

Analiza przeżycia

Survival Analysis

2022

Analiza przeżycia

- Analiza takich **zdarzeń** jak zachorowanie, wyzdrowienie, śmierć, ciąża, ...
- Ważne jest nie tylko wystąpienie **zdarzenia**, ale również **czas** do momentu wystąpienia zdarzenia
- Przykład: Na początku wszystkie osobniki są chore (stan początkowy) i zagrożone śmiercią (**zdarzenie**).

Analiza przeżycia

- Wszystkie osobniki mają ten sam **stan** początkowy
- Przykłady:
 - Wszystkie osobniki są chore (**stan**) i zagrożone śmiercią (**zdarzenie**).
 - Wszystkie samice są ciężarne (**stan**) i z czasem może wystąpić poród (**zdarzenie**)


Analiza przeżycia

- AP uwzględnia, że dane są recenzowane
- Zwierzęta znikają w czasie obserwacji
- Tylko niektóre znikają z przyczyn, którymi się faktycznie interesujemy (np. zdarzenie-śmierć)

Dane cenzorowane (ucięte)

- Czas jest znany tylko dla niektórych osobników
- Dla innych czas jest nieznan:
 - **Zdarzenie** nie zaszło podczas trwania obserwacji
 - Zwierzę padło z innych przyczyn
 - Farmer wycofał zgodę, itp


Dane cenzorowane (ucięte)



Osobnik	Czas przeżycia	Zdarzenie
A	5	1 (śmierć)
B	10	0 (ucięte)
C	3	0 (ucięte)

Dane ucięte także z lewej strony

Rzadziej spotykane



Cele analizy przeżycia

- **Porównanie funkcji przeżycia/hazardu między grupami**
- Opis przeżycia znanym rozkładem teoretycznym (np. Weibull)
- Opis relacji między przeżyciem a potencjalnymi zmiennymi objaśniającymi

Funkcja przeżycia

Jakie jest prawdopodobieństwo, że osobnik przeżyje co najmniej 5 jednostek czasu (np. 5 dni)? $P(T > t=4)$


T = czas przeżycia, t = specyficzna wartość T

Ogólnie: $S(t) = P(T > t)$


Inaczej mówiąc, S to prawdopodobieństwo, że u osobnika zdarzenie nie wystąpi do czasu t

Funkcja przeżycia

Teoretyczny przebieg



Praktyczny przykład



$$S(t=0) = 1$$

S nigdy nie rośnie

Funkcja hazardu

$h(t)$ – warunkowe prawdopodobieństwo **zdarzenia** (np. śmierci) w następnej jednostce czasu przypadające na jednostkę czasu

$$h(t) = \lim_{\Delta t \rightarrow 0} P(t \leq T < (t+\Delta t) \mid T \geq t) / \Delta t$$


Myślimy tu raczej o gęstości prawdopodobieństwa (h może być większe od 1).

Przeżycie a hazard

$h(t) = [-1 / S(t)] \times$ pierwsza pochodna $S(t)$

Komputer łatwo przelicza między funkcjami

Typowe przebiegi funkcji hazardu



Estymator Kaplana-Meiera


- Uwzględnia cenzorowane dane
- Najpopularniejszy

$$\hat{S}(t) = \prod_{t_j \leq t} \frac{n_j - d_j}{n_j}$$

$S(0)=1$

Przedział (dzień)		Liczba zwierząt na początku (n)	Śmierć (d)	Utrata z innych powodów	S(t)
12	13	116	0	1	1,0
14	15	115	1	0	0,9913
55	56	85	1		0,7435
60	61	84	0	84	0,7435

Estymator Kaplan-Meiera




Cele analizy przeżycia

- Porównanie funkcji przeżycia/hazardu między grupami
- **Opis przeżycia znanym rozkładem teoretycznym (np. Weibulla)**
- Opis relacji między przeżyciem a potencjalnymi zmiennymi objaśniającymi

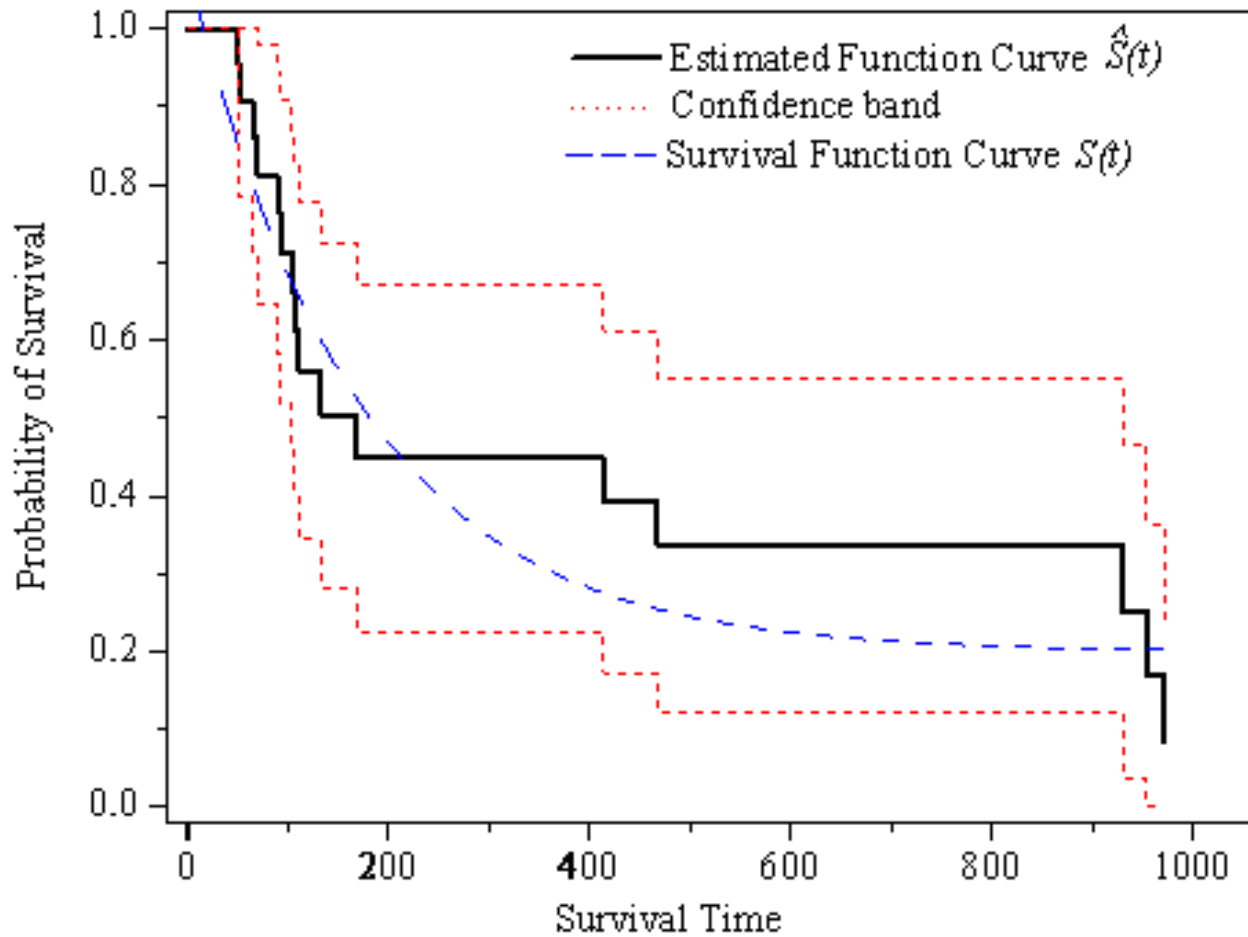
Rozkład Weibulla

- $S(t) = \exp(- (a \times t)^p)$
- $h(t) = a \times p \times (a \times t)^{p-1}$
- a = parametr skali
- p = parametr kształtu
- a i p muszą być oszacowane z danych
- Może przypominać rozkład wykładniczy lub normalny

Weibull Distribution (Shape = 3)



Kaplan-Meier oraz Weibull



Cele analizy przeżycia

- Porównanie funkcji przeżycia/hazardu między grupami
- Opis przeżycia znanym rozkładem teoretycznym (np. Weibull)
- **Opis relacji między przeżyciem a potencjalnymi zmiennymi objaśniającymi**

Modelowanie funkcji hazardu rozkładem wykładniczym

$$h(t, x) = h_0(t) \times \exp(\beta_1 x_1 + \dots + \beta_k x_k)$$

h_0 to zerowa linia hazardu (gdy każdy $x=0$)

- Model regresji wykładniczej: $h_0 = 1$ (mniej elastyczny)
- Regresja Weibulla: $h_0(t) = a \times p \times (a \times t)^{p-1}$
- Model proporcjonalnych hazardów Coksa: nie ma potrzeby definicji h_0 (bardzo praktyczne)

Model proporcjonalnych hazardów Coksa


$$\frac{\frac{h(t, x=1)}{h_0(t)}}{\frac{h(t, x=0)}{h_0(t)}} = e^{\beta_1 x_1}$$

- Podobne do regresji logistycznej
- Nie trzeba estymować parametrów funkcji zerowej h_0
- Ale warunek: HR musi być stałe w czasie, sprawdź rysując dla każdej grupy $\ln[-\ln(S(t))]$ względem $\ln(t)$, przebiegi powinny być równoległe

Model proporcjonalnych hazardów Coksa

Hazard ratio

$$= HR = h(t, \mathbf{x}=1) / h(t, \mathbf{x}=0) = \exp(\beta_1 x_1)$$



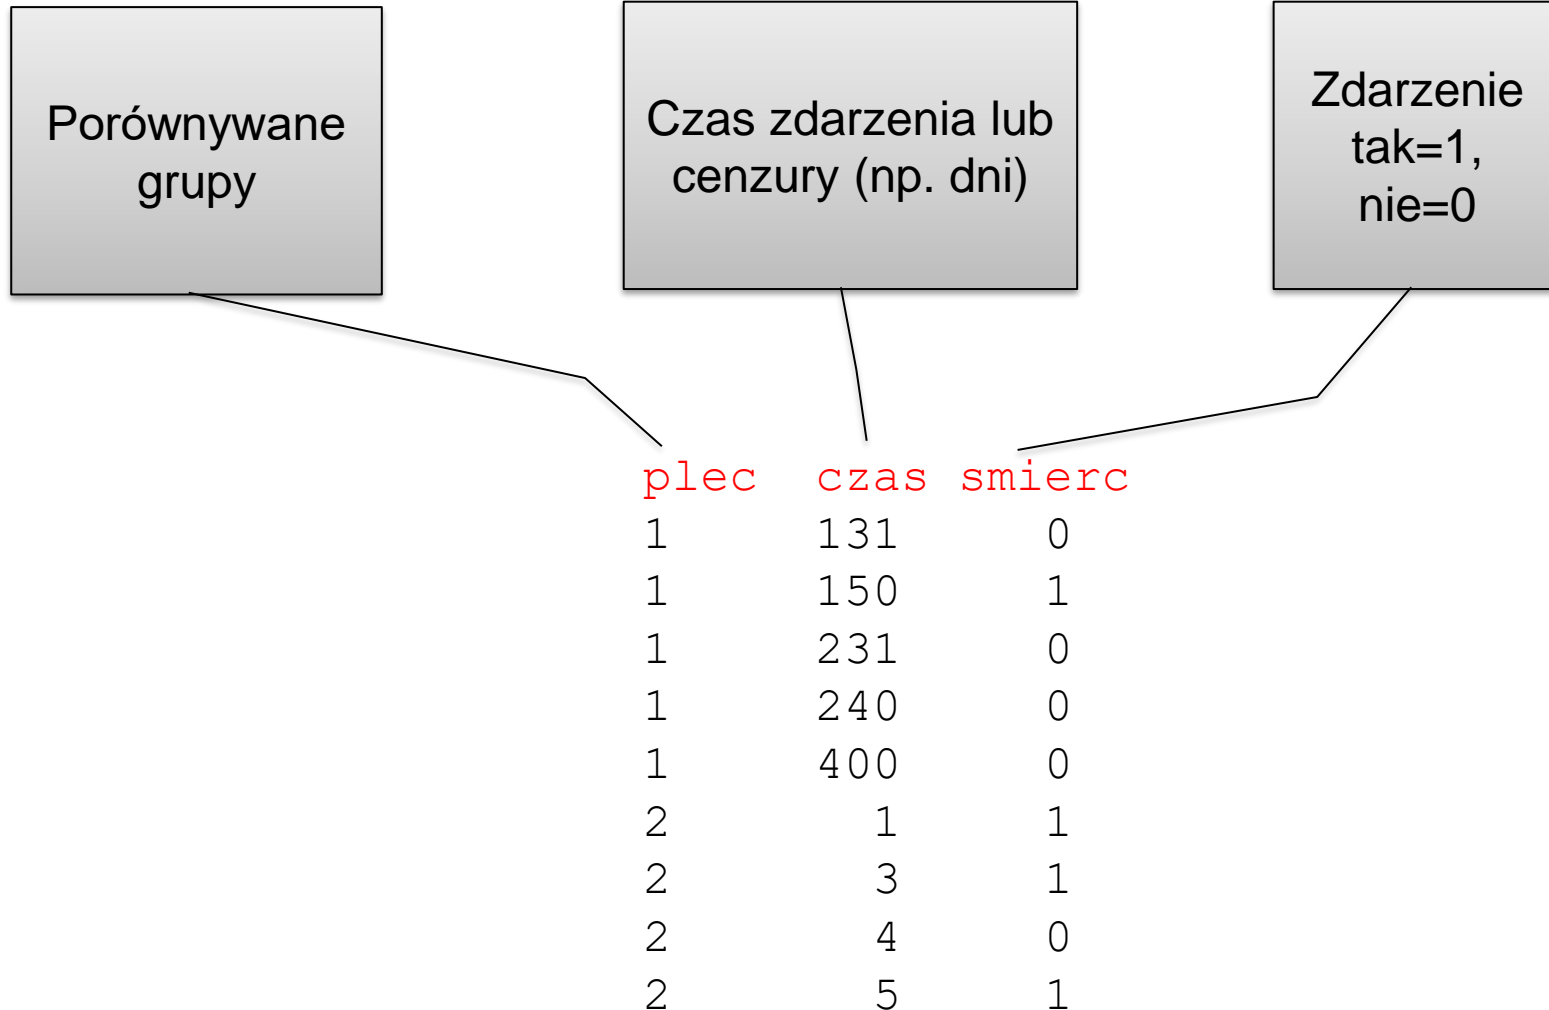
David Cox, ur. 1924

HR=1: czynnik nie ma znaczenia

HR>1: czynnik pozytywnie powiązany ze **zdarzeniem**

HR<1: czynnik negatywnie skorelowany

Przykład danych uciętych z prawej strony



Dane ucięte także z lewej strony

Czas
pozytywnego
testu

Czas zdarzenia lub
cenzury (np. dni)

plec	czas1	czas2	smierc
2	51	52	1
2	58	59	1
2	55	57	1
2	28	50	1
1	21	51	0
1	19	28	1
2	25	32	1

Analiza przeżycia w R

Zainstaluj i przygotuj do działania pakiet **survival**


```
install.packages( 'survival' )  
library( survival )
```

```
read.table( ,dane.txt', header=TRUE ) -> d
attach( d )
```

```
survfit( Surv( czas, smierc ) ~ plec ) -> fit
plot( fit )
```

```
summary( fit )
summary( fit )$surv -> s
summary( fit )$time -> t
plot( log(t), log( -log(s) ) )
```

```
coxph( formula = Surv( czas, smierc ) ~ plec ) -> wynik
summary( wynik )
```



Zadanie 1

Badano skuteczność szczepionki porównując grupę kontrolną (grupa=0) z zaszczepioną (grupa=1). Dane o poszczególnych osobnikach zebrano w pliku „szczepionka.txt”.

- (a) Narysuj wykres Kaplana-Meiera prezentujący prawdopodobieństwa przeżycia w czasie dla obu grup.
- (b) Zbadaj wpływ szczepienia modelem proporcjonalnych hazardów Coksa