

# Testowanie hipotez w wybranych wielowymiarowych rozkładach normalnych

**Roman Zmyślony**

Kościelisko 2016, 5-13 Września

# Plan prezentacji

1. Wielowymiarowy model normalny ze strukturą BS macierzy kowariancji
2. Algebry Jordana - zastosowania w statystyce
3. Model mieszany jednowymiarowy i optymalne estymatory i testy dla komponentów wariancyjnych
4. Test F i LRT dotyczący struktury kowariancji
5. Porównanie mocy (symulacje)

# 1. Wprowadzenie

Blokowo-symetryczna (BS) struktura kowariancji dla podwójnie wielowymiarowych danych ( $m$  wymiarowe wektory obserwacji powstałe poprzez powtarzane pomiary ze względu na  $u$  czynników lub punktów czasowych), która jest wielowymiarowym uogólnieniem symetrycznej struktury kowariancji dla wielowymiarowych obserwacji, została wprowadzona przez Rao (1945, 1953) przy okazji klasyfikacji genetycznie różnych grup, a następnie Arnold (1979) badał tę strukturę kowariancji przy opracowywaniu uogólnionego modelu liniowego z wymieniającym wektorem reszt o łącznym rozkładzie normalnym.

# 1. Wprowadzenie

Rozważane będą podwójnie wielowymiarowe dane następującej postaci:

$$\mathbf{y}_{num \times 1} = \text{vec}(\mathbf{Y}'_{um \times n}) \sim N((\mathbf{1}_n \otimes \mathbf{I}_{um})\boldsymbol{\mu}, \mathbf{I}_n \otimes \boldsymbol{\Gamma}_{um}),$$

gdzie  $\boldsymbol{\mu}$  i  $\boldsymbol{\Gamma}$  są nieznanymi,  $\boldsymbol{\mu}$  jest wektorem wymiaru  $um \times 1$  oraz

$$\boldsymbol{\Gamma} = \mathbf{I}_u \otimes \boldsymbol{\Gamma}_0 + (\mathbf{J}_u - \mathbf{I}_u) \otimes \boldsymbol{\Gamma}_1.$$

Poprzez  $\mathbf{I}$  oznaczono macierz identyczościową wymiaru  $u$ , a  $\mathbf{J} = \mathbf{1}\mathbf{1}'$  jest macierzą jedynek wymiaru  $u$ .  $\boldsymbol{\Gamma}_0$  i  $\boldsymbol{\Gamma}_1$  są nieznanymi parametrami wymiaru  $m \times m$ .

## 2. Najlepsze nieobciążone estymatory dla $\Gamma_0$ oraz $\Gamma_1$

Można pokazać, że najlepsze nieobciążone estymatory (BUE) dla  $\Gamma_0$  i  $\Gamma_1$  są postaci:

$$\begin{aligned}\tilde{\Gamma}_0 &= \frac{1}{(n-1)u} \mathbf{C}_0, \\ \tilde{\Gamma}_1 &= \frac{1}{(n-1)u(u-1)} \mathbf{C}_1,\end{aligned}$$

gdzie

$$\begin{aligned}\mathbf{C}_0 &= \sum_{s=1}^u \sum_{r=1}^n (\mathbf{y}_{r,s} - \bar{\mathbf{y}}_{\bullet s}) (\mathbf{y}_{r,s} - \bar{\mathbf{y}}_{\bullet s})', \\ \mathbf{C}_1 &= \sum_{s=1}^u \sum_{\substack{s^*=1 \\ s \neq s^*}}^u \sum_{r=1}^n (\mathbf{y}_{r,s} - \bar{\mathbf{y}}_{\bullet s}) (\mathbf{y}_{r,s^*} - \bar{\mathbf{y}}_{\bullet s^*})' .\end{aligned}$$

### 3. Testy dla komponentów wariancyjnych oparte na JNNE

$$H_0 : \sigma_i^2 = 0 \quad \text{vs.} \quad H_1 : \sigma_i^2 \neq 0$$

Niech  $y' Ay$  będzie nieobciążonym estymatorem  $\sigma_i^2$ . Ponadto, niech  $A_+$ ,  $A_-$  oznacza odpowiednio dodatnią i ujemną część macierzy  $A$ , tzn.  $A = A_+ - A_-$ .

**Uwaga.** Dla  $i < k$  estymator  $y' Ay$  jest nieokreślony, tj.  $A = A_+ - A_-$ , gdzie  $A_+, A_- \neq 0$ . Zauważmy, że

- jeśli  $H_0$  jest prawdziwa, to  $E(y' A_+ y) = E(y' A_- y)$ ,
- jeśli  $H_1$  jest prawdziwa, to  $E(y' A_+ y) > E(y' A_- y)$ .

### 3. Testy dla komponentów wariancyjnych oparte na JNNE

Test powinien odrzucać hipotezę (intuicyjnie)

$$H_0 : \sigma_i^2 = 0$$

jeśli

$$F = \frac{y' A_+ y}{y' A_- y}$$

jest dostatecznie duże.

### 3. Testy dla komponentów wariancyjnych oparte na JNNE

**Definicja.** *Algebrę nazywamy Jordana jeśli jest zamknięta ze względu na działanie  $A \circ B = \frac{AB+BA}{2}$ .*

Pełną charakteryzację nieredukowalnych algebr Jordana podali autorzy Jordan, Neumann i Wigner (1934):

- $\mathbb{R}$  z działaniami mnożenia i dodawania;
- $S^n$  - zbiór macierzy symetrycznych z działaniami  $A \circ B$ ;
- kwaterniony;
- specjalna algebra.



### 3. Testy dla komponentów wariancyjnych oparte na JNNE

Model normalny jest postaci:

$$y \sim N \left( X\beta, \sum_{i=1}^k \sigma_i^2 V_i \right)$$


Rozważmy trzy warunki:

1.  $sp \{MV_1M, \dots, MV_kM\}$  jest algebrą Jordana,
2.  $sp \{\{MV_1M, \dots, MV_kM\} \setminus \{MV_iM\}\}$  jest przemienną algebrą Jordana,
3.  $F = \frac{y'A_+y}{y'A_-y}$  ma rozkład F-Snedecora przy prawdziwości  $H_0 : \sigma_i^2 = 0$ .

**Twierdzenie (1996):** 1.  $\wedge$  2.  $\Rightarrow$  3.

**Twierdzenie (2002):** 1.  $\wedge$  3.  $\Rightarrow$  2.

## Test F dla hipotezy $H_0 : \sigma_i = 0$



Długość wektora  $r_0$  nie jest funkcją minimalnych statystyk dostatecznych.

### 3. Testy dla komponentów wariancyjnych oparte na JNNE

**Twierdzenie.** *Załóżmy, że podprzestrzeń*

$$sp \{MV_1M, \dots, MV_kM\}$$

*jest przemienną algebrą Jordana, natomiast*

$$sp \{ \{MV_1M, \dots, MV_kM\} \setminus \{MV_iM\} \}$$

*nią nie jest. Wówczas statystyka*

$$F = \frac{y' A_+ y}{y' A_- y}$$

*ma uogólniony rozkład F-Snedecora przy prawdziwości  $H_0 : \sigma_i^2 = 0$ , gdzie  $y' A y$  jest BIQUE parametru  $\sigma_i^2$ .*

#### 4. Hipotezy dotyczące struktury kowariancji dla podwójnie wielowymiarowych danych

$$H_0 : \mathbf{\Gamma}_1 = 0 \quad vs. \quad H_1 : \mathbf{\Gamma}_1 \neq 0.$$

Wykorzystując ideę zaprezentowaną w [A. Michalski, R. Zmysłony, *Testing hypotheses for variance components in mixed linear models*, *Statistics* 27(1996), 297-310] do testowania hipotez przy założeniu, że wszystkie elementy macierzy  $\mathbf{\Gamma}_1$  są nieujemne bądź niedodatnie.

**Lemat.** *Jeśli  $\mathbf{W}_1 \sim W_m(\mathbf{\Sigma}, n_1)$  i  $\mathbf{W}_2 \sim W_m(\mathbf{\Sigma}, n_2)$  są niezależne to dla każdego ustalonego wektora  $\mathbf{x} \neq 0 \in \mathbb{R}^m$  zachodzi:*

$$T = \frac{\mathbf{x}'\mathbf{W}_1\mathbf{x}}{\mathbf{x}'\mathbf{W}_2\mathbf{x}} \sim F_{n_1, n_2}.$$

#### 4. Hipotezy dotyczące struktury kowariancji dla podwójnie wielowymiarowych danych

*Dowód.* Zgodnie z twierdzeniem zaprezentowanym w [Mirośław Krzyśko, *Podstawy wielowymiarowego wnioskowania statystycznego*, UAM (2009), 58] jeśli  $\mathbf{W} \sim W_m(\boldsymbol{\Sigma}, n)$  to dla każdego  $\mathbf{x} \neq 0 \in \mathbb{R}^m$  zachodzi:

$$\frac{\mathbf{x}'\mathbf{W}\mathbf{x}}{\mathbf{x}'\boldsymbol{\Sigma}\mathbf{x}} \sim \chi_n^2.$$

Jeśli teraz obliczy się iloraz  $\frac{\mathbf{x}'\mathbf{W}_1\mathbf{x}}{n_1}$  i  $\frac{\mathbf{x}'\mathbf{W}_2\mathbf{x}}{n_2}$  to dostajemy:

$$\frac{\frac{\mathbf{x}'\mathbf{W}_1\mathbf{x}}{n_1}}{\frac{\mathbf{x}'\mathbf{W}_2\mathbf{x}}{n_2}} = \frac{\frac{\mathbf{x}'\mathbf{W}_1\mathbf{x}}{n_1\mathbf{x}'\boldsymbol{\Sigma}\mathbf{x}}}{\frac{\mathbf{x}'\mathbf{W}_2\mathbf{x}}{n_2\mathbf{x}'\boldsymbol{\Sigma}\mathbf{x}}} \sim \frac{\frac{\chi_{n_1}^2}{n_1}}{\frac{\chi_{n_2}^2}{n_2}} \sim F_{n_1, n_2}.$$

□

## 5. Dodatnia i ujemna część estymatora $\tilde{\Gamma}_1$

Wykorzystując wyniki otrzymane w [A. Roy, R. Leiva, I. Žežula, D. Klein, *Testing the equality of mean vectors for paired doubly multivariate observations in blocked compound symmetric covariance matrix setup*, Journal of Multivariate Analysis, 137, 50-60] otrzymujemy, że macierze:

$$(n-1)(u-1)\tilde{\Delta}_1 = (n-1)(u-1)(\tilde{\Gamma}_0 - \tilde{\Gamma}_1)$$

oraz

$$(n-1)\tilde{\Delta}_2 = (n-1)(\tilde{\Gamma}_0 + (u-1)\tilde{\Gamma}_1)$$

mają rozkład Wisharta i są niezależne.

## 5. Dodatnia i ujemna część estymatora $\tilde{\Gamma}_1$

Warto zwrócić uwagę na to, że:

$$(n-1)(u-1)\tilde{\Delta}_1 = (n-1)(u-1)(\tilde{\Gamma}_0 - \tilde{\Gamma}_1) \sim W_m(\mathbf{\Gamma}_0 - \mathbf{\Gamma}_1, (n-1)(u-1)),$$

$$(n-1)\tilde{\Delta}_2 = (n-1)(\tilde{\Gamma}_0 + (u-1)\tilde{\Gamma}_1) \sim W_m(\mathbf{\Gamma}_0 + (u-1)\mathbf{\Gamma}_1, n-1).$$

Odejmując lewe strony drugiej z powyższych równości pomnożonej przez  $u-1$  od pierwszej, oraz dokonując kilku prostych przekształceń dostajemy, że:

$$(n-1)(u-1)\tilde{\Delta}_2 - (n-1)(u-1)\tilde{\Delta}_1 = (n-1)(u-1)\tilde{\Gamma}_0 + (n-1)(u-1)^2\tilde{\Gamma}_1 - (n-1)(u-1)\tilde{\Gamma}_0 + (n-1)(u-1)\tilde{\Gamma}_1 = (n-1)(u-1)[u-1+1]\tilde{\Gamma}_1 = (n-1)u(u-1)\tilde{\Gamma}_1.$$

$$\text{Zatem } \tilde{\Gamma}_1 = \frac{(n-1)(u-1)\tilde{\Delta}_2 - (n-1)(u-1)\tilde{\Delta}_1}{(n-1)u(u-1)} = \frac{\tilde{\Delta}_2 - \tilde{\Delta}_1}{u}.$$

## 5. Dodatnia i ujemna część estymatora $\tilde{\Gamma}_1$

Wykorzystując podejście Michalskiego i Zmyślonego, łatwo zauważyć, że estymator  $\tilde{\Gamma}_1$  można wyrazić jako różnicę jego części dodatniej i ujemnej, a więc:

$$\tilde{\Gamma}_1 = \frac{\tilde{\Delta}_2 - \tilde{\Delta}_1}{u} = \tilde{\Gamma}_{1+} - \tilde{\Gamma}_{1-},$$

gdzie  $\tilde{\Gamma}_{1+} = \frac{\tilde{\Delta}_2}{u}$  to dodatnia część estymatora, natomiast  $\tilde{\Gamma}_{1-} = \frac{\tilde{\Delta}_1}{u}$  to jego ujemna część.



## 6. Postać testu F

**Twierdzenie.** *Z faktu, że estymator parametru  $\Gamma_1$  jest dany poprzez:*

$$\tilde{\Gamma}_1 = \tilde{\Gamma}_{1+} - \tilde{\Gamma}_{1-} = \frac{\tilde{\Delta}_2 - \tilde{\Delta}_1}{u},$$

*to statystyka testowa testu F ma postać:*

$$T = \frac{\mathbf{1}'\tilde{\Gamma}_{1+}\mathbf{1}}{\mathbf{1}'\tilde{\Gamma}_{1-}\mathbf{1}}$$

*i przy prawdziwości hipotezy zerowej  $H_0 : \Gamma_1 = 0$  ma rozkład F-Snedecora z  $n - 1$  i  $(n - 1)(u - 1)$  stopniami swobody.*

## 6. Postać testu F

*Dowód.* Przy prawdziwości hipotezy zerowej  $\Gamma_1 = 0$  zachodzi, że:

$$(n-1)u\tilde{\Gamma}_{1+} = (n-1)\tilde{\Delta}_2 \sim W_m(\Gamma_0, n-1),$$

$$(n-1)u(u-1)\tilde{\Gamma}_{1-} = (n-1)(u-1)\tilde{\Delta}_1 \sim W_m(\Gamma_0, (n-1)(u-1)).$$

Wykorzystując powyższe równości oraz wcześniejszy lemat, można pokazać, że:

$$T = \frac{\frac{(n-1)u\mathbf{1}'\tilde{\Gamma}_{1+}\mathbf{1}}{(n-1)}}{\frac{(n-1)u(u-1)\mathbf{1}'\tilde{\Gamma}_{1-}\mathbf{1}}{(u-1)(n-1)}} = \frac{\mathbf{1}'\tilde{\Gamma}_{1+}\mathbf{1}}{\mathbf{1}'\tilde{\Gamma}_{1-}\mathbf{1}}.$$

□

## 7. Postać testu ilorazu wiarygodności

W przypadku testu ilorazu wiarygodności (LRT) do weryfikacji hipotez postaci:

$$H_0 : \mathbf{\Gamma}_1 = 0 \quad vs. \quad H_1 : \mathbf{\Gamma}_1 \neq 0$$

nie wymaga się dodatkowo założenia odnośnie jednakowego znaku wszystkich elementów macierzy  $\mathbf{\Gamma}_1$ , w odróżnieniu od testu F, który de facto bada czy suma wszystkich elementów tej macierzy jest różna od zera.

Postać statystyki testowej testu LRT jest następująca:

$$L = \frac{\left| \frac{(n-1)(u-1)\tilde{\mathbf{\Delta}}_1 + (n-1)\tilde{\mathbf{\Delta}}_2}{nu} \right|^{-\frac{nu}{2}}}{\left| \frac{n-1}{n} \tilde{\mathbf{\Delta}}_1 \right|^{-\frac{n(u-1)}{2}} \left| \frac{n-1}{n} \tilde{\mathbf{\Delta}}_2 \right|^{-\frac{n}{2}}}.$$

## 7. Postać testu ilorazu wiarygodności

Po kilku prostych przekształceniach można pokazać, że:

$$L = \frac{\left| \frac{(u-1)\tilde{\Delta}_1 + \tilde{\Delta}_2}{u} \right|^{-\frac{nu}{2}}}{\left| \tilde{\Delta}_1 \right|^{-\frac{n(u-1)}{2}} \left| \tilde{\Delta}_2 \right|^{-\frac{n}{2}}}.$$

Przy prawdziwości hipotezy zerowej  $H_0 : \mathbf{\Gamma}_1 = 0$  statystyka  $-2 \ln(L)$  ma graniczny rozkład chi-kwadrat z  $\frac{m(m+1)}{2}$  stopniami swobody.

## 8. Porównanie mocy testów: F i LRT

W celu porównania mocy obu testów przyjęto, że macierze  $\mathbf{\Gamma}_0$  oraz  $\mathbf{\Gamma}_1$  mają następującą postać:

$$\mathbf{\Gamma}_0 = \begin{bmatrix} 0.01221 & 0.02172 & 0.00901 \\ 0.02172 & 0.07492 & 0.01682 \\ 0.00901 & 0.01682 & 0.01108 \end{bmatrix},$$

$$\mathbf{\Gamma}_1 = \begin{bmatrix} 0.01038 & 0.01931 & 0.00824 \\ 0.01931 & 0.06678 & 0.01529 \\ 0.00824 & 0.01529 & 0.00807 \end{bmatrix}.$$

Dodatkowo założono, że  $u = 2$  oraz  $n = 25$ .

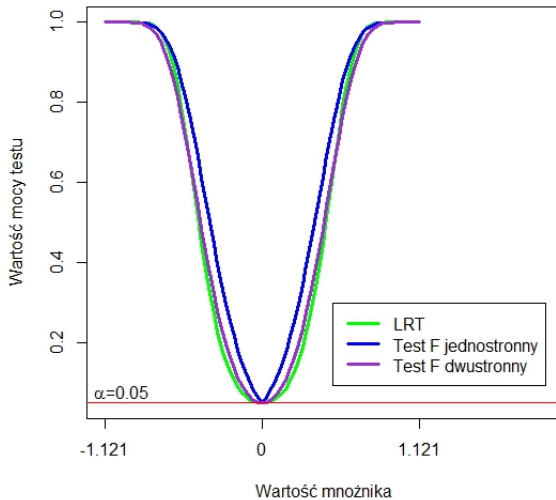
## 8. Porównanie mocy testów: F i LRT

Dla ustalonej postaci macierzy  $\mathbf{\Gamma}_0$  i  $\mathbf{\Gamma}_1$  oraz wartości  $u$ , ustalono przedział dla wartości mnożnika  $\lambda$ , taki, że dla każdej wartości z tego przedziału poniższe dwa warunki są spełnione:

1.  $\mathbf{\Gamma}_0 + (u - 1)\lambda\mathbf{\Gamma}_1$  jest dodatnio określoną macierzą,
2.  $\mathbf{\Gamma}_0 - \lambda\mathbf{\Gamma}_1$  jest dodatnio określoną macierzą.

Ich spełnienie gwarantuje dodatnią określoność macierzy  $\mathbf{\Gamma}$ .  
Przyjęty poziom istotności  $\alpha = 5\%$ .

## Porównanie mocy testów

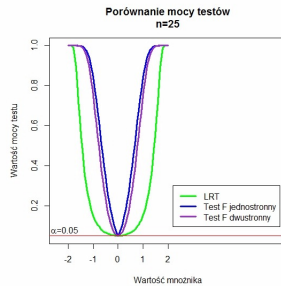

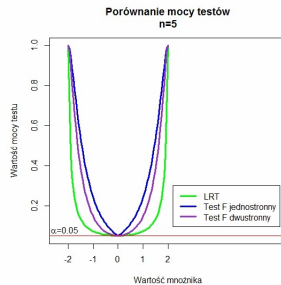



## 8. Porównanie mocy testów: F i LRT

Rozważany będzie jeszcze jeden przypadek. Tym razem bardzo szczególny, gdyż mianowicie  $\Gamma_0$  i  $\Gamma_1$  będą skalarami, a więc  $m = 1$ . Niech  $\Gamma_0 = 2$  oraz  $\Gamma_1 = 1$ . Dodatkowo przyjęto, że  $u = 2$ , natomiast parametr  $n$  będzie przyjmować jedną z wartości ze zbioru  $\{3, 5, 10, 25\}$ .

Z warunków na dodatnią określoność macierzy  $\mathbf{\Gamma}$  nietrudno wywnioskować, że odpowiednie wartości mnożnika  $\lambda$  powinny zawierać się w przedziale  $[-2, 2]$ .





# References

- [1] Arnold, S.F. 1979. Linear models with exchangeably distributed errors. *Journal of the American Statistical Association*. 74, 194-199.
- [2] Drygas, H., 1970. *The Coordinate-Free Approach to Gauss-Markov Estimation*, Berlin, Heidelberg: Springer.

- [3] Gąsiorek E., Michalski A., Zmyślony R. 2000, Tests of independence of normal random variables with known and unknown variance ratio, *Discussiones Mathematicae Probability and Statistics* 20 2, 233-247.
- [4] Gnot, S., Klonecki, W. and Zmyślony, R. 1976. Uniformly minimum variance unbiased estimation in Euclidean vector spaces, *Bull. de l'Academie Polon. des Sciences* XXIV 4, 281-286.
- [5] Gnot, S., Klonecki, W. and Zmyślony, R. 1977a. Uniformly minimum variance unbiased estimation in various classes of estimators. *Statistics* 8(2), 199-210.
- [6] Gnot, S., Klonecki, W. and Zmyślony, R. 1977b. Uniformly minimum variance unbiased estimation in various classes of estimators, *Math. Operationsforsch. Statist., Ser. Statistics* 8 2, 199-210.

- [7] Gnot, S., Klonecki, W. and Zmyślony, R. 1980. Best unbiased estimation: a coordinate free-approach. *Probability and Statistics*, 1(1), 1-13.
- [8] Jordan, P., Neumann, von, J. and Wigner, E., 1934. On an algebraic generalization of the quantum mechanical formalism. *The Annals of Mathematics*, 35(1), 29-64.
- [9] Kruskal, W., 1968. When are Gauss-Markov and Least Squares Estimators Identical? A Coordinate-Free Approach. *The Annals of Mathematical Statistics*, 39(1), pp.70-75.
- [10] Lehmann, E.L. and Casella, G., 1998. *Theory of Point Estimation* Second Edition, Springer.

- [11] Roy, A. and Leiva, R. 2008. Likelihood ratio tests for triply multivariate data with structured correlation on spatial repeated measurements. *Statistics & Probability Letters*, 78(13), 1971-1980.
- [12] Seely, J.F., 1971. Quadratic subspaces and completeness. *The Annals of Mathematical Statistics*, 42(2), 710-721.
- [13] Seely, J.F., 1972. Completeness for a family of multivariate normal distributions. *The Annals of Mathematical Statistics*, 43, 1644-1647.
- [14] Seely, J.F., 1977. Minimal sufficient statistics and completeness for multivariate normal families. *Sankhya (Statistics). The Indian Journal of Statistics. Series A*, 39(2), 170-185.
- [15] Zmyślony, R. 1976. On estimation of parameters in linear models, *Aplicaciones Mathematicae XV* 3(1976), 271-276.

- [16] Zmyślony, R. 1978. A characterization of best linear unbiased estimators in the general linear model, *Lecture Notes in Statistics*, 2, 365-373.
- [17] Zmyślony, R. 1980. Completeness for a family of normal distributions, *Mathematical Statistics, Banach Center Publications* 6, 355-357.