

# Grundzüge der Ereignisdatenanalyse

Regressionsmodelle

Sommersemester 2009

# Übersicht

Wiederholung

Grundbegriffe und -probleme

Parametrische Modelle

Exponential- und Weibull-Modell

Weitere Modelle

Cox Proportional Hazard Model

Beispiel in Stata

Zusammenfassung

## Wie war das mit der SPD?

- ▶ „Versuchen Sie, in zwei bis drei Sätzen zu erklären, warum die SPD bei den nicht-parteigebundenen Ostdeutschen 1994 relativ gut abgeschnitten hat. Gehen Sie dabei auf den Median und die Quartile ein.“
- ▶ Die Wahlwahrscheinlichkeiten von CDU und PDS werden sehr stark von der Bewertung des Sozialismus beeinflusst: Die CDU ist im unteren Quartil die stärkste, im oberen Quartil aber die schwächste Partei, bei der PDS ist das Bild fast spiegelbildlich.
- ▶ Dagegen hat die SPD den Vorteil, daß ihre Kurve flach verläuft.
- ▶ Sie ist in den beiden mittleren Quartilen und an den Rändern der äußeren Quartile erfolgreich, was sie insgesamt zur dominierenden Partei macht.

## Was sind Ereignisdaten?

- ▶ Alternative Begriffe: Failure-/Survival- etc. Analyse
- ▶ Einfacher Fall: Zeitdauer bis Ereignis eintritt
- ▶ Komplexer Fall: Zeit, die Objekt in einem von mehreren (evtl. reversiblen) Zuständen zubringt
- ▶ Politikwissenschaftliche Beispiele
  - ▶ Lebensdauer einer Regierung
  - ▶ Beginn/Dauer von Krieg und Frieden
  - ▶ Karrieren von Mandatsträgern
- ▶ Alternative Analysemodelle: Panelanalyse, Logit-Analyse, ...


# Terminologie

- ▶ Stammt aus der Medizin bzw. Ingenieurwissenschaften
- ▶ „Ereignis“ = Tod eines Patienten, Versagen einer Maschine
- ▶ Verwirrend = „Risiko“ für das Ende eines Krieges, „Versagen“ = Ende einer Kandidatur = Einzug ins Parlament . . .
- ▶ Relevante Variable = Zeitdauer bis zum Eintritt eines Ereignisses

## Ein Beispiel: Kabinette in Italien

Beginn	Ende	Dauer	PM	Ausrichtung
28/06/92	28/04/93	304	Giuliano Amato	links
28/04/93	10/05/94	377	Carlo Azeglio Ciampi	links
10/05/94	17/01/95	252	Silvio Berlusconi	rechts
17/01/95	17/05/96	486	Lamberto Dini	links
18/05/96	21/10/98	886	Romano Prodi	links
21/10/98	22/12/99	427	Massimo D'Alema	links
22/12/99	25/04/00	125	Massimo D'Alema (2. Amtszeit)	links
25/04/00	11/06/01	412	Giuliano Amato (2. Amtszeit)	links
11/06/01	23/04/05	1412	Silvio Berlusconi (2. Amtszeit)	rechts
23/04/05	17/05/06	389	Silvio Berlusconi (3. Amtszeit)	rechts
01/05/06	08/05/08	738	Romano Prodi (2. Amtszeit)	links
08/05/08	?	(385)	Silvio Berlusconi	rechts

## Ein Beispiel: Kabinette in Italien

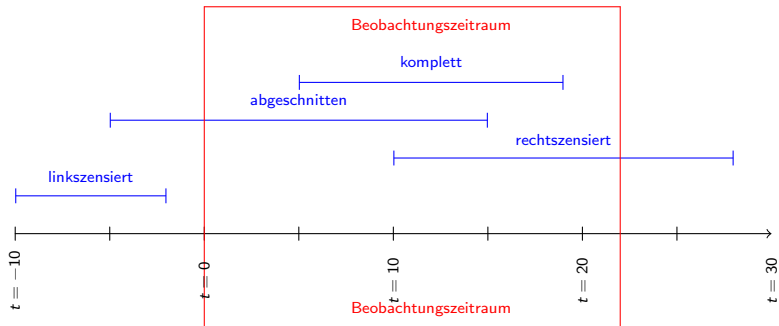


## Warum besondere Modelle?


- ▶ Kovariaten nicht notwendigerweise über Zeit stabil
- ▶ Keine Werte  $y < 0$
- ▶ Beobachtungen möglicherweise bimodal, „rechtszensiert“, „linkszensiert“, „abgeschnitten“ (truncated)
- ▶ Hochgradige Abweichung von Normalverteilung für  $\epsilon$
- ▶ Abweichungen sind *informativ*



# Abgeschnitten, linkszensiert, rechtszensiert?



## Was ist die abhängige Variable?



- ▶  $T$ : Zufallsvariable (Dauer bis zum Eintritt des Ereignis);  $t$ : Zeitpunkt, Realisation von  $T$
- ▶  $t$  beginnt mit dem Beginn der Beobachtung
- ▶ Falls keine truncation/left-censoring mit Beginn der Exposition identisch
- ▶ Beschreibung durch (theoretische) Verteilungen / Funktionen

## Was sind die wichtigen Funktionen/Verteilungen?

1. Dichtefunktion von  $T$ :  $f(t)$
2. Kumulative Verteilungsfunktion:  $F(t) = \Pr(T \leq t)$
3. Survivor-Funktion:  $S(t) = 1 - F(t) = \Pr(T > t)$
4. **Hazard-Funktion**  $h(t)$
5. (Kumulative Hazard-Funktion:  
 $H(t) = \int_0^t h(u) du = -\ln(S(t))$ )

### Verhältnis zueinander?

- ▶ Alle vier/fünf Funktionen sind äquivalent
- ▶ Verschiedene Parametrisierungen

## Was ist eine Dichtefunktion (-schätzung)?

- ▶ Histogramm
  - ▶ Absolute oder
  - ▶ relative Häufigkeiten
  - ▶ Summe der Flächen (Säulen) = 1
- ▶ Problem: Sprünge
- ▶ (Potentiell) unendlich viele Fälle + kontinuierliche Werten → stetige Verteilung

## Was ist eine Dichtefunktion (-schätzung)?


- ▶ Histogramm
  - ▶ Absolute oder
  - ▶ relative Häufigkeiten
  - ▶ Summe der Flächen (Säulen) = 1
- ▶ Problem: Sprünge
- ▶ (Potentiell) unendlich viele Fälle + kontinuierliche Werten → stetige Verteilung
- ▶ = Dichte; Fläche unter Kurve = 1 = 100%
- ▶ Entspricht Histogramm mit unendlich schmalen Streifen

## Was sagt uns die Dichtefunktion?

- ▶ Alle Objekte starten gleichzeitig
- ▶ Wie wahrscheinlich ist eine bestimmte Überlebenszeit
- ▶ Bzw. instantane Wahrscheinlichkeit des Ereignisses (Regierungsende) zu einer bestimmten Zeit
- ▶ Unkonditional
- ▶ Dichteschätzung über Überlebenszeiten

## Was sagt uns die Dichtefunktion?

- ▶ Alle Objekte starten gleichzeitig
- ▶ Wie wahrscheinlich ist eine bestimmte Überlebenszeit
- ▶ Bzw. instantane Wahrscheinlichkeit des Ereignisses (Regierungsende) zu einer bestimmten Zeit
- ▶ Unkonditional
- ▶ Dichteschätzung über Überlebenszeiten



## Was sagt uns die kumulative Verteilungsfunktion?

- ▶ Definitives Integral über Dichtefunktion
- ▶ Wieviele Objekte sind zu einem bestimmten Zeitpunkt bereits „gestorben“?
- ▶ Bzw. wie hoch ist die kumulative Wahrscheinlichkeit des Versagens?

### Kumulative Verteilungsfunktion

$$F(t) = \Pr(T \leq t) = \int_0^t f(t) dt$$



## Was sagt uns die Survivor-Funktion?

- ▶ Wie hoch ist die Wahrscheinlichkeit, bis zu einem bestimmten Zeitpunkt „zu überleben“
- ▶ Bzw. äquivalent wieviele der ursprünglichen Objekte sind zu einem bestimmten Zeitpunkt „noch am Leben“ (im Ausgangszustand)

### Survivor-Funktion

$$S(t) = 1 - F(t) = \Pr(T > t) = 1 - \int_0^t f(t) dt$$

## Was sagt uns die Hazard-Funktion?

- ▶ „Intensity“, „age-specific failure rate“, aktuelles Risiko:  
(instantane) *Rate* des Versagens (z. B. Kabinettsauflösung,  
wenn Objekt bis dahin durchgehalten hat)
  - ▶ Diskrete Zeit: bezogen auf Zeitraum
  - ▶ Kontinuierliche Zeit: Grenzwert für Länge des Zeitraums  $\rightarrow 0$
- ▶ Konditionale Variante der Dichtefunktion

### Hazard-Funktion

$$\begin{aligned} h(t) &= \lim_{\Delta t \rightarrow 0} \frac{\Pr(t + \Delta t > T > t | T > t)}{\Delta t} \\ &= \frac{f(t)}{S(t)} \end{aligned}$$

## Wie war das mit dem Grenzwert?

- ▶ Z. B. Dichtefunktion:
  - ▶ Im Intervall  $[t = 10; t = 20]$  endet Prozentsatz (kumulative Verteilungsfunktion)  $\rightarrow$  Risiko des Scheiterns in diesem Intervall
  - ▶ Wieviel scheitern exakt bei  $t = 10$ ?
  - ▶ Intervall immer schmaler machen  $[10; 11] \rightarrow [10; 10 + 10^{-10}] \rightarrow [10; 10 + 10^{-100}]$
  - ▶ Breite des Intervalls  $\rightarrow 0$ ; Prozentsatz  $\rightarrow$  Dichte bzw. Steigung/Ableitung der kumulativen Verteilungsfunktion an diesem Punkt = instantanes Risiko des Scheiterns

## Wie war das mit dem Grenzwert?

- ▶ Z. B. Dichtefunktion:
  - ▶ Im Intervall  $[t = 10; t = 20]$  endet Prozentsatz (kumulative Verteilungsfunktion)  $\rightarrow$  Risiko des Scheiterns in diesem Intervall
  - ▶ Wieviel scheitern exakt bei  $t = 10$ ?
  - ▶ Intervall immer schmaler machen  $[10; 11] \rightarrow [10; 10 + 10^{-10}] \rightarrow [10; 10 + 10^{-100}]$
  - ▶ Breite des Intervalls  $\rightarrow 0$ ; Prozentsatz  $\rightarrow$  Dichte bzw. Steigung/Ableitung der kumulativen Verteilungsfunktion an diesem Punkt = instantanes Risiko des Scheiterns
- ▶ Niedriges Risiko: man kann auch davor gescheitert sein
- ▶ Hazard: instantanes Risiko, geteilt durch Wahrscheinlichkeit, bis hierhin überlebt zu haben
- ▶ Höher, da für Ausgeschiedene kein Risiko mehr besteht

## Was ist die inhaltliche Bedeutung der Hazard Rate?


- ▶ Hazard – Risiko zu einem gegebenen *Zeitpunkt* (Grenzwert)
- ▶ Steht im Zentrum moderner Ereignisdatenanalyse
- ▶ Hat eine bestimmte Form
  - ▶ Kann über die Zeit konstant sein, steigen, fallen
  - ▶ Bei *konstantem* Hazard wird das Überleben über die Zeit immer unwahrscheinlicher
  - ▶ Fällt der Hazard auf null, ist das weitere Überleben zunächst gesichert, wenn man es bis hierhin geschafft hat
  - ▶ Menschliche Mortalität hat eine badewannenförmige Hazard-Funktion

## Was ist die Bedeutung der kumulativen Hazard-Funktion?

- ▶ Beschreibt das Risiko, das im Lauf der Zeit akkumuliert wird („Umdrehungen“)
- ▶ Wie oft würde ein Objekt (im Mittel) „sterben“, wenn Scheitern wiederholbar?
- ▶ Äquivalent: Überlebenswahrscheinlichkeit, da  $S(t) = \exp(-H(t))$
- ▶ Bzw. Wahrscheinlichkeit, *mindestens einmal* zu scheitern ( $F(t) = 1 - S(t)$ )


## Ein konstruiertes Beispiel

- ▶ lineare Dichtefunktion
- ▶  $f(t) = 0.1 - 0.005 \times t$



## Kumulierte Verteilungsfunktion


►  $F(t) = \int_0^t f(t) dt = 0.1 \times t - 0.0025t^2$






# Survivor-Funktion

►  $1-F(t)$







# Hazard-Funktion

- ▶  $h(t) \frac{f(t)}{S(t)}$
- ▶ Ausfallrate, bezogen auf überlebende Objekte



# Im Überblick



## Survivor-, Dichte- und Hazard-Funktion

1.  $h(t) = \frac{f(t)}{S(t)}$

2.  $f(t) = h(t) \times S(t)$

3.  $S(t) = \frac{f(t)}{h(t)}$

- ▶ Moderne Anwendungen *parametrisieren* Modell in Hazard-Variante
- ▶  $h_j(t) = \text{somefunction}(h_0; \beta_0 + \mathbf{x}_j\beta_x)$
- ▶ Fehler  $\epsilon$  aus dem linearen Modell steckt in Dichtefunktion  $\rightarrow$  wandert in Hazard-Funktion
- ▶ Wahl von „somefunction“ ( $=g(\cdot)$ )  $\rightarrow$  Likelihood-Funktion
- ▶ Meistens *proportional*:  $h_j(t) = h_0(t) \exp(\beta_0 + \mathbf{x}_j\beta_x)$

## Diskrete vs. kontinuierliche Zeit

- ▶ Kann das Ereignis zu einer beliebigen Zeit auftreten?
- ▶ In politikwissenschaftlichen Anwendungen praktisch immer diskrete Zeiten (z. B. Tage)
- ▶ Survivor-Funktion in der Praxis mit „Treppen“
- ▶ Hazard-Rate leichter zu verstehen
- ▶ Verschiedene Anwendungen

# Parametrische, semiparametrische, non-parametrische Modelle

- ▶ Parametrisch: Annahmen über Verteilungs-/Hazard-Funktion
  - ▶ „Baseline Hazard“ hat bestimmte Form
  - ▶ Form/Lage durch Kovariaten verändert
  - ▶ Effizienzgewinne
  - ▶ Bias, wenn Annahmen falsch
- ▶ Semi-parametrisch:
  - ▶ Keine Annahmen über baseline hazard  $h_0$  (Hazard-Funktion)
  - ▶ Aber parametrische Wirkung der  $x$ -Variablen
  - ▶ Serie von binären Analysen
- ▶ Non-parametrisch: keine Annahmen

## Was passiert mit zensierten Beobachtungen?

- ▶ Rechtszensierung relativ leicht handhabbar
- ▶ Schätzung der Parameter mittels Maximum Likelihood
- ▶ Likelihood eines Falles: Dichtefunktion
  - ▶ Für vollständig beobachtete Fälle keine Probleme
  - ▶ Rechtszensierte Fälle enthalten Information über das Überleben bis *zum Ende der Beobachtung* → Survivor-Funktion
  - ▶ Für Rechtszensierte Fälle → in Likelihood-Funktion einschließen

## Wie funktioniert das Exponential-Modell?


- ▶ Parametrisierung via Hazard-Rate
- ▶  $h(t) = \exp(\beta_0 + \mathbf{X}\beta)$
- ▶ Hazard-Rate ist konstant (flache Linie), Kovariaten verschieben *Exponenten* und damit Niveau der Linie
- ▶ „Gedächtnisloser“ Prozeß → exponentieller Zerfall bzw. Exponentialverteilung als Dichtefunktion (Parameter  $\lambda$ ;  $f(x; \lambda) = \lambda \exp(-\lambda x)$ )



## Wie funktioniert das Exponential-Modell?

- ▶ Parametrisierung via Hazard-Rate
- ▶  $h(t) = \exp(\beta_0 + \mathbf{X}\beta)$
- ▶ Hazard-Rate ist konstant (flache Linie), Kovariaten verschieben *Exponenten* und damit Niveau der Linie
- ▶ „Gedächtnisloser“ Prozeß → exponentieller Zerfall bzw. Exponentialverteilung als Dichtefunktion (Parameter  $\lambda$ ;  $f(x; \lambda) = \lambda \exp(-\lambda x)$ )
- ▶ Einfach, aber für uns nicht realistisch


# Exponentialverteilung mit verschiedenen $\lambda$



# Weibull-Modell

- ▶ Eng mit Exponential-Modell verwandt ( $\alpha = 1 \rightarrow$  Exponentialverteilung)
- ▶ Weibull-Verteilung
  - ▶ Flexibel
  - ▶  $k > 0 =$  „shape“,  $\lambda > 0 =$  „scale“
  - ▶  $f(x; \lambda; k) = \frac{k}{\lambda} \left(\frac{x}{\lambda}\right)^{k-1} \exp(-(x/\lambda)^k)$
  - ▶ Entspricht konstanten, steigendem oder fallendem Hazard
- ▶ Parametrisierung:  $h(t) = \exp(\mathbf{X}\boldsymbol{\beta} + \alpha \ln(t))$
- ▶  $\alpha$  legt die Form der Verteilung fest

## Weibull: Mögliche Dichteverteilungen



## Wie werden die Modelle parametrisiert?

- ▶ Verschiedene Programme, verschiedene Parametrisierungen
- ▶ Zwei Varianten:
  1. Log-lineares Modell (Accelerated Failure Time)
    - ▶ Logarithmus der Zeit bis failure als abhängige Variable
    - ▶ Linearer Prädiktor inkl.  $\epsilon$  (nicht normalverteilt)
  2. Proportional Hazard: Veränderung des instantanen Risikos

## Was gibt es sonst noch?

- ▶ Statt Exponential- oder Weibull-Verteilungen auch andere Verteilungen möglich
- ▶ Flexibler (z. B. generalised Gamma) → drei Parameter
- ▶ Parametrisch (Annahme über funktionale Form *und* Form der Hazard-Funktion)
- ▶ Aber ...

## Was gibt es sonst noch?

- ▶ Statt Exponential- oder Weibull-Verteilungen auch andere Verteilungen möglich
- ▶ Flexibler (z. B. generalised Gamma) → drei Parameter
- ▶ Parametrisch (Annahme über funktionale Form *und* Form der Hazard-Funktion)
- ▶ Aber ...
  - ▶ Haben wir als Sozialwissenschaftler starke Annahmen über Form des Hazard?
  - ▶ Interessiert uns das überhaupt?

## Wie sieht das Cox Proportional Hazard Model aus?


- ▶  $h(t) = h_0(t) \exp(\mathbf{X}\beta)$
- ▶ **Baseline-Hazard**: wird nicht-parametrisch aus den Daten geschätzt
- ▶ **Proportional**: Kovariaten haben multiplikativen Effekt auf Baseline-Hazard
- ▶ Basiert auf einem partiellen Likelihood-Verfahren
- ▶ Erweiterung ermöglicht Umgang mit variierenden Kovariaten



## Mögliche Probleme mit dem Cox-Modell?

1. Unpräziser, vor allem bei kleinen Datensätzen
2. Ties problematisch (wenn häufig)
3. Nicht angemessen, wenn Form der Zeitabhängigkeit von Interesse
4. Schwächere Theorie

## Dauer von 54 UN-Missionen 1948-2001



- ▶  $\bar{y} = 74$ , Median 25.5, aber 15 noch nicht abgeschlossen (rechtszensiert)
- ▶ Korrigierte Schätzmethoden: Median 30 Monate, Mittelwert 228 Monate
- ▶ Drei Konflikttypen: civil war, inderstate conflict, internationalised civil war

## Weibull: Hängt Dauer vom Konflikttyp ab?

Weibull regression -- log relative-hazard form

No. of subjects =	54	Number of obs =	54
No. of failures =	39		
Time at risk =	3994		
Log likelihood =	-84.655157	LR chi2(2) =	17.67
		Prob > chi2 =	0.0001

_t	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
civil	.8879245	.3832017	2.32	0.020	.1368629	1.638986
interst	-1.401441	.5117817	-2.74	0.006	-2.404515	-.3983673
_cons	-3.459909	.4952858	-6.99	0.000	-4.430652	-2.489167
/ln_p	-.2145617	.1237889	-1.73	0.083	-.4571834	.02806
p	.806895	.0998846			.6330642	1.028457
1/p	1.239319	.1534138			.97233	1.579619

## Was bedeutet das?

- ▶  $p < 1$  Hazard reduziert sich mit der Zeit (Signifikanz?)
- ▶ Relative Hazard Parametrisierung
  - ▶ Für Referenzkategorie ist hazard =  $\exp(-3.46)0.8t^{0.8-1} \exp(0)$
  - ▶ Für interstate conflict ist hazard =  $\exp(-3.46)0.8t^{0.8-1} \exp(-1.4 \times 1)$
  - ▶  $\exp(-1.4) = 0.25$ , d. h. hazard ist zu jedem Zeitpunkt 75% niedriger
  - ▶ Civil war:  $\exp(0.89) = 2.44 \rightarrow$  hazard 144% höher
- ▶ Einsätze bei interstate conflict dauern am längsten, bei Bürgerkriegen am kürzesten (höheres Risiko des „Scheiterns“  $\rightarrow$  schnelleres Ende)

# Weibull: Accelerated failure time

Weibull regression -- accelerated failure-time form

No. of subjects =	54	Number of obs =	54
No. of failures =	39		
Time at risk =	3994		
Log likelihood =	-84.655157	LR chi2(2) =	17.67
		Prob > chi2 =	0.0001



_t	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]	
civil	-1.100421	.4457861	-2.47	0.014	-1.974146	-.2266966
interst	1.736832	.6165459	2.82	0.005	.5284242	2.94524
_cons	4.28793	.2652436	16.17	0.000	3.768062	4.807798
/ln_p	-.2145617	.1237889	-1.73	0.083	-.4571834	.02806
p	.806895	.0998846			.6330642	1.028457
1/p	1.239319	.1534138			.97233	1.579619

## Was bedeutet das?

- ▶ Andere Parametrisierung,
- ▶ Identische Likelihood, identische Ergebnisse (weil  $h(t) \Leftrightarrow f(t)$ )
- ▶ Umgekehrte Vorzeichen: niedrigerer hazard – längere Zeitdauer
- ▶ Civil war < internationalised civil war < interstate conflict

# Geht das besser?



## Geht das besser?



- ▶ Geschätzte hazard-/survival-Funktionen für internationalised civil war



## Geht das besser?



- ▶ Geschätzte hazard-/survival-Funktionen für internationalised civil war
- ▶ Unter der Annahme, daß Zeiten mit geschätzten Parametern Weibull-verteilt sind

# Welche Ergebnisse bringt das Cox model?

Cox regression -- Breslow method for ties

No. of subjects =	54	Number of obs =	54
No. of failures =	39		
Time at risk =	3994		
Log likelihood =	-127.15763	LR chi2(2) =	8.93
		Prob > chi2 =	0.0115

	_t	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
	civil	.7348046	.3781278	1.94	0.052	-.0063122 1.475921
	interst	-.8556111	.5042314	-1.70	0.090	-1.843886 .1326643

Bzw.

Cox regression -- Breslow method for ties

```
No. of subjects =          54          Number of obs =          54
No. of failures =          39
Time at risk   =          3994
Log likelihood = -127.15763
LR chi2(2)     =           8.93
Prob > chi2    =          0.0115
```

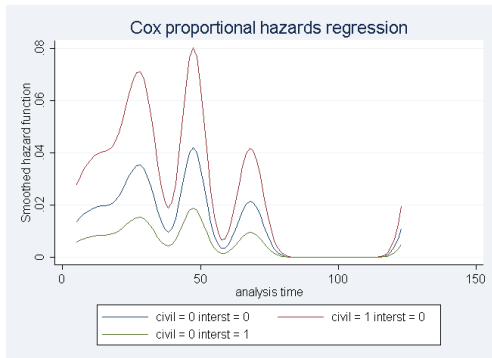
```
-----+-----
      _t | Haz. Ratio   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
      civil |  2.085075   .7884246     1.94   0.052   .9937077   4.375065
      interst | .4250234   .2143101    -1.70   0.090   .1582014   1.141867
```

- ▶  $\exp(\text{Koeffizient}) = \text{hazard ratio (Voreinstellung)}$


## Was bedeutet das?

- ▶ Keine Konstante – keine Annahme über Form des base hazard
- ▶ **Aber:** Form des hazard für alle Fälle gleich!
- ▶ Hazard für civil war ca. zweimal größer als baseline hazard
- ▶ Hazard für interstate conflict weniger als halb so groß wie baseline hazard
- ▶ Identische Reihenfolge: civil war < internationalised civil war < interstate conflict

# Geschätzte Hazard-Raten (geglättet)



## Geschätzte Survivor-Funktionen



- ▶ Step-Funktionen
- ▶ Alle Missionen  $> 128$  Monate rechtszensiert

# Zusammenfassung

- ▶ Vielzahl von Besonderheiten bei der Analyse von Ereignisdaten
- ▶ „Normale“ Modelle führen fast unweigerlich in die Irre
- ▶ **Essentiell:** Unterschiede und Beziehungen zwischen  $f(t)$ ,  $S(t)$ ,  $h(t)$
- ▶ Vielzahl von Analysemöglichkeiten, dynamisches Feld

## Übung für heute

- ▶ Datensatz <http://www.kai-arzheimer.com/Lehre-Regression/unmissions.dta> in Stata laden
  - ▶ Schätzen Sie für die UN-Daten noch einmal das Exponentialmodell in der Fehlerzeit-Parametrisierung: `streg civil interst ,dist(expon) time`
1. Wie interpretieren Sie die Vorzeichen der Koeffizienten?
  2. Wie sehen die Hazard-Funktionen für die drei Konflikttypen aus? Kurzes Nachdenken genügt!
  3. Mit `stcurve ,hazard at1(civil = 0 interst =0) at2(civil = 0 interst =1) at3(civil = 1 interst =0)` können Sie sehen, ob Sie richtig gedacht haben