

# 7. Verweildauernmodelle


## 7.1 Das Grundproblem:

Es ist häufig von Interesse, die Zeit des Verweilens in bestimmten Zuständen — z.B. Arbeitslosigkeit — direkt zu modellieren. Dazu eignen sich die bisher besprochenen Modelle nicht. In diesem Kapitel geht es darum, die Dauer des Verweilens eines bestimmten Zustandes zu analysieren.

### Beispiele:

Dauer der Arbeitslosigkeit, Überlebensdauer einer Patientin nach einer Operation, Überlebensdauer eines Motors, Dauer einer Nichthandelsperiode bei Aktienrenden, Dauer bis zum default eines Kreditnehmers, Dauer bis zum Kauf eines neuen Autos

## 7.2 Wie sehen Verweildauerdaten aus?



## 7.3 Grundlegende Konzepte

Was wird modelliert? Zei (Verweilen) zwischen Zus ändern

Ein paar Definitionen:

Failure function:  $P[T < t] \approx F(t)$

Survival function:  $P[T \geq t] \approx 1 - F(t)$

Hazard function:  $\lambda(t, \Delta) = P[t \leq T \leq t + \Delta | T \geq t]$

Integrated hazard function:  $\Gamma(t) = \int_0^t \lambda(\tau) d\tau$

**Hazard function?** Inverse of Mill's Ratio in Tobit-Modellen; Rate, mit der eine Verweildauer beende wird gegeben, dass sie weniger als  $t$  Sekunden gedauert hat.


**Zusammenhänge:**  $\lambda(t, \Delta) = \frac{f(t)}{S(t)} = \frac{dF(t)/dt}{S(t)} = - \frac{d \ln(S(t))}{dt}$

## Duration dependence:

$$\frac{d \lambda(t, \Delta)}{dt} = \begin{cases} > 0 & \longrightarrow & \text{positive duration dependence} \\ = 0 & \longrightarrow & \text{no duration dependence} \\ < 0 & \longrightarrow & \text{negative duration dependence} \end{cases}$$

**Integrated hazard function?** keine einfache Interpretation, eher als Spezifikationscheck  
angewendet; konvexe in der Hazard  $\longrightarrow$  positive Duration Dependence,  
konkave in der Hazard  $\longrightarrow$  negative Duration Dependence

**Zensierung:** führt zu verzerrten Schätzergebnissen, Zensierungsmöglichkeiten:



## 7.4 Nichtparametrische Modelle

### Worum gehts?

keine Spezifikation von Parametern

keine Berücksichtigung erklärender Variablen

wird für die vorläufige Analyse verwendet

hilfreich bei der Bestimmung der funktionalen Form (Arbeitsdauerabhängigkeit)

Berechnung der "sample survivor function"

### Berechnung

ohne Zensurierung:

$$\hat{S}(t) = \frac{\text{\# Beobachtungen, die länger als } t \text{ überleben}}{1} = \frac{1}{n}$$

**mit Zensierung:**

$n_j$  is die Anzahl der Verweildauern, die bei der Verweildauer  $t_j$  weder beende noch zensier sind:

$$n_j = \sum_{i \geq j}^K (m_i + h_i)$$

**Schätzer für Hazardrate:**

$$\hat{\lambda}(t_j) = h_j/n_j,$$

also die Anzahl der failures ge eil durch die Anzahl der Beobach ungen, die noch "a risk" sind.

**Kaplan–Meier–Schätzer ist:**

$$\hat{S}(t_j) = \prod_{i=1}^j (n_i - h_i)/n_i = \prod_{i=1}^j (1 - \hat{\lambda}_i)$$

# Große Ähnlichkeit zu Sterbetabellen

## Beispiel: Modelling time-between-trade beim BUND-futures Handel an der LIFFE

```


. sts list
      failure_d: 1 (meaning all fail)
analysis time_t: tbc

```

Time	Beg. Total	Fail	Net Lost	Survivor Function	Std. Error	[95% Conf. Int.]
1	1269	40	0	0.9685	0.0049	0.9573 0.9758
2	1229	52	0	0.9275	0.0073	0.9118 0.9405
3	1177	51	0	0.8873	0.0089	0.8686 0.9035
4	1126	66	0	0.8353	0.0104	0.8137 0.8546
5	1060	63	0	0.7857	0.0115	0.7620 0.8072
6	997	76	0	0.7258	0.0125	0.7003 0.7494
7	921	66	0	0.6738	0.0132	0.6472 0.6988
8	855	53	0	0.6320	0.0135	0.6048 0.6579
9	802	60	0	0.5847	0.0138	0.5571 0.6113
10	742	53	0	0.5429	0.0140	0.5151 0.5699
68	21	2	0	0.0150	0.0034	0.0094 0.0229
69	19	1	0	0.0142	0.0033	0.0087 0.0219
70	18	2	0	0.0126	0.0031	0.0075 0.0200
71	16	2	0	0.0110	0.0029	0.0064 0.0180
72	14	1	0	0.0102	0.0028	0.0058 0.0171
73	13	1	0	0.0095	0.0027	0.0052 0.0161
74	12	1	0	0.0087	0.0026	0.0046 0.0151
75	11	1	0	0.0079	0.0025	0.0041 0.0141
76	10	2	0	0.0063	0.0022	0.0030 0.0120
77	8	3	0	0.0039	0.0018	0.0015 0.0088
78	5	3	0	0.0016	0.0011	0.0003 0.0055
79	2	2	0	0.0000	.	.




# Kaplan–Meier–Schätzung





# Integrated hazard function



## 7.5 Parametrische und semiparametrische Modelle

**Warum parametrische und semiparametrische Modelle?** Kaplan-Meier-Schätzer erlaubt nicht, für beobachtbare Hazardfunktionen zu konvergieren  $\rightarrow$  Gefahr, auf falsche Evidenz zu finden.

**Beispiel:** wenn Kreditausfälle einer Privatbank und einer Landesbank verglichen werden, sollte für die Unterschiede zwischen den Kreditnehmern konvergieren werden.

**Beliebte funktionale Formen:**

	Exp.	Weibull	loglog
$F(t)$	$1 - \exp(-\gamma t)$	$1 - \exp(-\gamma t^\alpha)$	$1 - \frac{1}{1 + t^\alpha \gamma}$
$S(t)$	$\exp(-\gamma t)$	$\exp(-\gamma t^\alpha)$	$1 / (1 + t^\alpha \gamma)$
$f(t)$	$\gamma \exp(-\gamma t)$	$\gamma \alpha t^{\alpha-1} \exp(-\gamma t^\alpha)$	$\gamma \alpha t^{\alpha-1} / (1 + t^\alpha \gamma)^2$
$\lambda(t)$	$\gamma$	$\gamma \alpha t^{\alpha-1}$	$\gamma \alpha t^{\alpha-1} / (1 + t^\alpha \gamma)$
$\Gamma(t)$	$\gamma t$	$\gamma t^\alpha$	$\ln(1 + \gamma t^\alpha)$
dur. dep.	memoryless	pos. if $\alpha > 1$ neg. if $\alpha < 1$	$\alpha > 1$ first incr., then decr. $\alpha < 1$ decr.

# Likelihoodfunktion

Dich  $e$  einer Verweildauer von  $t$  Sekunden ist  $f(\boldsymbol{\theta}, t)$ , wobei  $\boldsymbol{\theta}$  die Parameter der Variablen bezeichne, die die Verweildauer verursachen.

**Likelihoodfunktion:** (gemeinsame Wahrscheinlichkeitsverteilung der Stichprobe als Funktion der Parameter  $\boldsymbol{\theta}$ )

$$\ell = \prod_{i=1}^N f(\boldsymbol{\theta}, t)$$

Umschreiben als:

$$\ln(\ell) = \sum_{i=1}^N \ln(\lambda(t_i, \boldsymbol{\theta})) - \sum_{i=1}^N \Gamma(t_i, \boldsymbol{\theta})$$

Z.B. für die Weibull-Familie:

$$\ln(\ell) = \sum_{i=1}^N \ln(\gamma) + \sum_{i=1}^N \ln(\alpha) + (\alpha - 1) \sum_{i=1}^N \ln(t_i) - \gamma \sum_{i=1}^N t_i^\alpha$$

## 7.5.1 Das proportionale hazard Modell

Hazardrate  $\lambda$  hängt von erklärenden Variablen  $\mathbf{X}$  mit dem unbekanntem Koeffizienten  $\beta$  und der "baseline hazard" (unbekannt, verlangt Schätzung)  $\lambda_0(t)$  ab:

$$\lambda(t, \mathbf{X}_i, \lambda_0) = \phi(\mathbf{X}_i, \beta) \lambda_0(t)$$

Der Effekt der erklärenden Variablen ist es, die baseline hazard mit einem Faktor zu multiplizieren, der zeitunabhängig ist (rescaling heime axis).

Häufige Spezifikation von  $\phi(\mathbf{X}_i, \beta)$ :

$$\phi(\mathbf{X}_i, \beta) = \exp(\mathbf{X}_i \beta)$$

Es gilt:

$$\frac{\partial \ln(\lambda(t, \mathbf{X}_i, \beta, \lambda_0))}{\partial \mathbf{X}_i} = \beta_i,$$

der Koeffizient ist also ein konsistenter proportionaler Effekt auf die Wahrscheinlichkeit, eine Verweildauer abzuschließen.

# Der Weibull-Fall

$$\lambda(t, \mathbf{X}_i, \beta, \alpha) = \exp(\mathbf{X}_i \beta) t^{\alpha-1}$$

**Beispiel:** Proportional hazard Modell für die Zeit zwischen Transaktionen mit Handelsinifierungsfolge, Lichte-Dummy und verzögerte Werte und der Transaktionspreisveränderungen als erklärenden Variablen.

# Weibull-Schätzergebnisse

```

. streg sa_1 hb_1 sa_2 hb_2 sa_3 hb_3 dp_1 dp_2 dp_3 lunch, dlc(w) nolog noh
      failure_d: 1 (meaning all fail)
      analysis time _ci tvc

Weibull regression -- log relative-hazard form

      No. of subjects =      1269
      No. of failures =      1269
      Time at risk    =      21569
      Log likelihood = -1769.6904

      LR chi2(10)      =      20.2
      Prob > chi2      =      0.027

-----+-----
      _b_   Coef.   Std. Err.      z    P>|z|    [95% Conf. Interval]
-----+-----
      sa_1   -.028794   .077495     -0.384   .697   -0.161519   .1039303
      hb_1   -.0063046   .076763     -0.082   .935   -.1467694   .1341603
      sa_2   -.04791    .019875     -2.418   .016   -.0805496   -.0152706
      hb_2   .0357616    .013526     2.643   .008   .0086922   .0628311
      dp_1   .000321    .006904     0.003   .998   -.0137219   .0136978
      dp_2   .005809    .0179389    0.073   .943   -.0149306   .0161324
      dp_3   -.0008219    .0670248    -0.117   .907   -.0143707   .0128289
      lunch   .9004426    .1469762    6.137   .000   .6065208   .8943645
      _cons   -3.265107    .0916453    -35.628   0.000   -3.444729   -3.005406

      /ln_p | .1459825 .0211454  6.904  0.000   .1045382 .1874268
      p | 1.157176 .024469  1.110198  1.206142
      1/p | .8641728 .0182733 .8290898 .9007404


```

## Wir lernen daraus:


1. Z.B.: Wenn sich die vergangenen beiden rades seller-ini lier waren, dann verändert sich die Hazardra e um  $exp(-.029784) - 1 = .97065517 - 1$ , sie sink
2. Das Verhältnis der Hazardra e is increasing in dieser Spezifika ion denn  $p = \alpha = 1.157176$  und hochsignifikant größer als 1.



# Survival function



# Hazard function



## 7.5.2 Das partial Likelihood Modell

**Probleme bei proportional hazard:** (1.) Zei unabhängigkeit der Regressoren und (2.) Nicht-Identifikation des baseline-hazards.

**Probleme bei partial Likelihood:** (1.) Zei unabhängigkeit der Regressoren und (2.) weder Survival noch Hazardfunktion können berechnet werden.

Wenn die Verweildauer gemäß ihrer Länge geordnet sind ( $t_1 < t_2 < \dots < t_k$ ) und es keine 'ties' (Verweildauern gleicher Länge) gibt, dann ist die konditionale Wahrscheinlichkeit dass eine non-erade innerhalb der Verweildauer  $t_l$  beobachtet wird:

$$\frac{\lambda(t_l, \mathbf{X}_l, \beta)}{\sum_{i=1}^N \lambda(t_i, \mathbf{X}_i, \beta)},$$

also der Beitrag zu der Wahrscheinlichkeit ist der hazard der kürzesten Verweildauer und der Summe des hazards der Verweildauern der Individuen 'at risk'.

Unter der proportional hazard-Annahme  $\lambda(t, \mathbf{X}, \beta) = \phi(\mathbf{X}, \beta) \lambda_0(t)$  ergibt sich:

$$\frac{\phi(\mathbf{X}_l, \beta)}{\sum_{i=1}^N \phi(\mathbf{X}_i, \beta)}.$$

Die Likelihoodfunktion ergibt sich aus dem Produkt der individuellen Beiträge:

$$\ln(\ell) = \sum_{i=1}^N \left( \ln(\phi(\mathbf{X}_i, \beta)) - \ln \left[ \sum_{j=i}^N \phi(\mathbf{X}_j, \beta) \right] \right).$$

**Ergo I:** Ungefähr Abwesenheit von Information über den baseline-hazard ist nur die Ordnung der Verweildauern informativ.

**Ergo II:** Wenn es viele Ereignisse gibt, dann habe ich ein Problem! Lösung: Approximation durch Gewichtung mit  $m_i$ :

$$\ln(\ell) = \sum_{i=1}^N \left( \ln(\phi(\mathbf{X}_i, \beta)) - \ln \left[ \sum_{j=i}^N \phi(\mathbf{X}_j, \beta) \right]^{m_i} \right)$$

mit  $m_i$  als der Anzahl der Beobachtungen deren Verweildauer in  $t_i$  endet.

# Partial-Likelihood Schätzergebnisse

```

. stcox ss_1 bb_1 ss_2 bb_2 ss_3 bb_3 dp_1 dp_2 dp_3 lunch, nhr
      failure_d: 1 (meaning all fail)
analysis time _t: tbt

Iteration 0: log likelihood = -7844.4407
Iteration 1: log likelihood = -7835.0491
Iteration 2: log likelihood = -7835.8406
Iteration 3: log likelihood = -7835.8404
Refining estimates:
Iteration 0: log likelihood = -7835.8404

Cox regression -- Breslow method for ties

No. of subjects =      1269      Number of obs =      1269
No. of failures =      1269
Time at risk    =      21569
Log likelihood  = -7835.8404
LR chi2(10)    =      17.20
Prob > chi2    =      0.0700

```

_____t_____	_____d_____	Coef.	Std. Err.	z	P> z	[95% Conf. Interval]
ss_1		-.0132514	.0774162	-0.171	0.864	-.1649844 .1384816
bb_1		-.0130337	.0766974	-0.170	0.865	-.1633578 .1372904
ss_2		-.0362492	.0817223	-0.444	0.657	-.196422 .1239235
bb_2		-.0411148	.0812446	-0.506	0.613	-.2003513 .1181217
ss_3		-.0385257	.0772077	-0.499	0.618	-.1898499 .1127985
bb_3		-.0355326	.077057	-0.461	0.645	-.1865615 .1154963
dp_1		.0000221	.0068623	0.003	0.997	-.0134278 .0134721
dp_2		.0010299	.0077716	0.133	0.895	-.0142022 .0162621
dp_3		-.0003261	.0068879	-0.047	0.962	-.0138262 .013174
lunch		-.4707697	.1252265	-3.759	0.000	-.7162091 -.2253304

## Wir lernen daraus:

Z.B.: Wenn sich die vergangenen beiden rades seller-initier waren, dann veränder sich die Hazardrate um  $\exp(-.0132514) - 1 = .98683601 - 1$ , die Hazardrate sink also um  $\exp(-.0132514) - 1 = -.01316399$  oder 1.32 Prozen .

## 7.6 Stichworte zu Kapitel 7

- Zensierung
- ies
- Kaplan–Meier–Schätzung
- Hazardrate
- Inegred hazard
- proportional hazard model
- partial Likelihood model

## 7.7 Literaturhinweise

**Ein guter Übersichtsartikel:** Kiefer, N.M. (1988), “Economic Duration Data and Hazard Functions,” *Journal of Economic Literature* 31, 646–679.

**Zwei gute Lehrbücher:** Lancaster, T. (1990), *The Econometric Analysis of Transition Data*, Cambridge: Cambridge University Press.

Blossfeld, H.-P. und Rohwer, G. (1995), *Techniques of Event History Modeling: New Approaches to Causal Analysis*, Mahwah: Lawrence Erlbaum Associates.