

## Credit Metrics

Wurde bei J.P.Morgan entwickelt.

Wird in erster Linie für die Evaluierung von Bond Portfolios verwendet. (Siehe Crouhy et al. (2000), J.P.Morgan Inc. (1997))

Basiert auf ein Bonität-Einstufungssystem (zB. von *Moody* oder von *Standard and Poor's*).

Berücksichtigt die Veränderungen im PF-Wert aufgrund von Veränderungen in den Bonität-Einstufungen.

Sei  $P$  ein Portfolio von  $n$  Krediten mit einer fixen Laufzeit (zB. 1 Jahr). Sei  $S_i$  der Zustand-Indikator von Kreditnehmer  $i$ .

Die möglichen Zustände werden mit  $0, 1, \dots, m$  bezeichnet, wobei  $S_i = 0$  der Zahlungsunfähigkeit entspricht.

### **Beispiel 1** *Einstufungssystem von Standard and Poor's*

$m = 7$ ;  $S_i = 0$  heißt Zahlungsunfähigkeit;  $S_i = 1$  oder *CCC*;  $S_i = 2$  oder *B*;  $S_i = 3$  oder *BB*;  $S_i = 4$  oder *BBB*;  $S_i = 5$  oder *A*;  $S_i = 6$  oder *AA*;  $S_i = 7$  oder *AAA*.

Für jeden Kreditnehmer wird die Dynamik der Bonität-Einstufungen mit Hilfe einer Markov Kette mit Zustandsmenge  $\{0, 1, \dots, m\}$  und Übergangsmatrix  $P$  modelliert.

Die Übergangswahrscheinlichkeiten werden mit Hilfe von historischen Daten geschätzt, zB.:

Ursprüngliche Einstufung	Einstufung am Ende des Jahres							Zahlungs- unfähigkeit
	AAA	AA	A	BBB	BB	B	CCC	
AAA	90.81	8.33	0.68	0.06	0.12	0	0	0
AA	0.70	90.65	7.79	0.64	0.06	0.14	0.02	0
A	0.09	2.27	91.05	5.52	0.74	0.26	0.01	0.06
BBB	0.02	0.33	5.95	86.93	5.30	1.17	0.12	0.18
BB	0.03	0.14	0.67	7.73	80.53	8.84	1.00	1.06
B	0	0.11	0.24	0.43	6.48	83.46	4.07	5.20
CCC	0.22	0	0.22	1.30	2.38	11.24	64.86	19.79

### Recovery Rates

Im Fall einer Zahlungsunfähigkeit hängt die recovery rate von der Einstufung des Kreditnehmers ab. Der Durchschnittswert und die Standardabweichung der recovery rate werden aufgrund von historischen Daten innerhalb jeder Einstufungsklasse geschätzt.

## Evaluierung der Bonds im Falle einer Neu-Einstufung

**Beispiel 2** Betrachten wir ein BBB Bond mit Laufzeit 5 Jahre.

Er zahlt jedes Jahr ein Kupon von 6%.

Die forward Zinsstrukturkurven (forward yield curves) für jede Einstufungsklasse sind wie folgt gegeben (in %):

Einstufung	1. Jahr	2. Jahr	3. Jahr	4. Jahr
AAA	3.60	4.17	4.73	5.12
AA	3.65	4.22	4.78	5.17
A	3.73	4.32	4.93	5.32
BBB	4.10	4.67	5.25	5.63
BB	6.05	7.02	8.03	8.52
CCC	15.05	15.02	14.03	13.52

Für ein Nennwert von 100 zahlt der Bond 6 Währungseinheiten am Ende des 1., 2., 3. und 4. Jahres. Am Ende des 5. Jahres zahlt der Bond 106 Währungseinheiten.

Annahme: Am Ende des ersten Jahres wird der Bond neu als A Bond eingestuft. Wert des Bonds am Ende des ersten Jahres:

$$V = 6 + \frac{6}{1+3,73\%} + \frac{6}{(1+4,32\%)^2} + \frac{6}{(1+4,93\%)^3} + \frac{106}{(1+5,32\%)^4} = 108.64$$

Analog wird der Wert des Bonds am Ende des 1. Jahres ermittelt, falls er zu diesem Zeitpunkt zu anderen Klassen eingestuft wird.

Es wird eine recovery rate von 51.13% im Falle von Zahlungsunfähigkeit angenommen.

Einstufung am Ende des 1. Jahres	Wert
AAA	109.35
AA	109.17
A	108.64
BBB	107.53
BB	102.01
B	98.09
CCC	83.63
Zahlungsunfähigkeit	51.13

## Wert und Risiko eines Bond-Portfolios in Credit Metrics

Die Abhängigkeit der Neueinstufungen unterschiedlicher Bonds und die Wahrscheinlichkeiten von Neueinstufungen von Gruppen von Bonds werden mit Hilfe der dazugehörigen Rendite berechnet.

Die Rendite von Bond  $i$  wird als Normalverteilung  $Y_i$  modelliert.

Seien  $d_{Def}, d_{CCC}, \dots, d_{AAA} = +\infty$  Schwellwerte, sodass für ein Kreditnehmer die Wahrscheinlichkeit des Übergangs in einer neuen Stufe  $S_i$  am Ende einer vordefinierten Periode folgendermaßen gegeben sind:  $P(S_i = 0) = \phi(d_{Def})$ ,  $P(S_i = CCC) = \phi(d_{CCC}) - \phi(d_{Def})$ ,  $\dots$ ,  $P(S_i = AAA) = 1 - \phi(d_{AAA})$ .

Die Rendite mehrerer Bonds werden mit Hilfe der multivariaten Normalverteilung modelliert.

Die Korrelationsmatrix dieser Verteilung wird in Credit Metrics mit Hilfe von Faktormodellen berechnet.

Dann können Gesamtwahrscheinlichkeiten wie

$$P(S_1 = 0, \dots, S_n = 3) = P(Y_1 \leq d_{Def}, \dots, d_B < Y_n \leq d_{BB})$$

berechnet werden. Als Modell für die Abhängigkeitsstruktur des Vektors  $(Y_1, Y_2, \dots, Y_n)$  wird die Gauss'sche Copula(!) verwendet.

Die Risikomasse eines Kreditportfolios werden mit Hilfe von Simulationen berechnet. Es werden viele Szenarien generiert, aufgrund derer der empirische VaR ermittelt wird.

## Die Bernoulli gemischte Verteilung

Der 0-1 Zufallsvektor  $X = (X_1, \dots, X_n)^T$  hat eine Bernoulli gemischte Verteilung (BMV) wenn es einen Zufallsvektor  $Z = (Z_1, Z_2, \dots, Z_m)^T$ ,  $m < n$ , und Funktionen  $f_i: \mathbb{R}^m \rightarrow [0, 1]$ ,  $i = 1, 2, \dots, n$ , gibt, sodass  $X$  bedingt durch  $Z$  ein Vektor von unabhängigen Bernoulli verteilten Zufallsvariablen ist und

$$P(X_i = 1|Z) = f_i(Z) , P(X_i = 0) = 1 - f_i(Z)$$

Für  $x = (x_1, \dots, x_n)^T \in \{0, 1\}^n$  gilt

$$P(X = x|Z) = \prod_{i=1}^n f_i(Z)^{x_i} (1 - f_i(Z))^{1-x_i}$$

Die unbedingte Verteilung:

$$P(X = x) = E(P(X = x|Z)) = E\left(\prod_{i=1}^n f_i(Z)^{x_i} (1 - f_i(Z))^{1-x_i}\right)$$

Annahme: alle Funktionen  $f_i$  sind identisch,  $f_i = f$ . Für die Anzahl der Zahlungsunfähigkeitsfällen  $N = \sum_{i=1}^n X_i$  gilt  $N|Z \sim \text{Binomial}(n, f(Z))$ .

## Die Poisson gemischte Verteilung

Der diskrete Zufallsvektor  $X = (X_1, \dots, X_n)^T$  hat eine Poisson gemischte Verteilung (PMV) wenn es einen Zufallsvektor  $Z = (Z_1, Z_2, \dots, Z_m)^T$ ,  $m < n$ , und Funktionen  $\lambda_i: \mathbb{R}^m \rightarrow (0, \infty)$ ,  $i = 1, 2, \dots, n$ , gibt, sodass  $X$  bedingt durch  $Z$  ein Vektor von unabhängigen Poisson verteilten Zufallsvariablen ist und

$$P(X_i = x_i | Z) = \frac{\lambda_i(Z)^{x_i}}{x_i!} e^{-\lambda_i(Z)} \text{ für } x_i \in \mathbb{N} \cup \{0\}$$

Für  $x = (x_1, \dots, x_n)^T \in (\mathbb{N} \cup \{0\})^n$  gilt

$$P(X = x | Z) = \prod_{i=1}^n \frac{\lambda_i(Z)^{x_i}}{x_i!} e^{-\lambda_i(Z)}$$

Die unbedingte Verteilung:

$$P(X = x) = E(P(X = x | Z)) = E\left(\prod_{i=1}^n \frac{\lambda_i(Z)^{x_i}}{x_i!} e^{-\lambda_i(Z)}\right)$$

Annahme:  $\tilde{X} = (\tilde{X}_1, \dots, \tilde{X}_n)^T$  ist PMV mit Faktoren  $Z$ .

Sei  $X_i = I_{[1, \infty)}(\tilde{X}_i)$ .  $X = (X_1, \dots, X_n)$  ist BMV mit  $f_i(Z) = 1 - e^{-\lambda_i(Z)}$

Für  $\lambda_i(Z)$  klein gilt  $\tilde{N} = \sum_{i=1}^n \tilde{X}_i \approx \sum_{i=1}^n X_i$ .

$\tilde{N} | Z \sim \text{Poisson}(\bar{\lambda}(Z))$  wobei  $\bar{\lambda} = \sum_{i=1}^n \lambda_i(Z)$ .

## Beispiele von Bernoulli gemischten Verteilungen

Annahmen:

- $Z$  ist univariat (d.h. es gibt einen Risikofaktor)
- $f_i = f$  für alle  $i$

Es gilt:  $P(X_i = 1|Z) = f(Z)$ ,  $\forall i$ ;  $N|Z = \sum_{i=1}^n X_i \sim \text{Binomial}(n, f(Z))$ .

Die unbedingte Wahrscheinlichkeit, dass die ersten  $k$  Kreditnehmer zahlungsunfähig werden

$$P(X_1 = 1, \dots, X_k = 1, X_{k+1} = 0, \dots, X_n = 0) =$$

$$E(P(X_1 = 1, \dots, X_k = 1, X_{k+1} = 0, \dots, X_n = 0|Z)) = E(f(Z)^k(1-f(Z))^{n-k})$$

Sei  $G$  die Verteilungsfunktion von  $Z$ . Dann gilt:

$$P(X_1 = 1, \dots, X_k = 1, X_{k+1} = 0, \dots, X_n = 0) = \int_{-\infty}^{\infty} f(z)^k(1-f(z))^{n-k}d(G(z))$$

Die Verteilung der Anzahl  $N$  der Zahlungsunfähigen Kreditnehmer :

$$P(N = k) = \binom{n}{k} \int_{-\infty}^{\infty} f(z)^k(1-f(z))^{n-k}d(G(z))$$



## Die Beta-gemischte Verteilung

Es gilt  $Z \sim \text{Beta}(a, b)$  und  $f(z) = z$ .

Die Dichte  $g$  von  $Z$ :  $g(z) = \frac{1}{\beta(a, b)} z^{a-1} (1-z)^{b-1}$ , für  $a, b > 0$ ,  $z \in (0, 1)$   
wobei  $\beta(a, b) = \int_0^1 z^{a-1} (1-z)^{b-1} dz$  die Euler'sche Betafunktion ist.

Verteilung der Anzahl der zahlungsunfähigen Kreditnehmer:

$$\begin{aligned} P(N = k) &= \binom{n}{k} \int_0^1 z^k (1-z)^{n-k} g(z) dz = \\ &= \binom{n}{k} \frac{1}{\beta(a, b)} \int_0^1 z^{a+k-1} (1-z)^{n-k+b-1} dz = \\ &= \binom{n}{k} \frac{\beta(a+k, b+n-k)}{\beta(a, b)} \quad \text{beta-binomial Verteilung} \end{aligned}$$

### Probit-normal Mischung

$Z \sim N(0, 1)$ ,  $f(z) = \phi(\mu + \sigma z)$ ,  $\mu \in \mathbb{R}$ ,  $\sigma > 0$  und  $\phi$  ist die Standard Normalverteilungsfunktion.

### Logit-normal Mischung

$Z \sim N(0, 1)$ ,  $f(z) = (1 + \exp\{\mu + \sigma z\})^{-1}$ ,  $\mu \in \mathbb{R}$ ,  $\sigma > 0$ .

## CreditRisk<sup>+</sup> - Ein Poisson gemischtes Modell

(Entwickelt von CSFB in 1997, siehe Crouhy et al. (2000) und [http://www.credit\\_suisse.com/investment\\_banking/research/en/credit\\_risk.jsp](http://www.credit_suisse.com/investment_banking/research/en/credit_risk.jsp))

$m$  unabhängige Risikofaktoren  $Z_1, Z_2, \dots, Z_m$ ,  $Z_j \sim \Gamma(\alpha_j, \beta_j)$ ,  
 $j = 1, 2, \dots, m$ , sodass  $E(Z_j) = 1$ .

$$\lambda_i(Z) = \bar{\lambda}_i \sum_{j=1}^m a_{ij} Z_j, \quad \sum_{j=1}^m a_{ij} = 1 \quad \text{für } i = 1, 2, \dots, n.$$

$\bar{\lambda}_i > 0$ ,  $\alpha_j, \beta_j$  sind Konstante.  $\alpha_j, \beta_j$  werden meistens so gewählt, dass  $E(\lambda_i(Z)) = \bar{\lambda}_i > 0$  gilt.

Die Dichte von  $Z_j$  ist folgendermassen gegeben:  $f_j(z) = \frac{z^{\alpha_j-1} \exp\{-z/\beta_j\}}{\beta_j^{\alpha_j} \Gamma(\alpha_j)}$

Verlust bei Kredit  $i$  durch Zahlungsunfähigkeit von Kreditnehmer  $i$ :  
 $LGD_i = (1 - \lambda_i)L_i$ ,  $1 \leq i \leq n$ , wobei  $\lambda_i$  die erwartete deterministische 'Recovery rate' ist und  $L_i$  die Höhe von Kredit  $i$  ist.

Das Ziel ist, die Verlustverteilung durch eine diskrete Verteilung zu approximieren und für diese die Erzeugende Funktion zu ermitteln.

Sei  $Y$  eine diskrete ZV mit Wertebereich  $\{y_1, \dots, y_m\}$  oder eine kontinuierliche ZV mit Dichtefunktion  $f(y)$  in  $\mathbb{R}$

**Definition 1** Die erzeugende Funktion von  $Y$  ist definiert als  $g_Y(t) := E(t^Y) = \sum_{i=1}^m t^{y_i} P(Y = y_i)$  bzw.  $g_Y(t) := \int_{-\infty}^{\infty} t^y f(y) dy$  für  $t \in [0, 1]$ .

### Einige Eigenschaften der erzeugenden Funktionen:

- (i) Wenn  $Y \sim \text{Bernoulli}(p)$  dann  $g_Y(t) = 1 + p(t - 1)$ .
- (ii) Wenn  $Y \sim \text{Poisson}(\lambda)$ , dann  $g_Y(t) = \exp\{\lambda(t - 1)\}$ .
- (iii) Für unabhängige Zufallsvariablen  $X_1, \dots, X_n$  gilt

$$g_{X_1 + \dots + X_n}(t) = \prod_{i=1}^n g_{X_i}(t).$$

- (iv) Sei  $Y$  eine Zufallsvariable mit Dichtefunktion  $f$  und sei  $g_{X|Y=y}(t)$  die erzeugende Funktion von  $X|Y = y$ . Dann gilt

$$g_X(t) = \int_{-\infty}^{\infty} g_{X|Y=y}(t) f(y) dy.$$

(v) Sei  $g_X(t)$  die erzeugende Funktion von  $X$ . Dann gilt

$$P(X = k) = \frac{1}{k!} g_X^{(k)}(0) \text{ wobei } g_X^{(k)}(t) = \frac{d^k g_X}{dt^k}.$$

## Die Erzeugende Funktion der Verlustverteilung

Jeder Verlust wird als ganzzahliges Vielfaches einer vordefinierten Verlusteinheit  $L_0$  (zB.  $L_0 = 10^6$  Euro):

$$LGD_i = (1 - \lambda_i)L_i \approx \left[ \frac{(1 - \lambda_i)L_i}{L_0} \right] L_0 = v_i L_0 \text{ mit } v_i := \left[ \frac{(1 - \lambda_i)L_i}{L_0} \right]$$

wobei  $[x] = \arg \min_t \{|t - x| : t \in \mathbb{Z}, t - x \in (-1/2, 1/2]\}$ .

Die Verlustfunktion:  $L = \sum_{i=1}^n X_i v_i L_0$ .

(a) Ermittlung der erzeugenden Funktion für  $N = X_1 + \dots + X_n$   
 $X_i|Z \sim \text{Poisson}(\lambda_i(Z)), \forall i \implies g_{X_i|Z}(t) = \exp\{\lambda_i(Z)(t - 1)\}, \forall i \implies$

$$g_{N|Z}(t) = \prod_{i=1}^n g_{X_i|Z}(t) = \prod_{i=1}^n \exp\{\lambda_i(Z)(t - 1)\} = \exp\{\mu(t - 1)\}, \quad (5)$$

$$\text{mit } \mu := \sum_{i=1}^n \lambda_i(Z) = \sum_{i=1}^n (\bar{\lambda}_i \sum_{j=1}^m a_{ij} Z_j).$$

$$\begin{aligned} g_N(t) &= \int_0^\infty \dots \int_0^\infty g_{N|Z=(z_1, z_2, \dots, z_m)} f_1(z_1) \dots f_m(z_m) dz_1 \dots dz_m = \\ &= \int_0^\infty \dots \int_0^\infty \exp \left\{ \sum_{i=1}^n \left( \bar{\lambda}_i \sum_{j=1}^m a_{ij} z_j \right) (t - 1) \right\} f_1(z_1) \dots f_m(z_m) dz_1 \dots dz_m = \end{aligned}$$

$$\int_0^\infty \dots \int_0^\infty \exp \left\{ (t-1) \sum_{j=1}^m \left( \underbrace{\sum_{i=1}^n \bar{\lambda}_i a_{ij}}_{\mu_j} \right) z_j \right\} f_1(z_1) \dots f_m(z_m) dz_1 \dots dz_m =$$

$$\int_0^\infty \dots \int_0^\infty \exp\{(t-1)\mu_1 z_1\} f_1(z_1) dz_1 \dots \exp\{(t-1)\mu_m z_m\} f_m(z_m) dz_m =$$

$$\prod_{j=1}^m \int_0^\infty \exp\{z_j \mu_j (t-1)\} \frac{1}{\beta_j^{\alpha_j} \Gamma(\alpha_j)} z_j^{\alpha_j-1} \exp\{-z_j/\beta_j\} dz_j \quad (6)$$

Die Berechnung der einzelnen Integrale in (6) ergibt:

$$\int_0^\infty \frac{1}{\Gamma(\alpha_j) \beta_j^{\alpha_j}} \exp\{z_j \mu_j (t-1)\} z_j^{\alpha_j-1} \exp\{-z_j/\beta_j\} dz_j = \left( \frac{1 - \delta_j}{1 - \delta_j t} \right)^{\alpha_j}$$

$$\delta_j = \beta_j \mu_j / (1 + \beta_j \mu_j). \quad (7)$$

Es gilt also  $g_N(t) = \prod_{j=1}^m \left( \frac{1 - \delta_j}{1 - \delta_j t} \right)^{\alpha_j}$ .

(b) Ermittlung der erzeugenden Funktion für  $L = \sum_{i=1}^n X_i v_i L_0$ .

Bedingter Verlust aufgrund Zahlungsunfähigkeit von Kreditnehmer  $i$ :

$L_i|Z = v_i(X_i|Z)$ ;  $L_i|Z$  unabhängig für  $i = 1, 2, \dots, n$ .

$$g_{L_i|Z}(t) = E(t^{L_i}|Z) = E(t^{v_i X_i}|Z) = g_{X_i|Z}(t^{v_i}).$$

Die erzeugende Funktion des gesamten Verlusts bedingt durch  $Z$ :

$$g_{L|Z}(t) = g_{L_1+L_2+\dots+L_n|Z}(t) = \prod_{i=1}^n g_{L_i|Z}(t) = \prod_{i=1}^n g_{X_i|Z}(t^{v_i}) = \exp \left\{ \sum_{j=1}^m Z_j \left( \sum_{i=1}^n \bar{\lambda}_i a_{ij} (t^{v_i} - 1) \right) \right\}.$$

Ähnlich wie bei der Berechnung von  $g_N(t)$  erhalten wir:

$$g_L(t) = \prod_{j=1}^m \left( \frac{1 - \delta_j}{1 - \delta_j \Lambda_j(t)} \right)^{\alpha_j} \quad \text{wobei } \Lambda_j(t) = \frac{1}{\mu_j} \sum_{i=1}^n \bar{\lambda}_i a_{ij} t^{v_i}.$$

$\delta_j$  und  $\mu_j$  sind wie in (7) bzw. (5) gegeben.

**Beispiel 3** Kreditportfolio mit  $n = 100$  Krediten, Anzahl der Risikofaktoren  $m = 1$  oder  $m = 5$ ,  $\bar{\lambda}_i = \bar{\lambda} = 0.15$ , für  $i = 1, 2, \dots, n$ ,  $\alpha_j = \alpha = 1$ ,  $\beta_j = \beta = 1$ ,  $a_{i,j} = 1/m$ ,  $i = 1, 2, \dots, n$ ,  $j = 1, 2, \dots, m$

$$P(N = k) = \frac{1}{k!} g_N^{(k)}(0) = \frac{1}{k!} \frac{d^k g_N}{dt^k}.$$

Für die Berechnung von  $P(N = k)$ ,  $k = 0, 1, \dots, 100$ , kann folgende rekursive Formel verwendet werden:

$$g_N^{(k)}(0) = \sum_{l=0}^{k-1} \binom{k-1}{l} g_N^{(k-1-l)}(0) \sum_{j=1}^m l! \alpha_j \delta_j^{l+1}, \quad k > 1$$



## Monte Carlo Methoden in Kreditrisiko-Management

$P$  Kreditportfolio bestehend aus  $m$  Krediten;

Verlustfunktion  $L = \sum_{i=1}^n L_i$ ; Die Verluste  $L_i$  sind unabhängig bedingt durch einen Vektor  $Z$  von ökonomischen Einflussfaktoren.

Gesucht:

$$VaR_\alpha(L) = q_\alpha(L), CVaR_\alpha = E(L|L > q_\alpha(L)), CVaR_{i,\alpha} = E(L_i|L > q_\alpha(L)).$$

Bei Anwendung von Monte Carlo (MC) Simulation tritt das Problem der Simulation von seltenen Ereignissen auf ("rare event simulation")!

ZB.  $\alpha = 0,99$ . Nur etwas 1% der standard MC Simulationen führt zu einem Verlust  $L$ , sodass  $L > q_\alpha(L)$ .

Standard MC Schätzer:

$$\widehat{CVaR}_\alpha^{(MC)}(L) = \frac{1}{\sum_{i=1}^n I_{(q_\alpha, +\infty)}(L_i)} \sum_{i=1}^n L_i I_{(q_\alpha, +\infty)}(L_i)$$

wobei  $L_i$  der Verlustwert in der  $i$ -ten Simulationslauf ist.

$\widehat{CVaR}_\alpha^{(MC)}(L)$  ist sehr instabil, d.h. hat eine sehr hohe Varianz, wenn die Anzahl der Simulationen  $n$  nicht sehr sehr groß ist.

## Grundlagen von “Importance Sampling”

Sei  $X$  eine ZV in einem Wahrscheinlichkeitsraum  $(\Omega, \mathcal{F}, P)$  mit absolut stetiger Verteilungsfunktion und Dichtefunktion  $f$ .

Gesucht:  $\theta = E(h(X)) = \int_{-\infty}^{\infty} h(x)f(x)dx$  für eine bekannte Funktion  $h$ .

Berechnung der Wahrscheinlichkeit eines Ereignisses  $A$ :  $h(x) = I_A(x)$ .

Berechnung von CVaR:  $h(x) = xI_{x>c}(x)$  mit  $c = VaR(X)$ .

### Algorithmus 1 (Monte Carlo Integration)

(1) Generiere  $X_1, X_2, \dots, X_n$  unabhängig aus der Dichte  $f$ .

(2) Berechne den standard MC Schätzer  $\hat{\theta}_n^{(MC)} = \frac{1}{n} \sum_{i=1}^n h(X_i)$ .

Aus dem starken Gesetz der großen Zahlen:  $\lim_{n \rightarrow \infty} \hat{\theta}_n^{(MC)} = \theta$ .  
Im Falle von *seltenen Ereignissen* ( $h(x) = I_A(x)$ ,  $P(A) \ll 1$ ) ist die Konvergenz sehr langsam.

Sei  $g$  eine Wahrscheinlichkeitsdichte, sodass  $f(x) > 0 \Rightarrow g(x) > 0$ .

Wir definieren das *Likelihood ratio* als:  $r(x) := \begin{cases} \frac{f(x)}{g(x)} & g(x) > 0 \\ 0 & g(x) = 0 \end{cases}$

Es gilt:

$$\theta = \int_{-\infty}^{\infty} h(x)r(x)g(x)dx = E_g(h(x)r(x)) \quad (8)$$

### **Algorithmus 2** (*Importance Sampling*)

(1) Generiere  $X_1, X_2, \dots, X_n$  unabhängig aus der Dichte  $g$ .

(2) Berechne den IS Schätzer  $\hat{\theta}_n^{(IS)} = \frac{1}{n} \sum_{i=1}^n h(X_i)r(X_i)$ .

$g$  heißt "Importance Sampling"-Dichte.

Ziel: Auswahl einer "Importance Sampling"-Dichte, sodass die Varianz des IS-Schätzers wesentlich kleiner als die Varianz des standard MC Schätzers ist.

$$\text{var}_g \left( \hat{\theta}_n^{(IS)} \right) = (1/n)(E_g(h^2(X)r^2(X)) - \theta^2)$$

$$\text{var} \left( \hat{\theta}_n^{(MC)} \right) = (1/n)(E(h^2(X)) - \theta^2)$$

Theoretisch kann die Varianz des IS-Schätzers auf 0 reduziert werden!

Annahme  $h(x) \geq 0, \forall x$ .

Für  $g^*(x) = f(x)h(x)/E(h(x))$  gilt:  $\hat{\theta}_1^{(IS)} = h(X_1)r(X_1) = E(h(X))$ .

Der IS-Schätzer gibt den richtigen Wert nach einer einzigen Simulation!

Sei  $h(x) = I_{\{X \geq c\}}(x)$  wobei  $c \gg E(X)$  (seltenes Ereignis). Es gilt  $E(h^2(X)) = P(X \geq c)$  und aus (8) folgt:

$$E_g(h^2(X)r^2(X)) = \int_{-\infty}^{\infty} h^2(x)r^2(x)g(x)dx = E_g(r^2(X); X \geq c) = \quad (9)$$

$$\int_{-\infty}^{\infty} h^2(x)r(x)f(x)dx = \int_{-\infty}^{\infty} h(x)r(x)f(x)dx = E(r(X); X \geq c) \quad (10)$$

Das Ziel ist  $g$  so auszuwählen, dass  $E_g(h^2(X)r^2(X))$  klein wird, oder sodass  $r(x)$  für  $x \geq c$  klein und das Ereignis  $X \geq c$  unter der Dichte  $g$  wahrscheinlicher als unter der Dichte  $f$  ist.

## Exponential tilting: Bestimmung des IS-Dichte für “light tailed” Variablen

Sei  $M_X(t): \mathbb{R} \rightarrow \mathbb{R}$  die Momentum-generierende Funktion von  $X$ :

$$M_X(t) = E(e^{tX}) = \int_{-\infty}^{\infty} e^{tx} f(x) dx$$

IS-Dichte:  $g_t(x) = \frac{e^{tx} f(x)}{M_X(t)}$

Likelihood Ratio:  $r_t(x) = \frac{f(x)}{g_t(x)} = M_X(t) e^{-tx}$ .

Sei  $\mu_t = E_{g_t}(X) = E(X \exp\{tX\}) / M_X(t)$ .

Wie kann man ein geeignetes  $t$  für ein bestimmtes IS Problem ermitteln?

Z.B. für die Schätzung der Tail-Wahrscheinlichkeit?

Das Ziel ist  $t$  so zu wählen, dass  $E(r(X); X \geq c) = E(I_{X \geq c} M_X(t) e^{-tX})$  klein wird.

$$e^{-tx} \leq e^{-tc}, \text{ für } x \geq c, t \geq 0 \Rightarrow E(I_{X \geq c} M_X(t) e^{-tX}) \leq M_X(t) e^{-tc}.$$

Wir setzen  $t = \operatorname{argmin}\{M_X(t) e^{-tc} : t \geq 0\}$ .

Daraus folgt  $t = t(c)$  wobei  $t(c)$  die Lösung der Gleichung  $\mu_t = c$  ist.

(Eine eindeutige Lösung existiert für alle relevanten Werte von  $c$  - ohne Beweis).

## Exponential Tilting für die Normalverteilung

Sei  $X \sim N(0, 1)$  mit Dichtefunktion  $\phi(x)$ .

$$g_t(x) = \frac{e^{tx}\phi(x)}{M_X(t)} = \frac{e^{tx}\phi(x)}{e^{t^2/2}} = \frac{1}{\sqrt{2\pi}} \exp\left\{-\frac{1}{2}(x-t)^2\right\} \text{ und } \mu_t = \frac{E(X \exp\{tX\})}{M_X(t)} = t$$

D.h. unter der Verteilung  $g_t$  gilt  $X \sim N(t, 1)$

Die Gleichung  $\mu_t = c$  lautet  $t = c$ .

## IS im Falle von Wahrscheinlichkeitsmaßen

Seien  $f$  und  $g$  Wahrscheinlichkeitsdichten. Definiere zwei Wahrscheinlichkeitsmasse  $P$  und  $Q$ :

$$P(A) = \int_{x \in A} f(x) dx \text{ und } Q(A) = \int_{x \in A} g(x) dx$$

Die grundlegende Gleichung der IS (8) lautet dann:

$$\theta = E^P(h(X)) = E^Q(h(X)r(X))$$

Analog: Exponential tilting im Fall von Wahrscheinlichkeitsdichten:

Sei  $X$  eine ZV in  $(\Omega, \mathcal{F}, P)$  sodass  $M_X(t) = E^P(\exp\{tX\}) < \infty, \forall t$ .

Sei  $Q_t(A) := E^P\left(\frac{\exp\{tX\}}{M_X(t)}; A\right)$  ein Wahrscheinlichkeitsmaß in  $(\Omega, \mathcal{F})$ .

Der IS-Algorithmus bleibt gleich:

Simuliere unabhängige Realisierungen von  $X_i$  in  $(\Omega, \mathcal{F}, Q_t)$  und setze

$$\hat{\theta}_n^{(IS)} = (1/n) \sum_{i=1}^n X_i r_t(X_i) \text{ wobei } r_t(X) = M_X(t) \exp\{-tX\}.$$

## Anwendung von IS auf Bernoulli Mischung Modelle

(siehe Glasserman und Li (2003))

Sei  $L = \sum_{i=1}^m e_i Y_i$  die Verlustfunktion eines Kreditportfolios.

$Y_i$  sind die Verlustindikatoren mit Default-Wahrscheinlichkeit  $\bar{p}_i$  und  $e_i = (1 - \lambda_i)L_i$  die positiven deterministischen *Exposures* ( $\lambda_i$  sind recovery rates und  $L_i$  sind die Kredithöhen),  $i = 1, 2, \dots, m$ .

Sei  $Z$  ein Vektor von ökonomischen Einflussfaktoren, sodass  $Y_i|Z$  unabhängig sind und  $Y_i|(Z = z) \sim \text{Bernoulli}(p_i(z))$ .

Ziel: Schätzung von  $\theta = P(L \geq c)$  mit Hilfe des IS-Ansatzes, für ein gegebenes  $c$ ,  $c \gg E(L)$ .

**Vereinfachter Fall:**  $Y_i$  sind unabhängig,  $i = 1, 2, \dots, m$ .

Sei  $\Omega = \{0, 1\}^m$  der Raum der Zustände von  $Y$ .

Das Wahrscheinlichkeitsmaß  $P$  in  $\Omega$ :

$$P(\{y\}) = \prod_{i=1}^m \bar{p}_i^{y_i} (1 - \bar{p}_i)^{1-y_i}, \quad y \in \{0, 1\}^m.$$

Die Momentum-generierende Funktion von  $L$ :  $M_L(t) = \prod_{i=1}^m (e^{te_i \bar{p}_i} + 1 - \bar{p}_i)$ .

Das Wahrscheinlichkeitsmaß  $Q_t$ :

$$Q_t(\{y\}) = \prod_{i=1}^n \left( \frac{\exp\{te_i y_i\}}{\exp\{te_i\} \bar{p}_i + 1 - \bar{p}_i} \bar{p}_i^{y_i} (1 - \bar{p}_i)^{1-y_i} \right).$$

Seien  $\bar{q}_{t,i}$  neue Default-Wahrscheinlichkeiten:

$$\bar{q}_{t,i} := \exp\{te_i\} \bar{p}_i / (\exp\{te_i\} \bar{p}_i + 1 - \bar{p}_i).$$

Somit gilt:

$$Q_t(\{y\}) = \prod_{i=1}^m \bar{q}_i^{y_i} (1 - \bar{q}_i)^{1-y_i}, \quad y \in \{0, 1\}^m.$$

D.h. nach der exponential tilting sind die Default-Indikatoren unabhängig mit neuen Default-Wahrscheinlichkeiten  $\bar{q}_{t,i}$ .

$\lim_{t \rightarrow \infty} \bar{q}_{t,i} = 1$  und  $\lim_{t \rightarrow -\infty} \bar{q}_{t,i} = 0 \Rightarrow$   
 $E^{Q_t}(L)$  nimmt alle Werte in  $(0, \sum_{i=1}^m e_i)$  an für  $t \in \mathbb{R}$ .

Für IS-Anwendungen wähle  $t$ , sodass  $\sum_{i=1}^m e_i \bar{q}_{t,i} = c$ .

**Allgemeiner Fall:**  $Y_i$  sind unabhängig bedingt durch  $Z$

1. Schritt: Schätzung der bedingten Überschuss-Wahrscheinlichkeit  $\theta(z) := P(L \geq c | Z = z)$  für eine gegebene Realisierung  $z$  der ökonomischen Faktoren  $Z$ , mit Hilfe des im vereinfachten Fall beschriebenen IS-Ansatzes.



### Algorithmus 3 (IS für die bedingte Verlustverteilung)

- (1) Für ein gegebenes  $z$  berechne die bedingten Default-Wahrscheinlichkeiten  $p_i(z)$  (wie im einfachen Unabhängigkeitsfall) und löse folgende Gleichung:

$$\sum_{i=1}^m \frac{\exp\{te_i\}p_i(z)}{\exp\{te_i\}p_i(z) + 1 - p_i(z)} = c$$

Die Lösung  $t = t(c, z)$  gibt den richtigen tilting-Grad.

- (2) Erzeuge  $n_1$  bedingte Realisierungen des Vektors der Default-Indikatoren  $(Y_1, \dots, Y_m)$ . Die einzelnen Indikatoren  $Y_i$ , werden unabhängig aus  $\text{Bernoulli}(q_i)$ ,  $i = 1, 2, \dots, m$ , simuliert, wobei

$$q_i = \frac{\exp\{t(c, z)e_i\}p_i(z)}{\exp\{t(c, z)e_i\}p_i(z) + 1 - p_i(z)}$$

- (3) Sei  $M_L(t, z) := \prod[\exp\{te_i\}p_i(z) + 1 - p_i(z)]$  die bedingte Momentenerzeugende Funktion von  $L$ . Seien  $L^{(1)}, L^{(2)}, \dots, L^{(n_1)}$  die  $n_1$  bedingten Realisierungen von  $L$  für die  $n_1$  simulierten Realisierungen

gen von  $Y_1, Y_2, \dots, Y_m$ . Berechne den IS-Schätzer für die Tail-Wahrscheinlichkeit der bedingten Verlustverteilung:

$$\hat{\theta}_{n_1}^{(IS)}(z) = M_L(t(c, z), z) \frac{1}{n_1} \sum_{j=1}^{n_1} I_{L^{(j)} \geq c} \exp\{-t(c, z)L^{(j)}\} L^{(j)}.$$

2. Schritt: Schätzung der unbedingten Überschuss Wahrscheinlichkeit  $\theta = P(L \geq c)$ .

Naive Vorgangsweise: Erzeuge mehrere Realisierungen  $z$  der Einflussfaktoren  $Z$  und berechne  $\hat{\theta}_{n_1}^{(IS)}(z)$  für jede dieser Realisierungen. Der gesuchte Schätzer ist der Durchschnittswert der Schätzer  $\hat{\theta}_{n_1}^{(IS)}(z)$  über alle Realisierungen  $z$ .

Das ist nicht die beste Lösung, siehe Glasserman und Li (2003).

Bessere Herangehensweise: IS für die Einflussfaktoren.

Annahme:  $Z \sim N_p(0, \Sigma)$  (zB. probit-normal Bernoulli Mischung)

Die IS-Dichte  $g$  ist die Dichte von  $N_p(\mu, \Sigma)$  für einen "neuen" Erwartungswertvektor  $\mu \in \mathbb{R}^p$ . Eine gute Wahl von  $\mu$  sollte zu häufigen Realisierungen  $z$  die zu höheren bedingten Default-Wahrscheinlichkeiten  $p_i(z)$  führen.

Likelihood Ratio:

$$r_\mu(Z) = \frac{\exp\{-\frac{1}{2}Z^t \Sigma^{-1} Z\}}{\exp\{-\frac{1}{2}(Z - \mu)^t \Sigma^{-1} (Z - \mu)\}} = \exp\{-\mu' \Sigma^{-1} Z + \frac{1}{2} \mu' \Sigma^{-1} \mu\}$$

**Algorithmus 4** (vollständige IS für Bernoulli Mischung Modelle mit Gauss'schen Faktoren)

- (1) Erzeuge  $z_1, z_2, \dots, z_n \sim N_p(\mu, \Sigma)$  ( $n$  ist die Anzahl der Simulationssrunden)
- (2) Für jedes  $z_i$  berechne  $\hat{\theta}_{n_1}^{(IS)}(z_i)$  wie in Algorithmus 3.
- (3) Berechne den IS-Schätzer für die unbedingte Überschuss-Wahrscheinlichkeit:

$$\hat{\theta}_n^{(IS)} = \frac{1}{n} \sum_{i=1}^n r_{\mu}(z_i) \hat{\theta}_{n_1}^{(IS)}(z_i)$$

## Die Auswahl von $\mu$

$\mu$  soll so gewählt werden, dass die Varianz des Schätzers klein ist.

Idee von Glasserman und Li (2003) (Skizze):

$$\hat{\theta}_{n_1}^{(IS)}(z) \approx P(L \geq c | Z = z) \Rightarrow$$

Suche eine gute IS-Dichte für die Funktion  $z \mapsto P(L \geq c | Z = z)$ .

Die optimale IS-Dichte  $g^*$  ist proportional zu

$$P(L \geq c | Z = z) \exp\left\{-\frac{1}{2}z^t \Sigma^{-1} z\right\}.$$

Vorschlag: Wähle eine IS-Dichte mit demselben Modus wie die optimale Dichte  $g^*$ .

Das führt zu folgendem Optimierungsproblem:

$$\mu = \operatorname{argmax}_z \left\{ P(L \geq c | Z = z) \exp\left\{-\frac{1}{2}z^t \Sigma^{-1} z\right\} \right\}.$$

Exakte Lösung ist schwierig weil  $P(L \geq c | Z = z)$  ist i.a. nicht in analytischer Form verfügbar.

Siehe Glasserman und Li (2003) für Lösungsansätze.