

W. OKTABA (Lublin)

*TWIERDZENIE DOTYCZĄCE METODY WYZNACZANIA OCEN  
KOMPONENTÓW WARIANCYJNYCH  
W MODELACH LOSOWYCH DLA DANYCH NIEORTOGONALNYCH*

**1. Streszczenie i problem.** Podstawą przybliżonych metod ocen komponentów wariancyjnych w przypadku modeli losowych opartych na danych nieortogonalnych jest pierwsza metoda Hendersona [3]. Nazywamy ją przybliżoną, gdyż zamiast wartości oczekiwanych sum kwadratów, występujących w analizie wariancji a obliczonych metodą najmniejszych kwadratów, w metodzie tej wyznaczamy wartości oczekiwane ważonych sum kwadratów. Pierwsza metoda Hendersona polega na przyrównaniu sum kwadratów odchyłeń dla  $p-1$  efektów losowych ( $p$ -tym składnikiem modelu jest średnia populacji  $\mu$ ) modelu do ich wartości oczekiwanych; wartości te wyrażają się jako kombinacje liniowe nieznanymi wariancji efektów. Współczynniki przy tych wariancjach, zwanych niekiedy komponentami wariancyjnymi, wyznacza się dla każdego modelu oddzielnie. Rozwiązanie odpowiedniego układu  $p-1$  równań daje nieobciążone oceny  $p-1$  wariancji.

Metoda Le Roy [4], czyli metoda R (por. [5]), oceniania komponentów jest uproszczeniem metody Hendersona, gdyż nie operuje sumami kwadratów odchyłeń, a wprost sumami kwadratów, i nie wymaga każdorazowego obliczania wartości oczekiwanych tych sum.

W metodzie R konstruuje się układ  $p$  równań z  $p$  niewiadomymi: kwadratem średniej  $\mu^2$  i  $p-1$  wariancjami efektów:  $\sigma_1^2, \dots, \sigma_e^2$ . Układ taki otrzymujemy przyrównując  $p$  sum kwadratów do ich wartości oczekiwanych, będących kombinacjami liniowymi parametrów  $\mu^2, \sigma_1^2, \dots, \sigma_e^2$  z pewnymi współczynnikami  $W$ . W zastosowaniach pomijamy obliczanie wartości oczekiwanych, wyznaczając współczynniki  $W$  według prostej reguły (por. [4]).

Tworząc odpowiednie kombinacje liniowe  $p$  równań układu tak, by uzyskać sumy kwadratów odchyłeń po lewych stronach, otrzymujemy po prawych stronach równań wyrażenia, które można otrzymać metodą Hendersona.

Le Roy przedstawił metodę R nie podając ogólnego uzasadnienia słuszności reguły tworzenia współczynników  $W$ . Ograniczył się jedynie

do kilku modeli losowych opartych na klasyfikacji krzyżowej kompletnej i niekompletnej, a nie rozważał modeli opartych na dowolnej kombinacji klasyfikacji krzyżowej z hierarchiczną.

Autor niniejszej pracy dostrzegł, że do tych ostatnich modeli metoda R i odpowiadająca jej reguła tworzenia współczynników  $W$  da się również zastosować; odpowiednią metodę nazwano RO (por. [5]). Wystarczy jedynie wprowadzić odpowiednią symbolikę dla klasyfikacji hierarchicznej i kombinacji tej klasyfikacji z klasyfikacją krzyżową oraz odpowiednio zmodyfikować regułę.

W niniejszej pracy przedstawiamy ogólne twierdzenie z dowodem, podające *explicite* wzory na współczynniki  $W$  w przypadku modeli z nieskorelowanymi efektami losowymi dla danych nieortogonalnych, gdy modele są oparte na dowolnej kombinacji klasyfikacji krzyżowej i hierarchicznej lub na niekompletnej klasyfikacji krzyżowej. Szczególnym przypadkiem tego twierdzenia jest reguła podana przez Le Roy, gdy ograniczymy się do klasyfikacji krzyżowej zupełnej lub niezupełnej.

Przykład zastosowania twierdzenia jest omówiony na końcu niniejszej pracy, a modele i konkretne przykłady liczbowe na zastosowanie twierdzenia i wzorów na współczynniki  $W$  obszerniej przedstawiono w innej pracy autora [5]. Z zamieszczonego twierdzenia można w szczególności wyprowadzić wzory Ganguli [2], jeżeli ograniczymy się do nieortogonalnej klasyfikacji hierarchicznej, oraz wyprowadzić wzory Crumpa [1], gdy będziemy rozpatrywali dane ortogonalne (tj. takie, że w każdej z podklas występuje ta sama liczba obserwacji).

**2. Założenia i symbolika.** Dane liczbowe w najogólniejszej formie tworzą bądź kombinację klasyfikacji krzyżowej z hierarchiczną, bądź niezupełną klasyfikację krzyżową (por. [5]).

Przypuścmy, że takie ogólne dane uzyskano losując z nieskończonej populacji poziomów każdego z  $r-1$  czynników  $A_1, A_2, \dots, A_{r-1}$ .

W przypadku gdy wyniki tworzą tylko klasyfikację krzyżową, porządkujemy czynniki w dowolny sposób. W przypadku klasyfikacji hierarchicznej numerujemy je w porządku zstępującym: np. w  $A_1$  zawiera się  $A_2$ , w  $A_2$  zawiera się  $A_3, \dots$ , w  $A_{r-2}$  zawiera się  $A_{r-1}$ .

Ten rodzaj uporządkowania wprowadzamy również dla kombinacji klasyfikacji krzyżowej z hierarchiczną z tym uzupełnieniem, że kolejne numery klasyfikacji hierarchicznej następują po numerze czynnika klasyfikacji krzyżowej, w której czynniki są uplasowane hierarchicznie, np. dla  $A \times B(C(D)) \times F$  numerujemy:  $A = A_1, D = A_2, C = A_3, B = A_4, F = A_5$ .

W przypadku klasyfikacji hierarchicznej  $A_2$  w  $A_1$  numerujemy poziomy czynnika  $A_2$  począwszy od jedyinki dla każdego poziomu czynnika  $A_1$ .



bolu decyduje tylko liczba i nazwa występujących czynników, jakkolwiek interpretacja obu efektów i ich wariancji jest różna. Taka wspólna symbolika dla problemu ogólnego, przyjęta w dowodzie twierdzenia, nie prowadzi do nieporozumień, gdyż nie dokonuje się takich przekształceń, w których odróżnianie wymienionych efektów i ich wariancji byłoby konieczne. Odróżnianie to (charakterystyczne dla metody RO, ale zbędne w metodzie R) jest oczywiście konieczne w końcowym zestawieniu ocen wariancji, a w szczególności w zastosowaniach do konkretnych modeli, gdyż wiąże się z interpretacją uzyskanych ocen.

Rozważmy losowy model ogólny postaci

$$(4) \quad y_{j_1 j_2 \dots j_r} = \mu + \overbrace{(a_{j_1} + \dots + a_{j_{t_1} j_{t_2} \dots j_{t_f}} + \dots)}^{(p-2) \text{ składników}} + e_{j_1 j_2 \dots j_r},$$

który zapiszemy krócej w postaci

$$(5) \quad y_{J_r} = \mu + (a_{j_1} + \dots + a_{J_{T_f}} + \dots) + e_{J_r} = \mu + \sum_{j=1}^{p-2} a_{J_{T_j}} + e_{J_r},$$

gdzie  $y_{J_r}$  jest  $j_r$ -tą obserwacją w podklasie  $(j_1, j_2, \dots, j_{r-1})$ ,  $e_{J_r}$  — błędem losowym,  $a_{j_1}$  — losowym efektem głównym  $j_1$ -ego poziomu czynnika  $A_1$ ,  $a_{j_{t_1} j_{t_2} \dots j_{t_f}} = a_{J_{T_f}}$  — efektem interakcyjnym między czynnikami  $A_{t_1}, A_{t_2}, \dots, A_{t_f}$  ( $f = 1, 2, \dots, r-1$ ), wybranymi spośród  $r-1$  czynników  $A_1, A_2, \dots, A_{r-1}$ . Dla krótkości zbiór wskaźników  $j_{t_1}, j_{t_2}, \dots, j_{t_f}$ , będący podzbiorem zbioru  $j_1, j_2, \dots, j_{r-1}$ , oznaczymy symbolem  $J_{T_f}$ .

Zauważmy, że  $J_{r-1} = J_{T_{r-1}}$ . Liczba efektów głównych i interakcyjnych  $a$ , a zatem i zbiorów  $J_{T_f}$  w modelu (4), jest równa  $p-2$ . Zauważmy bowiem, że w modelu kropki między  $a_{j_1}$  i  $a_{J_{T_f}}$  i kropki na prawo od  $a_{J_{T_f}}$  oznaczają ewentualne inne efekty główne niż efekt  $a_{j_1}$  czynnika  $A_1$  oraz inne efekty interakcyjne modelu niż efekt  $a_{j_{t_1} j_{t_2} \dots j_{t_f}}$ , a więc efekty interakcyjne oparte na innych (na ogół nie na wszystkich) podzbiórach zbioru  $J_{r-1}$  (por. § 4). Zespół wskaźników  $J_{T_f}$  zależy od rodzaju klasyfikacji danych liczbowych.

W podanym modelu zakładamy, że wszystkie efekty  $a$  i  $e$  są nieskorelowane i mają średnie równe zeru, tj.

$$(6) \quad E(a_{j_1}) = \dots = E(a_{J_{T_f}}) = \dots = E(e_{J_r}) = E(a_{j_1} \cdot a_{J_{T_f}}) = E(a_{j_1} \cdot e_{J_r}) = \\ = \dots = E(a_{J_{T_f}} \cdot e_{J_r}) = 0,$$

gdzie  $E$  oznacza wartość oczekiwaną. Wariancjami efektów  $a$  i  $e$  są

$$(7) \quad E(a_{j_1}^2) = \sigma_1^2, \dots, E(a_{J_{T_f}}^2) = \sigma_{j_{t_1} j_{t_2} \dots j_{t_f}}^2, \dots, E(e_{J_r}^2) = \sigma_e^2,$$

gdzie symbol  $\sigma_{j_{t_1} j_{t_2} \dots j_{t_f}}^2$  oznacza wariancję efektu interakcji między  $f$  czynnikami  $A_{t_1}, A_{t_2}, \dots, A_{t_f}$  i jest stałą wielkością dla ustalonych czynników  $A_{t_1}, A_{t_2}, \dots, A_{t_f}$  (mogą się zmieniać poziomy czynników).

Interesuje nas problem wyznaczania nieobciążonych ocen wariancji  $\sigma_1^2, \dots, \sigma_{i_1 i_2 \dots i_k}^2, \dots, \sigma_e^2$ . Odpowiednią metodę postępowania RO (por. [5]), omówioną w niniejszej pracy w § 1, referujemy w następujących punktach I, II i III.

I. Niech składnikami sum kwadratów odchyłeń (form kwadratowych) dla  $p-1$  źródeł zmienności występujących w analizie wariancji (por. [3]) modelu (4) będzie  $p$  sum kwadratów (por. kol. 2 tablicy 1):

1)  $\sum_{J_r} y_{J_r}^2$ , czyli suma kwadratów wszystkich  $n$  indywidualnych obserwacji  $y$ ,

2)  $\sum_{I_k} Y_{I_k}^2 / n_{I_k}$  ( $k = 1, 2, \dots, r-1$ ), czyli  $p-2$  sumy kwadratów dla tyluż efektów głównych i interakcyjnych  $\alpha$ ;  $p-2 \geq r-1$ , gdyż może być więcej niż jeden zbiór postaci  $I_k$ , albowiem  $I_k$  oznacza podzbiór o  $k$  elementach wybrany spośród  $r-1$  elementów zbioru  $J_{r-1}$ .

3)  $Y^2/n$ , czyli „poprawka”.

$Y_{I_k}$  definiujemy jako

$$(8) \quad Y_{I_k} = Y_{i_1 i_2 \dots i_k} = \sum_{D_k + j_r} y_{J_r},$$

gdzie sumowanie rozciąga się na wskaźnik  $j_r$  i zbiór wskaźników  $D_k$ , który jest dopełnieniem zbioru  $I_k$  do zbioru  $J_{r-1}$ ; tak więc  $D_k$  obejmuje wskaźniki  $i_{k+1}, i_{k+2}, \dots, i_{r-1}$ . Kształt sum kwadratów formy 2) wynika z modelu.

Zbiory wskaźników  $I_k$  o  $k$  elementach i  $J_{T_f}$  o  $f$  elementach, jako podzbiory zbioru  $J_{r-1}$  mogą obejmować co najmniej jeden element i co najwyżej  $r-1$  elementów; zbiorów  $I_k$  lub  $J_{T_f}$  jest  $p-2$ , tj. tyle, ile składników w modelu; zbiory  $I_{r-1}$ ,  $J_{T_{r-1}}$  i  $J_{r-1}$  są identyczne i różnią się co najwyżej permutacją elementów.

A oto objaśnienie innych oznaczeń:

$Y = \sum_{J_r} y_{J_r}$  jest sumą wszystkich obserwacji po wskaźnikach  $j_1, j_2, \dots, j_r$  zbioru  $J_r$ ; liczbę obserwacji w podklasie  $(i_1, i_2, \dots, i_k)$  określa

$$(9) \quad n_{I_k} = n_{i_1 i_2 \dots i_k} = \sum_{i_{k+1}, \dots, i_{r-1}} n_{j_1 j_2 \dots j_{r-1}} = \sum_{D_k} n_{J_{r-1}}.$$

II. Wartości oczekiwane składników sum kwadratów postaci

$$(10) \quad \sum_{J_r} y_{J_r}^2, \quad \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}, \quad \frac{Y^2}{n},$$

z uwagi na postać modelu (4), są kombinacjami liniowymi  $p-1$  wielkości: kwadratu średniej  $\mu^2$  i wariancji  $\sigma_1^2, \dots, \sigma_{i_1 i_2 \dots i_f}^2, \dots, \sigma_e^2$  z pewnymi współczynnikami  $W$  (por. kol. 4, 5 i 6 tablicy 1), będącymi funkcjami liczebności w podklasach  $n_{J_{r-1}}$ .

III. Rozwiązanie układu  $p$  równań powstałych z przyrównania tych kombinacji do odpowiednich  $p$  składników sum kwadratów postaci (10), czyli układu (11), daje nieobciążone oceny wariancji.

$$(11) \quad \begin{aligned} \sum_{J_r} y_{J_r}^2 &= n\mu^2 + \sum^{p-2} n\sigma_{i_1 t_2 \dots t_j}^2 + n\sigma_e^2, \\ \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} &= n\mu^2 + \sum^{p-2} W_{I_k [J_{T_j}]} \sigma_{i_1 t_2 \dots t_j}^2 + \left( \sum_{I_k} 1 \right) \sigma_e^2, \\ \frac{Y^2}{n} &= n\mu^2 + \sum^{p-2} W_{1 [J_{T_j}]} \sigma_{i_1 t_2 \dots t_j}^2 + 1 \cdot \sigma_e^2. \end{aligned}$$

Znaczenie symboli  $W$  z odpowiednimi wskaźnikami jest podane w twierdzeniu paragrafu następnego.

**3. Twierdzenie.** Udowodnimy twierdzenie, które określa regułę tworzenia współczynników  $W$  bez uciekania się do obliczania wartości oczekiwanych.

**Twierdzenie.** Przy nieskorelowanych efektach modelu losowego (4) i wprowadzonych oznaczeniach wartości oczekiwane  $p$  składników sum kwadratów formy (10) są kombinacjami liniowymi kwadratu średniej  $\mu^2$  i wariancji wszystkich  $p-1$  efektów losowych  $\sigma_1^2, \dots, \sigma_{i_1 t_2 \dots t_j}^2, \dots, \sigma_e^2$  ze współczynnikami  $W$  (por. (11)) określonymi przez następujące reguły.

1° a)  $W = n$  przy  $\mu^2$  dla każdego z  $p$  składników;

b)  $W =$  liczbie stopni swobody przy  $\sigma_e^2$  dla odpowiedniego składnika sumy kwadratów, tj.

$$(12) \quad \begin{aligned} W &= \sum_{J_r} 1 = n & \text{dla} & \sum_{J_r} y_{J_r}^2, \\ W &= \sum_{I_k} 1 & \text{dla} & \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}, \\ W &= 1 & \text{dla} & \frac{Y^2}{n}; \end{aligned}$$

c) współczynnikiem przy wariancji  $\sigma_{i_1 t_2 \dots t_j}^2$  w rozwinięciu wyrażenia  $E(Y^2/n)$  (przypisujemy mu wskaźnik 1) jest

$$W_{1 [J_{T_j}]} = \frac{1}{n} \sum_{J_{T_j}} n_{J_{T_j}}^2;$$

d) w rozwinięciu wyrażenia  $E \sum_{J_r} y_{J_r}^2$  jest

$$W_{J_r [J_{T_j}]} = W_{J_r [0]} = n.$$

2° Współczynnikami przy  $p-2$  wariancjach kształtu  $\sigma_{i_1 i_2 \dots i_f}^2 = \sigma_{T_f}^2$  w rozwinięciu wyrażenia  $E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}$  są

$$a) W_{I_k[J_{T_f}]} = \sum_{I_k} \frac{\sum_{J_{T_f}} n_{I_k + J_{T_f}}^2}{n_{I_k}}, \text{ jeżeli dwa zbiory wskaźników } I_k \text{ i } J_{T_f}$$

odpowiednio z elementami  $i_1, i_2, \dots, i_k$  oraz  $j_1, j_2, \dots, j_f$  są rozłączne (iloczyn zbiorów  $I_k J_{T_f} = 0$ ),

$$b) W_{I_k[J_{T_f}]} = W_{I_k[I_k J_{T_f} + U_g]} = W_{I_k[U_g]} = \sum_{I_k} \frac{\sum_{U_g} n_{I_k + U_g}^2}{n_{I_k}}, \text{ jeżeli zbior}$$

ry  $I_k$  i  $J_{T_f}$  mają wspólne elementy, ale  $J_{T_f}$  nie zawiera się w zbiorze  $I_k$ ; zbiór  $U_g$  obejmujący wskaźniki  $u_1, u_2, \dots, u_g$  jest dopełnieniem iloczynu zbiorów  $J_{T_f}$  i  $I_k$  do zbioru  $J_{T_f}$ , a więc zbiór wskaźników  $U_g$  można otrzymać przez usunięcie ze zbioru  $J_{T_f}$  wskaźników wspólnych ze zbiorem  $I_k$ ,

c)  $W_{I_k[J_{T_f}]} = W_{I_k[0]} = n$ , jeżeli zbiór  $J_{T_f}$  zawiera się w zbiorze  $I_k$ , a w szczególności pokrywa się z nim; zbiór pusty 0 w nawiasach prostokątnych [ ] jest dopełnieniem iloczynu zbiorów  $I_k J_{T_f}$  do zbioru  $J_{T_f}$ .

Zbiory  $I_k$  i  $J_{T_f}$  są podzbiarami odpowiednio o  $k$  i  $f$  elementach wybranych ze zbioru wskaźników  $J_{r-1}$  postaci  $j_1, j_2, \dots, j_{r-1}$ .

Reguły 1° i 2° zestawiono w tabelicy 1.

TABLICA 1

L.p.	Suma kwadratów	Wskaźniki przy $\sum$	$\mu^2$	$\sigma_{T_f}^2$	$\sigma_c^2$	
			0	$J_{T_f}$	$J_r$	
1	2	3	4	5	6	
1	$\sum_{J_r} y_{J_r}^2$	$J_r$	$n$	$J_r J_{T_f} = J_{T_f};$	$W_{J_r[0]} = n$	$n$
2	$\sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}$	$I_k$	$n$	a) $I_k J_{T_f} = 0;$ b) $J_{T_f} = I_k J_{T_f} + U_g;$ c) $I_k J_{T_f} = J_{T_f};$	$W_{I_k[J_{T_f}]}$ $W_{I_k[U_g]}$ $W_{I_k[0]}$	$\sum_{I_k} 1$
3	$\frac{Y^2}{n}$	1	$n$	$W_{1[J_{T_f}]} = \frac{1}{n} \sum_{J_{T_f}} n_{J_{T_f}}^2$		1

Dowód. Ad 1°. Wyodrębnimy w dowodzie punktu 1° trzy części A, B i C.

A. Zauważmy, że wobec (4) mamy

$$(13) \quad E(y_{J_r}) = \mu.$$

Stąd wobec tożsamości

$$E(z^2) = \text{Var}(z) + E^2(z)$$

otrzymujemy

$$(14) \quad E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} = \sum_{I_k} \frac{E Y_{I_k}^2}{n_{I_k}} = \sum_{I_k} \frac{\text{Var}(Y_{I_k}) + E^2(Y_{I_k})}{n_{I_k}}.$$

Z uwagi na (1), (2) i

$$\sum_{D_k+J_r} 1 = \sum_{D_k} n_{I_{r-1}} = \sum_{D_k} n_{J_{r-1}} = n_{I_k}$$

oraz wobec (8) mamy

$$\begin{aligned} Y_{I_k} &= \sum_{D_k+J_r} y_{J_r} = \sum_{D_k+J_r} \left[ \mu + \sum_{p-2} \alpha_{J_{T_f}} + e_{J_r} \right] = \\ &= \mu n_{I_k} + \sum_{D_k+J_r} \sum_{p-2} \alpha_{J_{T_f}} + \sum_{D_k+J_r} e_{J_r}. \end{aligned}$$

Stąd, ponieważ średnie efektów są zerami,

$$(15) \quad E(Y_{I_k}) = \mu n_{I_k}.$$

Definiując średnią  $\bar{e}_{I_k}$  za pomocą relacji  $\sum_{D_k+J_r} e_{J_r} = n_{I_k} \bar{e}_{I_k}$ , uzyskujemy kolejno:

$$(16) \quad \begin{aligned} \text{Var}(Y_{I_k}) &= \text{Var} \left[ \mu n_{I_k} + \sum_{D_k+J_r} \sum_{p-2} \alpha_{J_{T_f}} + n_{I_k} \bar{e}_{I_k} \right] = \\ &= \text{Var} \left[ \sum_{D_k+J_r} \sum_{p-2} \alpha_{J_{T_f}} \right] + n_{I_k} \sigma_e^2. \end{aligned}$$

W rezultacie ze względu na (14), (15) i (16) mamy:

$$(17) \quad \begin{aligned} E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} &= \sum_{I_k} \frac{\text{Var} \left[ \sum_{D_k+J_r} \sum_{p-2} \alpha_{J_{T_f}} \right] + n_{I_k} \sigma_e^2 + n_{I_k}^2 \mu^2}{n_{I_k}} = \\ &= n \mu^2 + \sigma_e^2 \sum_{I_k} 1 + \sum_{I_k} \frac{\text{Var} \left( \sum_{D_k+J_r} \sum_{p-2} \alpha_{J_{T_f}} \right)}{n_{I_k}}, \end{aligned}$$

gdzież

$$(18) \quad \sum_{I_k} n_{I_k} = n.$$

B. Wyznaczmy wartość oczekiwaną dla  $Y^2/n$ . Wobec  $E(Y) = \mu$ ,  $\sum_{J_r} \alpha_{J_{T_f}} = \sum_{J_{T_f}} n_{J_{T_f}} \alpha_{J_{T_f}}$  oraz  $\sum_{J_r} e_{J_r} = n\bar{e}$  mamy

$$\begin{aligned} E \frac{Y^2}{n} &= \frac{1}{n} [\text{Var}(Y) + E^2(Y)] = \\ &= \frac{1}{n} \left[ \text{Var} \sum_{J_r} (\alpha_{j_1} + \dots + \alpha_{J_{T_f}} + \dots + e_{J_r}) \right] + n^2 \mu^2 = \\ &= \frac{1}{n} \left[ \text{Var} \left( \sum_{J_r} \alpha_{J_{T_f}} \right) + \text{Var} \sum_{J_r} e_{J_r} + n^2 \mu^2 \right] + R, \end{aligned}$$

gdzie  $R$  nie obejmuje wyrażen z  $\mu$ ,  $e$  i  $\alpha_{J_{T_f}}$  dla ustalonego  $\alpha_{J_{T_f}}$ . Dalej

$$\begin{aligned} E \frac{Y^2}{n} &= R + n\mu^2 + \frac{1}{n} \text{Var} \left( \sum_{J_{T_f}} n_{J_{T_f}} \alpha_{J_{T_f}} \right) + \frac{1}{n} \text{Var}(n\bar{e}) = \\ &= R + n\mu^2 + \frac{1}{n} \sum_{J_{T_f}} n_{J_{T_f}}^2 \sigma_{i_1 t_2 \dots t_f}^2 + \sigma_e^2. \end{aligned}$$

C. Wreszcie obliczmy wartość oczekiwaną dla sumy kwadratów wszystkich obserwacji. Wobec  $E(y_{J_r}) = \mu$  obliczmy kolejno:

$$\begin{aligned} (20) \quad E \sum_{J_r} y_{J_r}^2 &= \sum_{J_r} E y_{J_r}^2 = \sum_{J_r} [\text{Var}(y_{J_r}) + E^2(y_{J_r})] = \\ &= \sum_{J_r} [\text{Var}(\alpha_{J_{T_f}} + e_{J_r}) + \mu^2] + P = n\mu^2 + n\sigma_{i_1 t_2 \dots t_f}^2 + n\sigma_e^2 + P, \end{aligned}$$

gdzie  $P$  oznacza człony niezależne od  $\mu$ ,  $\alpha_{J_{T_f}}$  i  $e$  dla ustalonego  $\alpha_{J_{T_f}}$ .

Udowodniliśmy więc, że współczynnik przy  $\mu^2$  jest równy  $n$  w rozwinięciu wartości oczekiwanej dowolnego składnika sumy kwadratów (por. 1<sup>o</sup>a)) oraz wykazaliśmy 1<sup>o</sup>b) (por. (17), (19) i (20)).

Ponadto udowodniliśmy 1<sup>o</sup>c) (por. (19)) i 1<sup>o</sup>d) (por. (20)).

Ad 2<sup>o</sup>. Zauważmy, że wyrażenie (17) można przedstawić w postaci:

$$E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} = n\mu^2 + \sigma_e^2 \sum_{I_k} 1 + \sum_{I_k} \frac{\text{Var} \left[ \sum_{D_k + I_r} (\alpha_{j_1} + \dots + \alpha_{J_{T_f}} + \dots + \alpha_{I_k} + \dots) \right]}{n_{I_k}},$$

gdzie zbiory  $J_{T_f}$  i  $I_k$  odpowiednio o  $f$  elementach  $j_{t_1}, j_{t_2}, \dots, j_{t_f}$  i  $k$  elementach  $i_1, i_2, \dots, i_k$  są podzbiorem zbioru  $J_{r-1}$  o elementach  $j_1, j_2, \dots, j_{r-1}$ . Jest widoczne, że współczynnik  $W$  (oznaczmy go przez  $W_{I_k \{J_{T_f}\}}$ ) przy wariancji  $\sigma_{i_1 t_2 \dots t_f}^2 = \sigma_{T_f}^2$  w  $E \sum_{I_k} Y_{I_k}^2 / n_{I_k}$  ma postać

$$(21) \quad W_{I_k \{J_{T_f}\}} = \sum_{I_k} \frac{\text{Var} \left( \sum_{D_k + I_r} \alpha_{J_{T_f}} \right)}{n_{I_k}}.$$

Zauważmy, że z uwagi na to, iż  $j_r$  nie występuje w zbiorze  $J_{T_f}$ , mamy

$$(22) \quad \sum_{D_k + j_r} a_{J_{T_f}} = \sum_{D_k} n_{I_{r-1}} a_{J_{T_f}}.$$

Rozważmy oddzielnie trzy przypadki, gdy zbiory  $J_{T_f}$  i  $I_k$

- a) są rozłączne;
- b) mają wspólne elementy, ale  $J_{T_f}$  nie zawiera się w  $I_k$ ;
- c) zbiór  $J_{T_f}$  zawiera się w zbiorze  $I_k$ , a w szczególności oba zbiory pokrywają się.

*Ad a).* W przypadku gdy  $J_{T_f}$  i  $I_k$  są zbiorami rozłącznymi, zbiór  $J_{T_f}$  zawiera się w zbiorze  $D_k$  o elementach  $i_{k+1}, \dots, i_{r-1}$ . Niech zbiór  $Z_g$  o elementach  $z_1, z_2, \dots, z_g$  ( $g = r-1-k-f$ ) będzie dopełnieniem zbioru  $J_{T_f}$  do  $D_k = J_{T_f} + Z_g$ .

Wobec

$$(23) \quad \sum_{Z_g} n_{I_k + J_{T_f} + Z_g} = n_{I_k + J_{T_f}},$$

gdzie  $I_{r-1} = I_k + J_{T_f} + Z_g$  jest zbiorem o elementach  $i_1, i_2, \dots, i_k, j_{t_1}, j_{t_2}, \dots, j_{t_f}, z_1, z_2, \dots, z_g$ , otrzymujemy

$$(24) \quad \begin{aligned} \sum_{D_k} n_{I_{r-1}} a_{J_{T_f}} &= \sum_{J_{T_f} + Z_g} n_{I_k + J_{T_f} + Z_g} a_{J_{T_f}} = \\ &= \sum_{J_{T_f}} a_{J_{T_f}} \sum_{Z_g} n_{I_k + J_{T_f} + Z_g} = \sum_{J_{T_f}} n_{I_k + J_{T_f}} a_{J_{T_f}}. \end{aligned}$$

Stąd wobec (24) i (22) wyrażenie (21) ze względu na  $\text{Var}(a_{J_{T_f}}) = \sigma_{i_1 t_2 \dots t_f}^2$  przybiera postać

$$(25) \quad \begin{aligned} \sum_{I_k} \frac{\text{Var}\left(\sum_{D_k} n_{I_{r-1}} a_{J_{T_f}}\right)}{n_{I_k}} &= \sum_{I_k} \frac{\text{Var}\left(\sum_{J_{T_f}} n_{I_k + J_{T_f}} a_{J_{T_f}}\right)}{n_{I_k}} = \\ &= \left( \sum_{I_k} \frac{\sum_{J_{T_f}} n_{I_k + J_{T_f}}^2}{n_{I_k}} \right) \sigma_{i_1 t_2 \dots t_f}^2. \end{aligned}$$

Dowód 2<sup>o</sup>a) jest więc zakończony.

*Ad b).* Niech zbiory  $J_{T_f}$  i  $I_k$  mają wspólne elementy, ale  $J_{T_f}$  nie zawiera się w  $I_k$ . Symbolem  $U_g$  oznaczmy zbiór o elementach  $u_1, u_2, \dots, u_g$ , będący dopełnieniem iloczynu zbiorów  $J_{T_f} I_k$  do zbioru  $J_{T_f}$ , tj.  $J_{T_f} = I_k J_{T_f} + U_g$ . Następnie, niech  $H_m$  o elementach  $h_1, h_2, \dots, h_m$  będzie dopełnieniem zbioru  $I_k + U_g$  do  $I_{r-1}$ . Zbiór  $H_m$  może być pusty. Wtedy  $D_k = U_g + H_m$  i  $I_{r-1} = I_k + D_k$  oraz

$$\begin{aligned} \sum_{D_k} n_{I_{r-1}} a_{J_{T_f}} &= \sum_{U_g + H_m} n_{I_k + U_g + H_m} a_{J_{T_f}} = \\ &= \sum_{U_g} a_{J_{T_f}} \sum_{H_m} n_{I_k + U_g + H_m} = \sum_{U_g} n_{I_k + U_g} a_{J_{T_f}}, \end{aligned}$$

gdyż zbiory  $J_{T_f}$  i  $H_m$  są rozłączne. Stąd wobec (21) i (22) mamy dalej

$$\sum_{I_k} \frac{\text{Var}(\sum_{U_g} n_{I_k+U_g} \alpha_{J_{T_f}})}{n_{I_k}} = \sum_{I_k} \frac{\text{Var} \sum_{U_g} n_{I_k+U_g}^2}{n_{I_k}} \sigma_{t_1 t_2 \dots t_f}^2,$$

a więc

$$(26) \quad W_{I_k|U_g} = \sum_{I_k} \frac{\sum_{U_g} n_{I_k+U_g}^2}{n_{I_k}}.$$

Zauważmy, że jest to współczynnik przy  $\sigma_{t_1 t_2 \dots t_f}^2$ , gdy rozwinięto

$$E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}.$$

Wyrażenie na  $W_{I_k|U_g}$  można otrzymać ze zbiorów  $I_k$  i  $J_{T_f}$ , korzystając z transformacji kształtu:

$$W_{I_k|J_{T_f}} = W_{I_k|I_k J_{T_f} + U_g} = W_{I_k|U_g},$$

tzn. rugując ze zbioru  $J_{T_f}$  elementy wspólne ze zbiorem  $I_k$  i pozostawiając w nawiasie prostokątnym zbiór  $U_g$ , który jest dopełnieniem iloczynu zbiorów  $J_{T_f} I_k$  do zbioru  $J_{T_f}$ . Dowód punktu 2<sup>o</sup>b) jest zakończony.

Ad c). Niech  $J_{T_f}$  zawiera się w zbiorze  $I_k$  lub jest z nim identyczny. Wtedy zbiory  $J_{T_f}$  i  $D_k$  są rozłączne i wobec tego

$$\sum_{D_k+I_r} \alpha_{J_{T_f}} = \alpha_{J_{T_f}} \sum_{D_k+I_r} 1 = \alpha_{J_{T_f}} \sum_{D_k} n_{I_r-1} = n_{I_k} \alpha_{J_{T_f}}.$$

Stąd człon z  $\sigma_{t_1 t_2 \dots t_f}^2$  w rozwinięciu

$$E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}$$

wobec (21) i (22) ma postać

$$\sum_{I_k} \frac{\text{Var}(n_{I_k} \alpha_{J_{T_f}})}{n_{I_k}} = \sum_{I_k} \frac{n_{I_k}^2}{n_{I_k}} \sigma_{t_1 t_2 \dots t_f}^2 = \sum_{I_k} n_{I_k} \sigma_{t_1 t_2 \dots t_f}^2 = n \sigma_{t_1 t_2 \dots t_f}^2.$$

Oznaczając współczynnik przy  $\sigma_{t_1 t_2 \dots t_f}^2$  w rozwinięciu

$$E \sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}}$$

przez  $W_{I_k|J_{T_f}}$ , uzyskujemy jego wartość  $n$ .

Zauważmy, że korzystając z reguły opisanej uprzednio w 2°b), a polegającej na rugowaniu ze zbioru  $J_{T_f}$  elementów należących do zbioru  $I_k$ , otrzymujemy

$$W_{I_k|J_{T_f}} = W_{I_k|I_k J_{T_f}} = W_{I_k|0}.$$

Symbolowi  $W_{I_k|0}$  przypisujemy umownie wartość  $n$ . Dowód punktu 2°c) jest zakończony.

Zauważmy, że ta sama reguła o rugowaniu z  $J_{T_f}$  elementów należących do  $I_k$  stosuje się także w przypadku 2°a): wtedy rugowania nie ma, gdyż zbiory  $I_k$  i  $J_{T_f}$  są rozłączne. Powyższe wzory można również stosować w przypadku krzyżowej klasyfikacji niekompletnej. Wtedy (por. [5]) sumowanie zaznaczone w twierdzeniu przeprowadza się oczywiście względem podklas zawierających obserwacje. Dowód twierdzenia jest zakończony.

UWAGA 1. Zauważyliśmy w dowodzie twierdzenia (por. 1°d) i 2°a), b), c)) prostą prawidłowość tworzenia wzorów na współczynniki  $W$ , a mianowicie:

*zbiór  $I_k$  (pierwszy zespół wskaźników przy  $W$ ) występuje pod znakiem pierwszej sumy, a drugi zbiór (drugi zespół wskaźników w nawiasach prostokątnych), który powstaje z wykreślenia ze zbioru  $J_{T_f}$  elementów wspólnych z  $I_k$ , występuje w liczniku ułamka pod znakiem drugiej sumy.*

Prawidłowość ta stanowi regułę, o której mówi Le Roy [4]. Zbiór  $I_k$  obejmuje wskaźniki, względem których sumuje się w sumie kwadratów

$$\sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}},$$

a zbiór  $J_{T_f}$  — wskaźniki odpowiadające wariancji  $\sigma^2$ , przy której występuje współczynnik  $W$  (por. tabl. 1).

UWAGA 2. Wzory na współczynniki  $W$  odpowiadające

I) sumie kwadratów wszystkich obserwacji  $\sum_{J_r} y_{J_r}^2$ ,

II) „poprawce”  $Y^2/n$ ,

występujące w 1°, można otrzymać ze wzorów w 2° (por. twierdzenie).

W tym celu wystarczy w przypadku I przyjąć:  $I_k = J_r$ ,  $n_{I_k} = 1$ ,  $Y_{I_k} = y_{J_r}$ , skąd

$$\sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} = \sum_{J_r} y_{J_r}^2.$$

Współczynnikiem przy  $\sigma^2$  jest  $\sum_{J_r} 1 = n$  (por. 1°b)). Wtedy 1°d) wynika natychmiast z 2°c).

W przypadku II przyjmujemy  $I_k = 1$  (tu 1 gra rolę zbioru pustego),  $n_{I_k} = n$ ,  $Y_{I_k} = Y_1 = Y$ . Wtedy

$$\sum_{I_k} \frac{Y_{I_k}^2}{n_{I_k}} = \frac{Y^2}{n}.$$

Współczynnikiem przy  $\sigma_e^2$  jest  $\sum_1 1 = 1$  (por. 1°b)). Wzór 1°c) wynika wprost z 2°a).

UWAGA 3. W przypadku danych ortogonalnych  $n_{J_r} = K = \text{const}$ , a więc  $j_r = 1, 2, \dots, K$  oraz

$$j_1 = 1, 2, \dots, a_1,$$

$$j_2 = 1, 2, \dots, a_2 = \text{const},$$

$$\dots \dots \dots$$

$$j_{r-1} = 1, 2, \dots, a_{r-1} = \text{const}.$$

Wtedy liczba obserwacji eksperymentu wynosi  $n = K \prod_{i=1}^{r-1} a_i$ . Punkty 1°a), 1°b), 1°d) twierdzenia nie ulegają zmianie. Wzory na współczynniki  $W$  w innych punktach przybierają następujące postacie:

$$1^\circ\text{c}) \quad W = \frac{n}{\prod_{w=1}^f a_{j_{t_w}}} = H \quad - \text{gdzie, jak zwykle, zbiór wskaźników}$$

$j_{t_1}, j_{t_2}, \dots, j_{t_f}$  jest podzbiorem zbioru  $j_1, j_2, \dots, j_{r-1}$ .

2°a)  $W_{I_k[J_{T_f}]} = H$ , gdzie  $i_1, i_2, \dots, i_k$  tworzą zbiór  $I_k$ , będący podzbiorem zbioru  $j_1, j_2, \dots, j_{r-1}$ . Wtedy  $n_{I_k} = \frac{n}{\prod_{w=1}^k a_{i_w}}$ .

$$2^\circ\text{b}) \quad W_{I_k[J_{T_f}]} = n.$$

4. Zastosowania. Dla ilustracji sposobu korzystania z udowodnionego twierdzenia, rozważmy model kształtu (por. § 4 w [5]):

$$(27) \quad y_{ijk\theta} = \mu + a_i + b_j + (ab)_{ij} + c(ab)_{k(ij)} + e_{ijk\theta},$$

gdzie  $r-1 = 3$ , wskaźniki  $i, j, k$  dotyczą poziomów czynników  $A, B, C$ , a czwarty wskaźnik  $g = 1, \dots, n_{ijk}$  rozróżnia indywidualne obserwacje  $E$  w podklasie  $(i, j, k)$ . Mamy

$$A: i = 1, \dots, I,$$

$$B: j = 1, \dots, J,$$

$$C \text{ w } AB, \text{ czyli } C(AB): k = 1, \dots, d_{ij},$$

$E$  w podklasach powstałych z umieszczenia poziomów czynnika  $C$  w klasyfikacji krzyżowej czynników  $A$  i  $B$  notujemy symbolicznie w postaci  $E(C(AB))$ .

Zauważmy, że numery czynników piszemy w modelu ogólnej postaci (por. [4]), a w ustalonym konkretnym modelu (np. (27)) zastępujemy je kolejnymi literami alfabetu łacińskiego. Tak więc symbole określające czynniki  $A_1, A_2, A_3, \dots$  zastępujemy przez  $A, B, C, \dots$ , a efekty  $\alpha_{j_1}, \alpha_{j_2}, \alpha_{j_1 j_2}, \alpha_{j_3(j_1)}, \dots$  odpowiednio przez  $a_i, b_j, (ab)_{ij}, c(a)_{k(i)}, \dots$ , gdzie  $j_1 = i, j_2 = j, j_3 = k$ .

Z porównania modelu (27) z ogólną postacią modelu (4) jest widoczne, że  $j_1 = i, j_2 = j, j_3 = k, j_4 = g$ .

Mamy  $p = 6$  składników w modelu, w tym  $p - 2 = 4$  efekty główne i interakcyjne.

$\alpha_{j_1} = a_i$  jest efektem głównym  $i$ -tego poziomu pierwszego czynnika ( $A$ ),

$\alpha_{j_2} = b_j$  jest efektem głównym  $j$ -tego poziomu drugiego czynnika ( $B$ ),

$\alpha_{j_1 j_2} = a_{ij} = (ab)_{ij}$  jest efektem interakcyjnym związanym z  $i$ -tym poziomem czynnika  $A$  oraz  $j$ -tym czynnika  $B$ ,

$\alpha_{j_1 j_2 j_3} = a_{ijk} = c(ab)_{k(ij)}$  jest efektem głównym  $k$ -tego poziomu czynnika  $C$  wewnątrz podklasy  $(i, j)$  klasyfikacji krzyżowej  $AB$ .

Wariancjami 5 efektów losowych są

$$E\alpha_{j_1}^2 = Ea_i^2 = \sigma_A^2, \quad E\alpha_{j_2}^2 = Eb_j^2 = \sigma_B^2, \quad E\alpha_{j_1 j_2}^2 = \sigma_{AB}^2,$$

$$E\alpha_{j_1 j_2 j_3}^2 = E[c(ab)_{k(ij)}]^2 = \sigma_{C(AB)}^2, \quad E\epsilon_{ijklg}^2 = \sigma_e^2.$$

Rolę  $Y_{I_k} = \sum_{D_k + i_r} y_{J_r}$  grają tu wielkości:

$$Y_{i\dots} = \sum_{jkg} y_{ijk}, \quad Y_{j..} = \sum_{ikg} y_{ijk},$$

$$Y_{ij..} = \sum_{kg} y_{ijk}, \quad Y_{ijk.} = \sum_g y_{ijk},$$

gdź przy efektach mamy zbiory wskaźników  $I_k$  kształtu: 1)  $i$ , 2)  $j$ , 3)  $ij$  oraz 4)  $ijk$ . Są one podzbiórami zbioru  $J_{r-1}$ , tj. zbioru  $ijk$ .

Rolę  $n_{I_k} = \sum_{D_k} n_{J_{r-1}}$  grają liczebności:

$$n_{i..} = \sum_{jk} n_{ijk}, \quad n_{j.} = \sum_{ik} n_{ijk}, \quad n_{ij.} = \sum_k n_{ijk}.$$

Sumami kwadratów, dla których oblicza się wartości oczekiwane, by otrzymać układ  $p = 6$  równań z  $p = 6$  niewiadomymi kształtu  $\mu^2, \sigma_A^2, \sigma_B^2, \sigma_{AB}^2, \sigma_{C(AB)}^2$  i  $\sigma_e^2$  są:

$$\sum_{ijk} y_{ijk}^2, \quad \sum_i \frac{Y_{i\dots}^2}{n_{i\dots}}, \quad \sum_j \frac{Y_{j..}^2}{n_{j..}}, \quad \sum_{ij} \frac{Y_{ij..}^2}{n_{ij.}}, \quad \sum_{ijk} \frac{Y_{ijk.}^2}{n_{ijk}}$$

i „poprawka”  $Y^2/n$ .

Współczynnikiem przy wariancji  $\sigma_{j_1 j_2}^2 = \sigma_{AB}^2$  (wskaźniki  $ij$  odpowiadają interakcji  $AB$ ) w rozwinięciu

$$E \sum_{ijk} \frac{Y_{ijk}^2}{n_{ijk}} \quad \text{jest} \quad W_{I_k[J_{T_j}]} = W_{ijk[ij]} = W_{ijk[0]} = n$$

(por. 2<sup>o</sup>c) w twierdzeniu), a w rozwinięciu

$$E \sum_j \frac{Y_{j..}^2}{n_{j.}} \quad \text{jest} \quad W_{I_k[J_{T_j}]} = W_{j[ij]} = W_{j[i]} = \sum_j \frac{\sum_i n_{ij}^2}{n_{j.}}$$

(por. 2<sup>o</sup>b)).

Współczynnikiem przy wariancji  $\sigma_A^2$  w rozwinięciu

$$E \sum_j \frac{Y_{j..}^2}{n_{j.}} \quad \text{jest} \quad W_{I_k[J_{T_j}]} = W_{j[i]}.$$

#### Prace cytowane

- [1] S. L. Crump, *The estimation of variance components in analysis of variance*, Biometrics 2 (1946), str. 7-11.  
 [2] M. Ganguli, *A note on nested sampling*, Sankhya 5 (1941), str. 449-452.  
 [3] C. R. Henderson, *Estimation of variance and covariance components*, Biometrics 9 (1953), str. 226-252.  
 [4] H. L. Le Roy und W. Gluckowski, *Die Bestimmung der Varianzkomponenten im a·b·c-Faktorenversuch mit ungleichen Klassenfrequenzen*, Biom. Zeitschr. 3 (1961), str. 73-91.  
 [5] W. Oktaba, *Estymacja komponentów wariancyjnych w nieortogonalnych modelach losowych opartych na kombinacji klasyfikacji krzyżowej z hierarchiczną*, Zastosow. Mat. 7 (1964), str. 435-463.

Praca wpłynęła 2. 11. 1964

В. ОКТАБА (Львов)

#### ТЕОРЕМА О МЕТОДЕ ОПРЕДЕЛЕНИЯ ОЦЕНОК ДИСПЕРСИОННЫХ КОМПОНЕНТОВ В СЛУЧАЙНЫХ МОДЕЛЯХ ДЛЯ НЕОРТОГОНАЛЬНЫХ ДАННЫХ

#### РЕЗЮМЕ

В работе доказано теорему дающую явные формулы коэффициентов в системе  $p$  уравнений при квадрате среднего значения совокупности  $\mu^2$  и  $p-1$  дисперсиях случайных эффектов в задаче оценки дисперсионных компонент в не-

ортогональной случайной модели основанной на произвольной комбинации перекрестной классификации с иерархической или же основанной на произвольной перекрестной классификации полной и неполной.

Решение соответствующей системы  $p$  уравнений с  $p$  неизвестными дает несмещенную дисперсию. Из этой теоремы следует как частный случай правило Леруа [4] если сузить задачу к модели основанной на перекрестной классификации полной или неполной.

Дается пример применения теоремы. Конкретные численные примеры применения этой теоремы на практике можно найти в другой работе автора [5].

---

W. ОКТАВА (Lublin)

*THEOREM CONCERNING THE METHOD OF DETERMINING THE ESTIMATES OF VARIANCE COMPONENTS IN RANDOM MODELS FOR NON-ORTHOGONAL DATA*

SUMMARY

The author proves a theorem showing explicit formulas for the coefficients  $W$  in a system of  $p$  equations with the mean population square  $\mu^2$  and  $p-1$  variances of random effects with regard to the problem of the estimation of variance components in a non-orthogonal random model based on an arbitrary combination of a cross-classification with a hierarchical classification or on an arbitrary complete and incomplete cross-classification. The solution of a suitable system of  $p$  equations with  $p$  unknowns gives unbiased variances. This theorem implies, as a particular case, the rule given by Le Roy [4] if we confine ourselves to a model based on a cross-classification, complete or incomplete.

The paper includes an example of the application of the theorem. Concrete numerical examples of its practical application can be found in another paper by the same author [5].

---