

# Teoria zdarzeń ekstremalnych (Extreme Value Theory, EVT) czyli teoria katastrof

Krzysztof Czarnowski

1 sierpnia, 2016

**(Wykorzystałem wiedzę i materiały udostępnione przez  
Joannę Czarnowską)**

# Gdzie zastosowania?

- Katastrofy naturalne

Na przykład ocena ryzyka wystąpienia ekstremalnych opadów i związanego z tym ryzyka powodzi lub choćby przeciążenia systemów burzowych i kanalizacyjnych.

# Gdzie zastosowania?

- Katastrofy naturalne  
Na przykład ocena ryzyka wystąpienia ekstremalnych opadów i związanego z tym ryzyka powodzi lub choćby przeciążenia systemów burzowych i kanalizacyjnych.
- Ubezpieczenia  
Szacowanie ryzyka wystąpienia szczególnie wysokich roszczeń i szacowanie poziomu wymaganych rezerw. Temat jest aktualny w związku z wdrażaniem dyrektywy Solvency II.

# Gdzie zastosowania?

- Katastrofy naturalne  
Na przykład ocena ryzyka wystąpienia ekstremalnych opadów i związanego z tym ryzyka powodzi lub choćby przeciążenia systemów burzowych i kanalizacyjnych.
- Ubezpieczenia  
Szacowanie ryzyka wystąpienia szczególnie wysokich roszczeń i szacowanie poziomu wymaganych rezerw. Temat jest aktualny w związku z wdrażaniem dyrektywy Solvency II.
- Inwestycje  
Zarządzanie ryzykiem strat.


# Gdzie zastosowania?

- Katastrofy naturalne  
Na przykład ocena ryzyka wystąpienia ekstremalnych opadów i związanego z tym ryzyka powodzi lub choćby przeciążenia systemów burzowych i kanalizacyjnych.
- Ubezpieczenia  
Szacowanie ryzyka wystąpienia szczególnie wysokich roszczeń i szacowanie poziomu wymaganych rezerw. Temat jest aktualny w związku z wdrażaniem dyrektywy Solvency II.
- Inwestycje  
Zarządzanie ryzykiem strat.
- Logistyka  
Szacowanie poziomu zapasów. (Tak naprawdę zdałem sobie sprawę z tego słuchając jednego z referatów w czasie *Innovation@Amazon*. Amazon to bardzo ciekawy przypadek!)
- ...

# Problem


Przykład z książki S. Coles, s. 9  
— opady dzienne w południowo  
wschodniej Anglii w latach 1914-  
62.

Estymacja prawdopodobieństwa  
wystąpienia ekstremalnych war-  
tości czyli estymacja ogona roz-  
kładu jest trudna.



Przykład z książki S. Coles, s. 9 — opady dzienne w południowo-wschodniej Anglii w latach 1914-62.


Estymacja prawdopodobieństwa wystąpienia ekstremalnych wartości czyli estymacja ogona rozkładu jest trudna.



- Standardowe metody parametryczne (MLE, metoda momentów) dobrze wyestymują ciało rozkładu, ogon zwykle bardzo słabo (mało danych, duża dysproporcja). I trzeba założyć jakiś kształt rozkładu!

Przykład z książki S. Coles, s. 9 — opady dzienne w południowo-wschodniej Anglii w latach 1914-62.

Estymacja prawdopodobieństwa wystąpienia ekstremalnych wartości czyli estymacja ogona rozkładu jest trudna.



- Standardowe metody parametryczne (MLE, metoda momentów) dobrze wyestymują ciało rozkładu, ogon zwykle bardzo słabo (mało danych, duża dysproporcja). I trzeba założyć jakiś kształt rozkładu!
- Empiryczna estymacja kwantyli ma taki problem, że prawdopodobieństwo wystąpienia wartości większych niż zaobserwowane maksimum wynosi zero. To nie jest dobrze!



## No to inaczej...

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.

## No to inaczej...

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.
- $X_1, X_2, \dots, X_n$  — niezależne zmienne losowe o jednakowym rozkładzie  $F_X(x) = P(X \leq x)$  (dystrybuanta, ang. *cumulative distribution function*)

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.
- $X_1, X_2, \dots, X_n$  — niezależne zmienne losowe o jednakowym rozkładzie  $F_X(x) = P(X \leq x)$  (dystrybuanta, ang. *cumulative distribution function*)
- Na przykład:  $X_i$  — opad dzienny,  $n = 365$ .

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.
- $X_1, X_2, \dots, X_n$  — niezależne zmienne losowe o jednakowym rozkładzie  $F_X(x) = P(X \leq x)$  (dystrybuanta, ang. *cumulative distribution function*)
- Na przykład:  $X_i$  — opad dzienny,  $n = 365$ .
- $M_n = \max(X_1, X_2, \dots, X_n)$

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.
- $X_1, X_2, \dots, X_n$  — niezależne zmienne losowe o jednakowym rozkładzie  $F_X(x) = P(X \leq x)$  (dystrybuanta, ang. *cumulative distribution function*)
- Na przykład:  $X_i$  — opad dzienny,  $n = 365$ .
- $M_n = \max(X_1, X_2, \dots, X_n)$
- Interesuje nas estymacja dystrybuanty  $F_{M_n}(x) = P(M_n \leq x)$

- Szukamy innego podejścia bardziej powiązanego z ogonem bazowego rozkładu, możliwie bez założeń o szczegółowym kształcie.
- Oszacujemy prawdopodobieństwo katastrofy w ciągu pewnego okresu czasu, na przykład wystąpienia wyjątkowo dużego opadu deszczu w ciągu roku.
- Katastrofa wystąpi gdy w ciągu tego czasu pewna wielkość przynajmniej raz przekroczy krytyczny poziom.
- $X_1, X_2, \dots, X_n$  — niezależne zmienne losowe o jednakowym rozkładzie  $F_X(x) = P(X \leq x)$  (dystrybuanta, ang. *cumulative distribution function*)
- Na przykład:  $X_i$  — opad dzienny,  $n = 365$ .
- $M_n = \max(X_1, X_2, \dots, X_n)$
- Interesuje nas estymacja dystrybuanty  $F_{M_n}(x) = P(M_n \leq x)$
- Jak to się zachowuje gdy  $n$  rośnie? Jakiś rozkład graniczny?



# Przecież to banalne!

- $\max(X_1, X_2, \dots, X_n) \leq x$  wtedy i tylko wtedy, gdy  $X_1 \leq x$  i  $X_2 \leq x$  i tak dalej, i w końcu  $X_n \leq x$

# Przecież to banalne!

- $\max(X_1, X_2, \dots, X_n) \leq x$  wtedy i tylko wtedy, gdy  $X_1 \leq x$  i  $X_2 \leq x$  i tak dalej, i w końcu  $X_n \leq x$
- czyli  $F_{M_n}(x) = F_X(x) \cdot F_X(x) \cdots F_X(x) = (F_X(x))^n$   
(Założyliśmy że wszystkie  $X_i$  mają ten sam rozkład i przede wszystkim niezależność! Czyli prawdopodobieństwa się mnożą.)

# Przecież to banalne!

- $\max(X_1, X_2, \dots, X_n) \leq x$  wtedy i tylko wtedy, gdy  $X_1 \leq x$  i  $X_2 \leq x$  i tak dalej, i w końcu  $X_n \leq x$
- czyli  $F_{M_n}(x) = F_X(x) \cdot F_X(x) \cdots F_X(x) = (F_X(x))^n$   
(Założyliśmy że wszystkie  $X_i$  mają ten sam rozkład i przede wszystkim niezależność! Czyli prawdopodobieństwa się mnożą.)
- W takim razie, jeśli  $F_X(x) < 1$  dla  $x < x_0$  i  $F_X(x) = 1$  dla  $x \geq x_0$ , to

$$\lim_{n \rightarrow \infty} F_{M_n}(x) = \begin{cases} 0 & \text{dla } x < x_0 \\ 1 & \text{dla } x \geq x_0. \end{cases}$$

# Przecież to banalne!

- $\max(X_1, X_2, \dots, X_n) \leq x$  wtedy i tylko wtedy, gdy  $X_1 \leq x$  i  $X_2 \leq x$  i tak dalej, i w końcu  $X_n \leq x$
- czyli  $F_{M_n}(x) = F_X(x) \cdot F_X(x) \cdots F_X(x) = (F_X(x))^n$   
(Założyliśmy że wszystkie  $X_i$  mają ten sam rozkład i przede wszystkim niezależność! Czyli prawdopodobieństwa się mnożą.)
- W takim razie, jeśli  $F_X(x) < 1$  dla  $x < x_0$  i  $F_X(x) = 1$  dla  $x \geq x_0$ , to

$$\lim_{n \rightarrow \infty} F_{M_n}(x) = \begin{cases} 0 & \text{dla } x < x_0 \\ 1 & \text{dla } x \geq x_0. \end{cases}$$

- Ups! Zginęliśmy w osobliwości!  
(Jeśli rozkład  $X$  nie jest ograniczony i stosownego  $x_0$  nie ma, to jest jeszcze gorzej — osobliwość ucieka do nieskończoności.)
- ... czy to jest cały czas ten sam problem?

# Normalizacja durniu! Normalizacja!

- Gdzieś to już widzieliśmy. . .
- Jeśli  $S_n = X_1 + X_2 + \dots + X_n$ , to  $S_n$  też zwykle „uciekają do nieskończoności”.

# Normalizacja durniu! Normalizacja!

- Gdzieś to już widzieliśmy...
- Jeśli  $S_n = X_1 + X_2 + \dots + X_n$ , to  $S_n$  też zwykle „uciekają do nieskończoności”.
- Sytuację ratuje normalizacja!

$$S_n^* = \frac{S_n - n\mu}{\sqrt{n\sigma^2}}$$

( $\mu$  i  $\sigma^2$  — średnia i wariancja rozkładu  $X$ )

# Normalizacja durniu! Normalizacja!

- Gdzieś to już widzieliśmy...
- Jeśli  $S_n = X_1 + X_2 + \dots + X_n$ , to  $S_n$  też zwykle „uciekają do nieskończoności”.
- Sytuację ratuje normalizacja!

$$S_n^* = \frac{S_n - n\mu}{\sqrt{n\sigma^2}}$$

( $\mu$  i  $\sigma^2$  — średnia i wariancja rozkładu  $X$ )

- Wówczas ciąg  $S_n^*$  ma rozkład graniczny  $N(0, 1)$ .

# Normalizacja durniu! Normalizacja!

- Gdzieś to już widzieliśmy. . .
- Jeśli  $S_n = X_1 + X_2 + \dots + X_n$ , to  $S_n$  też zwykle „uciekają do nieskończoności”.
- Sytuację ratuje normalizacja!

$$S_n^* = \frac{S_n - n\mu}{\sqrt{n\sigma^2}}$$

( $\mu$  i  $\sigma^2$  — średnia i wariancja rozkładu  $X$ )


- Wówczas ciąg  $S_n^*$  ma rozkład graniczny  $N(0, 1)$ .
- W przypadku maksimum normalizacja nie jest tak oczywista jak dla sum. . .



Maksimum z próbki niezależnych zmiennych losowych po odpowiedniej normalizacji może zbiegać według rozkładu tylko do jednego z trzech rozkładów: Weibulla, Gumbela lub Frecheta.

Leonard Tipett, 1902–1985  
angielski statystyk

Boris Gnienenko, 1912-1995  
radziecki matematyk



Ronald Fisher, 1890-1962  
angielski statystyk i biolog

Jeśli istnieją ciągi liczb  $a_n$  i  $b_n$  takie, że  $a_n > 0$  oraz znormalizowany ciąg maksimów

$$M_n^* = \frac{M_n - b_n}{a_n}$$

jest zbieżny (według rozkładu), czyli istnieje niezdegenerowana dystrybuanta  $H(x)$  taka, że

$$\lim_{n \rightarrow \infty} P(M_n^* \leq x) = H(x),$$

to  $H$  należy do jednej z trzech rodzin dystrybuant:

**Weibulla, Gumbela lub Frecheta**


# GEV, Generalized Extreme Value distribution

Rozkłady Weibulla, Gumbela i Frecheta można zebrać w **uogólniony rozkład wartości ekstremalnych**

$$H_0(x) = \exp\left(-\exp\left(-\frac{x-\mu}{\sigma}\right)\right) \quad \text{dla } \xi = 0,$$

oraz

$$H_\xi(x) = \exp\left(-\left(1 + \xi \cdot \frac{x-\mu}{\sigma}\right)_+^{-1/\xi}\right) \quad \text{dla } \xi \neq 0$$



$\xi < 0$  — rozkład Weibulla

$\xi = 0$  — rozkład Gumbela

$\xi > 0$  — rozkład Frecheta

- Pozornie konieczność normalizacji maksimumów jest problemem...

- Pozornie konieczność normalizacji maksimów jest problemem...
- ... ale dla danego  $n$  stałe normalizacyjne  $a_n$  i  $b_n$  można wchłonąć w  $\mu$  i  $\sigma$ , które i tak trzeba estymować!


- Pozornie konieczność normalizacji maksimów jest problemem...
- ... ale dla danego  $n$  stałe normalizacyjne  $a_n$  i  $b_n$  można wchłonąć w  $\mu$  i  $\sigma$ , które i tak trzeba estymować!
- Zatem jeśli tylko  $M_n^*$  ma rozkład zbliżony do GEV, to rozkład  $M_n$  też możemy przybliżać przy pomocy GEV tylko o innych parametrach (parametr kształtu  $\xi$  jest ten sam!).

- Pozornie konieczność normalizacji maksimów jest problemem...
- ... ale dla danego  $n$  stałe normalizacyjne  $a_n$  i  $b_n$  można wchłonąć w  $\mu$  i  $\sigma$ , które i tak trzeba estymować!
- Zatem jeśli tylko  $M_n^*$  ma rozkład zbliżony do GEV, to rozkład  $M_n$  też możemy przybliżać przy pomocy GEV tylko o innych parametrach (parametr kształtu  $\xi$  jest ten sam!).  
(Tyle tylko, że w przypadku  $M_n^*$  to jest ten sam rozkład, coraz lepszy gdy  $n$  rośnie, a w przypadku  $M_n$  rozkład „pływa”. Ale to zwykle nie przeszkadza.)

# Metoda maximów blokowych

- Dane dzielimy na  $m$  niezachodzących na siebie bloków, każdy o równej długości  $n$  – na przykład dane miesięczne czy roczne.
- Z każdego bloku wybieramy wartość największą:  
 $M_{n1}, M_{n2}, \dots, M_{nm}$ .
- Na podstawie uzyskanych  $m$  niezależnych obserwacji, estymujemy parametry  $\xi$ ,  $\mu$  i  $\sigma$  rozkładu GEV, na przykład metodą największej wiarygodności.

S. Coles — 3.3.2, s. 55  
Maximum Likelihood Estimation  
(MLE, metoda największej wiarygodności)





- Po dopasowaniu GEV zwykle najbardziej interesujące jest obliczenie stosownego kwantyla  $z_\alpha$  rzędu  $\alpha = 1 - p$ , zwykle dla małych wartości  $p$ .

- Po dopasowaniu GEV zwykle najbardziej interesujące jest obliczenie stosownego kwantyla  $z_\alpha$  rzędu  $\alpha = 1 - p$ , zwykle dla małych wartości  $p$ .
- Odwrócenie dystrybuanty GEV daje wzór:

$$z_\alpha = \begin{cases} \mu - \frac{\sigma}{\xi}(1 - (-\ln \alpha)^{-\xi}) & \text{dla } \xi \neq 0 \\ \mu - \sigma \ln(-\ln \alpha) & \text{dla } \xi = 0. \end{cases}$$


- Po dopasowaniu GEV zwykle najbardziej interesujące jest obliczenie stosownego kwantyla  $z_\alpha$  rzędu  $\alpha = 1 - p$ , zwykle dla małych wartości  $p$ .
- Odwrócenie dystrybuanty GEV daje wzór:

$$z_\alpha = \begin{cases} \mu - \frac{\sigma}{\xi}(1 - (-\ln \alpha)^{-\xi}) & \text{dla } \xi \neq 0 \\ \mu - \sigma \ln(-\ln \alpha) & \text{dla } \xi = 0. \end{cases}$$


- Interpretacja jest następująca: na przykład dla  $p = 5\%$  w kontekście opadów, wartość odpowiedniego kwantyla  $z_{95\%}$  to taki poziom, który będzie przekraczany średnio co 20 lat.

# Estymacja ogona inaczej — Peaks Over Threshold (POT)

## Metoda maximów blokowych




## Metoda przekroczeń progu




# Estymacja ogona inaczej — Peaks Over Threshold (POT)

## Metoda maximów blokowych



## Metoda przekroczeń progu



Dla zmiennej losowej  $X$  o dystrybuancie  $F$  i ustalonego progu  $u > 0$  definiujemy *nadwyżkę* jako  $Y = X - u$ . Dystrybuanta *nadwyżki* dana jest wzorem

$$F_u(y) = P(X - u \leq y | X > u)$$

# Uogólniony rozkład Pareto (GPD)

Twierdzenie udowodnione niezależnie przez Balkema i de Haana (1974) oraz Pickandsa (1975).

# Uogólniony rozkład Pareto (GPD)

Twierdzenie udowodnione niezależnie przez Balkema i de Haana (1974) oraz Pickandsa (1975).

## Twierdzenie

Dystrybuanty maximów  $M_n = \max(X_1, \dots, X_n)$  są zbieżne do dystrybuanty GEV z parametrem kształtu  $\xi$  wtedy i tylko wtedy, gdy

$$\lim_{u \rightarrow \infty} \sup_x |F_u(x) - G_{\xi, \beta(u)}(x)| = 0.$$

dla pewnej funkcji  $\beta$  zależnej od  $u$ , gdzie  $G_{\xi, \beta}$  jest dystrybuantą uogólnionego rozkładu Pareto:

$$G_{\xi, \beta}(x) = \begin{cases} 1 - (1 + \frac{\xi \cdot x}{\beta})^{-\frac{1}{\xi}} & \xi \neq 0 \\ 1 - \exp(-\frac{x}{\beta}) & \xi = 0 \end{cases}$$

# Metoda POT — co z tym progmem?

- Za niski próg może dawać za dużo danych pochodzących nie z ogona rozkładu, co zwiększy obciążenia estymatorów.



# Metoda POT — co z tym progiem?

- Za niski próg może dawać za dużo danych pochodzących nie z ogona rozkładu, co zwiększy obciążenia estymatorów.
- Wybór zbyt dużego progu spowoduje, że pozostanie nam za mało danych i wpłynie na wariancję.

# Metoda POT — co z tym progmem?

- Za niski próg może dawać za dużo danych pochodzących nie z ogona rozkładu, co zwiększy obciążenia estymatorów.
- Wybór zbyt dużego progu spowoduje, że pozostanie nam za mało danych i wpłynie na wariancję.
- Wielu autorów sugeruje taki wybór progu, aby liczba pozostałych danych była nie większa niż 10-15%. Często wybierany jest próg tak aby liczba ta była rzędu 5-10%.

# Metoda POT — co z tym progmem?

- Za niski próg może dawać za dużo danych pochodzących nie z ogona rozkładu, co zwiększy obciążenia estymatorów.
- Wybór zbyt dużego progmu spowoduje, że pozostanie nam za mało danych i wpłynie na wariancję.
- Wielu autorów sugeruje taki wybór progmu, aby liczba pozostałych danych była nie większa niż 10-15%. Często wybierany jest próg tak aby liczba ta była rzędu 5-10%.

Pomocny może być ciekawy fakt. Jeśli przez  $e(u)$  oznaczyć wartość średnią z przekroczeń progmu:

$$e(u) = E(\underbrace{X - u}_Y | X > u),$$

to jeśli dla pewnego  $u$  rozkład nadwyżek dobrze aproksymuje się GPD, to dla progów  $v > u$ ,  $e(v)$  jest liniową funkcją  $v$ .

- Mocno upraszczaliśmy! Co na przykład w sytuacji, gdy założenie o niezależności jest trudne do utrzymania? Są dostępne uogólnienia:
  - procesy stacjonarne
  - pewne procesy niestacjonarne, model sezonowy
  - procesy punktowe

- Mocno upraszczaliśmy! Co na przykład w sytuacji, gdy założenie o niezależności jest trudne do utrzymania? Są dostępne uogólnienia:
  - procesy stacjonarne
  - pewne procesy niestacjonarne, model sezonowy
  - procesy punktowe
- Ekstrema wektorów losowych — włączenie modelowania wzajemnych zależności. Także kopuły ekstremalne (książka QRM).

- Mocno upraszczaliśmy! Co na przykład w sytuacji, gdy założenie o niezależności jest trudne do utrzymania? Są dostępne uogólnienia:
  - procesy stacjonarne
  - pewne procesy niestacjonarne, model sezonowy
  - procesy punktowe
- Ekstrema wektorów losowych — włączenie modelowania wzajemnych zależności. Także kopuły ekstremalne (książka QRM).
- Metody bayesowskie.

- Mocno upraszczaliśmy! Co na przykład w sytuacji, gdy założenie o niezależności jest trudne do utrzymania? Są dostępne uogólnienia:
  - procesy stacjonarne
  - pewne procesy niestacjonarne, model sezonowy
  - procesy punktowe
- Ekstrema wektorów losowych — włączenie modelowania wzajemnych zależności. Także kopuły ekstremalne (książka QRM).
- Metody bayesowskie.
- Mało danych? Bootstrap? (To trochę moja fantazja, ale chyba widziałem gdzieś już takie prace.)

## A dalej jest nieskończoność. . .

- Mocno upraszczaliśmy! Co na przykład w sytuacji, gdy założenie o niezależności jest trudne do utrzymania? Są dostępne uogólnienia:
  - procesy stacjonarne
  - pewne procesy niestacjonarne, model sezonowy
  - procesy punktowe
- Ekstrema wektorów losowych — włączenie modelowania wzajemnych zależności. Także kopuły ekstremalne (książka QRM).
- Metody bayesowskie.
- Mało danych? Bootstrap? (To trochę moja fantazja, ale chyba widziałem gdzieś już takie prace.)
- . . .



- [https://en.wikipedia.org/wiki/Extreme\\_value\\_theory](https://en.wikipedia.org/wiki/Extreme_value_theory)
- Coles S. *An Introduction to Statistical Modeling of Extreme Values*. Springer, London 2001  
Dobrze napisana, wyważone proporcje teorii i praktycznych przykładów z różnych dziedzin.
- Alexander J. McNeil, Rudiger Frey, Paul Embrechts, *Quantitative Risk Management. Concepts, Techniques and Tools*. Princeton University Press 2005  
Biblia w dziedzinie zarządzania ryzykiem w finansach. Jest tam rozdział o EVT.
- Embrechts P., Klüppelberg C. and Mikosch T. *Modelling extremal events for insurance and finance*. Springer Berlin 1997  
Teoretyczne, czyli są tam wszystkie dowody, chyba...
- Ciekawy artykuł, który zwrócił moją uwagę:  
Coles S., Pericchi L., *Anticipating Catastrophies Through Extreme Value Modeling*, Journal of the Royal Statistical Society: Series C (Applied Statistics), Vol. 52.4 2003.