_{jz}Q_i - C_s)^2 \quad (10)$$

szukając zmiennych obrazujących wysokość kosztów stałych i jednostkowych kosztów zmiennych. Metoda ta polega na takim dobraniu ocen szacowanych parametrów, aby suma kwadratów odchyleń (tzn. różnic) empirycznych wartości danej funkcji od jej wartości szacowanych była minimalna.

Warunek konieczny ekstremum, który jest jednocześnie warunkiem dostatecznym przyjmuje postać:

$$\begin{cases} \frac{\partial \Gamma}{\partial C_{jz}} = 2 \sum_{i=1}^n (C_i - C_{jz}Q_i - C_s)(-Q_i) = 0 \\ \frac{\partial \Gamma}{\partial C_s} = 2 \sum_{i=1}^n (C_i - C_{jz}Q_i - C_s)(-1) = 0 \end{cases} \quad (11)$$

W tym celu rozwiązujemy układ równań:

$$\begin{cases} \sum_{i=1}^n C_i = n \cdot C_s + C_{jz} \cdot \sum_{i=1}^n Q_i \\ \sum_{i=1}^n Q_i C_i = C_{jz} \cdot \sum_{i=1}^n Q_i^2 + C_s \cdot \sum_{i=1}^n Q_i \end{cases} \quad (12)$$

przy założeniu, że dwuwymiarowa zmienna losowa (Q, C) ma rozkład normalny⁶. Wtedy regresja C względem Q jak i Q względem C jest w tym rozkładzie funkcją liniową.

Oznaczenia do układu (12):

n – liczba obserwacji,

$\sum_{i=1}^n C_i$ - s – suma obserwacji kosztów całkowitych,

$\sum_{i=1}^n Q_i^2$ – suma kwadratów obserwacji wielkości produkcji,

$\sum_{i=1}^n Q_i^2 C_i$ – suma iloczynów wielkości produkcji i kosztów całkowitych,

C_s – koszty stałe

C_{jz} – jednostkowe koszty zmienne.

6 Porównaj: J. Greń: Statystyka matematyczna, PWN, Warszawa 1987; H. Kowgier: Elementy rachunku prawdopodobieństwa i statystyki na przykładach z ekonomii, WNT, Warszawa 2011.



Rozwiązując układ (12) względem c_{jz} i c_s otrzymujemy:

$$c_s = \frac{1}{n} \sum_{i=1}^n C_i - c_{jz} \frac{1}{n} \sum_{i=1}^n Q_i = \bar{C} - c_{jz} \bar{Q} \quad (13)$$

$$c_{jz} = \frac{\sum_{i=1}^n Q_i C_i - \sum_{i=1}^n Q_i \sum_{i=1}^n C_i}{n \sum_{i=1}^n Q_i^2 - (\sum_{i=1}^n Q_i)^2} = \frac{\sum_{i=1}^n (Q_i - \bar{Q})(C_i - \bar{C})}{\sum_{i=1}^n (Q_i - \bar{Q})^2}. \quad (14)$$

Aby obliczyć odchylenie standardowe zmiennych Q i C w próbie możemy skorzystać z następujących wzorów:

$$\tilde{\sigma}_Q = \sqrt{\frac{1}{n} \sum_{i=1}^n (Q_i - \bar{Q})^2}, \quad \tilde{\sigma}_C = \sqrt{\frac{1}{n} \sum_{i=1}^n (C_i - \bar{C})^2}. \quad (15)$$

Natomiast kowariancja w próbie wyraża się wzorem:

$$\text{cov}(Q, C) = \frac{1}{n} \sum_{i=1}^n (Q_i - \bar{Q})(C_i - \bar{C}). \quad (16)$$

Wykorzystując odchylenie standardowe oraz kowariancję możemy obliczyć estymator współczynnika korelacji generalnej na mocy współczynnika korelacji r w próbie, który ma postać:

$$r = \sqrt{a_{QC} \cdot a_{CQ}}, \quad (17)$$

gdzie $a_{QC} = \frac{\text{cov}(Q, C)}{\tilde{\sigma}_C^2}$, $a_{CQ} = \frac{\text{cov}(Q, C)}{\tilde{\sigma}_Q^2}$ - współczynniki regresji w próbie

przy czym mamy po podstawieniu za $\tilde{\sigma}_Q$, $\tilde{\sigma}_C$ oraz $\text{cov}(Q, C)$:

$$r = \frac{\sum_{i=1}^n (Q_i - \bar{Q})(C_i - \bar{C})}{\sqrt{\sum_{i=1}^n (Q_i - \bar{Q})^2 \sum_{i=1}^n (C_i - \bar{C})^2}}. \quad (18)$$

Przykład empiryczny dotyczący produkcji jedno – asortymentowej

W pewnej firmie produkcję i koszty całkowite w danym roku po uwzględnieniu inflacji opisuje tabela 1.



Tabela 1.

Miesiąc	Produkcja (w sztukach) - Q_i	Koszty całkowite - C_i
Styczeń	$Q_1 = 120$	$C_1 = 9800$
Luty	$Q_2 = 140$	$C_2 = 10000$
Marzec	$Q_3 = 180$	$C_3 = 10500$
Kwiecień	$Q_4 = 200$	$C_4 = 11000$
Maj	$Q_5 = 180$	$C_5 = 10500$
Czerwiec	$Q_6 = 160$	$C_6 = 10200$
Lipiec	$Q_7 = 140$	$C_7 = 10000$
Sierpień	$Q_8 = 180$	$C_8 = 10500$
Wrzesień	$Q_9 = 200$	$C_9 = 11000$
Październik	$Q_{10} = 210$	$C_{10} = 11200$
Listopad	$Q_{11} = 200$	$C_{11} = 11000$
Grudzień	$Q_{12} = 190$	$C_{12} = 10800$

Źródło: Opracowanie własne.

Tabela 2.
Obliczenia pomocnicze.

Q_i	Q_i^2	C_i	$Q_i C_i$
$Q_1 = 120$	14400	$C_1 = 9800$	117600
$Q_2 = 140$	19600	$C_2 = 10000$	1400000
$Q_3 = 180$	32400	$C_3 = 10500$	1890000
$Q_4 = 200$	40000	$C_4 = 11000$	2200000
$Q_5 = 180$	32400	$C_5 = 10500$	1890000
$Q_6 = 160$	25600	$C_6 = 10200$	1632000
$Q_7 = 140$	19600	$C_7 = 10000$	1400000
$Q_8 = 180$	32400	$C_8 = 10500$	1890000
$Q_9 = 200$	40000	$C_9 = 11000$	2200000
$Q_{10} = 210$	44100	$C_{10} = 11200$	2352000
$Q_{11} = 200$	40000	$C_{11} = 11000$	2200000
$Q_{12} = 190$	36100	$C_{12} = 10800$	2052000
$\sum_{i=1}^{12} Q_i = 2100$	$\sum_{i=1}^{12} Q_i^2 = 376600$	$\sum_{i=1}^{12} C_i = 126500$	$\sum_{i=1}^{12} Q_i C_i = 22282000$

Źródło: Opracowanie własne.



Po powyższych obliczeniach układ (12) przyjmuje postać:

$$\begin{cases} 126500 = 2100C_{jz} + 12C_s \\ 22282000 = 376600C_{jz} + 2100C_s \end{cases}$$

i jest on układem liniowym o 2 niewiadomych. Rozwiązując go otrzymujemy:

$$C_{jz} = 15,87, C_s = 7762,82,$$

oraz funkcja kosztów całkowitych ma postać:

$$C = 15,87Q + 7762,62. \quad (19)$$

(1,01) (180,45)

Obliczmy współczynnik r , który mierzy zależność korelacyjną między wielkością produkcji a kosztami całkowitymi.

$$\bar{Q} = \frac{1}{12} \sum_{i=1}^{12} Q_i = \frac{2100}{12} = 175, \quad \bar{C} = \frac{1}{12} \sum_{i=1}^{12} C_i = \frac{126500}{12} = 10542,$$

$$\frac{1}{12} \sum_{i=1}^{12} (Q_i - \bar{Q})^2 = \frac{9075}{12} = 756,25, \quad \frac{1}{12} \sum_{i=1}^{12} (C_i - \bar{C})^2 = 31016778,$$

$$\left\{ \frac{1}{12} \sum_{i=1}^{12} (Q_i - \bar{Q})^2 \right\} \left\{ \frac{1}{12} \sum_{i=1}^{12} (C_i - \bar{C})^2 \right\} = 23456438362,5;$$

$$\frac{1}{12} \sum_{i=1}^{12} (Q_i - \bar{Q})(C_i - \bar{C}) = 22527328838,96.$$

Wówczas uwzględniając równanie (18) otrzymujemy: $r^2 = 0,96039$ oraz $r = 0,9799$.

Wartość $r = 0,9799$ świadczy o tym, że istnieje silna zależność korelacyjna między wielkością produkcji a kosztami całkowitymi. Sprawdźmy obecnie czy (estymator r współczynnika korelacji ρ) współczynnik korelacji pomiędzy zmiennymi Q i C istotnie różni się od pewnej liczby z przedziału $< -1, 1 >$. W tym celu należy zweryfikować hipotezę: $H_0: \rho = 0$ przy hipotezie alternatywnej $H_1: \rho \neq 0$, tzn. że zmienne Q i C są skorelowane wobec hipotezy alternatywnej, że zmienne Q i C są skorelowane.

W tym celu rozpatrzmy wartość statystyki t – Studenta:

$$t = \frac{r}{\sqrt{1-r^2}} \sqrt{n-2},$$

przy $n - 2$ stopniach swobody.

Podstawiając do ostatniego wzoru obliczone $r = 0,98$ oraz $n = 12$ otrzymujemy:

$$t = \frac{0,98}{\sqrt{1-(0,96)^2}} \sqrt{12-2} = 21,43.$$

Ustalając poziom istotności $\alpha = 0,1$ – z tablic t – Studenta uzyskujemy dla 10 stopni swobody wartość krytyczną $t_{0,1} = 1,812$. Wobec tego, że $|t| = 21,43 > t_{0,1} = 1,812$, na poziomie



istotności $\alpha = 0,1$ hipotezę H_0 mówiącej o braku korelacji należy odrzucić na korzyść hipotezy H_1 .

Sprawdzając znaczenie statystyczne współczynnika stojącego w równaniu regresji (19) mamy:

$$|t| = \frac{15,87}{1,01} = 15,71$$

Z tablic statystycznych dla jednostronnego testu krytycznego t z 10 stopniami swobody oraz $\alpha = 0,05$ dostajemy $t_{0,05} = 2,228$. Wobec tego, że $|t| = 15,71 > 2,228$ więc zmienna użyta w równaniu regresji jest potrzebna przy prognozowaniu szacunkowej wartości kosztów całkowitych. Podobnie korzystając z tablic statystycznych rozkładu F – Snedecora dla $t_1 = k = 1$ oraz $r_2 = n - (k + 1) = 12 - 2 = 10$, gdzie ilość zmiennych, n – ilość punktów danych otrzymujemy przy jednej zmiennej dla poziomu istotności $\alpha = 0,05$ wartość krytyczną $F_{0,05} = 4,96$. Podczas gdy wartość obserwowana obliczona przy pomocy pakietu STATISTICA 6.0 wynosi $F = 242,46$.

Wobec tego, że $F > F_{0,05}$ uzyskane równanie regresji jest użyteczne przy prognozowaniu kosztów całkowitych.

Wykorzystanie metody regresji wielorakiej do szacowania kosztów całkowitych w przypadku produkcji wielo–asortymentowej

Do szacowania kosztów całkowitych w przypadku produkcji wielo–asortymentowej można również zastosować metodę regresji wielorakiej. Przyjmijmy, że koszty całkowite w przypadku produkcji wielo–asortymentowej przyjmują postać

$$C = \sum_{i=1}^n z_i x_i + S$$

gdzie S – koszty stałe, z_i – jednostkowe koszty zmienne i – tego produktu.

Niech w $n + 1$ – wymiarowym rozkładzie wektora losowego $[C, X_1, X_2, \dots, X_n]$, rozkład warunkowy zmiennej losowej C dla danych ustalonych wartości zmiennych losowych niezależnych X_1, X_2, \dots, X_n będzie rozkładem normalnym⁷:

$$N = (\beta_0 x_1 + \beta_1 x_2 + \dots + \beta_n x_n + \beta_{n+1}, \sigma). \quad (20)$$

Wtedy funkcja regresji zmiennej C względem zmiennych X_1, X_2, \dots, X_n jest funkcją liniową wielowymiarową postaci:

$$g(x_1, x_2, \dots, x_n) = E(C | X_1 = x_1^*, X_2 = x_2^*, \dots, X_n = x_n^*) = \beta_1 x_1^* + \beta_2 x_2^* + \dots + \beta_n x_n^* + \beta_{n+1}.$$

⁷ Porównaj: J. Greń: Statystyka matematyczna, PWN, Warszawa 1987; H. Kowgier: Elementy rachunku prawdopodobieństwa i statystyki na przykładach z ekonomii, WNT, Warszawa 2011.



Jeżeli parametry $\beta_i (1 \leq i \leq n+1)$ nie są znane, to można je oszacować metodą najmniejszych kwadratów na podstawie L elementowej próby prostej $(x_{i1}, x_{i2}, \dots, x_{in}, C_i)$ dla $i = 1, 2, 3, \dots, L$ gdzie $L > n$. Wtedy otrzymujemy:

$$X = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} & 1 \\ x_{21} & x_{22} & \dots & x_{2n} & 1 \\ \dots & \dots & \dots & \dots & \dots \\ x_{L1} & x_{L2} & \dots & x_{Ln} & 1 \end{bmatrix}, C = \begin{bmatrix} C_1 \\ C_2 \\ \dots \\ C_L \end{bmatrix}. \quad (21)$$

Natomiast funkcja Λ , którą należy minimalizować jest postaci:

$$\Lambda = \sum_{i=1}^L (C_i - \beta_1 x_{i1} - \beta_2 x_{i2} - \dots - \beta_{n+1})^2 = \text{minimum}. \quad (22)$$

Funkcję Λ , która jest formą kwadratową, można napisać w postaci macierzowej:

$$\Lambda = C^T C - 2C^T X \beta + \beta^T X^T X \beta. \quad (23)$$

Przy założeniu, że X_1, X_2, \dots, X_n są liniowo niezależne można wykazać, że $X^T X$ – jest dodatnio określona macierzą nieosobliwą posiadającą macierz odwrotną.

Różniczkując Λ względem wektora β dostajemy:

$$\frac{\partial \Lambda}{\partial \beta} = -2X^T C + 2X^T X \beta. \quad (24)$$

Porównując otrzymany wektor do wektora zerowego otrzymujemy:

$$2X^T C = 2X^T X \beta. \quad (25)$$

Oznaczając przez z wektor ocen szacowanego wektora β a następnie mnożąc lewostronnie równanie macierzowe mamy:

$$(X^T X)^{-1} X^T C = (X^T X)^{-1} (X^T X) z = z \quad (26)$$

gdzie z – szukany wektor jednostkowych kosztów zmiennych i kosztów stałych.

Otrzymaną zależność teoretyczną, wykorzystamy teraz bezpośrednio w praktycznych obliczeniach.

Przykład empiryczny dotyczący produkcji wielu – asortymentowej

W pewnej firmie produkującej 3 asortymenty w ilościach sztuk $x_i (1 \leq i \leq 3)$ w poszczególnych miesiącach danego roku – koszty całkowite $C_i (1 \leq i \leq 3)$, po uwzględnieniu inflacji ukazuje tabela 3:

Stosując pakiet STATISTICA 6.0, uzyskujemy na bazie tabeli 3 następującą zależność opisującą koszty całkowite (trzywymiarowe równanie regresji):

$$\hat{C} = 371,81 x_1 + 457,29 x_2 + 486,81 x_3 + 178191,94, \quad (27)$$

(119,08) (93,19) (167,53) (459974)

gdzie wektor z przyjmuje postać:

$$z = \begin{bmatrix} 374,81 \\ 457,29 \\ 486,81 \\ 178191,94 \end{bmatrix},$$



Tabela 3.

Miesiąc	x_1 (sztuk)	x_2 (sztuk)	x_3 (sztuk)	C_i (zł)
1	180	240	320	510000
2	200	210	300	500000
3	160	200	280	460000
4	180	190	290	470000
5	200	200	300	490000
6	210	190	280	470000
7	160	140	280	440000
8	200	210	290	495000
9	190	200	270	480000
10	200	210	290	490000
11	180	200	300	485000
12	160	140	280	440000

Źródło: Opracowanie własne.

oraz współczynnik dopasowania otrzymanego modelu do danych rzeczywistych wynosi:

$$R^2 = 0,95 ,$$

co oznacza silną zależność między wielkością produkcji a kosztami całkowitymi.

Ponadto standardowe błędy szacunku parametrów strukturalnych modelu wynoszą :

$$D(z_1) = 119,08 , D(z_2) = 93,19 , D(z_3) = 167,53 , D(S) = 45997,4 .$$

Aby zbadać istotność statystyczną otrzymanych parametrów, stosujemy w tym przypadku test istotności t – Studenta. Najpierw obliczamy wartość krytyczną statystyki t – Studenta. W naszym przypadku przy $k = 8$ stopniach swobody i poziomie istotności $\alpha = 0,05$, otrzymujemy: $t_{0,05} = 2,306$.

Z drugiej strony sprawdzianem testu, jest statystyka t – Studenta liczona według wzoru:

$$t_{z_i} = \frac{|z_i|}{D(z_i)} \quad (i = 1,2,3) .$$

$$\text{Ponieważ } t_{z_1} = \frac{374,81}{119,08} = 3,14 , t_{z_2} = \frac{457,29}{93,19} = 4,90 , t_{z_3} = \frac{486,81}{167,53} = 2,90 ,$$

oraz $3,14 > 2,306$, $4,90 > 2,306$, $2,90 > 2,306$, więc wszystkie zmienne użyte w równaniu regresji są potrzebne przy prognozowaniu szacunkowej wartości kosztów całkowitych. Poza tym w naszym przypadku liczba zmiennych $k = k_1 = 3$, $k_2 = n - (k + 1) = 8$, gdzie $n = 12$ – liczba punktów danych. Z tablic rozkładu F – Snedecora, na poziomie istotności $\alpha = 0,05$ oraz $k_1 = 3$, $k_2 = 8$, dostajemy: $F_{0,05} = 4,07$.

Na podstawie obliczeń numerycznych pakietu STATISTICA 6.0 uzyskujemy, że $F = 52,57$. Wobec tego, że $F = 52,57 > F_{0,05} = 4,07$ uzyskane równanie regresji jest uży-



teczne przy prognozowaniu szacunkowej wartości kosztów całkowitych w poszczególnych miesiącach przyszłego roku. Przykładowo dla założonego z góry poziomu produkcji: $x_1 = 200, x_2 = 220, x_3 = 240$ w styczniu przyszłego roku otrzymujemy koszty całkowite na poziomie:

$$\hat{C} = 374,81 \cdot 200 + 457,29 \cdot 220 + 486,81 \cdot 240 + 178191 = 470592.$$

Tak samo postępując, możemy oszacować koszty całkowite w pozostałych miesiącach przyszłego roku, ponieważ jak wykazaliśmy na podstawie rozkładu F – Snedecora równanie regresji jest dla nas w tym celu użyteczne i pełni rolę prognostyczną .

Wnioski końcowe

Powyższe rozważania pokazują dużą użyteczność stosowania metody regresji liniowej do szacowania kosztów całkowitych zarówno w przypadku produkcji jedno – asortymentowej jak i wiele – asortymentowej. Oczywiście nie jest to jedyna metoda, którą można stosować przy szacowaniu kosztów całkowitych. Czasami bardziej efektywna może np. okazać się metoda regresji nieliniowej.

Some remarks on estimate total costs

Summary

In the paper has been showed on selected examples how one may to estimate well total costs by linear regress.

