

**Komisja Egzaminacyjna dla Aktuariuszy**

**LXXXV Egzamin dla Aktuariuszy**

**Sesja egzaminacyjna w dniu 9 czerwca 2022 r.**

**Modelowanie**

**Imię i nazwisko osoby egzaminowanej: .....**

**Czas trwania egzaminu: 120 minut**

### Uwagi

- a) W prezentowanych wynikach separatorem dziesiętnym (znakiem dziesiętnym) jest kropka „.”.
- b) Wartości  $\chi^2_{\alpha;v}$  rozkładu chi-kwadrat spełniające warunek  $P(\chi^2 \geq \chi^2_{\alpha;v}) = \alpha$

$v \backslash \alpha$	<b>0.995</b>	<b>0.99</b>	<b>0.975</b>	<b>0.95</b>	<b>0.9</b>	<b>0.1</b>	<b>0.05</b>	<b>0.025</b>	<b>0.01</b>	<b>0.005</b>
<b>1</b>	0.000	0.000	0.001	0.004	0.016	2.706	3.841	5.024	6.635	7.879
<b>2</b>	0.010	0.020	0.051	0.103	0.211	4.605	5.991	7.378	9.210	10.597
<b>3</b>	0.072	0.115	0.216	0.352	0.584	6.251	7.815	9.348	11.345	12.838
<b>4</b>	0.207	0.297	0.484	0.711	1.064	7.779	9.488	11.143	13.277	14.860
<b>5</b>	0.412	0.554	0.831	1.145	1.610	9.236	11.070	12.833	15.086	16.750
<b>6</b>	0.676	0.872	1.237	1.635	2.204	10.645	12.592	14.449	16.812	18.548
<b>7</b>	0.989	1.239	1.690	2.167	2.833	12.017	14.067	16.013	18.475	20.278
<b>8</b>	1.344	1.646	2.180	2.733	3.490	13.362	15.507	17.535	20.090	21.955
<b>9</b>	1.735	2.088	2.700	3.325	4.168	14.684	16.919	19.023	21.666	23.589
<b>10</b>	2.156	2.558	3.247	3.940	4.865	15.987	18.307	20.483	23.209	25.188
<b>11</b>	2.603	3.053	3.816	4.575	5.578	17.275	19.675	21.920	24.725	26.757
<b>12</b>	3.074	3.571	4.404	5.226	6.304	18.549	21.026	23.337	26.217	28.300
<b>13</b>	3.565	4.107	5.009	5.892	7.042	19.812	22.362	24.736	27.688	29.819
<b>14</b>	4.075	4.660	5.629	6.571	7.790	21.064	23.685	26.119	29.141	31.319
<b>15</b>	4.601	5.229	6.262	7.261	8.547	22.307	24.996	27.488	30.578	32.801

c) Dystrybuanta standardowego rozkładu normalnego.

	<i>0</i>	<i>0.01</i>	<i>0.02</i>	<i>0.03</i>	<i>0.04</i>	<i>0.05</i>	<i>0.06</i>	<i>0.07</i>	<i>0.08</i>	<i>0.09</i>
<i>0</i>	0.500	0.504	0.508	0.512	0.516	0.520	0.524	0.528	0.532	0.536
<i>0.1</i>	0.540	0.544	0.548	0.552	0.556	0.560	0.564	0.567	0.571	0.575
<i>0.2</i>	0.579	0.583	0.587	0.591	0.595	0.599	0.603	0.606	0.610	0.614
<i>0.3</i>	0.618	0.622	0.626	0.629	0.633	0.637	0.641	0.644	0.648	0.652
<i>0.4</i>	0.655	0.659	0.663	0.666	0.670	0.674	0.677	0.681	0.684	0.688
<i>0.5</i>	0.691	0.695	0.698	0.702	0.705	0.709	0.712	0.716	0.719	0.722
<i>0.6</i>	0.726	0.729	0.732	0.736	0.739	0.742	0.745	0.749	0.752	0.755
<i>0.7</i>	0.758	0.761	0.764	0.767	0.770	0.773	0.776	0.779	0.782	0.785
<i>0.8</i>	0.788	0.791	0.794	0.797	0.800	0.802	0.805	0.808	0.811	0.813
<i>0.9</i>	0.816	0.819	0.821	0.824	0.826	0.829	0.831	0.834	0.836	0.839
<i>1</i>	0.841	0.844	0.846	0.848	0.851	0.853	0.855	0.858	0.860	0.862
<i>1.1</i>	0.864	0.867	0.869	0.871	0.873	0.875	0.877	0.879	0.881	0.883
<i>1.2</i>	0.885	0.887	0.889	0.891	0.893	0.894	0.896	0.898	0.900	0.901
<i>1.3</i>	0.903	0.905	0.907	0.908	0.910	0.911	0.913	0.915	0.916	0.918
<i>1.4</i>	0.919	0.921	0.922	0.924	0.925	0.926	0.928	0.929	0.931	0.932
<i>1.5</i>	0.933	0.934	0.936	0.937	0.938	0.939	0.941	0.942	0.943	0.944
<i>1.6</i>	0.945	0.946	0.947	0.948	0.949	0.951	0.952	0.953	0.954	0.954
<i>1.7</i>	0.955	0.956	0.957	0.958	0.959	0.960	0.961	0.962	0.962	0.963
<i>1.8</i>	0.964	0.965	0.966	0.966	0.967	0.968	0.969	0.969	0.970	0.971
<i>1.9</i>	0.971	0.972	0.973	0.973	0.974	0.974	0.975	0.976	0.976	0.977
<i>2</i>	0.977	0.978	0.978	0.979	0.979	0.980	0.980	0.981	0.981	0.982
<i>2.1</i>	0.982	0.983	0.983	0.983	0.984	0.984	0.985	0.985	0.985	0.986
<i>2.2</i>	0.986	0.986	0.987	0.987	0.987	0.988	0.988	0.988	0.989	0.989
<i>2.3</i>	0.989	0.990	0.990	0.990	0.990	0.991	0.991	0.991	0.991	0.992
<i>2.4</i>	0.992	0.992	0.992	0.992	0.993	0.993	0.993	0.993	0.993	0.994
<i>2.5</i>	0.994	0.994	0.994	0.994	0.994	0.995	0.995	0.995	0.995	0.995
<i>2.6</i>	0.995	0.995	0.996	0.996	0.996	0.996	0.996	0.996	0.996	0.996
<i>2.7</i>	0.997	0.997	0.997	0.997	0.997	0.997	0.997	0.997	0.997	0.997
<i>2.8</i>	0.997	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.998
<i>2.9</i>	0.998	0.998	0.998	0.998	0.998	0.998	0.998	0.999	0.999	0.999
<i>3</i>	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999	0.999

**Zadanie 1.**

Wysokość pojedynczego roszczenia  $Y_i$  w pewnym portfelu ubezpieczeń AC modelowano z uwzględnieniem dwóch zmiennych objaśniających:

- *CarAge* - wiek samochodu (w latach)
- *Brand* – marka samochodu. Zmienna jakościowa przyjmująca następujące kategorie: *A, B, C, D, E, F* i *G*.

Oszacowano uogólniony model liniowy, w którym uwzględniono powyższe zmienne objaśniające i założono rozkład gamma dla  $Y_i$ . Przyjęto kanoniczną funkcję łączącą. Uzyskano następujące wyniki:

Coefficients:

	Estimate	Std. Error	t value	Pr(> t )
(Intercept)	7.460e-04	1.439e-05	51.825	< 2e-16 ***
<i>CarAge</i>	6.804e-06	1.498e-06	4.543	5.59e-06 ***
<i>BrandB</i>	-5.203e-06	3.562e-05	-0.146	0.88388
<i>BrandC</i>	8.323e-06	3.666e-05	0.227	0.82037
<i>BrandD</i>	8.680e-05	5.756e-05	1.508	0.13152
<i>BrandE</i>	-5.828e-06	4.490e-05	-0.130	0.89673
<i>BrandF</i>	4.322e-06	2.462e-05	0.176	0.86067
<i>BrandG</i>	7.993e-05	7.099e-05	1.126	0.26025
<i>CarAge:BrandB</i>	2.049e-07	4.099e-06	0.050	0.96013
<i>CarAge:BrandC</i>	1.148e-06	4.173e-06	0.275	0.78323
<i>CarAge:BrandD</i>	-5.024e-06	6.650e-06	-0.755	0.44999
<i>CarAge:BrandE</i>	-4.010e-06	4.372e-06	-0.917	0.35905
<i>CarAge:BrandF</i>	-1.147e-05	4.318e-06	-2.656	0.00791 **
<i>CarAge:BrandG</i>	-1.021e-05	7.537e-06	-1.355	0.17549

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for Gamma family taken to be **0.7826157**)

Null deviance: 11904 on 15866 degrees of freedom

Residual deviance: 11861 on 15853 degrees of freedom

AIC: 257036

- a) (**1p.**) Podaj definicję kanonicznej funkcji łączącej (linku kanonicznego)?
- b) (**2p.**) Jaką postać ma kanoniczna funkcja łącząca w uogólnionym modelu liniowym, w którym zmienna objaśniana ma rozkład gamma.  
Funkcja gęstości i wartość oczekiwana dla rozkładu gamma są odpowiednio równe:  $f(x) = \frac{\beta^\alpha}{\Gamma(\alpha)} x^{\alpha-1} \exp(-\beta x)$ ,  $x > 0$ ;  $\mu = \frac{\alpha}{\beta}$ .
- c) (**1p.**) Podaj postać wiersza w macierzy obserwacji (*design matrix, model matrix, regressor matrix*), który odpowiada 10-letniemu samochodowi marki F (wektora obserwacji dla tego samochodu).
- d) (**1p.**) Wykorzystując oszacowany model, wyznacz wariancję wysokości pojedynczej szkody dla tego samochodu (10-letni samochód marki F).

### Odpowiedzi

#### Odp. a)

Funkcję  $g(\cdot)$  nazywamy linkiem kanonicznym (kanoniczną funkcją wiążącą), gdy  $\theta_i = g(\mu_i)$ , gdzie  $\theta_i$  oznacza parametr kanoniczny rozkładu zmiennej losowej  $Y_i$  (należącego do wykładniczej rodziny rozkładów), natomiast  $\mu_i = E(Y_i)$ .

#### Odp. b)

Przyjmijmy następującą parametryzację wykładniczej rodziny rozkładów:

$$f(y_i; \theta_i, \phi) = \exp\left(\frac{y_i \theta_i - b(\theta_i)}{a(\phi)} + c(y_i, \phi)\right),$$

gdzie:  $\theta_i$  - parametr kanoniczny,  $\phi$  - parametr dyspersji.

Wiadomo, że  $\mu_i = b'(\theta_i)$ , czyli  $\theta_i = b'^{-1}(\mu_i)$ . Dla rozkładu gamma  $b(\theta_i) = -\ln(-\theta_i)$ , skąd otrzymujemy link kanoniczny postaci  $g(\mu_i) = -\frac{1}{\mu_i}$ .

#### Odp. c)

$$\mathbf{x}_i = [1 \ 10 \ 0 \ 0 \ 0 \ 0 \ 0 \ 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 10 \ 0]$$

#### Odp. d)

$$\text{Var}(Y_i) = 1580594,11$$

#### Rozwiązanie:

$$\mathbf{x}_i \boldsymbol{\beta}^T = 0,00070366, \text{ stąd } \mu_i = 1421.1369$$

$$\text{Var}(Y_i) = \phi \cdot \mu_i^2 = 0.7826157 \cdot 1421.1369^2 = 1580594,11$$

**Zadanie 2.**

Dla pewnego portfela ubezpieczeń badano zależność rocznej liczby szkód (zmienna  $K_i$ ) od wieku ubezpieczonego wyrażonego w latach (zmienna ilościowa *wiek*) oraz od tego, czy szkoda wystąpiła w poprzednim roku (zmienna jakościowa *szkoda.poprzedni.rok*, przyjmująca dwie wartości: „TAK”- gdy szkoda wystąpiła oraz „NIE”- gdy szkoda nie wystąpiła). Oszacowano dwa modele regresji Poissona z kanonicznymi funkcjami łączącymi (linkami kanonicznymi). W obydwu modelach jako zmienną offsetową uwzględniono czas ekspozycji (w latach) na skali kanonicznej. Uzyskano następujące wyniki:

**Model M1:**

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-1.410969	0.093913	-15.024	< 2e-16 ***
<i>wiek</i>	-0.009919	0.002089	-4.749	2.04e-06 ***
<i>szkoda.poprzedni.rok</i> TAK	0.088382	0.044637	1.980	0.0477 *

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)

Null deviance: 9881.4 on 24455 degrees of freedom

Residual deviance: 9856.0 on 24453 degrees of freedom

AIC: 13740

**Model M2** (zmienna *wiek.kw* =  $wiek^2$ ):

Coefficients:

	Estimate	Std. Error	z value	Pr(> z )
(Intercept)	-0.2613798	0.2844895	-0.919	0.3582
<i>wiek</i>	-0.0633078	0.0126683	-4.997	5.81e-07 ***
<i>wiek.kw</i>	0.0005816	0.0001354	4.294	1.75e-05 ***
<i>szkoda.poprzedni.rok</i> TAK	0.0944986	0.0446955	2.114	0.0345 *

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

(Dispersion parameter for poisson family taken to be 1)


Null deviance: 9881.4 on 24455 degrees of freedom

Residual deviance: 9839.1 on 24452 degrees of freedom

AIC: 13725

Na poniższym rysunku (Rys. 2.1) przedstawiono zależność średniej rocznej liczby szkód od wieku i wystąpienia szkody w poprzednim roku, otrzymaną na podstawie danych rzeczywistych i oszacowanych modeli M1 i M2. Wystąpienie lub niewystąpienie szkody rozróżniono kolorem.

Rysunek 2.1



- a) (2p.) Opisz składowe wykresu przedstawionego na rysunku 2.1, w szczególności krzywe A, B, C, D i punkty „luźno rozrzucone”. Który kolor oznacza wystąpienie, a który niewystąpienie szkody w poprzednim roku? **Odpowiedzi odpowiednio uzasadnij!**
- b) (1p.) Wskaż, który z tych dwóch modeli jest lepszy. Wybór uzasadnij w oparciu o przedstawione wyniki oszacowań modeli i wykres przedstawiony na rysunku 2.1.
- c) (2p.) Do zbioru uczącego wykorzystanego do oszacowania obydwu modeli należy 30-sto letni ubezpieczony z sześciomiesięczną ekspozycją na ryzyko ( $ekspozycja = 0.5$ ), w czasie której zgłosił jedną szkodę. W jego przypadku nie zanotowano szkody w poprzednim roku. Dla obydwu modeli wyznacz resztę Pearsona odpowiadającą tej obserwacji.

### Odpowiedzi:

.....

#### Odp. a)

Kolorem czerwonym oznaczono średnią roczną liczbę szkód dla kierowców, w przypadku których zanotowano szkodę w poprzednim roku. Wskazuje na to dodatnia wartość parametru przy zmiennej  $szkoda.poprzedni.rok$  TAK. Opis krzywych:

- A i B - średnia roczna liczba szkód oszacowana na podstawie modelu M2,
- C i D - średnia roczna liczba szkód oszacowana na podstawie modelu M1.

Punkty „luźno rozrzucone” oznaczają rzeczywistą średnią roczną liczbę szkód wyznaczoną na podstawie zbioru uczącego.

---

.....

**Odp. b)**

Należało wybrać model M2. Na taki wybór wskazuje mniejsza wartość kryterium AIC dla tego modelu (przy statystycznie istotnych wszystkich parametrach obydwu modeli) oraz zależność w kształcie litery „U” średniej rocznej liczby szkód wyznaczonej na podstawie zbioru uczącego od wieku (punkty „luźno rozrzucone”).

.....

**Odp. c)**Model M1

$$r_i^P = 3,021976876$$

Model M2

$$r_i^P = 2,894564838$$

---

**Rozwiązanie:**

Reszta Pearsona dla rozkładu Poissona:

$$r_i^P = \frac{y_i - \hat{\mu}_i}{\sqrt{\hat{\mu}_i}}$$

Model M1

$$\hat{\mu}_i = 0,090565115, \text{ stąd } r_i^P = \frac{1-0,090565115}{\sqrt{0,090565115}} = 3,021976876$$

Model M2

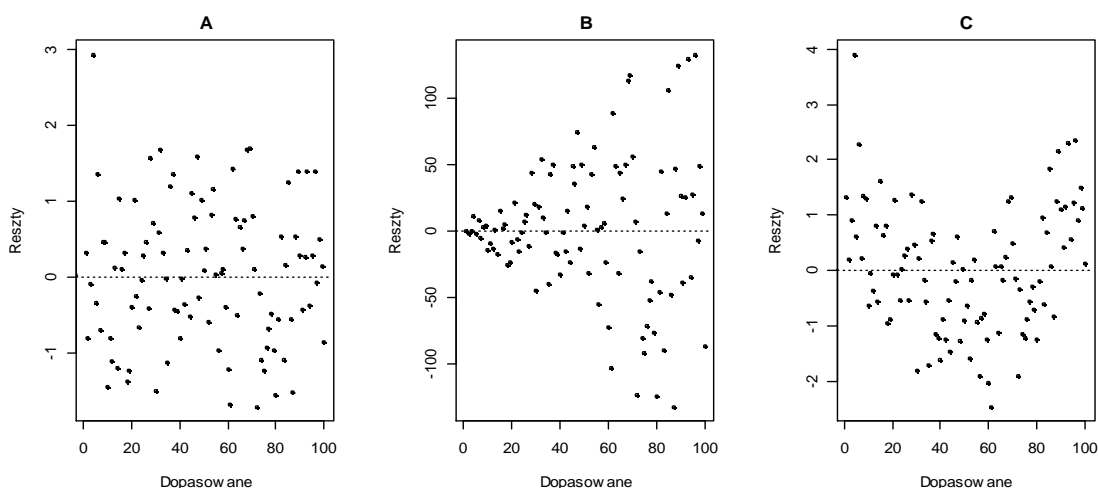
$$\hat{\mu}_i = 0,097264522, \text{ stąd } r_i^P = \frac{1-0,097264522}{\sqrt{0,097264522}} = 2,894564838$$



**Zadanie 3.**


- a) (2p.) Wymień cztery własności, które powinny spełniać reszty w liniowym modelu regresji.
- b) (1p.) Na poniższym rysunku (Rys. 3.1) przedstawiono wykresy reszty vs wartości dopasowane (*Residuals vs Fitted*) dla trzech oszacowanych modeli A, B i C. Co na podstawie tych wykresów można powiedzieć na temat reszt modeli A, B i C w kontekście własności omówionych w podpunkcie a)?

Rysunek 3.1



- c) (1p.) Zdefiniuj obserwację wpływową (*influential observation*) i krótko omów w jaki sposób można ją zidentyfikować.
- d) (1p.) Na wykresach zamieszczonych na poniższym rysunku (Rys. 3.2) linie ciągłe przedstawiają proste regresji wyznaczone bez uwzględnienia wyróżnionych punktów (tj. na lewym wykresie bez punktu A, a na prawym bez punktu B) a przerywane z ich uwzględnieniem. Czy obydwa punkty można uznać za wpływowe? Odpowiedź uzasadnij.

Rysunek 3.2



---

**Odpowiedzi:**.....  
**Odp. a)**

Reszty poprawnie oszacowanego modelu liniowego (m.in.):

- powinny mieć średnią równą zero,
- powinny mieć rozkład normalny,
- powinny być jednorodne,
- nie powinny zależeć funkcyjnie od wartości,
- powinny być niezależne,
- nie powinny być skorelowane ze zmiennymi niezależnymi,

.....  
**Odp. b)**

Wykresy reszty vs wartości dopasowane wskazują, że

- reszty modelu A spełniają warunki poprawnie oszacowanego modelu liniowego,
- reszty modelu B nie są jednorodne,
- reszty modelu C zależą funkcyjnie od wartości dopasowanych.

.....  
**Odp. c)**

Obserwacja wpływowa to taka, której usunięcie ze zbioru danych spowodowałoby dużą zmianę dopasowania (wartości oszacowanych parametrów). Obserwacja taka może, ale nie musi, być wartością odstającą i może, ale nie musi, mieć dużą dźwignię, ale będzie miała co najmniej jedną z tych dwóch właściwości. W celu jej identyfikacji można wykorzystać miarę Cooka.

.....  
**Odp. d)**

Za wpływowy można uznać tylko punkt A. Usunięcie go ze zbioru danych powoduje znacząco poprawę dopasowania modelu.

---

**Rozwiązanie:**

**Zadanie 4.**

Wystąpienie oszustwa w zgłaszanych roszczeniach modelowano z wykorzystaniem uogólnionego modelu liniowego. Dla wartości progowej (punktu odcięcia) równej 0.25 otrzymano następującą macierz trafności prognoz (Tab. 4.1):

Tabela 4.1

Prognozy	Faktyczne	
	N ( $y_i = 0$ )	P ( $y_i = 1$ )
N ( $y_i^P = 0$ )	1200	160
P ( $y_i^P = 1$ )	60	80

- (1p.) Wskaż jakie funkcje łączące (linki) mogą być wykorzystywane w uogólnionych modelach liniowych z binarną zmienną objaśnianą. Krótko wyjaśnij dlaczego takie funkcje są właściwe i podaj co najmniej trzy przykłady.
- (1p.) Oblicz specyficzność (*specificity*) i czułość (*sensitivity*), wykorzystując podane w treści zadania dane.
- (2p.) Narysuj krzywą ROC dla wartości progowej 0.25. Opisz osie oraz zaznacz i podaj współrzędne punktów, które odpowiadają wartościom progowym 0.25 oraz 0 i 1. Dodatkowo narysuj krzywe ROC dla
  - modelu nie posiadającego żadnych zdolności predykcyjnych;
  - hipotetycznego „idealnego” modelu.
- (1p.) Czy w tego typu modelach wysokość szkód może mieć wpływ na wybór wartości progowej (punktu odcięcia)? Odpowiedź krótko uzasadnij.

**Odpowiedzi****Odp. a)**

Za pomocą uogólnionych modeli liniowych z binarną zmienną objaśnianą modelujemy prawdopodobieństwo, że zmienna ta przyjmuje wartość jeden. Z kolei, predyktor liniowy może przyjmować dowolne wartości rzeczywiste. W związku z tym linkiem powinna być funkcja określona na przedziale  $[0, 1]$  i przyjmująca wartości ze zbioru liczb rzeczywistych. Może to być np. logit, probit lub odwrotna dystrybucja innego rozkładu określonego na zbiorze liczb rzeczywistych.

**Odp. b)**


$$\text{Specyficzność} = \frac{1200}{1260} = 0,9524$$

$$\text{Czułość} = \frac{80}{240} = 0,3333$$

**Odp. c)**

Krzywe ROC:

- niebieska dla wartości progowej 0.25
- czerwona przerywana dla modelu nie posiadającego żadnych zdolności predykcyjnych
- czerwona ciągła dla hipotetycznego „idealnego” modelu.

**Odp. d)**

Wysokość szkód może mieć wpływ na wybór wartości progowej. Z wartością progową związaną jest liczba kontroli przypadków, dla których prognozowana jest możliwość oszustwa. O liczbie takich kontroli może decydować porównanie ich kosztów z kosztami niesłusznie wypłaconych odszkodowań. Np. w przypadku bardzo wysokich możliwych odszkodowań, koszty częstych kontroli mogą okazać się niższe od niesłusznie wypłaconych odszkodowań.

**Rozwiązanie:**

**Zadanie 5.**

Na podstawie tygodniowych logarytmicznych stóp zwrotu  $r_t$  dla spółki *Allianz* z okresu od 21-11-2003 do 06-05-2022 (liczba obserwacji  $T=964$ ) oszacowano dwa modele M1 i M2:

- Model M1: ARMA(0,0)-GARCH(1,1) z rozkładem normalnym dla innowacji.
- Model M2: ARMA(0,0)-GARCH(1,1) ze skośnym rozkładem t-Studenta dla innowacji.

Uzyskano następujące wyniki:

**Model M1**

## Optimal Parameters


	Estimate	Std. Error	t value	Pr(> t )
mu	0.002223	0.001004	2.2135	0.026864
omega	0.000096	0.000024	3.9939	0.000065
alpha1	0.200018	0.036350	5.5026	0.000000
beta1	0.753919	0.036541	20.6324	0.000000

LogLikelihood : 1841.932

## Information Criteria

Akaike	-3.8131
Bayes	-3.7929
Shibata	-3.8132
Hannan-Quinn	-3.8054

Rysunek 5.1



Wartości rzeczywiste i oszacowane warunkowe wariancje  $\hat{\sigma}_t^2$  dla 3 ostatnich tygodni:

t	962	963	964
$r_t$	0.0004563085	-0.0137806499	-0.0556359297
$\hat{\sigma}_t^2$	0.0013652479	0.0011259237	0.0009960976

Model **M2**

## Optimal Parameters


	Estimate	Std. Error	t value	Pr(> t )
mu	0.001836	0.000983	1.8671	0.061890
omega	0.000059	0.000021	2.8474	0.004407
alpha1	0.127545	0.030192	4.2245	0.000024
beta1	0.835771	0.032503	25.7138	0.000000
skew	0.880624	0.040562	21.7108	0.000000
shape	5.799026	1.020120	5.6847	0.000000

LogLikelihood : 1886.593

## Information Criteria

Akaike	-3.9016
Bayes	-3.8713
Shibata	-3.9017
Hannan-Quinn	-3.8901

Rysunek 5.2

Wartości rzeczywiste i oszacowane warunkowe wariancje  $\hat{\sigma}_t^2$  dla 3 ostatnich tygodni:

t	962	963	964
$r_t$	0.0004563085	-0.0137806499	-0.0556359297
$\hat{\sigma}_t^2$	0.001531988	0.001339137	0.001208819

- (2p.) Krótko opisz klasę modeli GARCH( $p, q$ ).
- (2p.) Wskaż, który z modeli M1 i M2 jest lepszy. Wybór uzasadnij, powołując się na podane wyniki ich oszacowań, w tym na wykresy zamieszczone na rysunkach 5.1 i 5.2.
- (1p.) Wykorzystując wskazany model wyznacz prognozy warunkowej wariancji na okresy:  $T + 1, T + 2$ .

---

**Odpowiedzi:**

.....

**Odp. a)**

Modele klasy GARCH wykorzystuje się do analizy szeregów czasowych. Stosuje się je głównie w analizie i prognozowaniu zmienności cen instrumentów finansowych. Za ich pomocą można opisać typowe własności finansowych szeregów czasowych.

.....

**Odp. b)**

Należało wybrać model M2. Wskazują na to mniejsze wartości kryteriów informacyjnych, jak również lepsze dopasowanie skośnego rozkładu t-Studenta dla innowacji.

.....

**Odp. c)**

$$\hat{\sigma}_{965}^2 = 0.001490078$$

$$\hat{\sigma}_{966}^2 = 0.001493918$$

---

**Rozwiązanie:**

Model ARMA(0,0)-GARCH(1,1) ma postać:

$$\begin{aligned} r_t &= \mu + \varepsilon_t \\ \varepsilon_t &= z_t \sigma_t \\ \sigma_t^2 &= \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 \end{aligned}$$

Zatem wykorzystując model M2, otrzymujemy:

$$\hat{\varepsilon}_{964} = -0.0556359297 - 0.001836 = -0.05747166$$

$$\begin{aligned} \hat{\sigma}_{965}^2 &= 0.000059 + 0.127545 \cdot (-0.05747166)^2 + 0.835771 \cdot 0.001208819 \\ &= 0.001490078 \end{aligned}$$

$$\hat{\sigma}_{966}^2 = 0.001493918$$

**Zadanie 6.**

- a) (3p) Dane zgrupowano w następujący sposób:

$x_i$	$n_i$
$(c_0, c_1]$	$n_1$
$(c_1, c_2]$	$n_2$
$\vdots$	$\vdots$
$(c_{k-1}, c_k]$	$n_k$
$(c_k, \infty)$	0

gdzie  $c_0 = 0$ . Przedstaw sposób wyznaczania dystrybuanty empirycznej dla danych zgrupowanych. Co to jest krzywa ogiwalna (*ogive*)? Jak się ją wyznacza?

- b) (2p) Dane dotyczące wysokości 100 roszczeń (w tys. zł.) przedstawiono w następujący sposób:

$x_i$	$n_i$
$(0, 1]$	16
$(1, 3]$	22
$(3, 5]$	25
$(5, 10]$	18
$(10, 25]$	9
$(25, 50]$	6
$(50, 100]$	4
$(100, \infty)$	0

Wykorzystując krzywą ogiwalną wyznaczyć kwartył 1 ( $Q_1$ ) oraz decyl 9 (kwantyl rzędu 0.90).

**Odpowiedzi:****Odp. a)**

Strategia wyznaczania dystrybuanty dla danych zgrupowanych polega na obliczeniu dla końców przedziałów następujących jej wartości  $F_n(c_j) = \frac{1}{n} \sum_{i=1}^j n_i$  (gdzie  $n = \sum_{j=1}^k n_j$ ), a następnie połączeniu tych wartości w „rozsądny” sposób. Jeżeli połączymy punkty  $(c_j, F_n(c_j))$  odcinakami otrzymujemy dystrybuantę empiryczną nazywaną krzywą ogiwalną. Wówczas:

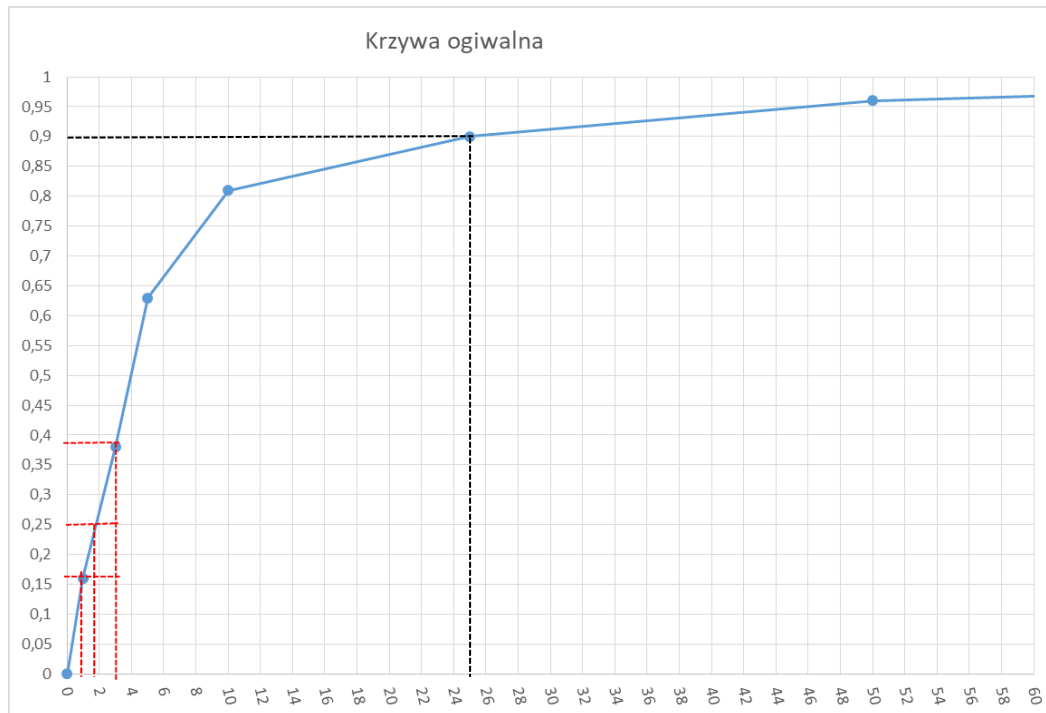
$$F_n(x) = \frac{c_j - x}{c_j - c_{j-1}} F_n(c_{j-1}) + \frac{x - c_{j-1}}{c_j - c_{j-1}} F_n(c_j), \quad c_{j-1} \leq x \leq c_j.$$

**Odp. b)**

$$q_{0.25} = Q_1 = 1.8181$$

$$q_{0.90} = 25$$



**Rozwiązanie:**

Kwartył pierwszy:

$$\frac{0.38 - 0.16}{3 - 1} = \frac{0.25 - 0.16}{q_{0.90} - 1}$$
$$q_{0.25} = Q_1 = 1.8181$$

$$q_{0.90} = 25$$

**Zadanie 7.**

- a) (2p.) Omów metodę symulacyjną wyznaczania rozkładu łącznych (zagregowanych) szkód w modelu ryzyka kolektywnego. Podaj sposób postępowania (algorytm).
- b) (3p.) Wyznacz realizację z rozkładu łącznych (zagregowanych) szkód w modelu ryzyka kolektywnego przy założeniu, że liczba szkód ma rozkład Poissona z parametrem  $\lambda = 2$  a wysokość pojedynczej szkody ma rozkład logarytmiczno-normalny z parametrami  $\mu = 1$  i  $\sigma = 2$ . Wykorzystaj po kolei niezbędną liczbę następujących wartości wylosowanych z rozkładu jednostajnego  $U[0, 1]$ : 0.545, 0.773, 0.968, 0.739, 0.905, 0.960, 0.560

**Odpowiedzi:****Odp. a)**

W modelu ryzyka kolektywnego łączne szkody są modelowane za pomocą zmiennej  $Z = \sum_{i=1}^K X_i$ , gdzie:  $K$  – zmienna losowa opisując roczną liczbę szkód,  $X_i$  - zmienne losowe o takim samym rozkładzie opisujące wysokości pojedynczych szkód.

Algorytm:

1. Generujemy liczbę szkód  $k$ , przy założeniu określonej postaci rozkładu zmiennej  $K$ .
2. Generujemy wysokości  $k$  szkód:  $x_1, \dots, x_k$ , przy założeniu określonej postaci rozkładu zmiennej  $X_i$ .
3. Wyznaczamy sumę  $z = x_1 + \dots + x_k$ , która jest jedną realizacją zmiennej  $Z$ .
4. Powtarzamy kroki (1)-(3) żadaną liczbę razy  $n$ .
5. Wyznaczamy dystrybuantę empiryczną  $F_n(z)$  na podstawie pseudolosowej próby  $z_1, \dots, z_n$ .

**Odp. b)**

$$z = 122,5800$$

**Rozwiązanie:**

ad. b)


1. Losujemy liczbę z rozkładu Poissona z parametrem  $\lambda = 2$ . Korzystamy z metody odwracania dystrybuanty. Znajdujemy najmniejszą liczbę  $k$  (całkowitą nieujemną), która spełnia nierówność  $F_K(k) \geq u$ , gdzie  $u$  jest wartością wylosowaną z rozkładu jednostajnego  $U[0, 1]$ . W rozważanym przypadku  $u = 0.545$ ,  $F_K(0) = 0.1353$ ,  $F_K(1) = 0.4060$ ,  $F_K(2) = 0.6767$ . Tak więc wylosowana liczba szkód wynosi 2.
2. Losujemy dwie liczby z rozkładu logarytmiczno-normalnego z parametrami  $\mu = 1$  i  $\sigma = 2$ . Korzystamy z metody odwracania dystrybuanty.  
 $F_{X_i}(x) = u$ , czyli  $\Phi^{-1}(u) = \frac{\ln(x) - \mu}{\sigma}$ , stąd  $F_{X_i}^{-1}(u) = \exp(\sigma \Phi^{-1}(u) + \mu)$   
Stąd  $x_1 = 12.1524$ ,  $x_2 = 110.4276$ .
3. Wyznaczamy realizację  $z = 12.1524 + 110.4276 = 122,5800$ .

**Zadanie 8.**

Analizując zależność między zmienną objaśnianą  $Y$  i zmienną objaśniającą  $X$ , w pierwszej kolejności oszacowano liniowy model regresji  $y_i = \alpha + \beta x_i + \varepsilon_i$ . Dla tego modelu:


- Wyniki testu Breuscha-Pagana są następujące:  
studentized Breusch-Pagan test  
data: model.1  
BP = 12.419, df = 1, p-value = 0.000425
- Wykres reszty vs wartości dopasowane (*Residuals vs Fitted*) przedstawia poniższy rysunek (Rys. 8.1):

Rysunek 8.1



Na potrzeby analizy skonstruowano także przedstawiony na rysunku 8.2 wykres, w którym na osi odciętych są podane wartości parametru  $\lambda$  w transformacji Boxa-Coxa, a na osi rzędnych wartości funkcji wiarygodności modelu, w którym zmienna objaśniana  $X$  została przekształcona przez tą transformację (z parametrem  $\lambda$ ).

Rysunek 8.2



- (1p) W jakim celu przeprowadza się transformacje zmiennej objaśnianej?
- (1p) Omów klasę transformacji Boxa-Coxa.

- c) (3p) Czy biorąc pod uwagę informacje podane w treści zadania, można twierdzić, że oszacowano adekwatny model? Jeżeli nie, to wskaż postać lepszego modelu.  
**Odpowiedzi uzasadnij powołując się na podane wykresy i wyniki testu.**

**Odpowiedzi:**

.....  
**Odp. a)**

Transformacje zmiennej zależnej przeprowadza się m.in. w celu:

- sprowadzenia zależności nieliniowych do postaci liniowej (wówczas często transformuje się również zmienne objaśniające),
- sprowadzenia jej rozkładu do rozkładu normalnego (zbliżonego do normalnego),
- stabilizacji wariancji.

.....  
**Odp. b)**

Klasę transformacji Boxa-Coxa określa się następująco:

$$y'_i = \begin{cases} \frac{y_i^\lambda - 1}{\lambda}, & \lambda \neq 0 \\ \ln(y_i), & \lambda = 0 \end{cases}, \quad y_i > 0$$

Warunek  $y_i > 0$  nie jest zbyt krępujący, gdyż można wstępnie przesunąć zakres obserwowanych wielkości w obszar wartości dodatnich.

.....  
**Odp. c)**

Nie. Wskazują na to wyniki testu jednorodności wariancji Breuscha-Pagana i prawdopodobna funkcyjna zależność reszt od wartości dopasowanych (rys. 8.1).

Na podstawie wykresu przedstawionego na rys. 8.2, można przypuszczać, że otrzymamy lepszy model dla przekształconej zmiennej objaśnianej za pomocą transformacji Boxa-Coxa z parametrem  $\lambda$  bliskim zeru lub równym zeru (czyli dla  $\ln(y_i)$ ).

.....  
**Rozwiązanie:**

**Zadanie 9.**

Dla pewnego portfela ubezpieczeń modelowano możliwość przedłużenia przez klienta polisy na kolejny rok. W tym celu, na podstawie danych zawartych w tabeli kontyngencji (Tab. 9.1), badano zależność między zmienną jakościową  $Y$  (przyjmującą dwie kategorie: *Tak* – klient przedłużył polisę, *Nie* – klient nie przedłużył polisy) oraz zmienną jakościową  $X$  określającą stan cywilny (przyjmującą trzy kategorie:  $M$  – w związku małżeńskim,  $S$  – singiel i  $P$  – inny).

Tabela 9.1

$Y \backslash X$	$M$	$S$	$P$
<i>Tak</i>	60	25	15
<i>Nie</i>	230	45	25

- (2p.) Krótko scharakteryzuj metody badania siły zależności między zmiennymi jakościowymi mierzonymi na skali nominalnej. Jak można sprawdzić, czy związek między takimi zmiennymi jest statystycznie istotny?
- (2p.) Wykorzystując odpowiedni test i dane z tab. 9.1, sprawdź czy między przedłużeniem przez klienta umowy a jego stanem cywilnym występuje istotny statystycznie związek. Przyjmij poziom istotności równy 0.05.
- (1p.) Wykorzystując dane z tab. 9.1 oblicz współczynnik korelacji  $V$  Cramera.

**Odpowiedzi:****Odp. a)**

Badanie siły zależności między zmiennymi jakościowymi mierzonymi na skali nominalnej bazuje na wartości statystyki  $\chi^2$  wyznaczonej na podstawie tabeli kontyngencji. W oparciu o tą wartość skonstruowanych jest kilka mierników siły zależności, np. współczynnik  $\phi$  Yule'a, współczynnik kontyngencji  $C$  Pearsona, współczynnik zbieżności  $T$  Czuprowa, współczynnik  $V$  Cramera. Istotność sprawdzana jest testem niezależności chi-kwadrat.

**Odp. b)**

Występuje istotny statystycznie związek między przedłużeniem przez klienta umowy a stanem cywilnym.

**Odp. c)**

Współczynnik  $V$  Cramera jest równy 0,1620.

**Rozwiązanie:****Ad. b)**

Statystyka  $\chi^2$  wyraża się wzorem:

$$\chi^2 = \sum_{i=1}^r \sum_{j=1}^k \frac{(n_{ij} - \hat{n}_{ij})^2}{\hat{n}_{ij}}$$

gdzie:

$n_{ij}$  – liczebności zaobserwowane,

$\hat{n}_{ij} = \frac{n_{i \cdot} \cdot n_{\cdot j}}{n}$  – liczebności teoretyczne (w tabeli na żółtym tle),

$n_{i \cdot}, n_{\cdot j}$  – liczebności brzegowe,

$n$  – liczba obserwacji,

$r, k$  – odpowiednio liczba wierszy i kolumn w tabeli kontyngencji.

Statystyka  $\chi^2$  ma rozkład Chi-Kwadrat o  $(r - 1)(k - 1)$  stopniach swobody.

Obliczenia pomocnicze:

$Y \backslash X$	$M$	$S$	$P$	$n_{i \cdot}$
<i>Tak</i>	60	25	15	100
<i>Nie</i>	230	45	25	300
$n_{\cdot j}$	290	70	40	400

$$\chi^2 = 10.4926$$

Wartość krytyczna na poziomie istotności 0.05 wynosi 5.991. Czyli występuje istotny statystycznie związek między przedłużeniem przez klienta umowy a jego stanem cywilnym.

**Ad. c)**

Współczynnik V Cramera wyraża się wzorem:

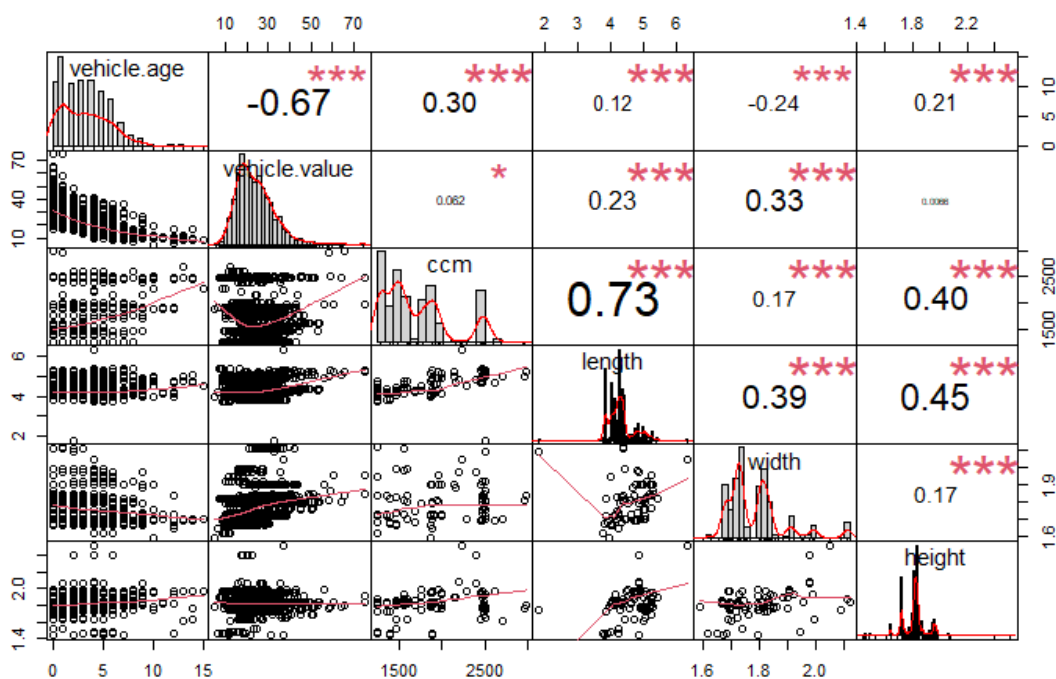
$$V = \sqrt{\frac{\chi^2}{n \cdot \min(r - 1, k - 1)}}$$

Stąd dla rozważanego przykładu  $V = 0,1620$

**Zadanie 10.**

Ubezpieczone samochody opisuje sześć następujących zmiennych ilościowych: *vehicle.age* (wiek samochodu), *vehicle.value* (wartość samochodu), *ccm* (pojemność silnika), *length* (długość samochodu), *width* (szerokość samochodu), *height* (wysokość samochodu). Informacje o współczynnikach korelacji między nimi przedstawiono na rysunku 10.1. W celu redukcji liczby tych zmiennych zestandaryzowano je i przeprowadzono analizę składowych głównych. Uzyskano następujące wyniki dla 5-ciu wartości własnych macierzy korelacji: 1.8923127, 0.6867119, 0.6358262, 0.2488560, 0.2417949.

Rysunek 10.1



- (2p.) Na czym polega analiza składowych głównych (*principal component analysis*)? Wskaż co najmniej trzy własności składowych głównych.
- (1p.) Na podstawie wyników zaprezentowanych na Rys. 10.1 wypowiedz się na temat zasadności przeprowadzenia w analizowanym przypadku redukcji liczby zmiennych za pomocą składowych głównych.
- (2p.) Jaką część wyjściowej wariancji reprezentują trzy pierwsze składowe główne?

**Odpowiedzi:****Odp. a)**

Analiza składowych głównych jest techniką eksploracji danych bez nadzoru. Polega na ortogonalnej transformacji układu badanych zmiennych  $X$  w zbiór nowych nieobserwowanych i niekorelowanych zmiennych  $Y$ . Nowe zmienne są liniowymi kombinacjami zmiennych obserwowanych. Po uporządkowaniu ich według malejącej wariancji, otrzymuje się główne składowe.

---

Głównych składowych można wyznaczyć tyle, ile było zmiennych pierwotnych. Jednak zazwyczaj kilka pierwszych wystarcza do wyjaśnienia większości wariancji układu zmiennych.

Własności składowych głównych (m.in.):

- są liniową kombinacją obserwowanych zmiennych,
- są ortogonalne względem siebie,
- kolejne składowe wyjaśniają malejącą ilość łącznej wariancji zmiennych,
- suma wariancji składowych jest równa sumie wariancji zmiennych pierwotnych.

.....

**Odp. b)**

Redukcje liczby zmiennych przeprowadza się, gdy wszystkie lub kilka z nich jest ze sobą istotnie skorelowanych. W analizowanym przypadku mamy do czynienia z taką sytuacją, więc przeprowadzenie redukcji liczby zmiennych za pomocą składowych głównych można uznać za zasadne.

.....

**Odp. c)**

Trzy pierwsze składowe główne reprezentują 81.22% wariancji.

---

**Rozwiązanie:**

Ponieważ mamy 6 zestandaryzowanych zmiennych, więc łączna wariancja jest równa 6.

Wariancja (wartość własna) brakującej składowej wynosi:

$$6 - (1.8923127 + 0.6867119 + 0.6358262 + 0.2488560 + 0.2417949) = 2.2944983$$

Jest ona największa, więc brakująca składowa jest pierwszą składową główną.

Zatem trzy pierwsze składowe główne tłumaczą  $\frac{2.2944983 + 1.8923127 + 0.6867119}{6} 100\% = 81.22\%$  wariancji.



---

**Sesja egzaminacyjna w dniu 9 czerwca 2022 r.****Modelowanie****Arkusz ocen**

Zadanie nr	Punktacja
1	
2	
3	
4	
5	
6	
7	
8	
9	
10	