

Maßgeschneiderte Schadenmodelle mit der stückweisen Pareto-Verteilung

Dr. Ulrich Riegel



DAV

DEUTSCHE
AKTUARVEREINIGUNG e.V.

ASTIN-Tagung, 30. April 2021

Agenda

- 1 Layerunabhängige Schadenmodelle
- 2 Pareto-Verteilung
- 3 Stückweise Pareto-Verteilung
- 4 PML-Kurven
- 5 Layerunabhängige Modelle für Sequenzen von Layern

Layerunabhängige Schadenmodelle

Wir betrachten Layer c_i vs a_i ($i = 1, \dots, n$), z.B. die Layer eines nichtproportionalen Rückversicherungsprogramms oder künstliche Referenz-/Kalkulationslayer.

Wir setzen voraus, dass sich der Aktuar bei jedem Layer c_i vs a_i bereits für einen Schätzer \hat{e}_i des erwarteten Schadens entschieden hat.


Definition: Ein kollektives Modell heißt *layerunabhängig*, wenn es für jeden Layer c_i vs a_i den erwarteten Schaden \hat{e}_i liefert. Wenn das Modell nur für einen/einige (aber nicht für alle) Layer den erwarteten Schaden trifft, dann heißt es *layerspezifisch*.

Warum sind layerunabhängige Modelle nützlich?

Wir betrachten zwei Beispiele!

Beispiel 1: NatCat Aggregate XL

Wir betrachten einen Cat-XL 90m xs 10m mit AAD 100m und AAL 100m für Hurrikan.
Unterhalb von 40m scheint das NatCat-Modell die Frequenz der Ereignisse zu unterschätzen:



Beispiel 1: NatCat Aggregate XL

Das NatCat-Modell scheint für den kompletten Layer 90m xs 10m zu billig zu sein. Daher teilen wir den Layer in zwei künstliche Teillayer auf, die wir unabhängig modellieren:

- Für den Layer 30m xs 10m verwenden wir das Burning Cost-Modell (kollektives Modell mit Poisson-Schadenzahl und der empirischen Schadenhöhenverteilung)
- Für den Layer 60m xs 40m verwenden wir das NatCat-Modell (ebenfalls ein kollektives Modell mit Poisson-Schadenzahl)

	NatCat-Modell	Geteiltes Modell
Erw. Schaden 30m xs 10m	18.53m	26.66m
Erw. Schaden 60m xs 40m	15.95m	15.95m
Erw. Schaden 90m xs 10m	34.48m	42.61m
Erw. Schaden nach AAD & AAL	3.68m	2.28m

Beispiel 1: NatCat Aggregate XL

Wie erwartet liefert das geteilte Modell einen höheren erwarteten Schaden im Layer 90m xs 10m. Aber warum erhalten wir einen nach AAD & AAL eine niedrigere erwartete Schadenlast?

Begründung:

- Der erwartete Schaden nach AAD & AAL hängt nicht nur vom erwarteten Schaden im Layer 90m xs 10m ab sondern auch ganz wesentlich von der Volatilität!
- Die Verwendung von unabhängigen Modellen für die künstlichen Teillayer ignoriert die Tatsache, dass die beiden Teillayer positiv korreliert sind. Dadurch wird die Schwankung unterschätzt.

⇒ Wir brauchen ein layerunabhängiges Modell, das für die beiden Teillayer jeweils den richtigen erwarteten Schaden liefert.

Beispiel 2: Motor-Marktquotierung

Das Ergebnis einer Marktquotierung ist oft eine Tabelle mit Raten für eine Folge von kurzen Layern:

Layer	Exp. Loss
1 xs 1	2,93%
1 xs 2	1,30%
1 xs 3	0,72%
1 xs 4	0,43%
1 xs 5	0,24%
1 xs 6	0,12%
1 xs 7	0,07%
1 xs 8	0,04%

Layer	Exp. Loss
1 xs 9	0,03%
1 xs 10	0,02%
1 xs 11	0,02%
1 xs 12	0,02%
1 xs 13	0,01%
1 xs 14	0,01%
Inf xs 15	0,12%

Hier ist es sehr praktisch, wenn man ein layerunabhängiges Marktmodell in den Pricing-Systemen zur Verfügung stellen kann!

Agenda

- 1 Layerunabhängige Schadenmodelle
- 2 Pareto-Verteilung**
- 3 Stückweise Pareto-Verteilung
- 4 PML-Kurven
- 5 Layerunabhängige Modelle für Sequenzen von Layern

Definition Pareto-Verteilung

Bevor wir zur stückweisen Pareto-Verteilung kommen benötigen wir ein paar Tatsachen zur Pareto-Verteilung.

Definition: Seien $t > 0$ und $\alpha > 0$. Die *Pareto-Verteilung* $\text{Pareto}(t, \alpha)$ hat die Verteilungsfunktion

$$F_{t,\alpha}(x) := \begin{cases} 0 & \text{für } x \leq t \\ 1 - \left(\frac{t}{x}\right)^\alpha & \text{für } x > t. \end{cases}$$

Diese Version der Pareto-Verteilung wird auch als *Pareto type I*, *European Pareto* oder *single-parameter Pareto* bezeichnet.

Eigenschaften der Pareto-Verteilung

Warum ist die Pareto-Verteilung bei Rückversicherern so beliebt?

Proposition:

- Sei $X \sim \text{Pareto}(t, \alpha)$. Dann ist $cX \sim \text{Pareto}(ct, \alpha)$ für alle $c > 0$
- Sei $X \sim \text{Pareto}(t_1, \alpha)$. Für $t_2 > t_1$ gilt dann $X|(X > t_2) \sim \text{Pareto}(t_2, \alpha)$

Folgerung:

- Das *Pareto-Alpha* α ist invariant unter Skalierung sowie Trunkierung von links
- Für Layer und Thresholds oberhalb t hängt das Verhältnis zwischen erwarteten Layerschäden und/oder xs-Frequenzen nur von α (und nicht von t) ab

Wir betrachten nun einige nützliche Konzepte wie die *Pareto-Extrapolation* und das *Pareto-Alpha* zwischen zwei *Layern*.


Zur Illustration verwenden wir das R-Paket Pareto, das Funktionen für die Pareto- und die stückweise Pareto-Verteilung bereitstellt.

Das Paket ist auf CRAN verfügbar:

Console:

```
> install.packages("Pareto")
```

In R Studio:



Mittlere Schadenhöhe im Layer

Mittlere Schadenhöhe im Layer: Seien $X \sim \text{Pareto}(t, \alpha)$ und $a, c \geq 0$. Dann ist

$$E(\min[c, \max(X - a, 0)]) = \int_a^{c+a} (1 - F_{t,\alpha}(x)) dx$$

die mittlere Schadenhöhe im Layer c xs a .

Beispiel: $t = 1000$, $\alpha = 2$, Layer 4000 xs 1000

```
> library(Pareto)
> Pareto_Layer_Mean(4000, 1000, 2)      # Parameter t can be skipped since t = 1000
[1] 800
```

Für $t = 5000$ gibt es im Layer nur Totalschäden:

```
> Pareto_Layer_Mean(4000, 1000, 2, t = 5000)
[1] 4000
```

Pareto-Extrapolation

Wir betrachten zwei Layer c_i vs a_i und eine Pareto(t, α)-verteilte Schadenhöhe mit ausreichend kleinem t . Was ist der erwartete Schaden im Layer c_2 vs a_2 wenn der erwartete Schaden des Layers c_1 vs a_1 gegeben ist?

Beispiel:

Der erw. Schaden in 4000 vs 1000 sei 500. Wie hoch ist der erw. Schaden im Layer 5000 vs 5000 unter der Annahme $\alpha = 2$?

```
> Pareto_Extrapolation(4000, 1000, 5000, 5000, 2) * 500
```

```
[1] 62.5
```

```
> Pareto_Extrapolation(4000, 1000, 5000, 5000, 2, ExpLoss_1 = 500)
```

```
[1] 62.5
```

Pareto-Alpha zwischen zwei Layern

Ist der erwartete Schaden von zwei Layern gegeben, dann gibt es i.d.R. ein eindeutiges Pareto-Alpha α das konsistent zu dem Verhältnis der beiden Layer-Erwartungen ist.

Beispiel:

Erwarteter Schaden im Layer 4000 xs 1000: 500

Erwarteter Schaden im Layer 5000 xs 5000: 62,5.

Alpha zwischen den Layern:

```
> Pareto_Find_Alpha_bt看_Layers(4000, 1000, 500, 5000, 5000, 62.5)
[1] 2
```

Probe: siehe vorhergehende Folie

Pareto-Alpha zwischen Frequenz und Layer

Gegeben seien die erwartete Frequenz x_s einem Threshold und der erwartete Schaden eines Layers. Dann gibt es typischerweise ein eindeutiges α , das konsistent mit diesen Daten ist.

Beispiel: Erwartete Frequenz x_s 500: 3,0
Erwarteter Schaden im Layer 4000 x_s 1000: 600

Alpha zwischen Frequenz und Layer:

```
> Pareto_Find_Alpha_btW_FQ_Layer(500, 3, 4000, 1000, 600)
[1] 2
```

Probe:

```
> Pareto_Layer_Mean(4000, 1000, 2, t = 500) * 3
[1] 600
```

Fitten der Schadenerwartung von zwei Layern

Diese Methoden können verwendet werden um ein Poisson-Pareto-Modell zu fitten, das den erwarteten Schaden von zwei Layern trifft.

Beispiel 1 von oben (Aggregate XL):


Erw. Schaden des Layers 30 xs 10 (Burning Cost): 26.66

Erw. Schaden des Layers 60 xs 40 (NatCat-Modell): 15.95

```
> Pareto_Find_Alpha_btw_Layers(30, 10, 26.66, 60, 40, 15.95)
[1] 1.086263
> # Frequency @ 10:
> 26.66 / Pareto_Layer_Mean(30, 10, 1.086263)
[1] 2.040392
```

Fitten der Schadenerwartung von zwei Layern

Ein kollektives Modell $\sum_{n=1}^N X_n$ mit $X_N \sim \text{Pareto}(10, 1.09)$ und $N \sim \text{Poisson}(2.04)$ trifft die Schadenerwartung beider Layer.



Passt ganz gut!

Fitten der Schadenerwartung von zwei Layern

Welchen Effekt hat die Verwendung dieses Fits für den Aggregate XL?

	NatCat-Modell	Geteiltes Modell	Pareto-Modell
Erw. Schaden 30 xs 10	18.53	26.66	26.66
Erw. Schaden 60 xs 40	15.95	15.95	15.95
Erw. Schaden 90 xs 10	34.48	42.61	42.61
Erw. Schaden nach AAD & AAL	3.68	2.28	4.78

Frequenzextrapolation und Pareto-Alpha zwischen Frequenzen

Ist die xs-Frequenz f_1 bei t_1 gegeben, so kann die xs-Frequenz f_2 bei t_2 direkt berechnet werden:

$$f_2 = f_1 \cdot \left(\frac{t_1}{t_2}\right)^\alpha$$

Anders herum können wir das Pareto-Alpha berechnen, wenn die beiden Frequenzen f_1 und f_2 bei t_1 und t_2 gegeben sind:

$$\alpha = \frac{\log(f_2/f_1)}{\log(t_1/t_2)}.$$

Agenda

- 1 Layerunabhängige Schadenmodelle
- 2 Pareto-Verteilung
- 3 Stückweise Pareto-Verteilung**
- 4 PML-Kurven
- 5 Layerunabhängige Modelle für Sequenzen von Layern

Definition der stückweisen Pareto-Verteilung

Definition:

Seien $\mathbf{t} := (t_1, \dots, t_n)$ ein Vektor von Thresholds mit $0 < t_1 < \dots < t_n < t_{n+1} := +\infty$ und $\alpha := (\alpha_1, \dots, \alpha_n)$ ein Vektor von Pareto-Alphas mit $\alpha_i \geq 0$ and $\alpha_n > 0$. Die *stückweise Pareto-Verteilung* $\text{Pareto}(\mathbf{t}, \alpha)$ hat die Verteilungsfunktion

$$F_{\mathbf{t}, \alpha}(x) := \begin{cases} 0 & \text{für } x < t_1 \\ 1 - \left(\frac{t_k}{x}\right)^{\alpha_k} \prod_{i=1}^{k-1} \left(\frac{t_i}{t_{i+1}}\right)^{\alpha_i} & \text{für } x \in [t_k, t_{k+1}). \end{cases}$$

Flexibilität der stückweisen Pareto-Verteilung

Die Familie der stückweisen Pareto-Verteilungen ist sehr flexibel:

Proposition: Die Menge der stückweisen Pareto-Verteilungen ist dicht im Raum der positivwertigen Verteilungen (bezüglich der Lévy-Metrik).

Anmerkungen:

- Man kann also jede positivwertige Verteilung beliebig genau durch eine stückweise Pareto-Verteilung approximieren.
- Eine sehr gute Approximation erfordert jedoch typischerweise viele Pareto-Stücke.
- Die stückweise Pareto-Verteilung ist eine gute Alternative zu diskreten Verteilungen, da sie angenehmer in der Handhabung ist.

Das R-Paket Pareto stellt Funktionen für die stückweise Pareto-Verteilung zur Verfügung, z.B.

Mittlere Schadenhöhe im Layer:

```
> t <- c(1000, 2000, 3000, 4000)
> alpha <- c(2, 1, 3, 20)
> PiecewisePareto_Layer_Mean(4000, 1000, t, alpha)
[1] 826.6969
```

Layer-Varianz:

```
> PiecewisePareto_Layer_Var(4000, 1000, t, alpha)
[1] 922221.2
```

Simulation:

```
> losses <- rPiecewisePareto(1000, t, alpha)
```

Maximum Likelihood-Schätzer für die Pareto-Alphas:

```
> PiecewisePareto_ML_Estimator_Alpha(losses, t)
[1] 2.1363325 0.9422449 3.3452221 16.8548997
```


Verteilungsfunktion:

```
> x <- 1:10 * 1000
> pPiecewisePareto(x, t, alpha)
[1] 0.0000000 0.7500000 0.8333333 0.9296875 0.9991894 0.9999789
[7] 0.9999990 0.9999999 1.0000000 1.0000000
```

Dichtefunktion:

```
> dPiecewisePareto(x, t, alpha)
[1] 0.000000e+00 1.250000e-04 1.666667e-04 3.515625e-04 3.242592e-06
[6] 7.048328e-08 2.768239e-09 1.676381e-10 1.413089e-11 1.546188e-12
```

Verteilungsfunktion:



Agenda

- 1 Layerunabhängige Schadenmodelle
- 2 Pareto-Verteilung
- 3 Stückweise Pareto-Verteilung
- 4 PML-Kurven**
- 5 Layerunabhängige Modelle für Sequenzen von Layern


Bei Naturgefahren arbeitet man häufig mit PML-Kurven, z.B.

Wiederkehrperiode	Frequenz	Schadenhöhe
1	1.000	100
2	0.500	200
5	0.200	400
10	0.100	700
20	0.050	1000
50	0.020	1500
100	0.010	2000

Wie kann man aus einer solchen Kurve ein kollektives Modell ableiten?


Interpolation von PML-Kurven

Wie interpoliert man am besten zwischen den gegebene Punkten?



Interpolation von PML-Kurven


Eine Möglichkeit:



Das ist ziemlich billig, wenn man nur wenige Punkte hat ...

Interpolation von PML-Kurven


Alternativ könnte man folgendermaßen interpolieren:



Das ist ziemlich teuer, wenn man nur wenige Punkte hat ...

Interpolation von PML-Kurven

Besserer Ansatz:



Was haben wir gemacht?

Interpolation von PML-Kurven

Seien $f_1 > \dots > f_n > 0$ die xs-Frequenzen und $0 < t_1 < \dots < t_n$ die zugehörigen Schadenhöhen aus der PML-Kurve.

Für $i = 1, \dots, n - 1$ seien

$$\alpha_i = \frac{\log(f_{i+1}/f_i)}{\log(t_i/t_{i+1})}$$

die Pareto-Alphas zwischen (t_i, f_i) und (t_{i+1}, f_{i+1}) . Außerdem wählen wir ein $\alpha_n > 0$.

Seien $\mathbf{t} := (t_1, \dots, t_n)$ und $\boldsymbol{\alpha} := (\alpha_1, \dots, \alpha_n)$.

Dann erhält man ein kollektives Modell $\sum_{n=1}^N X_n$ mit der gewünschten Eigenschaft, indem man N mit $E(N) = f_1$ und $X_n \sim \text{Pareto}(\mathbf{t}, \boldsymbol{\alpha})$ wählt.

Interpolation von PML-Kurven

Bemerkung:

Mit dem gewählten α_n wird die PML-Kurve oberhalb des letzten Punktes t_n extrapoliert. Analog kann man auch ein α_0 wählen und unterhalb von t_1 extrapolieren. In den extrapolierten Bereichen ist das Modell jedoch nur mit großer Vorsicht zu verwenden!

Beispiel:

```
> return_period <- c(1, 2, 5, 10, 20, 50, 100)
> amount <- c(100, 200, 400, 700, 1000, 1500, 2000)
> Fit <- Fit_PML_Curve(return_period, amount)
> 1 / Excess_Frequency(Fit, amount)
[1] 1 2 5 10 20 50 100
```

Agenda

- 1 Layerunabhängige Schadenmodelle
- 2 Pareto-Verteilung
- 3 Stückweise Pareto-Verteilung
- 4 PML-Kurven
- 5 Layerunabhängige Modelle für Sequenzen von Layern

Layerunabhängige Schadenmodelle

Wir haben gesehen, dass man mit der Pareto-Verteilung ein kollektives Modell fitten kann, dass die erwarteten Schäden von zwei Layern trifft.

Die stückweise Pareto-Verteilung kann verwendet werden,

- wenn man die Layererwartungswerte für mehr als zwei Layer reproduzieren möchten und/oder
- wenn man zusätzlich gegebene x_s -Frequenzen in den Fit einbeziehen möchte.

Beachte: Bei Integralfranchisen ist es sehr wichtig, dass das Modell eine realistische x_s -Frequenz aufweist. Integralfranchisen werden häufig bei der Separierung von Basis- und Cat- bzw. Großschäden verwendet.

Einfacher Fitting-Algorithmus

Wir betrachten eine Sequenz $0 < a_1 < \dots < a_n < a_{n+1} := +\infty$ von Prioritäten. Sei $c_j := a_{j+1} - a_j$ und sei e_j der erw. Schaden des Layers c_j xs a_j . Außerdem sei f_1 die erwartete xs-Frequenz bei a_1 .

Diese Daten kann man mit der stückweisen Pareto-Verteilung leicht fiten:

- Berechne das Pareto-Alpha α_1 zwischen f_1 und c_1 xs a_1
- Berechne die xs-Frequenz f_2 bei a_2 : $f_2 := (a_1/a_2)^{\alpha_1} \cdot f_1$
- Berechne das Pareto-Alpha α_2 zwischen f_2 und c_2 xs a_2
- Berechne die xs-Frequenz f_3 bei a_3 : $f_3 := (a_2/a_3)^{\alpha_2} \cdot f_2$
- ...
- Verwende ein kollektives Modell $\sum_{n=1}^N X_n$ mit $E(N) = f_1$ und $X_n \sim \text{Pareto}(\mathbf{t}, \alpha)$.

Einfacher Fitting-Algorithmus

Einfache R-Implementierung:

```
simple_matching_approach <- function(a, e, f_1) {  
  n <- length(a)  
  c <- c(diff(a), Inf)  
  f <- numeric(n)  
  f[1] <- f_1  
  alpha <- numeric(n)  
  for (i in seq_along(a)) {  
    alpha[i] <- Pareto_Find_Alpha_bt看_FQ_Layer(a[i], f[i], c[i], a[i], e[i])  
    if (i < n) {  
      f[i+1] <- f[i] * (a[i] / a[i+1])^alpha[i]  
    }  
  }  
  return(list(frequency = f_1, t = a, alpha = alpha))  
}
```

Einfacher Fitting-Algorithmus

Beispiel:

```
> a <- c(1000, 1500, 2000, 2500)
> e <- c(100, 90, 50, 40)
> f_1 <- 0.21
> simple_matching_approach(a, e, f_1)
$frequency
[1] 0.21

$t
[1] 1000 1500 2000 2500

$alpha
[1] 0.2270887 0.4157705 5.0346512 4.4534806
```

Einfacher Fitting-Algorithmus

Man kann folgende Aussage zeigen:

Proposition:

Für $n \leq 3$ ist es immer möglich eine x_s -Frequenz $f_1 > e_1/c_1$ zu finden, so dass der einfache Fitting-Algorithmus ein kollektives Modell liefert, dessen erw. Schaden für den Layer c_i x_s a_i gleich e_i ist ($i = 1, \dots, n$).

Einfacher Fitting-Algorithmus

Die schlechte Nachricht: Der einfach Fitting-Algorithmus funktioniert oft nicht, wenn wir vier oder mehr Layer haben!


Zum Beispiel kann man folgende Layer-Sequenz nicht mit diesem Ansatz fitten:

i	Haftung c_i	Priorität a_i	Erw. Schaden e_i	Rate on Line e_i/c_i
1	500	1.000	100	0,20
2	500	1.500	90	0,18
3	500	2.000	50	0,10
4	500	2.500	40	0,08

Wenn man mit f_1 anfängt, so dass man die ersten drei Layererwartungen trifft, so bekommt man immer $f_4 < 0,06$, was kleiner als das Rate on Line des vierten Layers ist ...


Einfacher Fitting-Algorithmus

Die roten Linien illustrieren die zulässigen Eintrittsfrequenzen für die Layer an. Die Frequenz-Kurve muss durch die roten Linien gehen!




Einfacher Fitting-Algorithmus

Mit $f_1 = 0,23$ ist f_2 kleiner als das Rate on Line des zweiten Layers ...
⇒ Wir müssen f_1 reduzieren!




Einfacher Fitting-Algorithmus

Mit $f_1 = 0,22$ fittet der Algorithmus die ersten drei Layer, aber f_4 ist kleiner als das Rate on Line des vierten Layers ...




Einfacher Fitting-Algorithmus

Weitere Reduktion von $f_1 > 0,2$ bringt nur einen kleinen Anstieg von f_4 .
 $f_1 = 0,21$:



Einfacher Fitting-Algorithmus

Weitere Reduktion von $f_1 > 0,2$ bringt nur einen kleinen Anstieg von f_4 .
 $f_1 = 0,205$:




Verbesserter Fitting-Algorithmus

Es gibt einen besseren Fitting-Algorithmus, der zwei Pareto-Stücke pro Layer verwendet:

- Funktioniert zuverlässig für beliebig viele Layer
- Man kann zusätzlich Eintrittsfrequenzen für die Layer vorgeben
- Verfügbar im R-Paket Pareto

Anwendung auf unser Problem-Beispiel:



Anwendung auf Beispiel 2


Beispiel 2 von oben (Motor-Marktquotierung):

```
> a <- 1:15  
> c <- c(diff(a), Inf)  
> e <- c(0.0293, 0.0130, 0.0072, 0.0043, 0.0024, 0.0013, 0.0007, 0.0004, 0.0003,  
+       0.0002, 0.00017, 0.00015, 0.00014, 0.00012, 0.0012)  
> Fit <- Fit_References(c, a, e)
```

Probe:

```
> Layer_Mean(Fit, c, a)  
[1] 0.02930 0.01300 0.00720 0.00430 0.00240 0.00130 0.00070 0.00040 0.00030 0.00020  
[11] 0.00017 0.00015 0.00014 0.00012 0.00120
```

Anwendung auf Beispiel 2



Literatur

S.W. Philbrick (1985) *A practical guide to the single parameter Pareto distribution*, PCAS LXXII, 44–84.

U. Riegel (2008) *Generalizations of common ILF models*, Blätter der DGVFM 29, 45–71.

U. Riegel (2018) *Matching tower information with piecewise Pareto*, European Actuarial Journal 8, 437–460.

U. Riegel (2018) *Pareto: The Pareto, Piecewise Pareto and Generalized Pareto Distribution*, R package version 2.4.2, <https://github.com/ulrichriegel/Pareto#pareto>.

M. Schmutz, R.R. Doerr (1998) *Das Pareto-Modell in der Sach-Rückversicherung. Formeln und Anwendungen*, Swiss Re Publications, Zürich

Fragen?

