

Zagadnienia aktuarialne – teoria i praktyka

pod redakcją
Walentego Ostasiewicza



Wydawnictwo Uniwersytetu Ekonomicznego we Wrocławiu
Wrocław 2011

Recenzenci

Helena Jasiulewicz, Wojciech Kordecki, Zbigniew Palmowski

Redaktor Wydawnictwa

Aleksandra Śliwka

Redakcja techniczna

Barbara Łopusiewicz

Korektor

Barbara Cibis

Łamanie

Beata Mazur

Projekt okładki

Beata Dębska

Publikacja jest dostępna na stronie www.ibuk.pl

Streszczenia opublikowanych artykułów są dostępne w międzynarodowej bazie danych The Central European Journal of Social Sciences and Humanities <http://cejsh.icm.edu.pl> oraz w The Central and Eastern European Online Library www.ceeol.com

Informacje o naborze artykułów i zasadach recenzowania znajdują się na stronie internetowej Wydawnictwa www.wydawnictwo.ue.wroc.pl

Kopiowanie i powielanie w jakiegokolwiek formie wymaga pisemnej zgody Wydawnictwa

© Copyright Uniwersytet Ekonomiczny we Wrocławiu
Wrocław 2011

ISSN 1899-3192

ISBN 978-83-7695-186-7

Wersja pierwotna: publikacja drukowana

Druk: Drukarnia TOTEM

Spis treści

Wstęp	7
Irmina Czarna, Zbigniew Palmowski , Porównanie prawdopodobieństw paryskiej i klasycznej ruiny dla procesu ryzyka typu Lévy'ego	9
Irmina Czarna, Zbigniew Palmowski , Problem wyboru optymalnej paryskiej dywidendy dla procesu ryzyka typu Lévy'ego – numeryczna analiza	22
Joanna Dębicka , Składki netto dla ubezpieczeń wielostanowych obciążone kosztami zawarcia i prowadzenia umowy	38
Monika Dyduch , Niekonwencjonalna metoda prognozy wartości jednostek funduszy emerytalnych	69
Stanisław Heilpern , Niestandardowe modele ryzyka – badanie wpływu stopnia zależności na prawdopodobieństwo ruiny	79
Aleksandra Iwanicka , Wpływ zewnętrznych czynników ryzyka na prawdopodobieństwo ruiny w dwuwymiarowym modelu ryzyka z lekkoogonowymi rozkładami wypłat	92
Helena Jasiulewicz, Wojciech Kordecki , Składki zaufania z zastosowaniem niesymetrycznych funkcji strat	101
Kamil Jodź , Składka w modelu ryzyka indywidualnego z zależnymi roszczeniami opisanymi funkcjami łączącymi	118
Marek Kałuszka, Michał Krzeszowiec , Własności składki <i>mean-value</i> przy zniekształconym prawdopodobieństwie	136
Zbigniew Michna , Procesy Lévy'ego w modelach ubezpieczeniowych	149
Agnieszka Mruklik , Ubezpieczenia na życie ze stochastyczną techniczną stopą oprocentowania – zastosowanie modelu Hulla i White'a	157
Agnieszka Pobłocka , Rezerwa IBNR w ubezpieczeniach majątkowych – praktyczne metody jej szacowania	173
Agata de Sas Stupnicka , Równowaga na rynku ubezpieczeń zdrowotnych w zależności od przyjętego sposobu rozliczania świadczeń medycznych	190
Joanna Sawicka , Zagadnienia kalkulacji składki zaufania na podstawie łącznej wartości i liczby szkód	202
Alicja Wolny-Dominiak , Analiza porównawcza modeli mieszanych szacowania stóp taryf w ubezpieczeniach majątkowych z wykorzystaniem krosvalidacji	229
Walenty Ostasiewicz , Polacy nie gęsi, iż swój język mają!	238

Summaries

Irmina Czarna, Zbigniew Palmowski , Comparison of Parisian and classical ruin probabilities for a Lévy risk process	21
Irmina Czarna, Zbigniew Palmowski , Numerical analysis of dividend problem with Parisian delay for a spectrally negative Lévy risk process	37
Joanna Dębicka , Expense-loaded premiums for multistate insurance contracts	68
Monika Dyduch , Alternative method of forecast of pension funds units value	78
Stanisław Heilpern , Nonstandard risk models – study of influence of the degree of dependence on the probability of ruin	91
Aleksandra Iwanicka , The influence of some outside risk factors on a ruin probability in a two-dimensional risk model with light-tailed claim sizes	100
Helena Jasiulewicz, Wojciech Kordecki , Credibility premiums using asymmetric loss functions	117
Kamil Jodź , Insurance premium in individual risk model with dependent claims described by copulas functions	135
Marek Kaluszka, Michał Krzeszowiec , Properties of mean-value principle under rank-dependent utility model	148
Zbigniew Michna , Lévy processes in insurance models	156
Agnieszka Mruklik , Life insurance with stochastic interest rate – an application of the Hull and White model	172
Agnieszka Pobłocka , IBNR reserve in non-life insurance. Practical methods of its estimation	189
Agata de Sas Stupnicka , Balance on the health insurance market – the impact of payment system	201
Joanna Sawicka , Calculation of credibility premium on the basis of number and total amount of claims	228
Alicja Wolny-Dominiak , Comparative analysis of mixed models for ratemaking in non-life insurance with k-fold cross-validation	237

Alicja Wolny-Dominiak

Uniwersytet Ekonomiczny w Katowicach

ANALIZA PORÓWNAWCZA MODELI MIESZANYCH SZACOWANIA STÓP TARYF W UBEZPIECZENIACH MAJĄTKOWYCH Z WYKORZYSTANIEM KROSWALIDACJI

Streszczenie: W pracy przedstawiono zastosowanie hierarchicznych mieszanych modeli liniowych (HGLM) w procesie wyznaczania stóp taryf *a priori*. Jako zmienną objaśnianą przyjęto średnią wartość wypłacanych odszkodowań (zmienna ciągła), a jako zmienną objaśniającą – zmienne taryfikacyjne charakteryzujące przedmiot ubezpieczenia oraz osobę ubezpieczającą się (zmienne nominalne wielokategorialne). W modelach HGLM istotnym problemem obliczeniowym jest wyznaczenie dewiencji, która może być stosowana jako kryterium wyboru ostatecznej postaci modelu. Zatem w celu uproszczenia początkowej fazy obliczeniowej w taryfikacji *a priori* (pomijając wyznaczanie dewiencji), do oceny modelu zaproponowano wykorzystanie procedury *k*-krotnej kroswalidacji. Analizę przypadku przedstawiono dla portfela polis komunikacyjnych. Procedura zaimplementowana została w programie komputerowym R.

Słowa kluczowe: stopa taryfy, hierarchiczny mieszany model liniowy, kroswalidacja.

1. Wstęp

Zakłady ubezpieczeń majątkowych powszechnie stosują w procesie wyznaczania stóp taryf *a priori* uogólnione modele liniowe (GLM), w których średnią (całkowitą) wartość szkody (zmienna objaśniana) uzależnia się od ustalonych zmiennych taryfikacyjnych (zmienne objaśniające). W modelach GLM przyjmuje się, iż wszystkie zmienne objaśniające mają stały wpływ na zmienną objaśnianą (*fixed effect*). Rozszerzeniem modeli GLM są liniowe modele mieszane, w których zakłada się, że część zmiennych taryfikacyjnych ma losowy wpływ na zmienną objaśnianą (*random effects*), co oznacza, że parametry strukturalne dla tych zmiennych są zmiennymi losowymi o określonych rozkładach [...]. W przypadku modelowania stóp taryf w ubezpieczeniach majątkowych zastosowanie znajdują mieszane modele liniowe klasy HGLM (*Hierarchical Generalized Linear Models*). W modelach HGLM losowe parametry strukturalne mogą przyjmować rozkład z dyspersyjnej rodziny rozkładów wykładniczych. To elastyczne założenie ma zasadnicze znaczenie w modelowaniu

danych ubezpieczeniowych, gdzie rozkład normalny znajduje zastosowanie rzadko, częściej rozkład gamma lub rodzina rozkładów Tweedie, czyli takich, dla których zachodzi $V(\mu) = \mu^p$ [Lee i in. 2006]. Mimo zalet stosowania modeli HGLM, które daje możliwość modelowania dyspersji, ich istotną wadą praktyczną jest stopień złożoności w procesie szacowania parametrów strukturalnych, mierników dobroci dopasowania, jak również walidacja modeli. W pracy przedstawiono procedurę k -krotnej kroswalidacji pozwalającą na szybką preselekcję modelu HGLM bez konieczności estymacji np. dewiancji.

W pierwszej części artykułu przedstawiono teoretyczny ogólny model HGLM do szacowania stóp taryf *a priori* typu gamma-gamma oraz proponowaną procedurę kroswalidacji. W części zasadniczej artykułu przedstawiono empiryczną analizę modeli na danych rzeczywistych zaczerpniętych z literatury przedmiotu [de Jong, Heller 2008]. Zastosowano model HGLM w trzech scenariuszach: uwzględniając wpływ zmiennych taryfikacyjnych na zmienną objaśnianą, uwzględniając dodatkowo interakcje pomiędzy zmiennymi, uwzględniając wpływ zmiennej taryfikacyjnej na dyspersję modelu. Wykorzystano funkcję `hglm{hglm}` oraz przeprowadzono 10-krotną kroswalidację, korzystając z programu komputerowego R.

2. Model HGLM do szacowania stóp taryf w ubezpieczeniach komunikacyjnych

Proces wyznaczania stóp taryf w ubezpieczeniach komunikacyjnych można zapisać w postaci modelu HGLM. Niech Y będzie średnią wartością szkody w portfelu, X_i zmienną taryfikacyjną mającą stały wpływ na wartości szkód, $i = 1, \dots, I$ zaś Z zmienną taryfikacyjną o losowym wpływie na wartości szkód. Zmienna objaśniana jest zmienną ciągłą, natomiast zmienne objaśniające są ciągłe lub nominalne wielokategorialne. Model HGLM typu gamma-gamma ma ogólną postać [Lee i in. 2006]:

$$\eta = g(\mu) = \mathbf{X}\beta + \mathbf{Z}u,$$

gdzie $\beta = [\beta_1, \dots, \beta_K]$ oraz $u = [u_1, \dots, u_K]$, \mathbf{X} oraz \mathbf{Z} są macierzami modelu. Parametry strukturalne modelu mają następującą interpretację: parametr β_i , $i = 1, \dots, I$, mierzy wpływ i -tej zmiennej taryfikacyjnej na wartość szkód (stały dla wszystkich kategorii), a parametr u_k , $k = 1, \dots, K$, mierzy poziom ryzyka w obrębie kategorii (zmienny dla każdej kategorii). Zmienna $Y|u$ oraz zmienna u mają rozkłady gamma.

Oszacowane wartości parametrów strukturalnych służą do wyznaczenia wskaźników taryfikacyjnych t . Wskaźniki taryfikacyjne w modelu gamma-gamma, w którym występują logarytmiczne funkcje połączenia, można przedstawić następująco:

$$t_i = \exp(\beta_i), \quad i = 1, \dots, I, \quad t_k = \exp(u_k), \quad k = 1, \dots, K.$$

Iloczyn wskaźników taryfikacyjnych dla wszystkich zmiennych uwzględnianych w modelu daje ostateczną stopę taryfy, dzieląc portfel niejednorodny na subportfele jednorodne.

Następnie dla konkretnej polisy wyznaczyć można stopę taryfy uzależnioną od liczby zmiennych taryfikacyjnych wprowadzonych do modelu. Składkę bazową można przyjąć np. na poziomie wyznaczonym przez wyraz wolny dla modelu GLM zmiennej $Y|u$.

3. Procedura k -krotnej krosvalidacji dla modelu HGLM

W pracy [Lee i in. 2006] zaproponowano zmodyfikowaną wersję dewiancji dla modeli HGLM pozwalającą na wybór z grupy modeli modelu najlepszego, czyli takiego, który daje minimalną wartość dewiancji, podobnie jak np. kryterium AIC. Niestety, miara ta w przypadku szacowania parametrów funkcją hierarchicznej wiarygodności (a nie klasycznej jak w przypadku modeli GLM) jest skomplikowana w szacowaniu.

Alternatywą dla dewiancji może być szacowanie rzeczywistego błędu predykcji dla modelu HGLM z wykorzystaniem k -krotnej krosvalidacji [Burman 1989]. W niniejszej pracy zastosowano następujący algorytm dla $k = 10$:

a) losowe wyznaczenie ze zbioru danych 10 podzbiorów o zbliżonej liczebności (n – liczebność całego zbioru, m_l – liczebność l -tego podzbioru, $l = 1, \dots, 10$),

b) 10-krotne szacowanie modelu HGLM na podzbiórze danych o liczebności $n - m_l$ z usunięciem zbioru walidującego,

c) 10-krotne wyznaczenie błędu $MSE_l = \frac{\sum (y - \hat{\mu}_l)^2}{m_l}$,

d) szacowanie błędu krosvalidacji: $cv = \sum_{l=1}^{10} \frac{m_l}{n} MSE_l$.

Porównując modele, wybrano model o najmniejszej wartości cv . Implementację procedury w programie komputerowym R przedstawiono w załączniku A.

4. Przykład empiryczny

Model HGLM zastosowano do budowy taryf *a priori* w ubezpieczeniach komunikacyjnych. Wykorzystano bazę danych szkód komunikacyjnych (*third party motor insurance claims*) zaczerpniętą z bazy http://www.acst.mq.edu.au/research/books/GLMsforInsuranceData/data_sets [de Jong, Heller 2008]. Baza danych zawiera następujące dane uwzględnione w modelu:

- a) Zmienne taryfikacyjne:
- *veh_value* – wartość pojazdu,
 - *veh_age* – wiek pojazdu: 1 (najmłodszy), 2, 3, 4,
 - *gender* – płeć kierowcy: 0 (kobieta), 1,

- *agecat* – wiek kierowcy: 1 (najmłodszy), 2, 3, 4, 5, 6,
 - *veh_body* – kształt pojazdu.
- b) Zmienna objaśniana:
- *claimcst0* – wartość szkody.
 - c) Ekspozycja na ryzyko (mierzona w okresie trwania polisy w stosunku do całego okresu uwzględnianego w bazie):
 - *exposure* – wartości z przedziału $[0,1]$.

W pierwszym kroku rozpatrywano trzy modele HGLM typu gamma-gamma, przyjmując jako efekt losowy zmienną *veh_body*:

1. Model 1 – średnia wartość szkody uzależniona jest od zmiennych taryfikacyjnych, takich jak: wartość pojazdu, wiek pojazdu, płeć kierowcy, wiek kierowcy, kształt pojazdu

$$\begin{aligned} \text{claimcst0} = & \beta_0^1 + \beta_1^1 \text{veh_value} + \beta_2^1 \text{veh_age} + \\ & + \beta_3^1 \text{gender} + \beta_4^1 \text{agecat} + u_1^1 \text{veh_body}. \end{aligned}$$

2. Model 2 – średnia wartość szkody uzależniona jest od zmiennych taryfikacyjnych, takich jak: wartość pojazdu, wiek pojazdu, płeć kierowcy, wiek kierowcy, kształt pojazdu, oraz występuje interakcja pomiędzy płcią i wiekiem kierowcy

$$\begin{aligned} \text{claimcst0} = & \beta_0^2 + \beta_1^2 \text{veh_value} + \beta_2^2 \text{veh_age} + \beta_3^2 \text{gender} + \\ & + \beta_4^2 \text{agecat} + \beta_5^2 \text{gender} * \text{agecat} + u_1^2 \text{veh_body}. \end{aligned}$$

3. Model 3 – średnia wartość szkody uzależniona jest od zmiennych taryfikacyjnych, takich jak: wartość pojazdu, wiek pojazdu, płeć kierowcy, wiek kierowcy, kształt pojazdu, a parametr dyspersji uzależniony jest od wieku pojazdu

$$\begin{aligned} \text{claimcst0} = & \beta_0^3 + \beta_1^3 \text{veh_value} + \beta_2^3 \text{gender} + \beta_3^3 \text{agecat} + u_1^3 \text{veh_body} \\ \phi = & \gamma_0 + \gamma_1 \text{veh_age}. \end{aligned}$$

W modelach przyjęto założenie, iż obserwowane wartości szkód y_i są niezależne, oraz przyjęto tożsamościową funkcję połączenia w modelu dyspersji. Oszacowane parametry strukturalne modelu przedstawiają tabele 1-3.

Tabela 1. Stałe parametry strukturalne w modelu 1

	Parametry stałe	Średni błąd szacunku	p-wartość
$\hat{\beta}_0^1$	7,5908	0,1561	0,0000
<i>veh_value</i>	0,0282	0,0249	0,2586
<i>veh_age</i>	0,0631	0,0239	0,0082
<i>Gender</i>	0,1786	0,0387	0,0000
<i>Agecat</i>	-0,0631	0,0132	0,0000

Źródło: obliczenia własne.

Tabela 2. Stałe parametry strukturalne w modelu 2

	Parametry stałe	Średni błąd szacunku	<i>p</i> -wartość
$\hat{\beta}_0^2$	7,5480	0,1596	0,0000
<i>veh_value</i>	0,0261	0,0249	0,2964
<i>veh_age</i>	0,0619	0,0239	0,0096
<i>Gender</i>	0,2837	0,0963	0,0032
<i>Agecat</i>	-0,0481	0,0179	0,0073
<i>gend:agecat</i>	-0,0312	0,0262	0,2340

Źródło: obliczenia własne.

Tabela 3. Stałe parametry strukturalne w modelu 3

	Parametry stałe	Średni błąd szacunku	<i>p</i> -wartość
$\hat{\beta}_0^3$	7,7411	0,1265	0,0000
<i>veh_value</i>	-0,0079	0,0186	0,6722
<i>Gender</i>	0,1840	0,0387	0,0000
<i>Agecat</i>	-0,0624	0,0132	0,0000

Źródło: obliczenia własne.

We wszystkich modelach *p*-wartość pokazuje, iż zmienna *veh_value* jest statystycznie nieistotna na poziomie istotności 5% oraz nie występuje interakcja pomiędzy zmiennymi *gender* oraz *agecat*. Do dalszej analizy zmodyfikowano więc modele następująco:

4. Model 1.1 – średnia wartość szkody uzależniona jest od zmiennych taryfikacyjnych, takich jak: wiek pojazdu, płeć kierowcy, wiek kierowcy, kształt pojazdu:

$$claimcst0 = \beta_0^{1.1} + \beta_1^{1.1}veh_age + \beta_2^{1.1}gender + \beta_3^{1.1}agecat + u_1^{1.1}veh_body.$$

5. Model 3.1 – średnia wartość szkody uzależniona jest od zmiennych taryfikacyjnych, takich jak: wiek pojazdu, płeć kierowcy, wiek kierowcy, kształt pojazdu, a parametr dyspersji uzależniony jest od wieku pojazdu

$$claimcst0 = \beta_0^{3.1} + \beta_1^{3.1}gender + \beta_2^{3.1}agecat + u_1^{3.1}veh_body$$

$$\phi = \gamma_0 + \gamma_1veh_age.$$

Oszacowane parametry strukturalne zmodyfikowanych modeli przedstawiają tab. 4-5.

Tabela 4. Stałe parametry strukturalne w modelu 1.1

	Parametry stałe	Średni błąd szacunku	<i>p</i> -wartość
$\hat{\beta}_0^{1.1}$	7,6998	0,1237	0,0000
<i>Veh_age</i>	0,0455	0,0178	0,0105
<i>gender</i>	0,1800	0,0387	0,0000
<i>agecat</i>	-0,0640	0,0132	0,0000

Źródło: obliczenia własne.

Tabela 5. Stałe parametry strukturalne w modelu 3.1

	Parametry stałe	Średni błąd szacunku	<i>p</i> -wartość
$\hat{\beta}_0^{3.1}$	7,7202	0,1210	0,0000
<i>gender</i>	0,1829	0,0387	0,0000
<i>agecat</i>	-0,0613	0,0132	0,0000

Źródło: obliczenia własne.

Widać, iż w powyższych modelach wszystkie zmienne są statystycznie istotnie.

W drugim kroku przeprowadzono 10-krotną krosvalidację, uzyskując następujące miary *cv* dla obu modeli:

- $cv^{1.1} = 12667.022$,
- $cv^{3.1} = 12649.699$.

Zatem model 3.1 jest lepszy. W modelu tym losowe parametry dla kształtu samochodu przedstawiają się następująco:

Tabela 6. Losowe parametry strukturalne modelu 3.1

<i>Veh_body</i>	Parametry losowe	Średni błąd szacunku	Wskaźniki taryfikacyjne
BUS	-0,146	0,268	0,86
CONVT	0,044	0,310	1,05
COUPE	0,238	0,167	1,27
HBACK	0,043	0,117	1,04
HDTOP	0,055	0,146	1,06
MCARA	-0,514	0,246	0,60
MIBUS	0,222	0,186	1,25
PANVN	0,037	0,171	1,04
RDSTR	-0,117	0,321	0,89
SEDAN	-0,064	0,116	0,94
STNWG	-0,032	0,116	0,97
TRUCK	0,182	0,148	1,20
UTE	0,050	0,131	1,05

Źródło: obliczenia własne.

Składka bazowa wyznaczana jako eksponent wyrazu wolnego modelu 3.1 wynosi 2253,37. Zatem skorygowana składka bazowa dla kształtu pojazdu, np. COUPE, wynosi 2858,19. Następnie w celu wyznaczenia ostatecznej stopy taryfy należy dalej korygować składkę bazową o kolejne wskaźniki taryfikacyjne dla innych zmiennych taryfikacyjnych występujących w modelu 3.1.

5. Podsumowanie

W artykule przedstawiono w zarysie ideę hierarchicznych liniowych modeli mieszanych oraz możliwości aplikacyjne w wyznaczaniu wskaźników taryfikacyjnych oraz budowie taryf. Przeanalizowano trzy modele, modelując dane zawarte w rzeczywistej bazie danych komunikacyjnych. Wyboru postaci modelu dokonano, stosując procedurę 10-krotnej krosvalidacji. Przeprowadzona procedura pokazuje, w jaki sposób można łatwo dokonać wstępnego wyboru modelu HGLM. W celu ostatecznego przyjęcia modelu do wyznaczania stóp taryf *a priori* niezbędne jest przeprowadzenie weryfikacji statystycznej modelu.

Literatura

- Burman P. (1989), *A comparative study of ordinary cross-validation, v-fold cross-validation and repeated learning-testing methods*, „Biometrika” no 76.
- de Jong P., Heller G.Z. (2008), *Generalized Linear Models for Insurance Data*, Cambridge University Press.
- Lee Y., Nelder A.J., Pawitan Y. (2006), *Generalized Linear Models with Random Effects, Monographs on Statistics and Applied Probability 106*, Chapman&Hall\CRC.

Załącznik A. Implementacja procedury krosvalidacji w programie komputerowym R

```
motor=read.csv(file="car.csv")
```

```
h1=hglm(fixed=claimcst0~veh_value+veh_age+gender+agecat, random=~1|veh_body, family=Gamma(lwejsciek="log"), rand.family=Gamma(lwejsciek="log"), data=motor)
```

```
h2=hglm(fixed=claimcst0~veh_value+veh_age+gender+agecat+gender*agecat, random=~1|veh_body, family=Gamma(lwejsciek="log"), rand.family=Gamma(lwejsciek="log"), data=motor)
```

```
h3=hglm(fixed=claimcst0~veh_value+gender+agecat, random=~1|veh_body, family=Gamma(lwejsciek="log"), disp=~veh_age, data=motor)
```

```
h1.1=hglm(fixed=claimcst0~veh_age+gender+agecat, random=~1|veh_body, family=Gamma(lwejsciek="log"), rand.family=Gamma(lwejsciek="log"), data=motor)
```

```

h3.1=hglm(fixed=claimcst0~gender+agecat,random=~1|veh_body,
family=Gamma(lwejsciek="log"),disp=~veh_age, data=motor)

K=10
n <- nrow(motor)
wyjscie <- NULL
K <- round(K)
K1 <- unique(round(n/(1L:floor(n/2))))
temp <- abs(k1 - K)
f <- ceiling(n/K)
s <- sample(rep(1L:K, f), n)
n.s <- table(s)
y <- motor$claimcst0
mse.01 <- mean((y-h1$fv)^2)
mse.03 <- mean((y-h3$fv)^2)
ms <- max(s)
CV1 <- 0
CV3 <- 0
predict.h1=c()
predict.h3=c()
Call1 <- h1$call
Call3 <- h3$call
for (i wejscie 1L:ms) {
j.wyjscie <- c(1L:n)[(s == i)]
j.wejscie <- c(1L:n)[(s != i)]
Call1$data <- data[j.wejscie, , drop = FALSE]
Call3$data <- data[j.wejscie, , drop = FALSE]
wynik.h1 <- eval.parent(Call1)
wynik.h3 <- eval.parent(Call3)
p.alpha <- n.s[i]/n
for (k wejscie 1:length(j.wyjscie)) {
predict.h1=c(predict.h1,wynik.h1$fv[k])
predict.h3=c(predict.h3,wynik.h3$fv[k])
}
mse1.i <- mean((y[j.wyjscie]- predict.h1)^2)
mse3.i <- mean((y[j.wyjscie]- predict.h3)^2)
CV1 <- CV1 + p.alpha * mse1.i
CV3 <- CV3 + p.alpha * mse3.i
mse.01 <- mse.01 - p.alpha * mean((y-h1$fv)^2)
mse.03 <- mse.03 - p.alpha * mean((y-h3$fv)^2)
}
CV_MSE1 <- CV1 + mse.01
CV_MSE3 <- CV3 + mse.02

```

COMPARATIVE ANALYSIS OF MIXED MODELS FOR RATEMAKING IN NON-LIFE INSURANCE WITH K-FOLD CROSS-VALIDATION

Summary: The paper presents the application of hierarchical generalized linear models (HGLM) in the process of *a priori* ratemaking. As explained variable assumed the average value of claims paid (the continuous variable) and as explanatory variables – variables characterizing the subject and the person insured (nominal variables). The important computational problem in HGLM models is to determine the deviance which can be used as a criterion for the selection of the final form of the model. Thus, in order to simplify the first part of computing *a priori* ratemaking (omitting the calculation of the deviance), k-fold cross-validation procedure was used and the estimated k-fold cross-validation prediction error was calculated. The case study was presented for a portfolio of motor insurance. The procedure was implemented in a computer program R.

Key words: ratemaking, the hierarchical generalized linear model, k-fold cross-validation.