

Założenie 5.16

Zmienna losowa Θ_i odpowiada profilowi ryzyka w i -tej grupie dla $i = 1, 2, \dots, I$. Ponadto

- (a) przy zadanym Θ_i zmienne losowe X_{ij} , $j = 1, 2, \dots, n$, są warunkowo niezależne oraz

$$\mathbb{E}[X_{ij}|\Theta_i] = m(\Theta_i),$$

$$\text{Var}[X_{ij}|\Theta_i] = \frac{\sigma^2(\Theta_i)}{w_{ij}};$$

- (b) zmienne losowe $\Theta_1, \dots, \Theta_I$ są niezależne i mają ten sam rozkład, a pary $(\Theta_1, \mathbf{X}_1), \dots, (\Theta_I, \mathbf{X}_I)$ są niezależne, gdzie $\mathbf{X}_i = (X_{i1}, \dots, X_{in})$ jest n -letnią obserwacją standaryzowanych łącznych szkód w i -tej grupie ryzyka.

Model Bühlmana–Strauba odpowiada następującemu mechanizmowi losowania warstwowego. W pierwszym losowaniu wybieramy profil ryzyka dla i -tej grupy ryzyka, zgodnie z rozkładem zmiennej losowej Θ_i . Wylosowany parametr ryzyka określa rozkład zmiennych losowych X_{ij} w i -tej grupie w drugim losowaniu. W ten sposób można modelować bardziej złożony portfel heterogeniczny, niż w punkcie 5.4.1, gdzie parametr ryzyka był wspólny dla całego portfela, podczas gdy obecnie jest on wspólny tylko dla i -tej grupy ryzyka i różni się między grupami.

Przykład 5.2

Przypuśćmy, że skumulowane szkody S_{ij} mają złożony rozkład Poissona (patrz definicja 1.17) o intensywności $\lambda(\Theta_i)w_{ij}$, a wielkość pojedynczych szkód Y ma rozkład F_Y , który nie zależy od Θ_i . Ponieważ $X_{ij} = S_{ij}/w_{ij}$, po skorzystaniu z wzoru (1.24) otrzymujemy

$$\mathbb{E}[X_{ij}|\Theta_i] = \lambda(\Theta_i)\mathbb{E}[Y|\Theta_i].$$

Postępując podobnie dla drugiej kumulanty złożonego rozkładu Poissona oraz korzystając z wzoru (1.24), otrzymujemy

$$\text{Var}[X_{ij}|\Theta_i] = \frac{\lambda(\Theta_i)}{w_{ij}}\mathbb{E}[Y^2|\Theta_i].$$

Zatem założenie 5.16 jest spełnione z $m(\Theta_i) = \lambda(\Theta_i)\mathbb{E}[Y|\Theta_i]$ oraz $\sigma^2(\Theta_i) = \lambda(\Theta_i)\mathbb{E}[Y^2|\Theta_i]$.

Interesować nas będzie indywidualna składka netto $\pi_{\Theta_i} = m(\Theta_i) = \mathbb{E}[X_{ij}|\Theta_i]$. W celu jej estymacji będziemy wykorzystywać portfelową składkę netto

$$\pi = \mathbb{E}[\pi_{\Theta_i}] = m_0,$$

która jest wartością oczekiwaną standaryzowanej łącznej szkody w całym portfelu. Podobnie jak w poprzednich rozdziałach, będziemy chcieli dla każdego $i = 1, 2, \dots, I$ wyestymować składkę indywidualną netto $m(\Theta_i)$, wykorzystując dostępne dane w postaci wektorów X_i , gdzie $X_i = (X_{i1}, \dots, X_{in})$. Obserwacje X_{ij} są znane na n lat wstecz dla każdej grupy ryzyka. Jako estymator indywidualnej składki netto przyjmujemy funkcję liniową obserwacji

$$\widehat{m(\Theta_i)} = a_{i0} + \sum_{j=1}^n a_{ij} X_{ij}, \quad (5.24)$$

gdzie a_{ij} , $i = 0, 1, \dots, I$, są tak dobranymi współczynnikami rzeczywistymi, aby $\widehat{\pi(\Theta_i)} = \widehat{m(\Theta_i)}$ stanowiły dekompozycję znanej składki portfelowej π na i -tą grupę ryzyka. Ponieważ Θ_i jest zmienną losową oraz $\mathbb{E}[\pi(\Theta_i)] = \pi$, średnio biorąc $\widehat{\pi(\Theta_i)}$ powinno również dawać π , czyli $\mathbb{E}[\widehat{\pi(\Theta_i)}] = \pi$. Oznaczmy przez \mathcal{L} klasę estymatorów liniowych, danych wzorem (5.24), które spełniają ten warunek. Niech $\mathcal{L}_0 \subseteq \mathcal{L}$ będzie klasą estymatorów *jednorodnych*, dla których $a_{i0} = 0$. W klasach \mathcal{L} i \mathcal{L}_0 dobierzemy współczynniki estymatora $\widehat{\pi(\Theta_i)}$ w ten sposób, aby zminimalizować średniokwadratową stratę $\mathbb{E}\left[\sum_{i=1}^I (\pi(\Theta_i) - \widehat{\pi(\Theta_i)})^2\right]$. Wykorzystamy w tym celu następujący lemat.

Lemat 5.17

Jeśli spełnione jest założenie 5.16 oraz estymator $\widehat{\pi(\Theta_i)} \in \mathcal{L}$, to

$$\mathbb{E}\left[\sum_{i=1}^I (\pi(\Theta_i) - \widehat{\pi(\Theta_i)})^2\right] = \sum_{i=1}^I \mathbb{E}\left[\pi(\Theta_i) - \widehat{\pi(\Theta_i)}\right]^2.$$

Dowód. Ponieważ estymator $\widehat{\pi(\Theta_i)}$ wykorzystuje dane $X_i = (X_{i1}, \dots, X_{in})$, z założenia 5.16

$$\mathbb{E}\left[\widehat{\pi(\Theta_i)}\widehat{\pi(\Theta_k)}\right] = \pi^2 \quad \text{dla } i \neq k.$$

Podobnie niezależność $\Theta_1, \dots, \Theta_I$ implikuje dla $i \neq k$ równość

$$\mathbb{E}[\pi(\Theta_i)\pi(\Theta_k)] = \pi^2.$$

Z założenia 5.16 wynika również, że dla $i \neq k$ mamy

$$\mathbb{E}\left[\pi(\Theta_i)\widehat{\pi(\Theta_k)}\right] = \pi^2.$$

Uwzględniając powyższe

$$\begin{aligned} \text{Cov}\left(\pi(\Theta_i) - \widehat{\pi(\Theta_i)}, \pi(\Theta_k) - \widehat{\pi(\Theta_k)}\right) &= \mathbb{E}\left[\left(\pi(\Theta_i) - \widehat{\pi(\Theta_i)}\right)\left(\pi(\Theta_k) - \widehat{\pi(\Theta_k)}\right)\right] \\ &= \mathbb{E}[\pi(\Theta_i)\pi(\Theta_k)] - \mathbb{E}\left[\pi(\Theta_i)\widehat{\pi(\Theta_k)}\right] - \mathbb{E}\left[\pi(\Theta_k)\widehat{\pi(\Theta_i)}\right] + \mathbb{E}\left[\widehat{\pi(\Theta_i)}\widehat{\pi(\Theta_k)}\right] \\ &= 0, \quad \text{dla } i \neq k. \end{aligned}$$