

WYDZIAŁ MATEMATYKI, INFORMATYKI I EKONOMETRII  
UNIwersytet Zielonogórski

Ewa Synówka-Bejenka

Estymacja dopuszczalna efektów stałych  
i losowych w modelach liniowych

ROZPRAWA DOKTORSKA NAPISANA POD KIERUNKIEM  
dra hab. Stefana Zontka, prof. UZ

Zielona Góra 2006

Serdecznie dziękuję Panu Profesorowi Stefanowi Zontkowi za cenne wskazówki i krytyczne uwagi, a także za życzliwość, wyrozumiałość i poświęcony czas, które okazały się bardzo pomocne przy pisaniu tej rozprawy.

# Spis treści

Wstęp	5
Wykaz ważniejszych oznaczeń	7
<b>1. Dopuszczalność w ogólnym modelu liniowym</b>	<b>8</b>
<b>2. Estymacja w mieszanym modelu liniowym</b>	<b>15</b>
2.1. Przykłady liniowych modeli mieszanych . . . . .	20
<b>3. Jawna charakterystyka estymatorów dopuszczalnych w wybranych modelach liniowych</b>	<b>24</b>
3.1. Zrównoważony model losowy $k$ -kierunkowej klasyfikacji hierar- chicznej . . . . .	25
3.2. Zrównoważony model losowy $k$ -kierunkowej klasyfikacji krzyżowej	30
3.3. Zrównoważony model losowy dwukierun- kowej klasyfikacji krzyżowej z interakcją . . . . .	37
<b>4. Jawna charakterystyka estymatorów dopuszczalnych w pewnym modelu liniowym z dwoma komponentami</b>	<b>46</b>
4.1. Przypadek, gdy $X \in \mathcal{R}(Z_1)$ . . . . .	47
4.2. Przypadek, gdy $X \notin \mathcal{R}(Z_1)$ . . . . .	49
4.3. Zastosowania . . . . .	52

<b>5. Model z dwoma komponentami</b>	<b>55</b>
<b>Podsumowanie</b>	<b>62</b>
<b>Spis literatury</b>	<b>64</b>

# Wstęp

Problem dopuszczalności liniowych estymatorów w ogólnym modelu liniowym był wielokrotnie rozważany w literaturze. Pierwszy rezultat, uzyskany przez Cohena (1966), dotyczył charakterystyki dopuszczalnych liniowych estymatorów dla wektora wartości oczekiwanych w modelu Gaussa-Markowa z macierzą kowariancji  $\sigma^2 I$ . Został on później uogólniony przez Rao (1976) na przypadek modelu, w którym wektor wartości oczekiwanych należy do pewnej podprzestrzeni liniowej, a macierz kowariancji ma postać  $\sigma^2 V$ , gdzie  $V$  jest pewną znaną, dodatnio określoną macierzą. Dalsze uogólnienia związane z modelem Gaussa-Markowa podali m.in. Hoffman (1977), Klonecki (1982), Mathew, Sinha i Rao (1984), Klonecki i Zontek (1988), Drygas i Zmyślony (1988) oraz Baksalary, Markiewicz i Rao (1989).

Podstawowym, dla rozważań w tej rozprawie, jest wynik LaMotte'a (1982). Jego uniwersalność polega na tym, że warunki konieczne i dostateczne na to, aby liniowy estymator był dopuszczalny są podane dla ogólnego modelu liniowego bez ograniczeń nałożonych na przestrzeń parametrów. LaMotte, poprzez lokalną optymalność (patrz Olsen, Seely i Birkes, 1976) w zstępującym ciągu rozmaitości liniowych, opisuje skończoną, krokową procedurę konstrukcji dowolnego estymatora dopuszczalnego. Otrzymuje się w ten sposób charakterystykę estymatorów dopuszczalnych, ale w bardzo uwikłanej formie. Wykorzystany będzie też inny rezultat LaMotte'a (1997) (patrz także Stępnia, 1987), który pokazuje, że jednoznacznie lokalnie optymalne estymatory i ich granice tworzą zupełną klasę estymatorów. Zastosujemy te wyniki do problemu jednoczes-

nej dopuszczalnej estymacji wektora efektów stałych i losowych w mieszanym modelu liniowym po wstępnym przejściu do równoważnego problemu estymacji tylko efektów stałych w odpowiednim modelu. Zagadnieniem estymacji efektów stałych i losowych zajmowali się m.in. Harville (1976), Peixoto i Harville (1986), Rao (1987), Robinson (1991) oraz Gross i Markiewicz (1999).

Rozprawa składa się z pięciu rozdziałów. W rozdziale pierwszym została opisana wspomniana już metoda LaMotte'a umożliwiająca charakterystykę liniowych estymatorów dopuszczalnych dla liniowej funkcji wektora wartości oczekiwanych w ogólnym modelu liniowym w pewnej rozmaitości liniowej.

W rozdziale drugim opisano mieszany model liniowy. Dokonano także redukcji problemu łącznej estymacji wektora efektów stałych i losowych do estymacji wektora efektów stałych w odpowiednim modelu liniowym w ograniczeniu do pewnej rozmaitości liniowej. Następnie sformułowano lemat, na mocy którego dopuszczalność estymatorów w odpowiadających sobie modelach jest równoważna. Na koniec rozdziału podane zostały przykłady modeli liniowych.

Rozdział trzeci składa się z trzech podrozdziałów, z których każdy zawiera charakterystykę dopuszczalnych estymatorów liniowych w zrównoważonym modelu losowym  $k$  – kierunkowej klasyfikacji hierarchicznej, zrównoważonym modelu losowym  $k$  – kierunkowej klasyfikacji krzyżowej oraz zrównoważonym modelu losowym dwukierunkowej klasyfikacji krzyżowej z interakcją.

Rozdział czwarty dotyczy problemu dopuszczalnej estymacji w modelu z dwoma komponentami, w którym zostało opuszczone pewne założenie z poprzedniego rozdziału. Odpowiednie twierdzenia pokazują, jaki wpływ ma to osłabienie założeń na postać klasy estymatorów dopuszczalnych.

W rozdziale piątym podane zostały warunki konieczne i dostateczne na to, aby estymator był dopuszczalny w ogólnym modelu liniowym z dwoma komponentami. Warunki te można postrzegać jako uogólnienie wyniku Rao (1976).

# Wykaz ważniejszych oznaczeń

$\mathbb{R}^n$  – zbiór  $n$ -wymiarowych wektorów o współrzędnych rzeczywistych

$v_i \in \mathbb{R}^n$  –  $i$ -ty  $n$ -wymiarowy wektor

$\mathcal{M}_{n \times t}$  – zbiór macierzy wymiaru  $n \times t$  o elementach rzeczywistych

$\mathcal{M}_n^{\geq}$  – zbiór macierzy symetrycznych i nieujemnie określonych wymiaru  $n \times n$

$A'$  – transpozycja macierzy  $A$

$A^{-1}$  – macierz odwrotna do  $A$

$A^+$  – odwrotność Moore'a-Penrose'a macierzy  $A$

$\text{tr}(A)$  – ślad macierzy kwadratowej  $A$

$\mathcal{R}(A)$  – przestrzeń liniowa generowana przez kolumny macierzy  $A$

$\mathcal{N}(A)$  – jądro macierzy  $A$

$\text{diag}(A_1, \dots, A_n)$  – macierz diagonalna, w której macierze  $A_1, \dots, A_n$  są elementami diagonalnymi

$A \otimes B$  – iloczyn Kroneckera macierzy  $A$  i  $B$

$T_A^t$  – liniowe przekształcenie odwzorowujące  $\mathcal{M}_{n \times t}$  w  $\mathcal{M}_{n \times t}$ , określone dla każdej macierzy  $B \in \mathcal{M}_{n \times t}$  wzorem  $T_A^t(B) = AB$ , gdzie  $A \in \mathcal{M}_{n \times n}$

$\mathcal{R}(T_A^t)$  – obraz przekształcenia  $T_A^t$

$\text{span}\mathcal{W}$  – przestrzeń liniowa rozpięta na elementach zbioru  $\mathcal{W}$

$[\mathcal{W}]$  – najmniejszy wypukły, domknięty stożek zawierający  $\mathcal{W}$

$\dim\mathcal{W}$  – wymiar przestrzeni liniowej  $\mathcal{W}$

$\min Z$  – najmniejszy element zbioru  $Z$

# 1. Dopuszczalność w ogólnym modelu liniowym

W tym rozdziale przypomnimy kilka najistotniejszych rezultatów uzyskanych przez LaMotte'a, które dotyczą sposobu wyznaczania estymatorów dopuszczalnych. Jak już było wspomniane we wstępie, podał on warunki konieczne i dostateczne na to, aby estymator liniowy był dopuszczalny w ogólnym modelu liniowym, nie zakładając przy tym żadnych ograniczeń na przestrzeń parametrów modelu.

Niech  $\mathbf{Y}$  będzie  $n$ -wymiarowym wektorem losowym, którego rozkład należy do pewnej rodziny rozkładów  $\mathcal{P}$ . Zakładamy, że dla każdego rozkładu  $P \in \mathcal{P}$  istnieje wektor wartości oczekiwanych  $E_P \mathbf{Y}$  oraz macierz kowariancji  $\text{cov}_P(\mathbf{Y})$ . Będziemy zajmowali się dopuszczalną estymacją funkcji  $\mathbf{K}'E_P \mathbf{Y}$ , gdzie  $\mathbf{K} \in \mathcal{M}_{n \times t}$ . Rozważania ograniczymy do liniowych estymatorów postaci  $\mathbf{L}'\mathbf{Y}$ , dla których macierz  $\mathbf{L}$  należy do następującej rozmaitości liniowej

$$\mathcal{L}_o = \{\mathbf{L}_o + \mathbf{\Pi}_o \mathbf{M} : \mathbf{M} \in \mathcal{M}_{n \times t}\},$$

gdzie  $\mathbf{L}_o \in \mathcal{M}_{n \times t}$  oraz  $\mathbf{\Pi}_o \in \mathcal{M}_{n \times n}$  są pewnymi ustalonymi macierzami.

Rozmaitości liniowe odgrywają ważną rolę w teorii estymacji. Klasycznym przykładem takiej rozmaitości jest zbiór liniowych nieobciążonych estymatorów funkcji  $\mathbf{K}'E_P \mathbf{Y}$  w modelu, w którym  $E_P \mathbf{Y} = \mathbf{X}\beta$ , gdzie  $\mathbf{X} \in \mathcal{M}_{n \times p}$  jest znaną macierzą, a  $\beta$  jest  $p$ -wymiarowym wektorem parametrów stałych. Estymatory



z tego zbioru możemy bowiem przedstawić w postaci

$$\mathbf{K}'(\mathbf{X}\mathbf{X}')(\mathbf{X}\mathbf{X}')^+\mathbf{Y} + \mathbf{M}' [I_n - \mathbf{X}\mathbf{X}'(\mathbf{X}\mathbf{X}')^+] \mathbf{Y},$$

gdzie  $\mathbf{M}$  jest dowolną  $(n \times t)$ -wymiarową macierzą. W tym przypadku klasa nieobciążonych estymatorów dla  $\mathbf{K}'\mathbf{X}\beta$  jest wyznaczona przez  $\mathcal{L}_o = \{\mathbf{L}_o + \mathbf{\Pi}_o\mathbf{M} : \mathbf{M} \in \mathcal{M}_{n \times t}\}$ , gdzie  $\mathbf{L}_o = \mathbf{X}\mathbf{X}'(\mathbf{X}\mathbf{X}')^+\mathbf{K}$  oraz  $\mathbf{\Pi}_o = I_n - \mathbf{X}\mathbf{X}'(\mathbf{X}\mathbf{X}')^+$ .

Do porównania estymatorów użyjemy funkcji ryzyka określonej na  $\mathcal{P}$ , którą dla estymatora  $\mathbf{L}'\mathbf{Y}$  definiujemy jako  $E[(\mathbf{L}'\mathbf{Y} - \mathbf{K}'E_P\mathbf{Y})'(\mathbf{L}'\mathbf{Y} - \mathbf{K}'E_P\mathbf{Y})]$ . Po prostych przekształceniach funkcję tę możemy przedstawić w postaci

$$\text{tr} [\mathbf{L}'\text{cov}_P(\mathbf{Y})\mathbf{L} + (\mathbf{L} - \mathbf{K})'E_P\mathbf{Y}(E_P\mathbf{Y})'(\mathbf{L} - \mathbf{K})].$$

Widzimy, że zależy ona od rozkładu  $P$  wektora losowego  $\mathbf{Y}$  poprzez  $\text{cov}_P(\mathbf{Y})$  oraz  $E_P\mathbf{Y}(E_P\mathbf{Y})'$ . LaMotte wykorzystał ten fakt i potraktował parę  $(\text{cov}_P(\mathbf{Y}), E_P\mathbf{Y}(E_P\mathbf{Y})')$  jako nowy parametr przebiegający zbiór postaci

$$\mathcal{T} = \{(\text{cov}_P(\mathbf{Y}), E_P\mathbf{Y}(E_P\mathbf{Y})') : P \in \mathcal{P}\}.$$

Zauważył też, że przy badaniu własności estymatorów przydaje się rozszerzenie pojęcia funkcji ryzyka ze zbioru  $\mathcal{T}$  na zbiór  $\mathcal{W} = \text{span}\mathcal{T}$ . Tę rozszerzoną funkcję ryzyka dla każdego  $(W_1, W_2) \in \mathcal{W}$  zdefiniował wzorem

$$\mathbf{R}(\mathbf{L}'\mathbf{Y}; (W_1, W_2)) = \text{tr} [\mathbf{L}'W_1\mathbf{L} + (\mathbf{L} - \mathbf{K})'W_2(\mathbf{L} - \mathbf{K})].$$

Niech  $\mathcal{L}$  będzie podzbiorem  $\mathcal{L}_o$ . Wtedy  $\mathcal{L}$  można opisać następująco

$$\{\mathbf{L}_1 + \mathbf{\Pi}\mathbf{M} : \mathbf{M} \in \mathcal{M}_{n \times t}\},$$

gdzie  $\mathbf{L}_1 \in \mathcal{L}_o$ , natomiast  $\mathbf{\Pi}$  jest macierzą wymiaru  $(n \times n)$  taką, że  $\mathcal{R}(\mathbf{\Pi}) \subset \mathcal{R}(\mathbf{\Pi}_o)$ . Zauważmy, że funkcję ryzyka estymatora  $\mathbf{L}'\mathbf{Y}$ , gdzie  $\mathbf{L} \in \mathcal{L}$ , możemy przedstawić w postaci

$$\mathbf{R}(\mathbf{L}'\mathbf{Y}; (W_1, W_2)) = \text{tr}[\mathbf{M}'\mathbf{T}_1(W)\mathbf{M}] + 2\text{tr}[\mathbf{M}'\mathbf{T}_2(W)] + \mathbf{R}(\mathbf{L}'_1\mathbf{Y}; (W_1, W_2)),$$

gdzie

$$\mathbf{T}_1(W) = \mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi} \text{ oraz } \mathbf{T}_2(W) = \mathbf{\Pi}'W_2\mathbf{K} - \mathbf{\Pi}'(W_1 + W_2)\mathbf{L}_1.$$

**Definicja 1.1.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $W \in \mathcal{W}$  w klasie  $\mathcal{L}$ , jeżeli  $R(\mathbf{L}'\mathbf{Y}; W) \leq R(\mathbf{L}'_*\mathbf{Y}; W)$  dla każdego  $\mathbf{L}_* \in \mathcal{L}$ .*

Poniższe twierdzenie (LaMotte, 1982) podaje pewne rezultaty dotyczące lokalnej optymalności.

**Twierdzenie 1.1.**

- (i) *W klasie  $\mathcal{L}$  istnieje co najmniej jeden estymator lokalnie optymalny w punkcie  $W = (W_1, W_2) \in \mathcal{W}$  wtedy i tylko wtedy, gdy macierz  $\mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi}$  jest macierzą nieujemnie określoną oraz  $\mathcal{R}(\mathbf{\Pi}'W_2\mathbf{K} - \mathbf{\Pi}'(W_1 + W_2)\mathbf{L}_1) \subseteq \mathcal{R}(\mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi})$ .*
- (ii) *Estymator  $\mathbf{L}'\mathbf{Y}$  jest estymatorem lokalnie optymalnym w punkcie  $W \in \mathcal{W}$  w klasie  $\mathcal{L}$  wtedy i tylko wtedy, gdy  $\mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi}$  jest macierzą nieujemnie określoną oraz  $\mathbf{\Pi}'(W_1 + W_2)\mathbf{L} = \mathbf{\Pi}'W_2\mathbf{K}$ .*
- (iii) *W klasie  $\mathcal{L}$  istnieje dokładnie jeden estymator optymalny w punkcie  $W$  wtedy i tylko wtedy, gdy  $\mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi}$  jest macierzą nieujemnie określoną taką, że  $\mathcal{R}(\mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi}) = \mathcal{R}(\mathbf{\Pi}')$ .*

Oznaczmy przez  $\mathcal{B}(W|\mathcal{L})$  zbiór tych macierzy  $\mathbf{L} \in \mathcal{L}$ , dla których estymator  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $W$  w klasie  $\mathcal{L}$ . Zauważmy, że dla danego punktu  $W \in \mathcal{W}$  może nie istnieć estymator  $\mathbf{L}'\mathbf{Y}$ , który jest w nim lokalnie optymalny w klasie  $\mathcal{L}$ , może istnieć dokładnie jeden taki estymator albo wreszcie może być wiele estymatorów lokalnie optymalnych w tym punkcie. Estymator  $\mathbf{L}'\mathbf{Y}$ , dla którego  $\mathcal{B}(W|\mathcal{L}) = \{\mathbf{L}\}$ , będziemy nazywać jednoznacznie lokalnie

optymalnym w punkcie  $W$  w klasie  $\mathcal{L}$ . Jednoznacznie lokalnie optymalne estymatory w klasie  $\mathcal{L}$  są scharakteryzowane w podpunkcie (iii) twierdzenia 1.1.

Zauważmy, że niepusty zbiór  $\mathcal{B}(W|\mathcal{L})$  jest także rozmaitością liniową. Oczywiście  $\mathcal{B}(W|\mathcal{L})$  jest podrozmaitością  $\mathcal{L}$ , a w przypadku, gdy nie wszystkie estymatory w klasie  $\mathcal{L}$  są lokalnie optymalne w punkcie  $W$ , jest właściwym podzbiorem  $\mathcal{L}$ . Punkty, w których każdy estymator  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w klasie  $\mathcal{L}$ , LaMotte nazwał trywialnymi. A zatem punkt  $W \in \mathcal{W}$  nazywamy *trywialnym* dla  $\mathcal{L}$ , jeżeli  $\mathcal{B}(W|\mathcal{L}) = \mathcal{L}$ . Przykładem takiego punktu jest  $W = (\mathbf{0}, \mathbf{0})$ . Zbiór wszystkich punktów trywialnych dla  $\mathcal{L}$  oznaczać będziemy przez  $\mathcal{S} = \mathcal{S}(\mathcal{L})$ . LaMotte udowodnił, że jeżeli przedstawimy  $\mathcal{L}$  w postaci  $\{\mathbf{L}_1 + \mathbf{\Pi}\mathbf{M} : \mathbf{M} \in \mathcal{M}_{n \times t}\}$ , to zbiór  $\mathcal{S}$  możemy zapisać następująco

$$\mathcal{S} = \mathcal{S}(\mathcal{L}) = \{(W_1, W_2) \in \mathcal{W} : \mathbf{\Pi}'(W_1 + W_2)\mathbf{\Pi} = 0, \mathbf{\Pi}'W_1\mathbf{L}_1 = \mathbf{\Pi}'W_2(\mathbf{K} - \mathbf{L}_1)\}.$$

Stosując jako kryterium porównawcze funkcję ryzyka możemy w klasie  $\mathcal{L}_o$  wprowadzić wśród rozważanych estymatorów następującą relację częściowego porządku.

**Definicja 1.2.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest lepszy niż estymator  $\mathbf{L}'_*\mathbf{Y}$  jeżeli*

$$R(\mathbf{L}'\mathbf{Y}; W) \leq R(\mathbf{L}'_*\mathbf{Y}; W) \text{ dla każdego } W \in \mathcal{T}$$

*i jeżeli ostra nierówność jest spełniona dla co najmniej jednego z tych punktów.*

**Definicja 1.3.** *Estymator  $\mathbf{L}'\mathbf{Y}$ , gdzie  $\mathbf{L} \in \mathcal{L}_o$ , jest estymatorem dopuszczalnym dla  $\mathbf{K}'\mathbf{E}_P\mathbf{Y}$  na zbiorze parametrów  $\mathcal{T}$ , jeżeli w klasie  $\mathcal{L}_o$  nie istnieje estymator lepszy niż  $\mathbf{L}'\mathbf{Y}$ .*

Podobnie definiujemy pojęcia *lepszy niż* oraz *dopuszczalny* w klasie  $\mathcal{L}$  na zbiorze parametrów  $\mathcal{T}$ , a także na każdym zbiorze  $\mathcal{C} \subseteq \mathcal{W}$ . LaMotte wykazał, że pojęcia te są równoważne na zbiorach  $\mathcal{T}$ ,  $[\mathcal{T}]$  oraz  $[\mathcal{T} + \mathcal{S}]$ , gdzie  $\mathcal{S} = \mathcal{S}(\mathcal{L})$ .

Punktem wyjścia w jego rozważaniach nad dopuszczalnością było rozszerzenie wyniku Olsena, Seely'ego i Birkesa (1976) do twierdzenia, że jeżeli  $L'Y$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$ , to istnieje niezerowy punkt  $W \in [\mathcal{T}]$ , w którym  $L'Y$  jest lokalnie optymalny w klasie  $\mathcal{L}_o$ . Następnie zauważył, że jeżeli  $L'Y$  jest lokalnie optymalny w punkcie  $W \in [\mathcal{T}]$  w klasie  $\mathcal{L}_o$ , to dopuszczalność  $L'Y$  w klasie  $\mathcal{L}_o$  na zbiorze  $\mathcal{T}$  jest równoważna dopuszczalności  $L'Y$  w klasie  $\mathcal{L}_1 = \mathcal{B}(W|\mathcal{L}_o)$  na zbiorze  $\mathcal{T}$ , co z kolei sugerowało, że chcąc uzyskać charakterystykę estymatorów dopuszczalnych w klasie  $\mathcal{L}_o$  należy powtórzyć tok rozumowania z jednoczesną redukcją wymiaru kolejno uzyskiwanych podrozmaitości aż do momentu uzyskania zbioru składającego się tylko z jednej macierzy. Niestety, w przypadku, gdy ograniczymy się jedynie do zbioru  $[\mathcal{T}]$ , redukcja wymiaru nie musi nastąpić. Stąd też propozycja LaMotte'a, aby rozszerzyć zbiór  $[\mathcal{T}]$  do zbioru  $[\mathcal{T} + \mathcal{S}_o]$ . Oczywiście, jeżeli  $\mathcal{T} \subset \mathcal{S}_o$ , to wówczas każdy estymator  $L'Y$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$ .

**Twierdzenie 1.2.** *Estymator  $L'Y$  jest dopuszczalny dla  $K'E_P Y$  w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$  wtedy i tylko wtedy, gdy  $\mathcal{T} \subset \mathcal{S}_o$  albo, gdy istnieje nietrywialny punkt  $W \in [\mathcal{T} + \mathcal{S}_o]$  taki, że  $L$  należy do klasy  $\mathcal{B}(W|\mathcal{L}_o)$ , w której  $L'Y$  jest dopuszczalny na  $\mathcal{T}$ .*

Twierdzenie 1.2 jest podstawowym dla dalszych naszych rozważań. Pozwala ono sprawdzić nie tylko, czy dany estymator  $L'Y$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$ , ale również umożliwia konstrukcję takich estymatorów.

Niech

$$\mathcal{A}(\mathcal{L}) = \{W \in [\mathcal{T} + \mathcal{S}] \setminus \mathcal{S} : \mathcal{B}(W|\mathcal{L}) \neq \emptyset\}.$$

Zauważmy, że dla dowolnego  $\mathcal{L} \subseteq \mathcal{L}_o$  mamy spełniony warunek  $[\mathcal{T}] \setminus \mathcal{S} \subseteq \mathcal{A}(\mathcal{L})$ .

Na bazie twierdzenia 1.2 można zaproponować następujący algorytm sprawdzania, czy estymator  $L'Y$  jest dopuszczalny dla  $K'E_P Y$  w klasie  $\mathcal{L}_o$ .

- (0) Podstawmy  $i = 0$ .
- (1) Jeżeli  $\mathcal{T} \subset \mathcal{S}_i$ , to estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$ .
- (2) Jeżeli  $\mathcal{T} \not\subset \mathcal{S}_i$ , to mamy dwie możliwości:
- (2.1) nie istnieje punkt  $W_i \in \mathcal{A}(\mathcal{L}_i)$ , dla którego  $\mathbf{L} \in \mathcal{L}_{i+1} = \mathcal{B}(W_i|\mathcal{L}_i)$ ,  
tym samym  $\mathbf{L}'\mathbf{Y}$  jest niedopuszczalny w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$ ,
- (2.2) istnieje pewien punkt  $W_i \in \mathcal{A}(\mathcal{L}_i)$ , dla którego  $\mathbf{L} \in \mathcal{L}_{i+1} = \mathcal{B}(W_i|\mathcal{L}_i)$ ,  
wtedy oznaczając przez  $\mathcal{S}_{i+1}$  zbiór punktów trywialnych dla  $\mathcal{L}_{i+1}$   
i dokonując podstawienia  $i + 1$  w miejsce  $i$  przechodzimy do punktu  
(1).

Zauważmy, że powyższa procedura kończy się po wykonaniu skończonej liczby kroków. Ostatecznie bowiem mamy, że  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  wtedy i tylko wtedy, gdy  $\mathcal{T} \subset \mathcal{S}_{i^*} = \mathcal{S}(\mathcal{L}_{i^*})$  dla pewnego  $0 \leq i^* \leq \dim \mathcal{W} - \dim \mathcal{S}_o$ . Oczywiście  $\mathcal{S}_{i^*} \supset \mathcal{S}_{i^*-1} \supset \dots \supset \mathcal{S}_o$ , a co za tym idzie  $\mathcal{L}_{i^*} \subset \mathcal{L}_{i^*-1} \subset \dots \subset \mathcal{L}_o$ .

Twierdzenie 1.2 daje także możliwość konstrukcji dopuszczalnych estymatorów w klasie  $\mathcal{L}_o$ .

- (0) Podstawmy  $i = 0$ .
- (1) Weźmy dowolny punkt  $W_i \in \mathcal{A}(\mathcal{L}_i)$ .
- (1.1) Jeżeli  $\mathcal{L}_{i+1} = \mathcal{B}(W_i|\mathcal{L}_i) = \{\mathbf{L}\}$ , to estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$ .
- (1.2) Jeżeli  $\mathcal{L}_{i+1} = \mathcal{B}(W_i|\mathcal{L}_i) \neq \{\mathbf{L}\}$ , to za  $i$  podstawiamy  $i + 1$  i przechodzimy do punktu (1).

Opisany sposób postępowania jest dosyć skomplikowany. Wymaga w każdym kroku wyznaczania nowych zbiorów  $\mathcal{L}$ ,  $\mathcal{S}$  i  $\mathcal{A}(\mathcal{L})$ , co na ogół nie jest rzeczą

prostą. Pomocnym może być tutaj wynik LaMotte'a (1997) (patrz także Stępniaak, 1987 i Zontek, 1988) pokazujący związek pomiędzy dopuszczalnymi estymatorami a granicami lokalnie optymalnych estymatorów wyznaczonych w sposób jednoznaczny. Rezultat ten w terminach ogólnego modelu liniowego przedstawia się następująco.

**Twierdzenie 1.3.** *Każdy dopuszczalny liniowy estymator dla  $\mathbf{K}'\mathbf{E}_P\mathbf{Y}$  w klasie estymatorów  $\mathcal{L}_o$  jest granicą jednoznacznie lokalnie optymalnych estymatorów w punktach należących do  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$ .*

Powyższe twierdzenie pozwala na ograniczenie uwagi do domknięcia zbioru macierzy  $\mathbf{L} \in \mathcal{L}_o$  takich, że  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalnym estymatorem w punktach ze zbioru  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$ . Są modele, w których aby wykazać, że estymator graniczny jest dopuszczalny wystarczy ograniczyć się w każdym kroku procedury LaMotte'a tylko do zbioru  $[\mathcal{T}]$ . W rozważanych w rozprawie modelach tak właśnie jest.

W dalszej części pracy, chcąc podać warunki konieczne i dostateczne na to, aby liniowy estymator pewnej liniowej funkcji był dopuszczalny, użyjemy modyfikacji lematu Shinozakiiego w ograniczeniu do klasy estymatorów  $\mathcal{L}_o$  (patrz Klonecki i Zontek, 1988).

**Lemat 1.1.** *Jeżeli  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{E}_P\mathbf{Y}$  w rozmaitości liniowej  $\mathcal{L}_o = \{\mathbf{L}_o + \mathbf{\Pi}_o\mathbf{M} : \mathbf{M} \in \mathcal{M}_{n \times t}\}$ , to dla każdej macierzy  $\mathbf{C} \in \mathcal{M}_{t \times s}$  estymator  $\mathbf{C}'\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{C}'\mathbf{K}'\mathbf{E}_P\mathbf{Y}$  w klasie  $\{\mathbf{L}_o\mathbf{C} + \mathbf{\Pi}_o\mathbf{N} : \mathbf{N} \in \mathcal{M}_{n \times s}\}$ .*

## 2. Estymacja w mieszanym modelu liniowym

W dalszej części rozprawy nasze rozważania dotyczące dopuszczalności estymatorów odnosić się będą do modeli liniowych, które są szczególnymi przypadkami tzw. *mieszanego modelu liniowego*. Model ten możemy przedstawić w postaci

$$Y = X\beta + Z_1u_1 + Z_2u_2 + \dots + Z_ku_k + e,$$

gdzie  $\beta$  jest  $p$ -wymiarowym wektorem nieznanych parametrów (tzw. efektów stałych),  $X \in \mathcal{M}_{n \times p}$ ,  $Z_1 \in \mathcal{M}_{n \times m_1}, \dots, Z_k \in \mathcal{M}_{n \times m_k}$  są macierzami o znanych elementach, natomiast  $u_1 \in \mathbb{R}^{m_1}, \dots, u_k \in \mathbb{R}^{m_k}$  oraz  $e \in \mathbb{R}^n$  są nieobserwowalnymi wektorami losowymi. Będziemy zakładać, że  $u_1, \dots, u_k$  i  $e$  są wzajemnie nieskorelowane, mają zerowe wartości oczekiwane, a ich macierze kowariancji wynoszą odpowiednio  $\sigma_1^2 I_{m_1}, \dots, \sigma_k^2 I_{m_k}$  oraz  $\sigma_{k+1}^2 I_n$ , gdzie  $\sigma_1^2 \geq 0, \dots, \sigma_k^2 \geq 0, \sigma_{k+1}^2 > 0$ . W teorii modeli liniowych nieznanne parametry  $\sigma_1^2, \dots, \sigma_{k+1}^2$  nazywane są *komponentami wariancyjnymi*.

W bardziej zwartej postaci powyższy model można zapisać następująco

$$Y = X\beta + Zu + e,$$

gdzie  $Z = (Z_1, \dots, Z_k)$  oraz  $u = (u'_1, u'_2, \dots, u'_k)'$ .

Przy poczynionych założeniach otrzymujemy, że  $EY = X\beta$  i  $\text{cov}(Y) = ZDZ' + \sigma_{k+1}^2 I_n$ , gdzie  $D = \text{cov}(u) = \text{diag}(\sigma_1^2 I_{m_1}, \sigma_2^2 I_{m_2}, \dots, \sigma_k^2 I_{m_k})$ , co będziemy

zapisywać symbolicznie jako

$$Y \sim (X\beta, ZDZ' + \sigma_{k+1}^2 I_n). \quad (2.1)$$

Istnieje szeroka klasa modeli liniowych o powyższej strukturze, które mają duże zastosowanie praktyczne. Służą one bowiem do modelowania wielu zjawisk, w których pojawia się źródło zmienności, np. do opisu danych pochodzących z eksperymentów genetycznych, medycznych, rolniczych, czy astronomicznych. Właśnie do opisu tych ostatnich astronom Airy (1861) użył jako pierwszy tzw. modelu jednokierunkowej klasyfikacji, który to model wraz z innymi przykładami zostanie omówiony pod koniec tego rozdziału.

Teraz zajmijmy się dopuszczalną estymacją wektora

$$[(K'X\beta)', (Q_1'Z_1u_1)', \dots, (Q_k'Z_ku_k)']' \quad (2.2)$$

w klasie liniowych estymatorów  $L'Y = (L_0, L_1, \dots, L_k)'Y$ , gdzie  $K, L_0 \in \mathcal{M}_{n \times t_0}$ ,  $\dots, Q_k, L_k \in \mathcal{M}_{n \times t_k}$ . Jako kryterium porównawcze estymatorów użyjemy funkcji ryzyka

$$\begin{aligned} R(L'Y) &= E \left\{ \left[ \begin{array}{c} L_0'Y - K'X\beta \\ L_1'Y - Q_1'Z_1u_1 \\ \vdots \\ L_k'Y - Q_k'Z_ku_k \end{array} \right]' \left[ \begin{array}{c} L_0'Y - K'X\beta \\ L_1'Y - Q_1'Z_1u_1 \\ \vdots \\ L_k'Y - Q_k'Z_ku_k \end{array} \right] \right\} \\ &= \text{tr} \{ (L_0 - K)'X\beta\beta'X'(L_0 - K) + L_0' \text{cov}(Y)L_0 \\ &\quad + \sum_{i=1}^k L_i'X\beta\beta'X'L_i + \sum_{i=1}^k L_i' \text{cov}(Y)L_i \\ &\quad + \sum_{i=1}^k \sigma_i^2 (L_i - Q_i)'Z_iZ_i'(L_i - Q_i) - \sum_{i=1}^k \sigma_i^2 L_i'Z_iZ_i'L_i \}. \end{aligned}$$

Zauważmy, że ryzyko to zależy liniowo od macierzy  $Z \text{cov}(u)Z'$ ,  $\text{cov}(e)$  oraz  $EY(EY)'$ . Nie można go przedstawić jako funkcji  $\text{cov}(Y)$  i  $EY(EY)'$ . Między innymi dlatego na tym etapie nie jesteśmy w stanie bezpośrednio wykorzystać



techniki LaMotte'a. Podobnie jak poprzednio zdefiniujemy w rozważanej klasie estymatorów następującą relację.

**Definicja 2.1.** *Estymator  $L'Y$  jest lepszy niż  $L'_*Y$ , jeżeli*

$$R(L'Y) \leq R(L'_*Y)$$

dla każdych  $Z\text{cov}(u)Z'$ ,  $\text{cov}(e)$  oraz  $EY(EY)'$  i jeżeli ostra nierówność jest spełniona dla co najmniej jednej kombinacji tych macierzy.

**Definicja 2.2.** *Estymator  $L'Y$  nazywa się dopuszczalny w klasie estymatorów  $\{(L_0, \dots, L_k) : L_0 \in \mathcal{M}_{n \times t_0}, \dots, L_k \in \mathcal{M}_{n \times t_k}\}$ , jeżeli nie istnieje estymator lepszy niż  $L'Y$ .*

Aby móc zastosować teorię dopuszczalnej estymacji liniowej funkcji wartości oczekiwanej w ogólnym modelu liniowym do rozważanego problemu, należałoby w funkcji straty „przerzucić” efekty losowe z estymowanej funkcji do części „modelowej”, tak by funkcja ryzyka w wyjściowym modelu pokrywała się z funkcją ryzyka odpowiedniego estymatora liniowego w modelu dodatkowo poszerzonym o efekty losowe. W ten sposób w obu modelach zbiór funkcji ryzyka pozostałby bez zmian. Zauważmy, że

$$\begin{bmatrix} L'_0 Y - K' X \beta \\ L'_1 Y - Q'_1 Z_1 u_1 \\ \vdots \\ L'_k Y - Q'_k Z_k u_k \end{bmatrix} = \begin{bmatrix} L_0 & L_1 & \cdots & L_k \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{bmatrix}' \mathbf{Y} - \mathbf{K}' \mathbf{X} \beta, \quad (2.3)$$

gdzie

$$\mathbf{Y} = \begin{pmatrix} Y \\ Z_1 u_1 \\ \vdots \\ Z_k u_k \end{pmatrix}, \quad \mathbf{K} = \begin{bmatrix} K & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \quad \text{oraz} \quad \mathbf{X} = \begin{pmatrix} X \\ \mathbf{0} \\ \vdots \\ \mathbf{0} \end{pmatrix}.$$

Zatem możemy rozważać funkcję ryzyka estymatora  $(L_0, \dots, L_k)'Y$  jako funkcję

$$\text{ryzyka liniowego estymatora } \mathbf{L}'\mathbf{Y} = \begin{bmatrix} L_0 & L_1 & \cdots & L_k \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{bmatrix}' \mathbf{Y} \text{ dla } \mathbf{K}'\mathbf{X}\beta$$

w następującym modelu

$$\mathbf{Y} \sim \left( \mathbf{X}\beta, \sum_{i=1}^{k+1} \sigma_i^2 \mathbf{V}_i \right), \quad (2.4)$$

gdzie

$$\mathbf{V}_i = (v_1 + v_{i+1})(v_1 + v_{i+1})' \otimes Z_i Z_i', \quad i = 1, \dots, k,$$

$$\mathbf{V}_{k+1} = v_1 v_1' \otimes I_n$$

oraz  $v_i$  jest  $i$ -tym wektorem należącym do  $\mathbb{R}^{k+1}$ . Ponieważ  $Q_1, \dots, Q_k$  są ustalonymi macierzami, więc klasa estymatorów dla  $\mathbf{K}'\mathbf{X}\beta$  w powyższym modelu jest ograniczona do zbioru

$$\mathcal{E}_o = \{\mathbf{N}'\mathbf{Y} : \mathbf{N} \in \mathcal{L}_o\},$$

gdzie

$$\mathcal{L}_o = \{\mathbf{L}_o + \mathbf{\Pi}_o \mathbf{M} : \mathbf{M} \in \mathcal{M}_{(k+1)n \times (t_0 + \dots + t_k)}\},$$

$$\mathbf{L}_o = \begin{bmatrix} \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{bmatrix}$$

oraz

$$\mathbf{\Pi}_o = \begin{bmatrix} I_n & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix}.$$

Oczywiście  $\mathcal{L}_o \subset \mathcal{M}_{(k+1)n \times (t_0 + \dots + t_k)}$  jest rozmaitością liniową. Zauważmy, że możemy ją równoważnie zapisać w postaci

$$\mathcal{L}_o = \mathbf{L}_o + \mathcal{R}(T_{\mathbf{\Pi}_o}^t),$$

gdzie  $t = \sum_{i=0}^k t_i$ . Równość (2.3) jest istotnym spostrzeżeniem do dalszych naszych rozważań. Sprowadza ona problem jednoczesnej estymacji liniowej funkcji wektora efektów stałych i losowych w modelu (2.1) do estymacji odpowiedniej liniowej funkcji wektora wartości oczekiwanych w modelu (2.4) w klasie  $\mathcal{L}_o$ , a to z kolei pozwala wykorzystać znane już narzędzia opisane w rozdziale 2. Ponieważ funkcja ryzyka estymatora  $\mathbf{L}'\mathbf{Y}$  dla  $\mathbf{K}'\mathbf{X}\beta$  daje się przedstawić w postaci

$$\text{tr}[\mathbf{L}'\text{cov}(\mathbf{Y})\mathbf{L} + (\mathbf{L} - \mathbf{K})'\mathbf{E}\mathbf{Y}(\mathbf{E}\mathbf{Y})'(\mathbf{L} - \mathbf{K})],$$

więc nową przestrzenią parametrów jest zbiór

$$\mathcal{T} = \left\{ \left( \sum_{i=1}^{k+1} \sigma_i^2 \mathbf{V}_i, \mathbf{X}\beta\beta'\mathbf{X}' \right) : \sigma_1^2 \geq 0, \dots, \sigma_k^2 \geq 0, \sigma_{k+1}^2 > 0, \beta \in \mathbb{R}^p \right\},$$

podczas gdy  $\mathcal{W} = \text{span}\mathcal{T}$  wyraża się wzorem

$$\mathcal{W} = \left\{ \left( \sum_{i=1}^{k+1} f_i \mathbf{V}_i, \mathbf{X}F\mathbf{X}' \right) : f_1, \dots, f_{k+1} \in \mathbb{R}, F \in \mathcal{M}_{p \times p}, F = F' \right\}.$$

Zauważmy, że dzięki opisanej „redukcji problemu” wystarczy podać warunki konieczne i dostateczne na to, aby estymator był dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w modelu (2.4).

**Lemat 2.1.** *Liniowy estymator jest dopuszczalny dla  $[(\mathbf{K}'\mathbf{X}\beta)', (\mathbf{Q}'_1 \mathbf{Z}_1 u_1)', \dots, (\mathbf{Q}'_k \mathbf{Z}_k u_k)']'$  w modelu (2.1) wtedy i tylko wtedy, gdy odpowiadający mu estymator jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w modelu (2.4).*

**Dowód.** Lemat jest natychmiastową konsekwencją równości (2.3) oraz tego, że

$$\begin{aligned} \mathbf{R}(\mathbf{L}'\mathbf{Y}; W) &= E\{[\mathbf{L}'\mathbf{Y} - \mathbf{K}'\mathbf{X}\beta][\mathbf{L}'\mathbf{Y} - \mathbf{K}'\mathbf{X}\beta]'\} \\ &= E\left\{ \begin{bmatrix} L'_0Y - K'X\beta \\ L'_1Y - Q'_1Z_1u_1 \\ \vdots \\ L'_kY - Q'_kZ_ku_k \end{bmatrix}' \begin{bmatrix} L'_0Y - K'X\beta \\ L'_1Y - Q'_1Z_1u_1 \\ \vdots \\ L'_kY - Q'_kZ_ku_k \end{bmatrix} \right\}. \end{aligned}$$

□

Do charakterystyki estymatorów dopuszczalnych dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w modelu (2.4) wykorzystamy twierdzenia 1.2 oraz 1.3.

## 2.1. Przykłady liniowych modeli mieszanych

W tym podrozdziale opiszemy modele, które są szczególnymi przypadkami modelu (2.1), a dla których, w kolejnych rozdziałach rozprawy, podana zostanie charakterystyka estymatorów dopuszczalnych dla wektora (2.2).

Dokładny opis klasy modeli mieszanych wraz z licznymi przykładami zastosowań znajduje się między innymi w książkach Gnota (1991) oraz Searle'a i in. (1992).

### Zrównoważony model losowy $k$ -kierunkowej klasyfikacji hierarchicznej

Niech  $Y_{i_1 \dots i_{k+1}}$ , gdzie  $i_j = 1, 2, \dots, n_j$  dla  $j = 1, \dots, k+1$ , będzie zmienną losową o następującej strukturze

$$Y_{i_1 \dots i_{k+1}} = \beta + u_{1i_1} + u_{2i_1i_2} + \dots + u_{ki_1 \dots i_k} + e_{i_1 \dots i_{k+1}},$$

gdzie  $\beta$  jest nieznanym parametrem,  $u_{1i_1}, \dots, u_{ki_1 \dots i_k}$  oraz  $e_{i_1 \dots i_{k+1}}$  są nieskorelowanymi zmiennymi losowymi z zerowymi wartościami oczekiwanymi i wariancjami odpowiednio  $\sigma_1^2, \dots, \sigma_k^2$  i  $\sigma_{k+1}^2$ . Przy tych założeniach, ustawiając zmien-

ne  $Y_{i_1 \dots i_{k+1}}$  w porządku leksykograficznym w  $n$ -wymiarowy wektor  $Y$ , gdzie  $n = n_1 \cdot n_2 \cdot \dots \cdot n_{k+1}$ , dostajemy *zrównoważony model  $k$ -kierunkowej klasyfikacji hierarchicznej* będący szczególnym przypadkiem modelu (2.1), dla którego  $X = \mathbf{1}_{n_1} \otimes \dots \otimes \mathbf{1}_{n_{k+1}} = \mathbf{1}_n$  oraz  $Z_i = I_{n_1} \otimes \dots \otimes I_{n_i} \otimes \mathbf{1}_{n_{i+1}} \otimes \dots \otimes \mathbf{1}_{n_{k+1}}$ , tzn.

$$Y \sim \left( \mathbf{1}_n \beta, \sum_{i=1}^k \sigma_i^2 (I_{n_1} \otimes \dots \otimes I_{n_i} \otimes \mathbf{J}_{n_{i+1}} \otimes \dots \otimes \mathbf{J}_{n_{k+1}}) + \sigma_{k+1}^2 I_n \right), \quad (2.5)$$

gdzie  $\mathbf{1}_a$  oznacza wektor składający się z  $a$  jedynek oraz  $\mathbf{J}_a = \mathbf{1}_a \mathbf{1}'_a$ .

### Zrównoważony model losowy $k$ -kierunkowej klasyfikacji krzyżowej

Niech  $Y_{i_1 \dots i_{k+1}}$ , gdzie  $i_j = 1, 2, \dots, n_j$  dla  $j = 1, \dots, k+1$ , będzie zmienną losową o następującej strukturze

$$Y_{i_1 \dots i_{k+1}} = \beta + u_{1i_1} + \dots + u_{ki_k} + e_{i_1 \dots i_{k+1}},$$

gdzie  $\beta$  jest nieznanym parametrem,  $u_{1i_1}, \dots, u_{ki_k}$  oraz  $e_{i_1 \dots i_{k+1}}$ , są nieskorelowanymi zmiennymi losowymi z zerowymi wartościami oczekiwanymi i wariancjami odpowiednio  $\sigma_1^2, \dots, \sigma_k^2$  i  $\sigma_{k+1}^2$ . Przy tych założeniach, ustawiając zmienne  $Y_{i_1, \dots, i_{k+1}}$  w porządku leksykograficznym w  $n$ -wymiarowy wektor  $Y$ , gdzie  $n = n_1 \cdot n_2 \cdot \dots \cdot n_{k+1}$ , uzyskujemy tzw. *zrównoważony model  $k$ -kierunkowej klasyfikacji krzyżowej*, który możemy wyrazić w następujący sposób

$$Y \sim \left( \mathbf{1}_n \beta, \sum_{i=1}^k \sigma_i^2 (\mathbf{J}_{n_1} \otimes \dots \otimes \mathbf{J}_{n_{i-1}} \otimes I_{n_i} \otimes \mathbf{J}_{n_{i+1}} \otimes \dots \otimes \mathbf{J}_{n_{k+1}}) + \sigma_{k+1}^2 I_n \right). \quad (2.6)$$

### Zrównoważony model losowy dwukierunkowej klasyfikacji krzyżowej z interakcją

Niech  $Y_{i_1 i_2 i_3}$ , gdzie  $i_j = 1, 2, \dots, n_j$  dla  $j = 1, 2, 3$ , będzie zmienną losową o następującej strukturze

$$Y_{i_1 i_2 i_3} = \beta + u_{1i_1} + u_{2i_2} + u_{3i_1 i_2} + e_{i_1 i_2 i_3},$$

gdzie  $\beta$  jest nieznanym parametrem,  $u_{1i_1}, u_{2i_2}, u_{3i_1i_2}$  oraz  $e_{i_1i_2i_3}$  są nieskorelowanymi zmiennymi losowymi z zerowymi wartościami oczekiwanymi i wariancjami odpowiednio  $\sigma_1^2, \sigma_2^2, \sigma_3^2$  i  $\sigma_4^2$ . Postępując ze zmiennymi  $Y_{i_1i_2i_3}$  tak, jak w dwóch poprzednich sytuacjach, uzyskujemy dla  $n$ -wymiarowego wektora  $Y$  następujący model

$$Y \sim (\mathbf{1}_n\beta, \sigma_1^2 I_{n_1} \otimes \mathbf{J}_{n_2} \otimes \mathbf{J}_{n_3} + \sigma_2^2 \mathbf{J}_{n_1} \otimes I_{n_2} \otimes \mathbf{J}_{n_3} + \sigma_3^2 I_{n_1} \otimes I_{n_2} \otimes \mathbf{J}_{n_3} + \sigma_4^2 I_n), \quad (2.7)$$

gdzie  $n = n_1 \cdot n_2 \cdot n_3$ . Model ten nazywany jest *zrównoważonym modelem losowym dwukierunkowej klasyfikacji krzyżowej z interakcją*.

### Model Rafajłowicza

Gnot, Rafajłowicz i Urbańska-Motyka (2001) użyli następującego modelu do opisu wartości pomiaru wykonanego przez  $j$ -ty sensor

$$y_j = N_j v + e_j,$$

gdzie  $j = 1, \dots, n_2$ ,  $v$  oznacza intensywność źródła, z którego został wysłany sygnał,  $N_j$  wpływ źródła sygnału na  $j$ -ty sensor, natomiast  $e_j$  jest błędem losowym tego pomiaru. Przy tych oznaczeniach mamy, że

$$y = Nv + e,$$

gdzie  $y = (y_1, \dots, y_{n_2})'$ ,  $N = (N_1, \dots, N_{n_2})'$  oraz  $e = (e_1, \dots, e_{n_2})'$ . O wektorze  $N$ , zwanym wektorem odpowiedzi sensora, zakładamy, że jest dany. Dodatkowo o nieskorelowanych zmiennych losowych  $v$  oraz  $e_j$  zakładamy, że mają wartości oczekiwane odpowiednio  $\beta$  oraz 0, natomiast wariancje  $\sigma_1^2 \geq 0$  i  $\sigma_2^2 > 0$ . Założenia te implikują, że

$$Ey = N\beta \quad \text{oraz} \quad \text{cov}(y) = \sigma_1^2 NN' + \sigma_2^2 I_{n_2}.$$

Zatem do opisu  $n_1$  niezależnych pomiarów wykonanych na każdym spośród  $n_2$  sensorów użyjemy następującego modelu

$$Y = \text{vec}(y^{(1)}, y^{(2)}, \dots, y^{(n_1)}),$$

gdzie  $y^{(i)} = (y_{i1}, \dots, y_{in_2})'$ ,  $y_{ij}$  oznacza  $i$ -ty pomiar  $j$ -tego sensora, natomiast  $\text{vec}(A)$  oznacza operator macierzowy tworzący wektor kolumnowy z kolumn macierzy  $A$  ustawianych kolejno jedna pod drugą. O wektorze losowym  $y^{(i)}$  zakładamy, że  $Ey^{(i)} = N\beta$  oraz  $\text{cov}(y^{(i)}) = \sigma_1^2 NN' + \sigma_2^2 I_{n_2}$ , co z kolei implikuje, że

$$Y \sim ((\mathbf{1}_{n_1} \otimes N)\beta, \sigma_1^2(I_{n_1} \otimes NN') + \sigma_2^2 I_n), \quad (2.8)$$

gdzie  $n = n_1 \cdot n_2$ .

Zauważmy, że kiedy  $N = \mathbf{1}_{n_2}$ , to otrzymujemy *zrównoważony model losowy jednokierunkowej klasyfikacji*, który jest jednocześnie szczególnym przypadkiem modeli (2.5) oraz (2.6) dla  $k = 1$ . Symbolicznie będziemy go zapisywać w postaci

$$Y \sim (\mathbf{1}_n \beta, \sigma_1^2(I_{n_1} \otimes \mathbf{1}_{n_2} \mathbf{1}_{n_2}') + \sigma_2^2 I_n). \quad (2.9)$$

# 3. Jawna charakterystyka estymatorów dopuszczalnych w wybranych modelach liniowych

W tym rozdziale podane zostaną w jawnej postaci warunki konieczne i dostateczne na to, aby liniowy estymator  $(L_0, L_1, \dots, L_k)'Y$  był dopuszczalny dla wektora  $[(K'X\beta)', (Q_1'Z_1u_1)', \dots, (Q_k'Z_ku_k)']'$  w modelach (2.5), (2.6) oraz (2.7). Na mocy lematu 2.1 zostaną one podane w terminach macierzy opisujących modele będące odpowiednikami modelu (2.4), w których możemy wykorzystać wyniki LaMotte'a opisane w rozdziale 1. Zauważmy, że dla tych modeli mamy

$$\mathcal{T} = \left\{ \left( \sum_{i=1}^{k+1} \sigma_i^2 \mathbf{V}_i, \beta^2 \mathbf{X} \mathbf{X}' \right) : \sigma_1^2 \geq 0, \dots, \sigma_k^2 \geq 0, \sigma_{k+1}^2 > 0, \beta \in \mathbb{R} \right\},$$

natomiast

$$[\mathcal{T}] = \left\{ \left( \sum_{i=1}^{k+1} s_i \mathbf{V}_i, s_0 \mathbf{X} \mathbf{X}' \right) : s_0 \geq 0, \dots, s_{k+1} \geq 0 \right\}.$$



### 3.1. Zrównoważony model losowy $k$ -kierunkowej klasyfikacji hierarchicznej

W tym podrozdziale podamy jawną postać wszystkich liniowych estymatorów dopuszczalnych dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$  w modelu (2.4), w którym postaci macierzy  $\mathbf{X}$  oraz  $\mathbf{V}_i$  zależą od odpowiednich macierzy modelu (2.5), tj.  $X = \mathbf{1}_n$ , natomiast  $Z_i = I_{n_1} \otimes \dots \otimes I_{n_i} \otimes \mathbf{1}_{n_{i+1}} \otimes \dots \otimes \mathbf{1}_{n_{k+1}}$  dla  $i = 1, \dots, k$ . Tym samym scharakteryzujemy liniowe estymatory dopuszczalne dla wektora (2.2) w modelu (2.5). Zaczniemy od podania warunków koniecznych i dostatecznych na to, aby estymator  $\mathbf{L}'\mathbf{Y}$  był jednoznacznie lokalnie optymalnym estymatorem dla  $\mathbf{K}'\mathbf{X}\beta$  w punkcie  $W = (W_1, W_2) \in [\mathcal{T}]$ .

Dla uproszczenia notacji, niech  $Z_0 = \mathbf{1}_n$  oraz  $Z_{k+1} = I_n$ . Kładąc  $p_i = n_{i+1} \cdot \dots \cdot n_{k+1}$  dla  $i = 0, \dots, k$  oraz  $p_{k+1} = 1$ , definiujemy następujące macierze

$$E_0 = \frac{1}{p_0} Z_0 Z_0'$$

oraz

$$E_i = \frac{1}{p_i} Z_i Z_i' - \frac{1}{p_{i-1}} Z_{i-1} Z_{i-1}' \quad \text{dla } i = 1, \dots, k+1.$$

Zauważmy, że  $E_0, \dots, E_{k+1}$  są idempotentnymi i ortogonalnymi macierzami takimi, że

$$Z_i Z_i' = p_i \sum_{j=0}^i E_j \quad \text{dla } i = 0, \dots, k.$$

**Lemat 3.1.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $(\sum_{i=1}^{k+1} s_i \mathbf{V}_i, s_0 \mathbf{X} \mathbf{X}')$  z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$  w modelu (2.4) odpowiadającym modelowi (2.5) wtedy i tylko wtedy, gdy  $s_0 \geq 0, \dots, s_k \geq 0, s_{k+1} > 0$  oraz*

$$\mathbf{L} = \begin{bmatrix} L_0 & L_1 & \cdots & L_k \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{bmatrix},$$

gdzie

$$\begin{aligned}
L_0 &= a_0 E_0 K, \\
L_i &= a_i \left\{ E_i + \sum_{j=0}^{i-1} \left[ \prod_{l=j}^{i-1} (1 - a_l) \right] E_j \right\} Q_i \quad \text{dla } i = 1, \dots, k, \\
a_i &= \frac{s_i p_i}{\sum_{j=i}^{k+1} s_j p_j} \quad \text{dla } i = 0, \dots, k.
\end{aligned} \tag{3.1}$$

**Dowód.** Estymator  $L'Y$  jest lokalnie optymalny w punkcie  $(\sum_{i=1}^{k+1} s_i V_i, s_0 \mathbf{X} \mathbf{X}')$  z  $[T]$  w klasie  $\mathcal{L}_o$  wtedy i tylko wtedy, gdy  $s_j \geq 0$  dla  $j = 0, \dots, k+1$  oraz

$$\Pi_o \left( \sum_{i=1}^{k+1} s_i V_i + s_0 \mathbf{X} \mathbf{X}' \right) L = s_0 \Pi_o \mathbf{X} \mathbf{X}' K.$$

Równoważnie równanie to możemy zapisać w postaci

$$\begin{bmatrix} ML_0 & ML_1 - s_1 Z_1 Z_1' Q_1 & \cdots & ML_k - s_k Z_k Z_k' Q_k \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} = \begin{bmatrix} s_0 \mathbf{X} \mathbf{X}' K & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix},$$

gdzie  $M = \sum_{i=0}^{k+1} s_i Z_i Z_i'$ . Oczywiście równanie to ma dokładnie jedno rozwiązanie ze względu na  $L_0, \dots, L_k$  wtedy i tylko wtedy, gdy macierz  $M$  jest nieosobliwa, czyli wtedy i tylko wtedy, gdy  $s_{k+1} > 0$ . Przy użyciu  $E_0, \dots, E_{k+1}$  możemy zapisać  $M$  następująco

$$M = \sum_{i=0}^{k+1} s_i \left( p_i \sum_{j=0}^i E_j \right) = \sum_{i=0}^{k+1} \left( \sum_{j=i}^{k+1} s_j p_j \right) E_i = \sum_{i=0}^{k+1} w_i E_i.$$

Ponieważ  $E_0, \dots, E_{k+1}$  są ortogonalne i idempotentne, więc

$$M^{-1} = \sum_{i=0}^{k+1} \frac{1}{w_i} E_i.$$

Zatem

$$L_0 = s_0 M^{-1} X X' K = \frac{s_0 p_0}{\sum_{j=0}^{k+1} s_j p_j} E_0 K$$

oraz

$$\begin{aligned} L_i &= s_i M^{-1} Z_i Z_i' Q_i = s_i p_i M^{-1} \left( \sum_{j=0}^i E_j \right) Q_i = \left( \sum_{j=0}^i \frac{s_i p_i}{\sum_{l=j}^{k+1} s_l p_l} E_j \right) Q_i \\ &= a_i \left( E_i + \sum_{j=0}^{i-1} \frac{\sum_{l=i}^{k+1} s_l p_l}{\sum_{l=j}^{k+1} s_l p_l} E_j \right) Q_i \quad \text{dla } i = 1, \dots, k. \end{aligned}$$

Zauważmy, że

$$\begin{aligned} \frac{\sum_{l=i}^{k+1} s_l p_l}{\sum_{l=j}^{k+1} s_l p_l} &= \frac{\sum_{l=j+1}^{k+1} s_l p_l}{\sum_{l=j}^{k+1} s_l p_l} \cdot \frac{\sum_{l=j+2}^{k+1} s_l p_l}{\sum_{l=j+1}^{k+1} s_l p_l} \cdots \frac{\sum_{l=i-1}^{k+1} s_l p_l}{\sum_{l=i-2}^{k+1} s_l p_l} \cdot \frac{\sum_{l=i}^{k+1} s_l p_l}{\sum_{l=i-1}^{k+1} s_l p_l} \\ &= (1 - a_j)(1 - a_{j-1}) \cdots (1 - a_{i-2})(1 - a_{i-1}), \end{aligned}$$

co kończy dowód lematu. □

**Twierdzenie 3.1.** *Estymator  $L'Y$  jest dopuszczalny dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (2.5) wtedy i tylko wtedy, gdy*

$$L \in \left\{ \left[ \begin{array}{cccc} L_0(a_0) & L_1(a_0, a_1) & \cdots & L_k(a_0, \dots, a_k) \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{array} \right] : a_i \in [0, 1], i = 0, \dots, k \right\}, \quad (3.2)$$

gdzie

$$L_0(a_0) = a_0 E_0 K$$

oraz

$$L_i(a_0, \dots, a_i) = a_i \left\{ E_i + \sum_{j=0}^{i-1} \left[ \prod_{l=j}^{i-1} (1 - a_l) \right] E_j \right\} Q_i \text{ dla } i = 1, \dots, k.$$

**Dowód.** Warunek konieczny. Zauważmy, że dla każdych ustalonych wartości  $s_{i+1} \geq 0, \dots, s_k \geq 0$  oraz  $s_{k+1} > 0$  współczynnik  $a_i$  dany wzorem (3.1) przebiega przedział  $[0, 1)$ , gdy  $s_i \in [0, +\infty)$  dla  $i = 0, \dots, k$ . Korzystając z lematu 3.1 mamy, że zbiór (3.2) jest domknięciem zbioru

$\{\mathbf{L}_* : \mathbf{L}'_* \mathbf{Y}$  jest jednoznacznie lokalnie optymalnym w punkcie z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o\}$ .

A zatem na mocy twierdzenia 1.3 pierwsza część dowodu jest zakończona.

Chcąc udowodnić warunek dostateczny, użyjemy krokowej metody zaproponowanej przez LaMotte'a. Liczba kroków będzie zależała od tych współczynników spośród  $a_0, a_1, \dots, a_k$ , które są równe 1.

Niech  $\mathcal{I} = \{i \in \{0, 1, \dots, k\} : a_i = 1\}$ ,

$$m_1 = \begin{cases} k + 1, & \text{gdy } \mathcal{I} = \emptyset, \\ \min \mathcal{I}, & \text{w przeciwnym przypadku} \end{cases}$$

oraz niech  $\mathcal{L} = \mathbf{L} + \mathcal{R}(T_{\mathbf{II}_o}^t)$ , gdzie  $t = \sum_{i=0}^k t_i$ . Co oznacza, że  $\mathcal{L} = \mathcal{L}_o$ . Dalej, niech  $W = (W_1, W_2)$  będzie punktem z  $[\mathcal{T}]$  określonym następująco

$$W = \begin{cases} \left( \mathbf{0}, \frac{1}{p_0} \mathbf{X} \mathbf{X}' \right), & \text{gdy } m_1 = 0, \\ \left( \frac{1}{p_1} \mathbf{V}_1, \frac{a_0}{p_0(1-a_0)} \mathbf{X} \mathbf{X}' \right), & \text{gdy } m_1 = 1, \\ \left( \sum_{i=1}^{m_1-1} \frac{a_i}{p_i \prod_{j=i}^{m_1-1} (1-a_j)} \mathbf{V}_i + \frac{1}{p_{m_1}} \mathbf{V}_{m_1}, \frac{a_0}{p_0 \prod_{j=0}^{m_1-1} (1-a_j)} \mathbf{X} \mathbf{X}' \right), & \text{w przeciwnym} \\ & \text{przypadku.} \end{cases}$$

Dalszą część dowodu przedstawimy w postaci następującego algorytmu.

**START:**

Ponieważ  $\mathbf{\Pi}(W_1 + W_2)\mathbf{L} = \mathbf{\Pi}W_2\mathbf{K}$ , więc  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $W$  w klasie  $\mathcal{L}$ .

**Jeżeli**  $m_1 = k + 1$ ;

W tym przypadku  $\mathcal{R}(\mathbf{\Pi}(W_1 + W_2)\mathbf{\Pi}) = \mathcal{R}(\mathbf{\Pi})$ , czyli  $\mathcal{B}(W|\mathcal{L}) = \{\mathbf{L}\}$ . Stąd  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w  $\mathcal{L}_o$ .

**W przeciwnym razie;**

Niech  $\mathcal{B}(W|\mathcal{L})$  będzie nową rozmaitością  $\mathcal{L}$ , którą możemy przedstawić w postaci

$$\mathcal{L} = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}}^t),$$

gdzie

$$\mathbf{\Pi} = \begin{bmatrix} I_n - \sum_{i=0}^{m_1} E_i & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}.$$

Niech  $\mathcal{I} \setminus \{m_1\}$  będzie nowym zbiorem  $\mathcal{I}$ ,

$$m_2 = \begin{cases} k + 1, & \text{gdy } \mathcal{I} = \emptyset, \\ \min \mathcal{I}, & \text{w przeciwnym przypadku} \end{cases}$$

oraz niech  $W = (W_1, W_2)$  będzie punktem z  $[\mathcal{T}]$  określonym w sposób

$$W = \begin{cases} \left( \frac{1}{p_{m_2}} \mathbf{V}_{m_2}, \mathbf{0} \right), & \text{gdy } m_2 = m_1 + 1, \\ \left( \sum_{i=m_1}^{m_2-1} \frac{a_i}{p_i \prod_{j=i}^{m_2-1} (1-a_j)} \mathbf{V}_i + \frac{1}{p_{m_2}} \mathbf{V}_{m_2}, \mathbf{0} \right), & \text{w przeciwnym razie.} \end{cases}$$

I ostatecznie niech  $m_2$  będzie nowym  $m_1$ .

**Przechodzimy do START;**

□

Zauważmy, że procedura ta musi zakończyć się po skończonej liczbie kroków, ponieważ po każdym wykonanym kroku wymiar kolejnych rozmaitości liniowych maleje. W skrajnym przypadku, gdy każdy ze współczynników  $a_0, \dots, a_k$  jest równy 1, musimy wykonać  $(k + 1) + 1$  kroków.

### 3.2. Zrównoważony model losowy $k$ -kierunkowej klasyfikacji krzyżowej

W tym podrozdziale podamy charakterystykę liniowych estymatorów dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$  w modelu (2.4), w którym postaci macierzy  $\mathbf{X}$  oraz  $\mathbf{V}_i$  są determinowane odpowiednimi macierzami modelu (2.6), tzn. macierzami  $X = \mathbf{1}_n$ , natomiast  $Z_i = \mathbf{1}_{n_1} \otimes \dots \otimes \mathbf{1}_{n_{i-1}} \otimes I_{n_i} \otimes \mathbf{1}_{n_{i+1}} \otimes \dots \otimes \mathbf{1}_{n_{k+1}}$  dla  $i = 1, \dots, k$ . Tak, jak poprzednio, celem uproszczenia zapisu, niech  $p_0 = n$ ,  $Z_0 = \mathbf{1}_n$ ,  $p_{k+1} = 1$  oraz  $Z_{k+1} = I_n$ . Kładąc  $p_i = \prod_{j \neq i} n_j$  dla  $i = 1, \dots, k$  i definiując

$$\begin{aligned} E_0 &= \frac{1}{p_0} Z_0 Z_0', \\ E_i &= \frac{1}{p_i} Z_i Z_i' - E_0 \quad \text{dla } i = 1, \dots, k, \\ E_{k+1} &= Z_{k+1} Z_{k+1}' - (E_0 + \dots + E_k) \end{aligned}$$

otrzymujemy, że  $E_0, \dots, E_{k+1}$  są idempotentnymi i ortogonalnymi macierzami, a macierze  $Z_0 Z_0', \dots, Z_{k+1} Z_{k+1}'$  są ich liniowymi kombinacjami. Aby móc scharakteryzować liniowe estymatory dopuszczalne dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na zbiorze  $\mathcal{T}$  w modelu (2.4), który odpowiada modelowi (2.6), udowodnimy najpierw następujący lemat.

**Lemat 3.2.** Estymator  $L'Y$  jest jednoznacznie lokalnie optymalny w punkcie  $(\sum_{i=1}^{k+1} s_i V_i, s_0 X X')$  z  $[T]$  w klasie  $\mathcal{L}_o$  w modelu (2.4) odpowiadającym modelowi (2.6) wtedy i tylko wtedy, gdy  $s_0 \geq 0, \dots, s_k \geq 0, s_{k+1} > 0$  oraz

$$L = \begin{bmatrix} L_0 & L_1 & \cdots & L_k \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{bmatrix},$$

gdzie

$$\begin{aligned} L_0 &= a_0 E_0 K, \\ L_i &= a_i \left[ E_i + (1 - a_0) \frac{\frac{1}{1-a_i}}{\sum_{j=1}^k \frac{1}{1-a_j} - (k-1)} E_0 \right] Q_i \text{ dla } i = 1, \dots, k, \\ a_0 &= \frac{s_0 p_0}{\sum_{j=0}^{k+1} s_j p_j}, \end{aligned} \tag{3.3}$$

$$a_i = \frac{s_i p_i}{s_i p_i + s_{k+1}} \text{ dla } i = 1, \dots, k. \tag{3.4}$$

**Dowód.** Niech  $(\sum_{i=1}^{k+1} s_i V_i, s_0 X X')$  będzie punktem z  $[T]$  takim, że  $s_0 \geq 0, \dots, s_{k+1} \geq 0$ . Tak, jak w dowodzie lematu 3.1 estymator  $L'Y$  jest jednoznacznie lokalnie optymalnym estymatorem wtedy i tylko wtedy, gdy  $s_{k+1} > 0$  oraz

$$\begin{aligned} L_0 &= s_0 M^{-1} X X' K, \\ L_i &= s_i M^{-1} Z_i Z_i' Q_i \text{ dla } i = 1, \dots, k, \end{aligned}$$

gdzie  $M = \sum_{i=0}^{k+1} s_i Z_i Z_i'$  można wyrazić wzorem

$$M = \left( \sum_{i=0}^{k+1} s_i p_i \right) E_0 + \sum_{i=1}^k (s_i p_i + s_{k+1}) E_i + s_{k+1} E_{k+1}.$$

Zatem

$$L_0 = \frac{s_0 p_0}{\sum_{j=0}^{k+1} s_j p_j} E_0 K,$$

natomiast

$$\begin{aligned} L_i &= \left( \frac{\frac{s_i p_i}{\sum_{j=0}^{k+1} s_j p_j} E_0 + \frac{s_i p_i}{s_i p_i + s_{k+1}} E_i \right) Q_i \\ &= \frac{s_i p_i}{s_i p_i + s_{k+1}} \left( E_i + \frac{s_i p_i + s_{k+1}}{\sum_{j=0}^{k+1} s_j p_j} E_0 \right) Q_i \text{ dla } i = 1, \dots, k. \end{aligned}$$

Zauważmy, że

$$\begin{aligned} \frac{s_i p_i + s_{k+1}}{\sum_{j=0}^{k+1} s_j p_j} &= \frac{\sum_{j=1}^{k+1} s_j p_j}{\sum_{j=0}^{k+1} s_j p_j} \cdot \frac{s_i p_i + s_{k+1}}{\sum_{j=1}^k (s_j p_j + s_{k+1}) - k s_{k+1} + s_{k+1}} \\ &= (1 - a_0) \frac{\frac{s_i p_i + s_{k+1}}{s_{k+1}}}{\sum_{j=1}^k \frac{s_j p_j + s_{k+1}}{s_{k+1}} - k + 1} \\ &= (1 - a_0) \frac{\frac{1}{1 - a_i}}{\sum_{j=1}^k \frac{1}{1 - a_j} - (k - 1)}, \end{aligned}$$

co kończy dowód. □

**Twierdzenie 3.2.** *Estymator  $L'Y$  jest dopuszczalny dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (2.6) wtedy i tylko wtedy, gdy*

$$L \in \left\{ \left[ \begin{array}{cccc} L_0(a_0) & L_1(a_1, A_1) & \cdots & L_k(a_k, A_k) \\ \mathbf{0} & -Q_1 & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & -Q_k \end{array} \right] : a_i \in [0, 1], i = 0, \dots, k \right\}, \quad (3.5)$$



gdzie

$$\begin{aligned} L_0(a_0) &= a_0 E_0 K, \\ L_i(a_i, A_i) &= a_i [E_i + (1 - a_0) A_i E_0] Q_i \quad \text{dla } i = 1, \dots, k \end{aligned}$$

oraz

$$A_i = \frac{\frac{1}{1-a_i}}{\sum_{j=1}^k \frac{1}{1-a_j} - (k-1)} \quad \text{dla } a_1 \in [0, 1), \dots, a_k \in [0, 1), \quad (3.6)$$

w przeciwnym razie

$A_1, \dots, A_k$  są nieujemnymi liczbami takimi, że  $\sum_{i=1}^k A_i = \sum_{i \in \mathcal{I}} A_i = 1$ , gdzie  $\mathcal{I} = \{i \in \{1, \dots, k\} : a_i = 1\}$ .

**Dowód.** Warunek konieczny. Zauważmy, że  $a_i$  określone wzorem (3.3) oraz (3.4) przyjmują każdą wartość z przedziału  $[0, 1)$  dla dowolnych  $s_0 \geq 0, \dots, s_k \geq 0$  oraz  $s_{k+1} > 0$ . Oczywiście dla  $A_i$  danego formułą (3.6) zachodzi  $1 < \sum_{i=1}^k A_i \leq k$ .

Ponieważ  $\sum_{j=1}^k \frac{1}{1-a_j} \rightarrow +\infty$ , gdy  $a_j \rightarrow 1$  dla co najmniej jednego  $j$ , tj. gdy  $\mathcal{I} \neq \emptyset$ , więc  $\sum_{i=1}^k A_i \rightarrow 1$  oraz  $A_j \rightarrow 0$  dla  $j \notin \mathcal{I}$ . Wszystko to implikuje, że zbiór (3.5) jest domknięciem zbioru

$\{\mathbf{L}_* : \mathbf{L}'_* \mathbf{Y}$  jest jednoznacznie lokalnie optymalnym w punkcie z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o\}$ .

Zatem, na mocy twierdzenia 1.3, pierwsza część dowodu jest zakończona.

Warunek dostateczny udowodnimy w następujący sposób.

(1) Jeżeli  $a_i \in [0, 1)$  dla każdego  $i = 0, 1, \dots, k$ , to wówczas możemy sprawdzić, że  $\mathbf{L}' \mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie

$$\left( \sum_{i=1}^k \frac{a_i}{p_i(1-a_i)} \mathbf{V}_i + \mathbf{V}_{k+1}, \frac{a_0}{p_0(1-a_0)} \left( \sum_{i=1}^k \frac{a_i}{1-a_i} + 1 \right) \mathbf{X} \mathbf{X}' \right) \in [\mathcal{T}]$$

w klasie  $\mathcal{L}_o$  i oczywiście dopuszczalny dla  $\mathbf{K}' \mathbf{X} \beta$  w tej klasie.

(2) Jeżeli  $a_0 = 1$ , to wtedy  $\mathbf{X} \mathbf{X}' \mathbf{L} = \mathbf{X} \mathbf{X}' \mathbf{K}$ , czyli  $\mathbf{L}' \mathbf{Y}$  jest lokalnie optymalny w punkcie  $(\mathbf{0}, \mathbf{X} \mathbf{X}') \in [\mathcal{T}]$  w klasie  $\mathcal{L}_o$ , ale nie jest jednoznaczny. Zbiór

$\mathcal{B}(\mathbf{0}, \mathbf{X}\mathbf{X}')|\mathcal{L}_o$ ) możemy przedstawić w postaci

$$\mathcal{L}_1 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t),$$

gdzie

$$\mathbf{\Pi}_1 = \begin{bmatrix} I_n - E_0 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}.$$

Następnie, jeżeli  $\mathcal{I} = \emptyset$ , to mamy spełnione równanie  $\mathbf{\Pi}_1 W_1 \mathbf{L} = \mathbf{0}$ , gdzie  $W_1 = \sum_{i=1}^k \frac{a_i}{p_i(1-a_i)} \mathbf{V}_i + \mathbf{V}_{k+1}$ . Stąd  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $(W_1, \mathbf{0}) \in [\mathcal{T}]$ , a ponieważ  $\mathcal{R}(\mathbf{\Pi}_1 W_1 \mathbf{\Pi}_1) = \mathcal{R}(\mathbf{\Pi}_1)$ , więc  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$ .

Jeżeli  $\mathcal{I} \neq \emptyset$ , to biorąc  $(\sum_{i \in \mathcal{I}} \frac{1}{p_i} \mathbf{V}_i, \mathbf{0}) \in [\mathcal{T}]$  mamy  $\mathbf{\Pi}_1 (\sum_{i \in \mathcal{I}} \frac{1}{p_i} \mathbf{V}_i) \mathbf{L} = \mathbf{0}$ , co oznacza, że  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w tym punkcie w klasie  $\mathcal{L}_1$ , ale nie jest jednoznaczny. Rozmaitość liniowa  $\mathcal{B}((\sum_{i \in \mathcal{I}} \frac{1}{p_i} \mathbf{V}_i, \mathbf{0})|\mathcal{L})$  może być wyrażona następująco

$$\mathcal{L}_2 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t),$$

gdzie

$$\mathbf{\Pi}_2 = \begin{bmatrix} I_n - (E_0 + \sum_{i \in \mathcal{I}} E_i) & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}.$$

Ostatecznie, jeżeli weźmiemy punkt  $(W_1, \mathbf{0}) \in [\mathcal{T}]$ , gdzie  $W_1 = (\sum_{i \notin \mathcal{I}} \frac{a_i}{p_i(1-a_i)} \mathbf{V}_i + \mathbf{V}_{k+1})$ , to możemy sprawdzić, że  $\mathbf{\Pi}_2 W_1 \mathbf{L} = \mathbf{0}$ . Ponieważ  $\mathcal{R}(\mathbf{\Pi}_2 W_1 \mathbf{\Pi}_2) = \mathcal{R}(\mathbf{\Pi}_2)$ , więc  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$ .

(3) Załóżmy teraz, że  $a_0 \in [0, 1)$  oraz  $\mathcal{I} \neq \emptyset$ . Niech  $\mathcal{I}_1 = \{i \in \mathcal{I} : A_i > 0\}$

i niech  $\mathcal{I}_2 = \mathcal{I} \setminus \mathcal{I}_1$ . Oczywiście  $\sum_{i \in \mathcal{I}_1} A_i = 1$ . Biorąc punkt  $(\sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} \mathbf{V}_i, \frac{a_0}{p_0(1-a_0)} \mathbf{X}\mathbf{X}')$

dostajemy, że

$$\mathbf{\Pi}_o \left[ \sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} \mathbf{V}_i + \frac{a_0}{p_0(1-a_0)} \mathbf{X} \mathbf{X}' \right] \mathbf{L} = \frac{a_0}{p_0(1-a_0)} \mathbf{\Pi}_o \mathbf{X} \mathbf{X}' \mathbf{K}.$$

Rzeczywiście,

$$\begin{aligned} & \left[ \sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} Z_i Z_i' + \frac{a_0}{p_0(1-a_0)} Z_0 Z_0' \right] L_0(a_0) \\ &= \left[ \sum_{i \in \mathcal{I}_1} A_i (E_0 + E_i) + \frac{a_0}{1-a_0} E_0 \right] a_0 E_0 K = \left( \sum_{i \in \mathcal{I}_1} A_i + \frac{a_0}{1-a_0} \right) a_0 E_0 K \\ &= \left( 1 + \frac{a_0}{1-a_0} \right) a_0 E_0 K = \frac{a_0}{1-a_0} E_0 K = \frac{a_0}{p_0(1-a_0)} \mathbf{X} \mathbf{X}' \mathbf{K}, \end{aligned}$$

$$\begin{aligned} & \left[ \sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} Z_i Z_i' + \frac{a_0}{p_0(1-a_0)} Z_0 Z_0' \right] L_j(a_j, A_j) - \frac{A_j}{p_j} Z_j Z_j' Q_j \\ &= \left[ \sum_{i \in \mathcal{I}_1} A_i (E_0 + E_i) + \frac{a_0}{1-a_0} E_0 \right] [E_j + (1-a_0) A_j E_0] Q_j - A_j (E_0 + E_j) Q_j \\ &= \left[ A_j E_j + (1-a_0) A_j \sum_{i \in \mathcal{I}_1} A_i E_0 + a_0 A_j E_0 \right] Q_j - A_j (E_0 + E_j) Q_j \\ &= [A_j E_j + (1-a_0) A_j E_0 + a_0 A_j E_0] Q_j - A_j (E_0 + E_j) Q_j = \mathbf{0}, \text{ dla } j \in \mathcal{I}_1 \end{aligned}$$

oraz

$$\begin{aligned} & \left[ \sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} Z_i Z_i' + \frac{a_0}{p_0(1-a_0)} Z_0 Z_0' \right] L_j(a_j, A_j) \\ &= \left[ \sum_{i \in \mathcal{I}_1} A_i (E_0 + E_i) + \frac{a_0}{1-a_0} E_0 \right] a_j E_j Q_j = \mathbf{0}, \text{ w przeciwnym razie.} \end{aligned}$$

Stąd wynika, że  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $W$  w klasie  $\mathcal{L}_0$  oraz, że zbiór  $\mathcal{B}(\left(\sum_{i \in \mathcal{I}_1} \frac{A_i}{p_i} \mathbf{V}_i, \frac{a_0}{p_0(1-a_0)} \mathbf{X} \mathbf{X}'\right) | \mathcal{L}_o)$  możemy przedstawić w następujący sposób

$$\mathcal{L}_1 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t),$$

gdzie

$$\mathbf{\Pi}_1 = \begin{bmatrix} I_n - (E_0 + \sum_{i \in \mathcal{I}_1} E_i) & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}.$$

Biorąc punkt  $(\sum_{i \in \mathcal{I}_2} \frac{1}{p_i} \mathbf{V}_i, \mathbf{0}) \in [T]$  dostajemy  $\mathbf{\Pi}_1(\sum_{i \in \mathcal{I}_2} \frac{1}{p_i} \mathbf{V}_i) \mathbf{L} = \mathbf{0}$ . Zatem  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w tym punkcie w klasie  $\mathcal{L}$ . Zbiór  $\mathcal{B}((\sum_{i \in \mathcal{I}_2} \frac{1}{p_i} \mathbf{V}_i, \mathbf{0}) | \mathcal{L}_1) \neq \{\mathbf{L}\}$  może być wyrażony w postaci

$$\mathcal{L}_2 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t),$$

gdzie

$$\mathbf{\Pi}_2 = \begin{bmatrix} I_n - (E_0 + \sum_{i \in \mathcal{I}} E_i) & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}.$$

Dalej możemy sprawdzić, że  $\mathbf{\Pi}_2(\sum_{i \notin \mathcal{I}} \frac{a_i}{p_i(1-a_i)} \mathbf{V}_i + \mathbf{V}_{k+1}) \mathbf{L} = \mathbf{0}$  jak również, że  $\mathbf{L}$  jest jedynym rozwiązaniem tego równania. To z kolei implikuje, że  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny w klasie  $\mathcal{L}_o$ , co kończy dowód.  $\square$

W modelu (2.6), w odróżnieniu od modelu (2.5), wystarczy wykonać co najwyżej trzy kroki, ponieważ liczba kroków determinowana jest nie tylko liczbą tych spośród współczynników  $a_i$ , które są równe 1, ale przede wszystkim postacią współczynników  $A_i$ .

### 3.3. Zrównoważony model losowy dwukierunkowej klasyfikacji krzyżowej z interakcją

W tym podrozdziale opiszemy klasę estymatorów dopuszczalnych dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na zbiorze parametrów  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (2.7). Estymatory te będą wyrażone jako kombinacje liniowe następujących macierzy

$$\begin{aligned} E_0 &= \frac{1}{p_0} Z_0 Z_0', \\ E_1 &= \frac{1}{p_1} Z_1 Z_1' - E_0, \\ E_2 &= \frac{1}{p_2} Z_2 Z_2' - E_0, \\ E_3 &= \frac{1}{p_3} Z_3 Z_3' - (E_0 + E_1 + E_2), \end{aligned}$$

gdzie  $Z_0 = \mathbf{1}_n, p_0 = n, p_1 = n_2 n_3, p_2 = n_1 n_3$ , natomiast  $p_3 = n_3$ . Oczywiście  $E_0, E_1, E_2$  oraz  $E_3$  są macierzami idempotentnymi i ortogonalnymi, a macierze  $Z_i Z_i'$  są ich liniowymi kombinacjami dla  $i = 0, 1, 2, 3$ . Aby skrócić zapis niektórych wzorów przyjmijmy jeszcze, że  $Z_4 = I_n, E_4 = I_n - (E_0 + E_1 + E_2 + E_3)$  oraz  $p_4 = 1$ .

**Lemat 3.3.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $(\sum_{i=1}^4 s_i \mathbf{V}_i, s_0 \mathbf{X}\mathbf{X}')$  z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$  w modelu (2.4) odpowiadającym modelowi (2.7) wtedy i tylko wtedy, gdy  $s_0 \geq 0, s_1 \geq 0, s_2 \geq 0, s_3 \geq 0, s_4 > 0$  oraz*

$$\mathbf{L} = \begin{bmatrix} L_0 & L_1 & L_2 & L_3 \\ \mathbf{0} & -Q_1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & -Q_2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & -Q_3 \end{bmatrix}, \quad (3.7)$$

gdzie

$$\begin{aligned}
L_0 &= a_0 E_0 K, \\
L_1 &= a_1 \left[ E_1 + (1 - a_0) \frac{\frac{1}{1-a_1}}{\frac{1}{1-a_1} + \frac{1}{1-a_2} - 1} E_0 \right] Q_1, \\
L_2 &= a_2 \left[ E_2 + (1 - a_0) \frac{\frac{1}{1-a_2}}{\frac{1}{1-a_1} + \frac{1}{1-a_2} - 1} E_0 \right] Q_2, \\
L_3 &= a_3 \left[ E_3 + (1 - a_2) E_2 + (1 - a_1) E_1 + (1 - a_0) \frac{1}{\frac{1}{1-a_1} + \frac{1}{1-a_2} - 1} E_0 \right] Q_3
\end{aligned}$$

oraz

$$a_0 = \frac{s_0 p_0}{s_0 p_0 + s_1 p_1 + s_3 p_3 + s_4}, \quad (3.8)$$

$$a_1 = \frac{s_1 p_1}{s_1 p_1 + s_3 p_3 + s_4}, \quad (3.9)$$

$$a_2 = \frac{s_2 p_2}{s_2 p_2 + s_3 p_3 + s_4}, \quad (3.10)$$

$$a_3 = \frac{s_3 p_3}{s_3 p_3 + s_4}. \quad (3.11)$$

**Dowód.** Niech  $\left( \sum_{i=1}^4 s_i \mathbf{V}_i, s_0 \mathbf{X} \mathbf{X}' \right)$  będzie punktem z  $[T]$  takim, że  $s_0 \geq 0, s_1 \geq 0, s_2 \geq 0, s_3 \geq 0$  oraz  $s_4 \geq 0$ . Estymator  $\mathbf{L}'\mathbf{Y}$ , gdzie macierz  $\mathbf{L}$  dana jest wzorem (3.7), jest jednoznacznie lokalnie optymalny wtedy i tylko wtedy, gdy  $s_4 > 0$  oraz

$$\begin{aligned}
L_0 &= s_0 M^{-1} \mathbf{X} \mathbf{X}' K, \\
L_i &= s_i M^{-1} Z_i Z_i' Q_i \quad \text{dla } i = 1, 2, 3,
\end{aligned}$$

gdzie

$$\begin{aligned}
M = \sum_{i=0}^4 s_i Z_i Z_i' &= \left( \sum_{i=0}^4 s_i p_i \right) E_0 + (s_1 p_1 + s_3 p_3 + s_4) E_1 \\
&\quad + (s_2 p_2 + s_3 p_3 + s_4) E_2 + (s_3 p_3 + s_4 p_4) E_3 + s_4 p_4 E_4.
\end{aligned}$$

Zatem

$$\begin{aligned}
L_0 &= \frac{s_0 p_0}{\sum_{j=0}^4 s_j p_j} E_0 K, \\
L_1 &= \frac{s_1 p_1}{s_1 p_1 + s_3 p_3 + s_4} \left( E_1 + \frac{s_1 p_1 + s_3 p_3 + s_4}{\sum_{j=0}^4 s_j p_j} E_0 \right) Q_1, \\
L_2 &= \frac{s_2 p_2}{s_2 p_2 + s_3 p_3 + s_4} \left( E_2 + \frac{s_2 p_2 + s_3 p_3 + s_4}{\sum_{j=0}^4 s_j p_j} E_0 \right) Q_2,
\end{aligned}$$

natomiast

$$L_3 = \frac{s_3 p_3}{s_3 p_3 + s_4} \left( E_3 + \frac{s_3 p_3 + s_4}{s_2 p_2 + s_3 p_3 + s_4} E_2 + \frac{s_3 p_3 + s_4}{s_1 p_1 + s_3 p_3 + s_4} E_1 + \frac{s_3 p_3 + s_4}{\sum_{j=0}^4 s_j p_j} E_0 \right) Q_3.$$

Następnie, w przypadku macierzy  $L_1, L_2$  oraz  $L_3$  stosujemy dla współczynników stojących przy macierzy  $E_0$  przekształcenia, które zostały omówione w dowodzie lematu 3.4.  $\square$

**Twierdzenie 3.3.** *Estymator  $L'Y$  jest dopuszczalny dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (2.7) wtedy i tylko wtedy, gdy*

$$L \in \left\{ \left[ \begin{array}{cccc} L_0(a_0) & L_1(a_1, A_1) & L_2(a_2, A_2) & L_3(a_3, A_1, A_2) \\ \mathbf{0} & -Q_1 & \mathbf{0} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & -Q_2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \mathbf{0} & -Q_3 \end{array} \right] : a_i \in [0, 1], i = 0, 1, 2, 3 \right\}, \quad (3.12)$$

gdzie

$$L_0(a_0) = a_0 E_0 K,$$

$$L_1(a_1, A_1) = a_1 [E_1 + (1 - a_0) A_1 E_0] Q_1,$$

$$L_2(a_2, A_2) = a_2 [E_2 + (1 - a_0) A_2 E_0] Q_2,$$

$$L_3(a_3, A_1, A_2) = a_3 [E_3 + (1 - a_2) E_2 + (1 - a_1) E_1 + (1 - a_0) (A_1 + A_2 - 1) E_0] Q_3$$

oraz

$$A_1 = \frac{\frac{1}{1-a_1}}{\frac{1}{1-a_1} + \frac{1}{1-a_2} - 1}, \quad (3.13)$$

$$A_2 = \frac{\frac{1}{1-a_2}}{\frac{1}{1-a_1} + \frac{1}{1-a_2} - 1} \quad (3.14)$$

dla  $a_1 \in [0, 1)$  i  $a_2 \in [0, 1)$ ,

w przeciwnym razie

$A_1$  i  $A_2$  są nieujemnymi liczbami takimi, że  $A_1 + A_2 = 1$ , przy czym  $A_1 = 0$ , gdy  $a_1 \in [0, 1)$  oraz  $A_2 = 0$ , gdy  $a_2 \in [0, 1)$ .

**Dowód.** Warunek konieczny. Zauważmy, że współczynniki  $a_0, a_1, a_2$  oraz  $a_3$  określone odpowiednio wzorami (3.8), (3.9), (3.10) oraz (3.11) przyjmują każdą wartość z przedziału  $[0, 1)$  przy odpowiednio dobranych  $s_0 \geq 0, s_1 \geq 0, s_2 \geq 0, s_3 \geq 0$  oraz  $s_4 > 0$ . Dalej, możemy sprawdzić, że dla  $A_1$  i  $A_2$  danych formułami (3.13) i (3.14) mamy, że  $1 < A_1 + A_2 \leq 2$ . Ponieważ  $\frac{1}{1-a_1} + \frac{1}{1-a_2} \rightarrow +\infty$ , gdy  $a_1 \rightarrow 1$  lub  $a_2 \rightarrow 1$ , więc  $A_1 + A_2 \rightarrow 1$  oraz  $A_i \rightarrow 0$  dla tego wskaźnika  $i$ , dla którego  $a_i \in [0, 1)$ . Stąd wynika, że zbiór (3.12) jest domknięciem zbioru

$\{\mathbf{L}_* : \mathbf{L}'_* \mathbf{Y}$  jest jednoznacznie lokalnie optymalnym w punkcie z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o\}$ .

Zatem na mocy twierdzenia 1.3 pierwsza część dowodu jest zakończona.

Warunek dostateczny. Podobnie, jak w przypadku twierdzeń 3.1 oraz 3.2, stosując metodę LaMotte'a wskażemy punkty należące do  $[\mathcal{T}]$ , w których estymatory  $\mathbf{L}'\mathbf{Y}$  z klasy (3.12) są lokalnie optymalne w odpowiednich rozmaitoś-



ciach liniowych  $\mathcal{L} \subseteq \mathcal{L}_o$ . Tak, jak w modelach (2.5) oraz (2.6) liczba kroków będzie zależała od tego, które i ile spośród współczynników  $a_i$  są równe 1. Ponieważ w modelu (2.7) występują cztery takie współczynniki, więc mamy do rozpatrzenia 16 różnych przypadków. Opiszemy 6 z nich, gdyż dla pozostałych dowód będzie analogiczny do dowodu twierdzenia 3.1 bądź 3.2. Ograniczymy się przy tym do podania kolejnych punktów i rozmaitości liniowych, ponieważ sposób postępowania został już wielokrotnie wcześniej opisany.

- (1) Jeżeli  $a_i \in [0, 1)$  dla każdego  $i = 0, 1, 2, 3$ , to wówczas możemy sprawdzić, że  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $W = (W_1, W_2) \in [T]$ , gdzie

$$W_1 = \frac{a_1}{p_1(1-a_1)(1-a_3)}\mathbf{V}_1 + \frac{a_2}{p_2(1-a_2)(1-a_3)}\mathbf{V}_2 + \frac{a_3}{p_3(1-a_3)}\mathbf{V}_3 + \mathbf{V}_4,$$

$$W_2 = \frac{a_0}{p_0(1-a_0)(1-a_3)} \left[ \frac{a_1}{(1-a_1)} + \frac{a_2}{(1-a_2)} + 1 \right] \mathbf{X}\mathbf{X}',$$

w klasie  $\mathcal{L}_o$  i oczywiście dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w tej klasie.

- (2) Jeżeli  $a_0 = 1, a_1 \in [0, 1), a_2 \in [0, 1), a_3 = 1$ , to

(k0)

$$W^{(0)} = (\mathbf{0}, \mathbf{X}\mathbf{X}'),$$

$$\mathcal{L}_1 = \mathcal{B}(W^{(0)}|\mathcal{L}_o) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t),$$

gdzie

$$\mathbf{\Pi}_1 = \begin{bmatrix} \mathbf{\Pi}_1 & \mathbf{0} & \cdots & \mathbf{0} \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{0} & \mathbf{0} & \cdots & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{(k+1)n \times (k+1)n}, \quad \mathbf{\Pi}_1 = I_n - E_0,$$

(k1)

$$\begin{aligned}W^{(1)} &= \left( \frac{a_1}{p_1(1-a_1)} \mathbf{V}_1 + \frac{a_2}{p_2(1-a_2)} \mathbf{V}_2 + \frac{1}{p_3} \mathbf{V}_3, \mathbf{0} \right), \\ \mathcal{L}_2 &= \mathcal{B}(W^{(1)} | \mathcal{L}_1) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t), \\ \Pi_2 &= E_4,\end{aligned}$$

(k2)

$$\begin{aligned}W^{(2)} &= (\mathbf{V}_4, \mathbf{0}), \\ \mathcal{L}_3 &= \mathcal{B}(W^{(2)} | \mathcal{L}_2) = \{\mathbf{L}\}.\end{aligned}$$

(3) Jeżeli  $a_0 = 1, a_1 \in [0, 1), a_2 = 1, a_3 = 1$ , to

(k0)

$$\begin{aligned}W^{(0)} &= (\mathbf{0}, \mathbf{X}\mathbf{X}'), \\ \mathcal{L}_1 &= \mathcal{B}(W^{(0)} | \mathcal{L}_o) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t), \\ \Pi_1 &= I_n - E_0,\end{aligned}$$

(k1)

$$\begin{aligned}W^{(1)} &= \left( \frac{1}{p_2} \mathbf{V}_2, \mathbf{0} \right), \\ \mathcal{L}_2 &= \mathcal{B}(W^{(1)} | \mathcal{L}_1) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t), \\ \Pi_2 &= E_1 + E_3 + E_4,\end{aligned}$$

(k2)

$$\begin{aligned}W^{(2)} &= \left( \frac{a_1}{p_1(1-a_1)} \mathbf{V}_1 + \frac{1}{p_3} \mathbf{V}_3, \mathbf{0} \right), \\ \mathcal{L}_3 &= \mathcal{B}(W^{(2)} | \mathcal{L}_2) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_3}^t), \\ \Pi_3 &= E_4,\end{aligned}$$

**(k3)**

$$\begin{aligned}W^{(3)} &= (\mathbf{V}_4, \mathbf{0}), \\ \mathcal{L}_4 &= \mathcal{B}(W^{(3)}|\mathcal{L}_3) = \{\mathbf{L}\}.\end{aligned}$$

(4) Jeżeli  $a_0 \in [0, 1), a_1 \in [0, 1), a_2 \in [0, 1), a_3 = 1$ , to

**(k0)**

$$W^{(0)} = \left( W_1^{(0)}, W_2^{(0)} \right),$$

gdzie

$$\begin{aligned}W_1^{(0)} &= \frac{a_1}{p_1(1-a_1)}\mathbf{V}_1 + \frac{a_2}{p_2(1-a_2)}\mathbf{V}_2 + \frac{1}{p_3}\mathbf{V}_3, \\ W_2^{(0)} &= \frac{a_0}{p_0(1-a_0)}\left(\frac{a_1}{(1-a_1)} + \frac{a_2}{(1-a_2)} + 1\right)\mathbf{X}\mathbf{X}', \\ \mathcal{L}_1 &= \mathcal{B}(W^{(0)}|\mathcal{L}_o) = \mathbf{L} + \mathcal{R}(T_{\Pi_1}^t), \\ \Pi_1 &= E_4,\end{aligned}$$

**(k1)**

$$\begin{aligned}W^{(1)} &= (\mathbf{V}_4, \mathbf{0}), \\ \mathcal{L}_2 &= \mathcal{B}(W^{(1)}|\mathcal{L}_1) = \{\mathbf{L}\}.\end{aligned}$$

(5) Jeżeli  $a_0 \in [0, 1), a_1 \in [0, 1), a_2 = 1, a_3 = 1$ , to

**(k0)**

$$\begin{aligned}W^{(0)} &= \left( \frac{1}{p_2}\mathbf{V}_2, \frac{a_0}{p_0(1-a_0)}\mathbf{X}\mathbf{X}' \right), \\ \mathcal{L}_1 &= \mathcal{B}(W^{(0)}|\mathcal{L}_o) = \mathbf{L} + \mathcal{R}(T_{\Pi_1}^t), \\ \Pi_1 &= E_1 + E_3 + E_4,\end{aligned}$$

(k1)

$$\begin{aligned}W^{(1)} &= \left( \frac{a_1}{p_1(1-a_1)} \mathbf{V}_1 + \frac{1}{p_3} \mathbf{V}_3, \mathbf{0} \right), \\ \mathcal{L}_2 &= \mathcal{B}(W^{(1)} | \mathcal{L}_1) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t), \\ \mathbf{\Pi}_2 &= E_4,\end{aligned}$$

(k2)

$$\begin{aligned}W^{(2)} &= (\mathbf{V}_4, \mathbf{0}), \\ \mathcal{L}_3 &= \mathcal{B}(W^{(2)} | \mathcal{L}_2) = \{\mathbf{L}\}.\end{aligned}$$

(6) Jeżeli  $a_0 \in [0, 1)$ ,  $a_1 = 1$ ,  $a_2 \in [0, 1)$ ,  $a_3 = 1$ , to

(k0)

$$\begin{aligned}W^{(0)} &= \left( \frac{1}{p_1} \mathbf{V}_1 +, \frac{a_0}{p_0(1-a_0)} \mathbf{X} \mathbf{X}' \right), \\ \mathcal{L}_1 &= \mathcal{B}(W^{(0)} | \mathcal{L}_o) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t), \\ \mathbf{\Pi}_1 &= E_2 + E_3 + E_4,\end{aligned}$$

(k1)

$$\begin{aligned}W^{(1)} &= \left( \frac{a_2}{p_2(1-a_2)} \mathbf{V}_2 + \frac{1}{p_3} \mathbf{V}_3, \mathbf{0} \right), \\ \mathcal{L}_2 &= \mathcal{B}(W^{(1)} | \mathcal{L}_1) = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t), \\ \mathbf{\Pi}_2 &= E_4,\end{aligned}$$

(k2)

$$\begin{aligned}W^{(2)} &= (\mathbf{V}_4, \mathbf{0}), \\ \mathcal{L}_3 &= \mathcal{B}(W^{(2)} | \mathcal{L}_2) = \{\mathbf{L}\}.\end{aligned}$$

- (7) Jeżeli  $a_0 = 1, a_1 = 1, a_2 \in [0, 1], a_3 \in [0, 1]$ , to postępujemy tak, jak w dowodzie twierdzenia 3.1.
- (8) W pozostałych przypadkach postępujemy podobnie, jak w dowodzie twierdzenia 3.2. W kolejnych krokach wskazujemy punkty, dla których współczynniki stojące przy macierzach  $\mathbf{V}_1, \dots, \mathbf{V}_4$  oraz  $\mathbf{X}\mathbf{X}'$  są odpowiednimi modyfikacjami tychże współczynników z dowodu twierdzenia 3.2, określających punkt, w którym  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w klasie  $\mathcal{L}_o$ .

□

# 4. Jawna charakterystyka estymatorów dopuszczalnych w pewnym modelu liniowym z dwoma komponentami

Nasze rozważania dotyczące dopuszczalności zostaną teraz ograniczone do pewnego modelu z dwoma komponentami. Model ten jest szczególnym przypadkiem modelu (2.1), dla którego  $k = 1$  oraz  $\beta \in \mathbb{R}$ , a macierz  $Z_1 Z_1'$  jest macierzą proporcjonalną do macierzy idempotentnej, tzn. że  $(Z_1 Z_1')^2 = p_1 Z_1 Z_1'$ , gdzie  $p_1$  jest dodatnią liczbą rzeczywistą. Będziemy go oznaczać następująco

$$Y \sim (X\beta, \sigma_1^2 Z_1 Z_1' + \sigma_2^2 I_n). \quad (4.1)$$

Przykładami powyższego modelu są modele (2.8) oraz (2.9). Podamy warunki konieczne i dostateczne na to, aby estymator liniowy był dopuszczalny dla wektora  $[(K'X\beta)', (Q_1'Z_1u_1)']'$  w modelu (4.1). Na mocy lematu 2.1 wyrazimy je w terminach macierzy określających model (2.4), który odpowiada rozważanemu modelowi z dwoma komponentami. Rozpatrzmy dwa przypadki, gdy  $X \in \mathcal{R}(Z_1)$  oraz  $X \notin \mathcal{R}(Z_1)$ . Dla wygody wyrażmy wektor  $X$  w postaci  $X_1 + X_2$ , gdzie  $X_1 \in \mathcal{R}(Z_1)$  natomiast  $X_2 \in \mathcal{N}(Z_1')$ .

## 4.1. Przypadek, gdy $X \in \mathcal{R}(Z_1)$

W tym podrozdziale zajmiemy się dopuszczalnością liniowych estymatorów  $L'Y$  dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  w modelu (2.4), który odpowiada modelowi (4.1) w przypadku, gdy  $X = X_1$ . Ponieważ zakładamy także, że  $(Z_1Z_1')^2 = p_1Z_1Z_1'$ , więc możemy przedstawić macierze  $XX'$ ,  $Z_1Z_1'$  oraz  $I_n$  jako kombinacje liniowe następujących ortogonalnych i idempotentnych macierzy

$$\begin{aligned} E_0 &= \frac{1}{X'X}XX', \\ E_1 &= \frac{1}{p_1}Z_1Z_1' - E_0 \end{aligned}$$

oraz

$$E_2 = I_n - \frac{1}{p_1}Z_1Z_1'.$$

Tak, jak poprzednio, niech  $p_0 = X'X$ ,  $Z_0 = X$ ,  $p_2 = 1$  oraz  $Z_2 = I_n$ . Zaczniemy od sformułowania lematu, który podaje postać estymatorów jednoznacznie lokalnie optymalnych, a następnie, powołując się na twierdzenie 1.3, wyrazimy w jawnej postaci klasę estymatorów dopuszczalnych dla wspomnianej już funkcji parametru  $\beta$ .

**Lemat 4.1.** *Niech  $X = X_1 \neq \mathbf{0}$ . Estymator  $L'Y$  jest jednoznacznie lokalnie optymalny w punkcie  $(s_1V_1 + s_2V_2, s_0XX')$  należącym do  $[T]$  w klasie  $\mathcal{L}_o$  w modelu (2.4) odpowiadającym modelowi (4.1) wtedy i tylko wtedy, gdy  $s_0 \geq$*

*0,  $s_1 \geq 0$ ,  $s_2 > 0$  oraz  $L = \begin{bmatrix} L_0 & L_1 \\ \mathbf{0} & -Q_1 \end{bmatrix}$ , gdzie*

$$L_0 = a_0E_0K,$$

$$L_1 = a_1(E_1 - (1 - a_0)E_0)Q_1$$

oraz

$$\begin{aligned} a_0 &= \frac{s_0p_0}{s_0p_0 + s_1p_1 + s_2p_2}, \\ a_1 &= \frac{s_1p_1}{s_1p_1 + s_2p_2}. \end{aligned} \tag{4.2}$$

**Dowód.** Dowód jest anologiczny do dowodu lematu 3.1 bądź 3.4 dla  $k = 1$ .  $\square$

**Twierdzenie 4.1.** *Niech  $X = X_1 \neq \mathbf{0}$ . Estymator  $L'Y$  jest dopuszczalny dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (4.1) wtedy i tylko wtedy, gdy*

$$L \in \left\{ \left[ \begin{array}{cc} L_0(a_0) & L_1(a_0, a_1) \\ \mathbf{0} & -Q_1 \end{array} \right] : a_0 \in [0, 1], a_1 \in [0, 1] \right\},$$

gdzie

$$\begin{aligned} L_0(a_0) &= a_0 E_0 K, \\ L_1(a_0, a_1) &= a_1 (E_1 - (1 - a_0) E_0) Q_1. \end{aligned}$$

**Dowód.** Dowód jest anologiczny do dowodu twierdzenia 3.1 bądź 3.2 dla  $k = 1$ .

$\square$

Podstawiając za  $E_0$  i  $E_1$  odpowiednio macierze  $\frac{1}{X'X}XX'$  oraz  $\frac{1}{p_1}Z_1Z_1' - E_0$ , uzyskujemy następujący wniosek.

**Wniosek 4.1.** *Niech  $X = X_1 \neq \mathbf{0}$ . Estymator  $L'Y$  jest dopuszczalny dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (4.1) wtedy i tylko wtedy, gdy*

$$L \in \left\{ \left[ \begin{array}{cc} L_0(a_0) & L_1(a_0, a_1) \\ \mathbf{0} & -Q_1 \end{array} \right] : a_0 \in [0, 1], a_1 \in [0, 1] \right\},$$

gdzie

$$L_0(a_0) = \frac{a_0}{X'X}XX'K, \tag{4.3}$$

$$L_1(a_0, a_1) = a_1 \left( \frac{1}{p_1}Z_1Z_1' - \frac{a_0}{X'X}XX' \right) Q_1. \tag{4.4}$$



Dla uzupełnienia naszych rozważań rozpatrzmy także przypadek, gdy  $X = \mathbf{0}$ .

**Twierdzenie 4.2.** *Niech  $X = \mathbf{0}$ . Estymator  $L'Y$  jest dopuszczalny dla  $\mathbf{0}$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w odpowiednim modelu (2.4) wtedy i tylko wtedy, gdy*

$$\mathbf{L} \in \left\{ \begin{bmatrix} \mathbf{0} & L_1(a_1) \\ \mathbf{0} & -Q_1 \end{bmatrix} : a_1 \in [0, 1] \right\},$$

gdzie

$$L_1(a_1) = \frac{a_1}{p_1} Z_1 Z_1' Q_1.$$

## 4.2. Przypadek, gdy $X \notin \mathcal{R}(Z_1)$

Jeżeli pominiemy założenie, że  $X \in \mathcal{R}(Z_1)$ , to uzyskamy wówczas inne postaci estymatorów jednoznacznie lokalnie optymalnych, a tym samym inne postaci estymatorów dopuszczalnych dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (4.1). Bowiemy, gdy  $X_2 \neq \mathbf{0}$ , to nie możemy macierzy  $XX'$ ,  $Z_1 Z_1'$  oraz  $I_n$  przedstawić w postaci pewnych kombinacji liniowych macierzy ortogonalnych i idempotentnych.

**Lemat 4.2.** *Niech  $X_2 \neq \mathbf{0}$ . Estymator  $L'Y$  jest jednoznacznie lokalnie optymalny w punkcie  $(s_1 \mathbf{V}_1 + s_2 \mathbf{V}_2, s_0 \mathbf{X} \mathbf{X}')$  należącym do  $[T]$  w klasie  $\mathcal{L}_o$  w modelu (2.4) odpowiadającym modelowi (4.1) wtedy i tylko wtedy, gdy  $s_0 \geq 0, s_1 \geq 0,$*

*$s_2 > 0$  oraz  $\mathbf{L} = \begin{bmatrix} L_0 & L_1 \\ \mathbf{0} & -Q_1 \end{bmatrix}$ , gdzie*

$$\begin{aligned} L_0 &= \frac{a_0}{X'X} \left[ X_1 X_1' + X_1 X_2' + \frac{1}{1-a_1} (X_2 X_1' + X_2 X_2') \right] K, \\ L_1 &= a_1 \left[ \frac{1}{p_1} Z_1 Z_1' - \frac{a_0}{X'X} X_1 X_1' - \frac{a_0}{(1-a_1)X'X} X_2 X_1' \right] Q_1 \end{aligned}$$

oraz

$$a_0 = \frac{s_0(1-a_1)X'X}{s_2 + s_0[(1-a_1)X'X + a_1 X_2' X_2]}, \quad (4.5)$$

natomiast  $a_1$  wyraża się wzorem (4.2).

**Dowód.** Tak jak w dowodzie lematów 3.1, 3.4 oraz 3.3 mamy, że estymator  $\mathbf{L}'\mathbf{Y} = \begin{bmatrix} L_0 & L_1 \\ \mathbf{0} & -Q_1 \end{bmatrix}' \mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $(s_1\mathbf{V}_1 + s_2\mathbf{V}_2, s_0\mathbf{X}\mathbf{X}')$  ze zbioru  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$  wtedy i tylko wtedy, gdy  $s_2 > 0$  oraz

$$\begin{aligned} L_0 &= s_0 M^{-1} \mathbf{X}\mathbf{X}'\mathbf{K}, \\ L_1 &= s_1 M^{-1} \mathbf{Z}_1\mathbf{Z}_1'Q_1, \end{aligned}$$

gdzie  $M = s_0\mathbf{X}\mathbf{X}' + s_1\mathbf{Z}_1\mathbf{Z}_1' + s_2I_n$ .

Wykorzystując równości

$$\begin{aligned} \mathbf{Z}_1\mathbf{Z}_1'\mathbf{X}\mathbf{X}' &= p(\mathbf{X}_1\mathbf{X}_1' + \mathbf{X}_1\mathbf{X}_2'), \\ \mathbf{X}\mathbf{X}'\mathbf{X}_1\mathbf{X}_1' &= \mathbf{X}_1'\mathbf{X}_1(\mathbf{X}_1\mathbf{X}_1' + \mathbf{X}_2\mathbf{X}_1') \end{aligned}$$

oraz

$$\mathbf{X}\mathbf{X}'\mathbf{X}_2\mathbf{X}_2' = \mathbf{X}_2'\mathbf{X}_2(\mathbf{X}_1\mathbf{X}_2' + \mathbf{X}_2\mathbf{X}_2'),$$

można sprawdzić, że

$$M^{-1} = -c \left( \mathbf{X}\mathbf{X}' - \frac{s_1 p_1}{s_1 p_1 + s_2} \mathbf{X}_1\mathbf{X}_1' + \frac{s_1 p_1}{s_2} \mathbf{X}_2\mathbf{X}_2' \right) + \frac{-s_1}{s_2(s_1 p_1 + s_2)} \mathbf{Z}_1\mathbf{Z}_1' + \frac{1}{s_2} I_n,$$

gdzie

$$c = \frac{s_0}{s_2(s_1 p_1 + s_2) + s_0(s_2 \mathbf{X}'\mathbf{X} + s_1 p_1 \mathbf{X}_2'\mathbf{X}_2)}.$$

Mało skomplikowane przekształcenia kończą dowód.  $\square$

**Twierdzenie 4.3.** *Niech  $\mathbf{X}_2 \neq \mathbf{0}$ . Estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (4.1) wtedy i tylko wtedy, gdy*

$$\mathbf{L} \in \left\{ \begin{bmatrix} L_0(a_0) & L_1(a_0, a_1) \\ \mathbf{0} & -Q_1 \end{bmatrix} : a_0 \in \left[ 0, \frac{(1-a_1)\mathbf{X}'\mathbf{X}}{(1-a_1)\mathbf{X}'\mathbf{X} + a_1\mathbf{X}_2'\mathbf{X}_2} \right], a_1 \in [0, 1] \right\}, \quad (4.6)$$

gdzie

$$\begin{aligned} L_0(a_0, a_1) &= \frac{a_0}{X'X}(X_1X'_1 + X_1X'_2)K + A(X_2X'_1 + X_2X'_2)K, \\ L_1(a_0, a_1) &= a_1 \left( \frac{1}{p_1}Z_1Z'_1 - \frac{a_0}{X'X}X_1X'_1 \right) Q_1 - a_1AX_2X'_1Q_1 \end{aligned}$$

oraz  $A = \frac{a_0}{(1-a_1)X'X}$  dla  $a_1 \in [0, 1)$ , w przeciwnym razie  $A = 0$ .

**Dowód.** Aby udowodnić warunek konieczny, zauważmy, że dla każdych ustalonych  $s_1 \geq 0, s_2 > 0$  współczynnik  $a_0$  dany wyrażeniem (4.5) przebiega przedział  $\left[0, \frac{(1-a_1)X'X}{(1-a_1)X'X+a_1X'_2X_2}\right)$ , gdy  $s_0 \in [0, +\infty)$ . Co więcej, dla  $a_1 \rightarrow 1$  mamy  $\frac{a_0}{1-a_1} \rightarrow 0$ . Podobnie jak poprzednio, korzystając z lematu 4.2, otrzymujemy, że zbiór określony wzorem (4.6) jest domknięciem zbioru

$\{\mathbf{L}_* : \mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalnym w punkcie z  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o\}$ ,

co na mocy twierdzenia 1.3 kończy dowód warunku koniecznego.

Załóżmy teraz, że  $\mathbf{L}'\mathbf{Y}$  jest estymatorem, dla którego macierz  $\mathbf{L}$  należy do zbioru (4.6). Jeżeli  $a_0 \in \left[0, \frac{(1-a_1)X'X}{(1-a_1)X'X+a_1X'_2X_2}\right)$  oraz  $a_1 \in [0, 1)$ , to wówczas estymator  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie


$$\left( \frac{a_1}{p_1(1-a_1)}\mathbf{V}_1 + \mathbf{V}_2, \frac{a_0}{(1-a_0)(1-a_1)X'X - a_0a_1X'_2X_2}\mathbf{X}\mathbf{X}' \right)$$

należącym do  $[\mathcal{T}]$  w klasie  $\mathcal{L}_o$ . Dla  $a_0 = \frac{(1-a_1)X'X}{(1-a_1)X'X+a_1X'_2X_2}$  oraz  $a_1 \in [0, 1)$  dowód przebiega tak samo, jak dowód twierdzenia 3.2, kiedy  $a_0 = 1$  i  $a_1 \in [0, 1)$ . Podobnie, w przypadku gdy  $a_0 = 0$  oraz  $a_1 = 1$ , który odpowiada sytuacji kiedy  $a_0 = 1$  i  $a_1 = 1$  w dowodzie twierdzenia 3.2 z tą tylko różnicą, że  $\mathbf{\Pi}_2 = \begin{bmatrix} \mathbf{\Pi}_2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$ , natomiast  $\mathbf{\Pi}_2$  jest macierzą rzutu ortogonalnego na przestrzeń  $\mathcal{N}(X\bar{X}' + Z_1Z'_1)$ .

□

Zauważmy, że kładąc  $X_2 = \mathbf{0}$ , uzyskujemy charakterystykę estymatorów dopuszczalnych  $\mathbf{L}'\mathbf{Y}$  podaną we wniosku 4.1.

Wyniki twierzeń 4.1 oraz 4.3 możemy przedstawić graficznie w sposób następujący.



Pierwszy z rysunków przedstawia obszar tych współczynników  $a_0$  i  $a_1$ , dla których liniowe estymatory są dopuszczalne dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  na  $\mathcal{T}$  w modelu (2.4) odpowiadającym modelowi (4.1) w przypadku, gdy  $X_1 = \mathbf{0}$  oraz  $X_2 \neq \mathbf{0}$ . W sytuacji, gdy  $X_1 \neq \mathbf{0}$  oraz  $X_2 \neq \mathbf{0}$  (rysunek 2), obszar ten jest od góry ograniczony przez fragment hiperboli. Przy ustalonym  $X_1 \neq \mathbf{0}$  i  $X_2 \rightarrow \mathbf{0}$  odpowiednie obszary wypełniają cały kwadrat, dając (po domknięciu) obszar tych  $a_0$  i  $a_1$ , dla których rozważane estymatory są dopuszczalne w odpowiednim modelu (2.4), dla którego  $X \in \mathcal{R}(Z_1)$ .

### 4.3. Zastosowania

Przedstawimy teraz charakterystykę liniowych estymatorów dopuszczalnych dla funkcji  $\beta + u_i$  w modelach (2.8) oraz (2.9), gdzie  $i = 1, 2, \dots, n_1$ . Wykorzystamy do tego, wynikający z lematu 2.1 oraz wniosku 4.1, następujący wniosek.

**Wniosek 4.2.** *Estymator  $(L_0, L_1)'Y$  jest dopuszczalny dla wektora  $[(K'X\beta)', (Q_1'Z_1u_1)']'$  w modelu (4.1), dla którego  $X \in \mathcal{R}(Z_1)$  wtedy i tylko wtedy, gdy*

$$(L_0, L_1) \in \{[L_0(a_0), L_1(a_0, a_1)] : a_0 \in [0, 1], a_1 \in [0, 1]\},$$

gdzie macierze  $L_0(a_0)$  oraz  $L_1(a_0, a_1)$  dane są wzorami (4.3) oraz (4.4).

Zauważmy, że jeżeli we wniosku 4.2 wstawimy w miejsce macierzy  $K$  oraz  $Q_1$  odpowiednio  $\frac{1}{n_1 N' N}(\mathbf{1}_{n_1} \otimes N)$  i  $\frac{1}{N' N}(I_{n_1} \otimes N)v_i$ , to dostaniemy w jawnej postaci klasę wszystkich estymatorów dopuszczalnych dla  $(\beta, u_i)'$  w modelu (2.8), gdzie  $v_i$  jest  $i$ -tym wektorem z przestrzeni  $\mathbb{R}^{n_1}$ .

**Wniosek 4.3.** *Estymator  $(L_0, L_1)'Y$  jest dopuszczalny dla  $(\beta, u_i)'$  w modelu (2.8) wtedy i tylko wtedy, gdy*

$$(L_0, L_1) \in \{[L_0(a_0), L_1(a_0, a_1)] : a_0 \in [0, 1], a_1 \in [0, 1]\},$$

gdzie

$$L_0(a_0) = \frac{a_0}{n_1 N' N}(\mathbf{1}_{n_1} \otimes N), \quad (4.7)$$

$$L_1(a_0, a_1) = \frac{a_1}{N' N} \left[ I_{n_1} \otimes N - \frac{a_0}{n_1}(\mathbf{1}_{n_1} \mathbf{1}'_{n_1} \otimes N) \right] v_i. \quad (4.8)$$

Stosując dla  $C = (1, 1)'$  lemat 4.3 oraz lemat 1.1, uzyskujemy następujący wniosek.

**Wniosek 4.4.** *Estymator  $l'Y$  jest dopuszczalny dla  $\beta + u_i$  w modelu (2.8) wtedy i tylko wtedy, gdy*

$$l'Y = [L'_0(a_0) + L'_1(a_0, a_1)]Y,$$

gdzie  $L_0(a_0)$  oraz  $L_1(a_0, a_1)$  są odpowiednio określone wzorami (4.7) i (4.8).

Jeżeli rozważamy liniowe estymatory dla  $\beta + u_i$  w modelu (2.9), to wniosek ten możemy zapisać w postaci

**Wniosek 4.5.** *Estymator  $l'Y$  jest dopuszczalny dla  $\beta + u_i$  w modelu (2.9) wtedy i tylko wtedy, gdy*

$$l'Y = a_0 \bar{Y} + a_1 (\bar{Y}_i - a_0 \bar{Y}) \text{ pod warunkiem, że } a_0 \in [0, 1] \text{ i } a_1 \in [0, 1],$$

gdzie  $\bar{Y}_i = \frac{1}{n_2} \sum_{j=1}^{n_2} Y_{ij}$  oraz  $\bar{Y} = \frac{1}{n} \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} Y_{ij}$ .

Zauważmy, że jeżeli weźmiemy  $C = (1, 0)'$ , to otrzymujemy dobrze znaną charakterystykę dopuszczalnych liniowych estymatorów dla  $\beta$ .

**Wniosek 4.6.** *Estymator  $\ell'Y$  jest dopuszczalny dla  $\beta$  w modelu (2.9) wtedy i tylko wtedy, gdy*

$$\ell'Y = a_0 \bar{Y} \text{ pod warunkiem, że } a_0 \in [0, 1].$$

## 5. Model z dwoma komponentami

W rozdziale tym interesować nas będzie dopuszczalna liniowa estymacja wektora  $[(K'X\beta)', (Q_1'Z_1u_1)']'$  w ogólnym modelu z dwoma komponentami, tzn. w modelu (2.1), dla którego  $k = 1$ . Przypomnijmy, że na mocy lematu 2.1, równoważnie będziemy zajmować się dopuszczalną estymacją  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w modelu (2.4), który odpowiada modelowi z dwoma komponentami. Osłabienie dla tego ostatniego założeń, które zostały postawione w poprzednim rozdziale, tj.  $\beta \in \mathbb{R}$  oraz  $(Z_1Z_1')^2 = p_1Z_1Z_1'$  dla  $p_1 > 0$ , powoduje problemy w uzyskaniu jawnych wzorów na estymatory dopuszczalne dla wspomnianego już wektora. Problemy te wiążą się między innymi z tym, że  $\beta$  jest teraz  $p$ -wymiarowym wektorem nieznanych parametrów, co wpływa na postaci zbiorów  $\mathcal{T}$  oraz  $[\mathcal{T}]$ . Oba te zbiory wyrazimy za pomocą pewnej, wygodnej dla dalszych rozważań, reparametryzacji, tzn.

$$\begin{aligned} \mathcal{T} &= \{(\text{cov}(\mathbf{Y}), E\mathbf{Y}(E\mathbf{Y})') : \beta \in \mathcal{R}^p, \sigma_1^2 \geq 0, \sigma_2^2 > 0\} \\ &= \left\{ \left( \rho^2 \begin{bmatrix} \lambda Z_1 Z_1' + (1 - \lambda) I_n & \lambda Z_1 Z_1' \\ \lambda Z_1 Z_1' & \lambda Z_1 Z_1' \end{bmatrix}, \begin{bmatrix} X\beta\beta'X' & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \right) : \right. \\ &\quad \left. \beta \in \mathcal{R}^p, \rho^2 = \sigma_1^2 + \sigma_2^2, \lambda = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} \right\}, \end{aligned}$$

natomiast

$$[\mathcal{T}] = \{(W_1(s, \lambda), W_2(\Phi)) = (s\mathbf{V}_\lambda, \mathbf{X}\Phi\mathbf{X}') : s \geq 0, \lambda \in [0, 1], \Phi \in \mathcal{M}_p^{\geq}\},$$

gdzie  $\mathbf{V}_\lambda = \begin{bmatrix} \lambda Z_1 Z_1' + (1 - \lambda) I_n & \lambda Z_1 Z_1' \\ \lambda Z_1 Z_1' & \lambda Z_1 Z_1' \end{bmatrix}$ .

Rozważymy dwa przypadki. Pierwszy z nich, to przypadek, kiedy iloraz wariancji efektu losowego do wariancji błędu losowego jest znany. Wówczas  $\lambda = \frac{\sigma_1^2}{\sigma_1^2 + \sigma_2^2} \in [0, 1)$  jest znane i problem redukuje się do charakteryzacji dopuszczalnych estymatorów dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w następującym modelu Gaussa-Markova

$$\mathbf{Y} \sim (\mathbf{X}\beta, \rho^2 \mathbf{V}_\lambda). \quad (5.1)$$

Poniższe twierdzenie podaje warunki konieczne i dostateczne na to, aby estymator był dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w powyższym modelu.

**Twierdzenie 5.1.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  w modelu (5.1) wtedy i tylko wtedy, gdy*

(i)  $\mathcal{R}(\mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L}) \subseteq \mathcal{R}(\mathbf{X})$ ,

(ii)  $(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L} \in \mathcal{M}_{2n}^{\geq}$ ,

gdzie  $\mathbf{\Pi}_o = \begin{bmatrix} I_n & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{2n \times 2n}$ .

**Dowód.** Załóżmy, że macierz  $\mathbf{L}$  spełnia warunki (i) oraz (ii). Wówczas istnieje macierz  $\Phi_1 \in \mathcal{M}_p^{\geq}$ , taka że  $\mathcal{R}(\mathbf{X}\Phi_1\mathbf{X}') = \mathcal{R}(\mathbf{X}) \cap \mathcal{N}[(\mathbf{K} - \mathbf{L})']$ . Oczywiście,

$$\mathbf{X}\Phi_1\mathbf{X}'(\mathbf{K} - \mathbf{L}) = 0, \quad (5.2)$$

co oznacza, że  $\mathbf{L}'\mathbf{Y}$  jest lokalnie optymalny w punkcie  $W = (W_1(0, \lambda), W_2(\Phi_1))$  w klasie  $\mathcal{L}_o$ . Zauważmy, że  $\mathcal{L}_1 = \mathcal{B}(W|\mathcal{L}_o)$  może być przedstawiona następująco

$$\mathcal{L}_1 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_1}^t),$$

gdzie  $\mathbf{\Pi}_1 = \begin{bmatrix} \mathbf{\Pi}_1 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{2n \times 2n}$  oraz  $\mathbf{\Pi}_1 = I_n - \mathbf{X}\Phi_1\mathbf{X}'(\mathbf{X}\Phi_1\mathbf{X}')^+$ . W szczególności, jeżeli  $\Phi_1 = \mathbf{0}$ , to  $\mathcal{L}_o = \mathcal{L}_1$  i wówczas ten krok może być pominięty.



Jeżeli natomiast  $\dim(\mathcal{R}(\mathbf{X})) = n$  oraz jeżeli  $\Phi_1$  jest dodatnio określona, to  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalnym estymatorem, a więc dopuszczalnym. W tym przypadku pierwszy krok procedury jest jednocześnie ostatnim.

Teraz pokażemy, że istnieje macierz  $\Phi_2 \in \mathcal{M}_p^{\geq}$  taka, że  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $(W_1(1, \lambda), W_2(\Phi_2))$  w klasie  $\mathcal{L}_1$ .

Ponieważ  $\mathcal{R}(\mathbf{\Pi}_1) \subseteq \mathcal{R}(\mathbf{\Pi}_o)$ , więc z (i) mamy

$$\mathcal{R}(\mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}) \subseteq \mathcal{R}(\mathbf{X}). \quad (5.3)$$

Dalej, ponieważ  $\mathbf{\Pi}_1 \mathbf{\Pi}_o = \mathbf{\Pi}_1$ , więc z (ii) oraz (5.2) wynika, że

$$\begin{aligned} (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L} &= (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} + (\mathbf{K} - \mathbf{L})' \mathbf{X} \Phi_1 \mathbf{X}' (\mathbf{X} \Phi_1 \mathbf{X}')^+ \mathbf{L} \\ &= (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} \in \mathcal{M}_{2n}^{\geq}. \end{aligned} \quad (5.4)$$

Podstawiając  $\Phi_2 = [(\mathbf{K} - \mathbf{L})' \mathbf{X}]^+ (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} [\mathbf{X}' (\mathbf{K} - \mathbf{L})]^+$ , na mocy (5.4), mamy  $\Phi_2 \in \mathcal{M}_p^{\geq}$ . Warunek (5.3) implikuje, że istnieje macierz  $\mathbf{A} \in \mathcal{M}_{p \times 2n}$  taka, że  $\mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} = \mathbf{X} \mathbf{A}$ . Stąd

$$\begin{aligned} (\mathbf{K} - \mathbf{L})' \mathbf{X} \Phi_2 &= (\mathbf{K} - \mathbf{L})' \mathbf{X} [(\mathbf{K} - \mathbf{L})' \mathbf{X}]^+ (\mathbf{K} - \mathbf{L})' \mathbf{X} \mathbf{A} [\mathbf{X}' (\mathbf{K} - \mathbf{L})]^+ \\ &= (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} [\mathbf{X}' (\mathbf{K} - \mathbf{L})]^+. \end{aligned}$$

Ponieważ  $(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}$  jest macierzą symetryczną, więc

$$(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}) = (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}. \quad (5.5)$$

Ponadto, ponieważ  $\mathcal{N}(\mathbf{\Pi}_1 \mathbf{X}) = \mathcal{N}[(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X}]$ , więc istnieje macierz  $\mathbf{B}$  należąca do  $\mathcal{M}_{2n \times 2n}$  taka, że  $\mathbf{B}(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X} = \mathbf{\Pi}_1 \mathbf{X}$ , czyli

$$\mathbf{B}(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} = \mathbf{B}(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X} \mathbf{A} = \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}.$$

Podobnie

$$\mathbf{B}(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}) = \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}).$$

Warunek (5.5) implikuje, że

$$\mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} = \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}), \quad (5.6)$$

czyli  $\mathbf{L}'\mathbf{Y}$  jest jednoznacznie lokalnie optymalny w punkcie  $(W_1(1, \lambda), W_2(\Phi_2))$  w klasie  $\mathcal{L}_1$ , co kończy pierwszą część dowodu.

Teraz załóżmy, że  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$ . Ponieważ  $\mathbf{L} \in \mathcal{L}_1$ , gdzie rozmaitość liniowa  $\mathcal{L}_1$  została zdefiniowana na początku dowodu, więc estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_1$ . Zatem na mocy twierdzenia 1.2 istnieje punkt  $W = (W_1(s, \lambda), W_2(\Phi_2)) \in \mathcal{A}(\mathcal{L}_1)$ , gdzie  $s > 0$  taki, że

$$s\mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L} = \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}).$$

Ponieważ  $\mathcal{R}(\mathbf{\Pi}_o - \mathbf{\Pi}_1) \subseteq \mathcal{R}(\mathbf{X})$ , więc  $\mathcal{R}(\mathbf{\Pi}_1 \mathbf{X}) \subseteq \mathcal{R}(\mathbf{X})$ . Stąd

$$\mathcal{R}(\mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L}) = \mathcal{R}((\mathbf{\Pi}_o - \mathbf{\Pi}_1) \mathbf{V}_\lambda \mathbf{L}) \oplus \mathcal{R}(\mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}) \subseteq \mathcal{R}(\mathbf{X}),$$

co kończy dowód warunku (i).

Dalej, ponieważ  $(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L} = (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_\lambda \mathbf{L}$  (co wynika z (5.4)) oraz  $\mathbf{X}'(\mathbf{K} - \mathbf{L}) = \mathbf{X}' \mathbf{\Pi}_1 (\mathbf{K} - \mathbf{L})$ , więc

$$s(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L} = (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' \mathbf{\Pi}_1 (\mathbf{K} - \mathbf{L}) \in \mathcal{M}_{2n}^\geq.$$

□

Rozważmy teraz ogólniejszą sytuację, kiedy iloraz  $\sigma^2$  oraz  $\sigma_e^2$  jest nieznanymi. Dodatkowo załóżmy, że  $\mathcal{R}(\mathbf{X}) \subseteq \mathcal{R}(\mathbf{Z})$ , gdzie  $\mathbf{Z} = [\mathbf{Z}'_1, 0]'$   $\in \mathcal{M}_{2n \times m}$ .

**Twierdzenie 5.2.** *Estymator  $\mathbf{L}'\mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  wtedy i tylko wtedy, gdy istnieje  $\lambda \in [0, 1]$ , dla której*

- (i)  $\mathcal{R}(\mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L}) \subseteq \mathcal{R}(\mathbf{X})$ ,
- (ii)  $(\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_o \mathbf{V}_\lambda \mathbf{L} \in \mathcal{M}_{2n}^\geq$ ,

oraz dodatkowo, gdy  $\lambda = 1$

$$(iii) \quad \mathbf{\Pi}_{Z_1} \mathbf{L} = \mathbf{0},$$

gdzie  $\mathbf{\Pi}_{Z_1} = \begin{bmatrix} \mathbf{\Pi}_{Z_1} & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}$ , natomiast  $\mathbf{\Pi}_{Z_1}$  jest macierzą rzutu ortogonalnego na przestrzeń  $\mathcal{N}(Z_1')$ .

**Dowód.** W przypadku, gdy  $\lambda \in [0, 1)$  dowód warunku dostatecznego wynika z twierdzenia 5.1. Jeżeli  $\lambda = 1$ , to musimy wykonać dodatkowy (trzeci) krok. Ponieważ

$$\mathbf{\Pi}_1 \mathbf{V}_1 \mathbf{L} = \mathbf{\Pi}_1 \mathbf{X} \Phi_2 \mathbf{X}' (\mathbf{K} - \mathbf{L}),$$

gdzie

$$\Phi_2 = [(\mathbf{K} - \mathbf{L})' \mathbf{X}]^+ (\mathbf{K} - \mathbf{L})' \mathbf{\Pi}_1 \mathbf{V}_1 \mathbf{L} [\mathbf{X}' (\mathbf{K} - \mathbf{L})]^+$$

(patrz (5.6)), więc  $\mathbf{L}' \mathbf{Y}$  jest lokalnie optymalny w punkcie  $(W_1(1, 1), W_2(\Phi_2))$  w klasie  $\mathcal{L}_1$ . Rozmaitość liniowa  $\mathcal{L}_2 = \mathcal{B}(W_1(1, 1), W_2(\Phi_2)) | \mathcal{L}_1$  ma następującą postać

$$\mathcal{L}_2 = \mathbf{L} + \mathcal{R}(T_{\mathbf{\Pi}_2}^t),$$

gdzie  $\mathbf{\Pi}_2 = \begin{bmatrix} \mathbf{\Pi}_2 & \mathbf{0} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \in \mathcal{M}_{2n \times 2n}$  oraz  $\mathbf{\Pi}_2 = \mathbf{\Pi}_1 [I_n - \mathbf{\Pi}_1 Z_1 Z_1' \mathbf{\Pi}_1 (\mathbf{\Pi}_1 Z_1 Z_1' \mathbf{\Pi}_1)^+]$ .

Macierz  $\mathbf{\Pi}_2$  jest macierzą rzutu ortogonalnego na  $\mathcal{N}(X \Phi_1 X') \cap \mathcal{N}(\mathbf{\Pi}_1 Z_1 Z_1' \mathbf{\Pi}_1)$ . Ponieważ  $\mathcal{R}(\mathbf{\Pi}_{Z_1}) \subseteq \mathcal{R}(\mathbf{\Pi}_1)$ , więc  $\mathbf{\Pi}_2 = \mathbf{\Pi}_{Z_1}$  oraz  $\mathbf{\Pi}_{Z_1} \mathbf{X} = \mathbf{0}$ . Korzystając z warunku (iii) mamy, że  $\mathbf{\Pi}_{Z_1} \mathbf{L} = \mathbf{\Pi}_{Z_1} \mathbf{X} = \mathbf{0}$ . To implikuje z kolei, że  $\mathbf{L}' \mathbf{Y}$  jest jednoznacznie lokalnie optymalny w  $(W_1(1, 0), W_2(0))$  w klasie  $\mathcal{L}_2$ .

Założmy teraz, że  $\mathbf{L}' \mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K} \mathbf{X} \beta$  w klasie  $\mathcal{L}_o$ . W oparciu o dowód twierdzenia 5.1 pozostał do rozważenia przypadek, kiedy  $\mathbf{L} \in \mathcal{L}_2 = \mathcal{B}((W_1(1, 1), W_2(\Phi_2)) | \mathcal{L}_1) \subset \mathcal{L}_1 = \mathcal{B}((W_1(0, \lambda), W_2(\Phi_1)) | \mathcal{L}_o)$ . Z lokalnej optymalności w punkcie  $(W_1(1, 1), W_2(\Phi_2))$  nadal wynikają warunki (i) oraz (ii) dla  $\lambda = 1$ . Ponieważ  $\mathbf{L}' \mathbf{Y}$  jest dopuszczalny dla  $\mathbf{K} \mathbf{X} \beta$  w klasie  $\mathcal{L}_2$  i ponieważ

$\mathcal{R}(\mathbf{X}) \subseteq \mathcal{R}(\mathbf{Z})$ , więc korzystając z twierdzenia 1.2 mamy, że istnieje punkt  $(W_1(s, 0), W_2(0)) \in \mathcal{A}(\mathcal{L}_2)$  z  $s > 0$ , dla którego  $s\Pi_Z\mathbf{L} = \mathbf{0}$ , co kończy dowód.  $\square$

W szczególnym przypadku, gdy  $\beta \in \mathbb{R}$ ,  $X \in \mathcal{R}(Z_1)$  oraz  $(Z_1 Z_1')^2 = p_1 Z_1 Z_1'$  dla  $p_1 > 0$  z charakterystyki estymatorów dopuszczalnych dla  $\mathbf{K}'\mathbf{X}\beta$  w klasie  $\mathcal{L}_o$  podanej w powyższym twierdzeniu wynika charakterystyka podana we wniosku 4.1 i odwrotnie. Korzystając z lematu 1.1, wystarczy wykazać równoważność pomiędzy tymi charakterystykami dla  $K = I_n$  i  $Q_1 = I_n$ . Wtedy dowód będzie bardziej przejrzysty.

Warunki (i) oraz (ii) twierdzenia 5.2 możemy wyrazić w terminach macierzy  $L_0$  i  $L_1$  następująco

$$(i') \quad \mathcal{R}(V_\lambda L_0) \subseteq \mathcal{R}(X), \quad \mathcal{R}(V_\lambda L_1 - \lambda Z_1 Z_1') \subseteq \mathcal{R}(X),$$

$$(ii') \quad \begin{bmatrix} (I_n - L_0)' V_\lambda L_0 & (I_n - L_0)' (V_\lambda L_1 - \lambda Z_1 Z_1') \\ -L_1 V_\lambda L_0 & -L_1 (V_\lambda L_1 - \lambda Z_1 Z_1') \end{bmatrix} \in \mathcal{M}_{2n}^{\geq},$$

gdzie  $V_\lambda = \lambda Z_1 Z_1' + (1 - \lambda)I_n$ .

Założmy teraz, że istnieje  $\lambda \in [0, 1)$ , dla której te warunki są spełnione. Na mocy warunku (ii') mamy, że macierz  $(I_n - L_0)' V_\lambda L_0$  jest symetryczna, tym samym macierz  $V_\lambda L_0$  jest też symetryczna. Zatem pierwszy z warunków (i') implikuje, że istnieje  $c \in \mathbb{R}$  takie, że  $V_\lambda L_0 = cXX'$ . Stąd

$$\begin{aligned} L_0 &= cV_\lambda^{-1}XX' = \left( \frac{-\lambda}{(1-\lambda)(p_1\lambda + 1 - \lambda)} Z_1 Z_1' + \frac{1}{1-\lambda} I_n \right) XX' \\ &= \frac{c}{p_1\lambda + 1 - \lambda} XX'. \end{aligned} \tag{5.7}$$

Z symetrii macierzy występującej w warunku (ii'), dotyczących elementów poza diagonalą, wynika również, że

$$V_\lambda L_1 - \lambda Z_1 Z_1' = -\lambda L_0' Z_1 Z_1'.$$

Zatem z (5.7) otrzymujemy, że

$$\begin{aligned} L_1 &= V_\lambda^{-1} \left( \frac{-cp_1\lambda}{p_1\lambda + 1 - \lambda} XX' + \lambda Z_1 Z_1' \right) \\ &= \frac{p_1\lambda}{p_1\lambda + 1 - \lambda} \left( \frac{1}{p_1} Z_1 Z_1' - \frac{cX'X}{p_1\lambda + 1 - \lambda} \frac{1}{X'X} XX' \right). \end{aligned} \quad (5.8)$$

Korzystając z (5.7) dostajemy

$$(I_n - L_0)' V_\lambda L_0 = c \left( 1 - \frac{cX'X}{p_1\lambda + 1 - \lambda} \right) XX'.$$

Z nieujemnej nieokreśloności tej macierzy wynika, że  $c \left( 1 - \frac{cX'X}{p_1\lambda + 1 - \lambda} \right) \geq 0$ . Stąd  $c \in [0, \frac{p_1\lambda + 1 - \lambda}{X'X}]$  lub równoważnie  $\frac{cX'X}{p_1\lambda + 1 - \lambda} \in [0, 1]$ .

Załóżmy teraz, że  $\lambda = 1$ . Z warunku (iii) twierdzenia 5.2 dostajemy, że

$$L_0 = \frac{1}{p_1} Z_1 Z_1' L_0 \quad (5.9)$$

oraz

$$L_1 = \frac{1}{p_1} Z_1 Z_1' L_1. \quad (5.10)$$

Z warunku (i) tego twierdzenia oraz symetrii macierzy  $Z_1 Z_1' L_0$  wynika, że istnieje  $c_* \in \mathbb{R}$  takie, że  $Z_1 Z_1' L_0 = c_* XX'$ . Korzystając z (5.9) mamy, że

$$L_0 = \frac{c_*}{p_1} XX'.$$

Postępując podobnie, jak w przypadku  $\lambda \in [0, 1)$  otrzymujemy

$$Z_1 Z_1' L_1 - Z_1 Z_1' = -c_* XX'.$$

Stąd i z (5.10) dostajemy następującą postać macierzy

$$L_1 = \left( \frac{1}{p_1} Z_1 Z_1' - \frac{c_* X'X}{p_1} \frac{1}{X'X} XX' \right).$$

Dalej, z nieujemnej określoności macierzy  $(I_n - L_0)' V_1 L_0$  mamy  $c_* \in [0, \frac{p_1}{X'X}]$ .

Pokazaliśmy zatem, że jeżeli istnieje  $\lambda \in [0, 1]$ , dla której spełnione są warunki twierdzenia 5.2, to estymator  $L'Y$  dla  $X\beta$  jest postaci podanej we wniosku 4.1.

Chcąc pokazać, że z charakterystyki podanej we wniosku 4.1 wynika charakterystyka podana w twierdzeniu 5.2, wystarczy podstawić  $\lambda = \frac{a_1}{a_1 + p_1(1 - a_1)}$ . Oczywiście, jeżeli  $a_1 \in [0, 1]$ , to  $\lambda \in [0, 1]$ . Wykonując standardowe przekształcenia, wykorzystując zależność  $Z_1 Z_1' X X' = p_1 X X'$ , dostajemy żądane wynikanie.

# Podsumowanie

W pracy rozważany był następujący model liniowy

$$Y = X\beta + Z_1u_1 + Z_2u_2 + \dots + Z_ku_k + e,$$

w którym zajmowano się dopuszczalną liniową estymacją wektora

$$[(K'X\beta)', (Q'_1Z_1u_1)', \dots, (Q'_kZ_ku_k)']'.$$

Kluczowym w całej rozprawie jest spostrzeżenie, że zagadnienie to można sprowadzić do równoważnego problemu dopuszczalności estymatora dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  w modelu

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

Uzyskano w jawnej postaci charakterystykę dopuszczalnych estymatorów dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  w modelach odpowiadających zrównoważonemu modelowi losowemu  $k$  – kierunkowej klasyfikacji hierarchicznej, zrównoważonemu modelowi losowemu  $k$  – kierunkowej klasyfikacji krzyżowej oraz zrównoważonemu modelowi losowemu dwukierunkowej klasyfikacji krzyżowej z interakcją. Opisano także jawną postać dopuszczalnych estymatorów  $L'Y$  dla  $K'X\beta$  w klasie  $\mathcal{L}_o$  w modelu odpowiadającym modelowi z dwoma komponentami, w którym  $\beta \in \mathbb{R}$ , a macierz  $Z_1Z'_1$  jest macierzą proporcjonalną do macierzy idempotentnej. Dla ogólnego modelu liniowego z dwoma komponentami przy założeniu, że  $\mathcal{R}(X) \subseteq \mathcal{R}(Z_1)$  podano warunki konieczne i dostateczne na to, aby odpowiedni estymator był dopuszczalny. Warunki te zostały wyrażone w terminach podobnych do tych, których użył Rao (1976) w modelu Gaussa-Markowa.

# Bibliografia

- [1] J.K. Baksalary, A. Markiewicz, C.R. Rao, *Admissible linear estimation in the general Gauss-Markov model with respect to an arbitrary quadratic risk function*, J. Statist. Planning and Inference **44** (1995), 341-347.
- [2] A. Cohen, *All admissible linear estimators of the mean vector*, Ann. Math. Statist. **37** (1966), 458-463.
- [3] H. Drygas, R. Zmysłony, *On admissible estimation for parametric functions in linear models*, Statistical Papers **29** (1988), 113-123.
- [4] S. Gnot, *Estymacja Komponentów Wariancyjnych w Modelach Liniowych*, WNT, Warszawa 1991.
- [5] S. Gnot, E. Rafajłowicz, A. Urbańska-Motyka, *Statistical inference in a linear model for spatially located sensors and random input*, Ann. Inst. statist. Math. **52.2** (2001), 370-379.
- [6] D.A. Harville, *Matrix Algebra From a Statistician's Perspective*, Springer-Verlag, New York 2000.
- [7] D.A. Harville, *Extension of the Gauss-Markov theorem to include the estimation of random effects*, Ann. of Statist. **4** (1976), 384-395.



- [8] K. Hoffman, *Admissibility of linear estimators with respect to restricted parameter sets*, Math. Operationsforsch. Statist., Ser. Statistics **4** (1977), 425-438.
- [9] W. Klonecki, *Linear estimators of the mean vector in linear models, problem of admissibility*, Prob. Math. Statist. **2** (1982).
- [10] W. Klonecki, S. Zontek, *On the structure of admissible linear estimators*, J. Multivariate Anal. **24** (1988), 11-30.
- [11] L.R. LaMotte, *Admissibility in linear estimation*, Ann. Statist. **10.1** (1982), 245-255.
- [12] L.R. LaMotte, *On limits of uniquely best linear estimators*, Metrika **45** (1997), 197-211.
- [13] T. Mathew, C.R. Rao, B.K. Sinha, *Admissible linear estimation in singular linear models*, Comm. Statist., Theory Methods **13** (1984), 3033-3045.
- [14] J. Gross, A. Markiewicz, *On admissibility of linear estimators with respect to the mean square error matrix criterion under the general mixed linear model*, Statistics **33** (1999), 57-71.
- [15] A. Olsen, J. Seely, D. Birkes, *Invariant quadratic estimation for two variance components*, Ann. Statist. **4** (1976), 591-612.
- [16] J.L. Peixoto, D.A. Harville, *Comparisons of alternative predictors under the balanced one-way random model*, JASA **81** (1986), 431-436.
- [17] C.R. Rao, *Estimation of parameters in a linear model*, Ann. Statist. **4** (1976), 1023-1037.
- [18] C.R. Rao, *Modele Liniowe Statystyki Matematycznej*, PWN, Warszawa 1982.

- [19] C.R. Rao, *Estimation in a linear models with mixed effects: a unified theory*, Proceedings Second International Tampere Conference in Statistics., Dept. of Mathematical Sciences, Univ. of Tempere, (1987), 73-98.
- [20] G.K. Robinson, *That BLUP is good thing: the estimation of random effects*, Statistical Science **6** (1991), 15-51.
- [21] N. Shinozaki, *A Study of Generalized Inverse of Matrix and Estimation with Quadratic Loss*, Ph.D. thesis, Keio University, Japan 1975.
- [22] R. Searle, G. Casella, C. McCulloch, *Variance Components*, Wiley, New York 1992.
- [23] C. Stępniaak, *A complete class for linear estimation in a general linear model*, Ann. Inst. Statist. Math. **39** (1987), 563-573.
- [24] E. Synówka-Bejenka, S. Zontek, *A characterization of admissible linear estimators of fixed and random effects in linear models*, (praca wysłana do druku).
- [25] S. Zontek, *Estymacja parametrów w modelach liniowych*, Rozprawa doktorska, IM PAN 1983.
- [26] S. Zontek, *Admissibility of limits of the unique locally best linear estimators with application to variance components models*, Probab. Math. Statist. **9** (1988), 29-44.