

Estadística Bayesiana y Riesgos

Manuel Mendoza Ramírez
Instituto Tecnológico Autónomo de México

Seminario Aleatorio. Contribuciones Recientes de la Estadística a la Actuaría en México.
ITAM. México, D.F. Noviembre 23, 2007.

Estadística Bayesiana y Solvencia

Manuel Mendoza Ramírez
Instituto Tecnológico Autónomo de México

Seminario Aleatorio. Contribuciones Recientes de la Estadística a la Actuaría en México.
ITAM. México, D.F. Noviembre 23, 2007.

Contenido

- ▶ Introducción
- ▶ Condición de solvencia
- ▶ Formulación estadística
- ▶ Alternativa Bayesiana
- ▶ Ejemplos
- ▶ Consideraciones finales

Introducción


Actuaría y Riesgos Financieros

- ▶ La incertidumbre está implícita y es inevitable en el origen de las Ciencias Actuariales
- ▶ Una parte de la Actuaría se ocupa del estudio de los fenómenos (aleatorios) que pueden producir las llamadas pérdidas contingentes
- ▶ La información disponible se utiliza para pronosticar el comportamiento futuro de las pérdidas

Introducción

Modelos


- ▶ Una componente fundamental es la distribución de pérdidas



Introducción

Modelos


- ▶ Una componente fundamental es la distribución de pérdidas




Introducción

Supuestos

- ▶ En forma natural se incorporan supuestos en el proceso de modelado. Por ejemplo, la hipótesis de independencia entre frecuencia y severidad de las pérdidas



Frecuencia



Severidad

Introducción

Supuestos

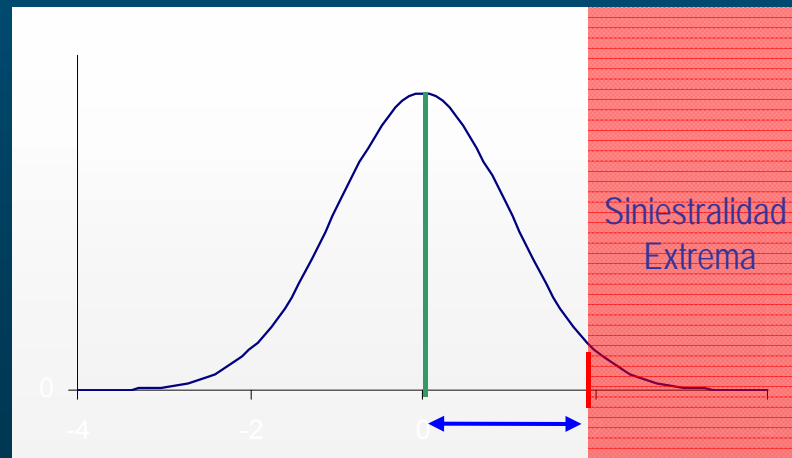
- ▶ En forma natural se incorporan supuestos en el proceso de modelado. Por ejemplo, la hipótesis de independencia entre frecuencia y severidad de las pérdidas

$$L = S \times F \Rightarrow E(L) = E(S) \times E(F)$$

Solvencia

Pérdidas Extremas

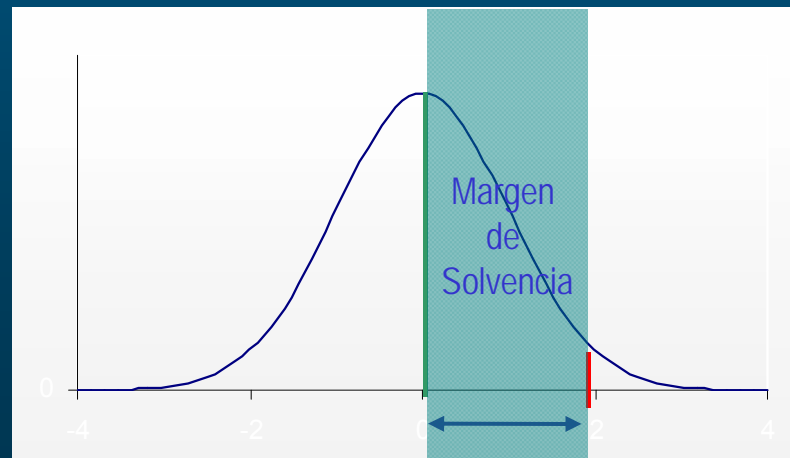
- ▶ Un análisis estadístico debe incluir una descripción completa de la distribución de interés. En Actuaría, en particular, es conveniente describir las pérdidas extremas



Solvencia

Pérdidas Extremas

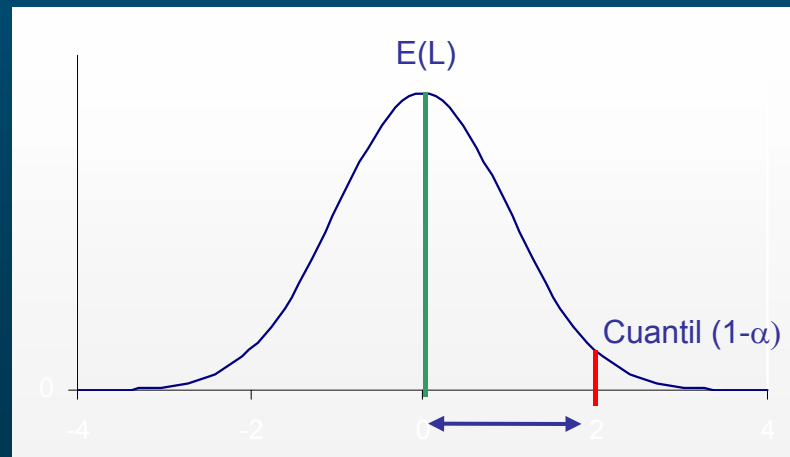
- ▶ Para las agencias reguladoras es importante establecer un margen de solvencia.



Solvencia

Pérdidas Extremas

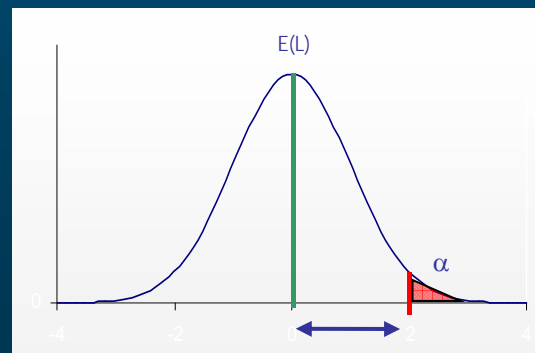
- ▶ Para las agencias reguladoras es importante establecer un margen de solvencia.



Solvencia

Condición de Solvencia

- ▶ Un sistema de seguros es **solvente** si cuenta con recursos suficientes para hacer frente a sus obligaciones.
- ▶ Un sistema es **$(1 - \alpha)$ -solvente** si cuenta con recursos para hacer frente a sus obligaciones con probabilidad $1 - \alpha$.



Formulación Estadística

▶ Dos series históricas:

- X_1, X_2, \dots, X_T (primas)
- Y_1, Y_2, \dots, Y_T (reclamaciones)

▶ Objetivo:

- Determinar el valor $q_{Y,T+1}^{1-\alpha}$ tal que $P(Y_{T+1} > q_{Y,T+1}^{1-\alpha}) = \alpha$

Formulación Estadística

► La serie de siniestralidad relativa

- W_1, W_2, \dots, W_T donde $W_i = \frac{Y_i}{X_i}$ ($i = 1, \dots, T$)
- W_1, W_2, \dots, W_T se suelen considerar i.i.d. (estabilidad)
- El interés se concentra en el valor $q_W^{1-\alpha}$ tal que

$$P(W > q_W^{1-\alpha}) = \alpha$$

Formulación Estadística

► Entonces, para la siguiente observación,

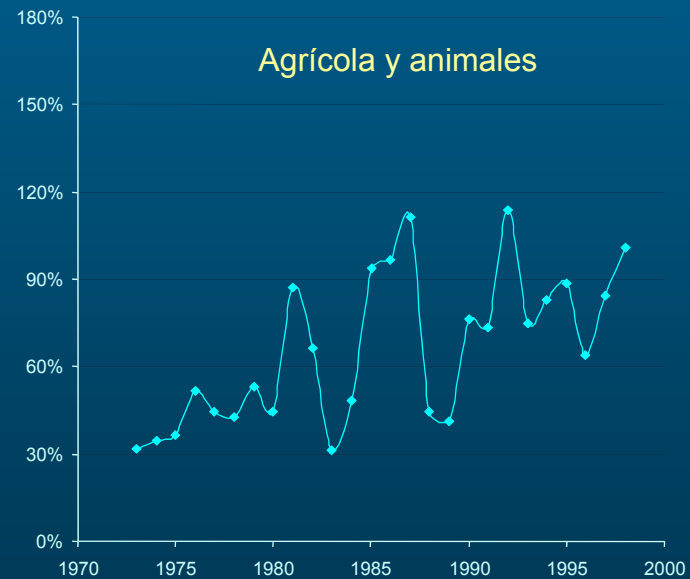

- $P(W_{T+1} > q_W^{1-\alpha}) = \alpha \quad \Rightarrow \quad P\left(\frac{Y_{T+1}}{X_{T+1}} > q_W^{1-\alpha}\right) = \alpha$

► De manera que

- $P(Y_{T+1} > (q_W^{1-\alpha})(X_{T+1})) = \alpha \quad \Rightarrow \quad q_{Y,T+1}^{1-\alpha} = (q_W^{1-\alpha})(X_{T+1})$

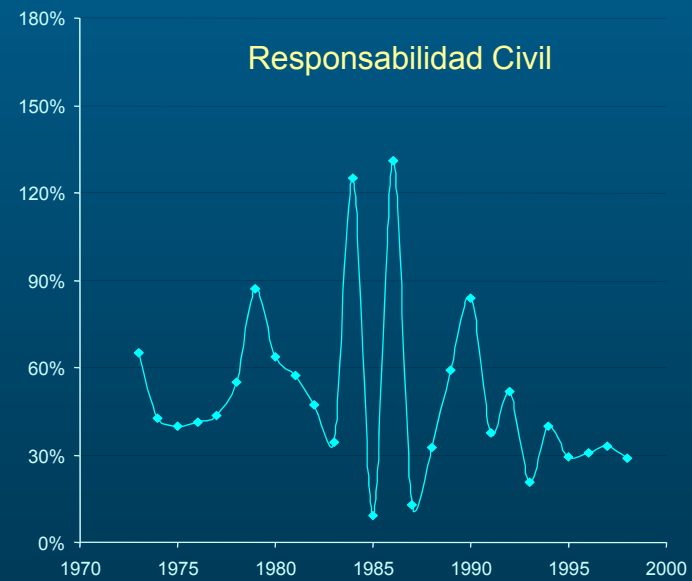

Formulación Estadística

Datos históricos





Formulación Estadística

Datos históricos



Formulación Estadística

Datos históricos



Formulación Estadística

Distribución para W

- ▶ Problema estadístico
 - Estimar los cuantiles de la distribución de W
- ▶ Normalidad como primera aproximación
 - El cálculo es extremadamente simple ($q_W^{1-\alpha} = \hat{\mu}_W + z_{(1-\alpha)} \hat{\sigma}_W$)
 - Los datos históricos no son compatibles con el supuesto

Formulación Estadística

Distribución para W

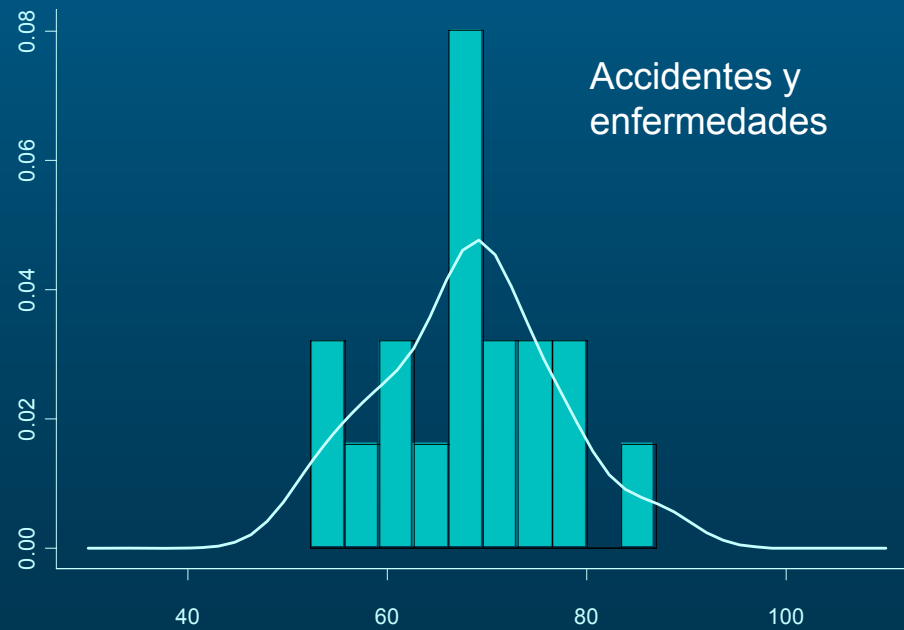
- ▶ Aproximar la densidad de W con mezclas de normales

$$f(\mathbf{w}) = \frac{1}{T} \sum_{i=1}^T \mathbf{N}(\mathbf{w} \mid \mathbf{w}_i, \sigma^2)$$

- ▶ w_1, \dots, w_T valores observados; σ^2 se determina con un criterio de ajuste.

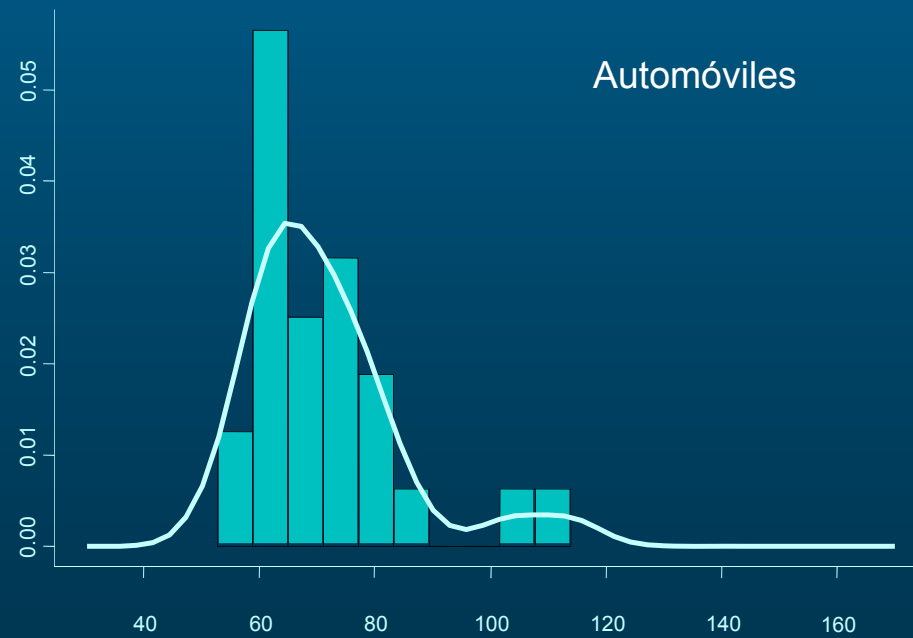
Formulación Estadística

Distribución para W



Formulación Estadística

Distribución para W



Formulación Estadística

Distribución para W

- ▶ La mezcla captura el patrón de asimetría
- ▶ No incorpora el efecto de estimación de los parámetros

Formulación Estadística

Modelo Condicional

- ▶ En cada periodo de tiempo: $Y_i = W_i \times X_i$ ($i = 1, \dots$)
 - ▶ X_i = primas emitidas
 - ▶ W_i = tasa de siniestralidad relativa
 - ▶ Y_i = siniestralidad

Formulación Estadística

Distribución para W

- ▶ $\{ X_1, X_2, \dots \}$ una serie de observaciones correlacionadas
- ▶ $\{ W_1, W_2, \dots \}$ realizaciones i.i.d. de un modelo $P(W | \phi)$
- ▶ $\{ Y_1, Y_2, \dots \}$ debe su aleatoriedad a $\{ X_i \}$, $\{ W_i \}$ y son correlacionadas como resultado de la correlación en $\{ X_i \}$

Formulación Estadística

Distribución para W

- ▶ La distribución de Y_{T+1} , dado $X_{T+1} = x$, está totalmente determinada por la de W_{T+1} .

$$Y_{T+1} = W_{T+1} \times x$$

- ▶ Basta entonces
 - Asignar una distribución $P(W_{T+1} | \phi)$
 - Estimar el cuantil de interés para W
 - Estimar del cuantil condicional de Y_{T+1}

Alternativa Bayesiana

Características Generales

- ▶ Fundado sobre una base axiomática

Inferencia \Leftrightarrow problema de decisión

- ▶ Proceso de aprendizaje basado en la fórmula de Bayes

Final \propto Verosimilitud \times Inicial

Alternativa Bayesiana

Características Generales

- ▶ Fórmula de Bayes

$$p(\theta \mid \text{datos}) \propto p(\text{datos} \mid \theta) \times p(\theta)$$

- ▶ Mecanismo general para la producción de pronósticos

Distribución Predictiva

$$p(X \mid \text{datos}) = \int p(X \mid \theta) p(\theta \mid \text{datos}) d\theta$$

Alternativa Bayesiana

Análisis Predictivo

- ▶ Dado $X_{T+1} = x$, el comportamiento de Y_{T+1} , está determinado por W_{T+1} :

$$Y_{T+1} = W_{T+1} \times X_{T+1}$$

- ▶ Algoritmo, si se adopta un modelo $P(W_{T+1} | \phi)$
 - Asignar una inicial para ϕ y combinarla con la información histórica para obtener la final para ϕ ,
 - Determinar la distribución predictiva para W_{T+1}
 - Calcular el cuantil predictivo condicional para Y_{T+1} , dado X_{T+1}

Alternativa Bayesiana

Distribución para W

- ▶ La selección del modelo $P(W | \phi)$ constituye un reto interesante.
- ▶ La Normal no es, en general, una buena elección.
(Asimetría, valores positivos)
- ▶ Una mezcla de Normales también presenta inconvenientes.

Alternativa Bayesiana

Distribución para W

- ▶ Una posibilidad es suponer que una transformación de W es Normal.

$$U = \frac{W^\lambda - 1}{\lambda} \quad (\text{Transformación de Box-Cox})$$

- ▶ La introducción de λ da lugar a otro problema de decisión (la selección de un valor concreto para λ).

Alternativa Bayesiana

Distribución para W

- ▶ Con propósitos de ilustración

$$\lambda \rightarrow 0 \quad \Rightarrow \quad U = \ln(W)$$

$$Y_i = W_i \times X_i \quad \Rightarrow \quad \ln(Y_i) = \ln(W_i) + \ln(X_i)$$

$$V_i = U_i + c_i$$

$$V_i = \ln(Y_i), \quad U_i = \ln(W_i), \quad c_i = \ln(X_i)$$

Alternativa Bayesiana

Distribución para W

- ▶ En particular, $V_{T+1} = U_{T+1} + c_{T+1}$
- ▶ Dado un valor fijo de X_{T+1} (c_{T+1} constante),

predictiva para U_{T+1} \Leftrightarrow predictiva para V_{T+1}

\Leftrightarrow predictiva para Y_{T+1}

Alternativa Bayesiana

► El problema en estos términos es muy simple

- Datos: $D = \{ U_1, U_2, \dots, U_T \}$ i.i.d. $N(\mu, \tau)$ ($\tau^{-1} = \sigma^2$)
- $\phi = (\mu, \tau)$; Distribución inicial de referencia: $P(\mu, \tau) \propto \tau^{-1}$



Distribución Final: $P(\mu, \tau | D) = \text{Normal - Gamma}$

Distribución Predictiva Final: $P(U_{T+1} | D) = \text{Student}$

Alternativa Bayesiana

Análisis Predictivo

- Predictiva Final: $P(U_{T+1} | D) = \text{Student}$, $U_{T+1} = \ln(W_{T+1})$

$$V_{T+1} = U_{T+1} + c_{T+1}, \quad c_{T+1} = \ln(X_{T+1})$$

\Rightarrow (dado X_{T+1})

- Predictiva Final: $P(V_{T+1} | D) = \text{Student}$, $V_{T+1} = \ln(Y_{T+1})$
- Predictiva Final: $P(Y_{T+1} | D) = \text{log - Student}$

Alternativa Bayesiana

Análisis Predictivo

- ▶ El cuantil de orden $(1-\alpha)$ de la distribución predictiva de Y_{T+1} , dado X_{T+1} , resulta:

$$Y_{T+1}^{(1-\alpha)} = X_{T+1} \left(\prod_{i=1}^T w_i^{1/T} \right) \exp(t_{T-1}^{(1-\alpha)} [(1 + 1/T) \tilde{S}_U^2]^{1/2})$$

donde

$t_{T-1}^{(1-\alpha)}$ es el cuantil de una Student con $T-1$ g. de l. y $\tilde{S}_U^2 = \frac{1}{T-1} \sum (u_i - \bar{u})^2$

Alternativa Bayesiana

El supuesto de independencia

- ▶ Una alternativa al supuesto de independencia es un modelo auto regresivo estacionario de primer orden:

Para $i = 1$:

$$U_1 \sim N(\mu, \tau)$$

mientras que para $i = 2, \dots, T+1$:

$$U_i | U_{i-1} \sim N(\mu + \rho(U_{i-1} - \mu), \tau / (1 - \rho^2))$$

Alternativa Bayesiana

El supuesto de independencia

- ▶ El modelo es estacionario

$$U_i \sim N(\mu, \tau) \quad \text{para } i = 1, 2, \dots, T+1$$

- ▶ La distribución conjunta de U_1, U_2, \dots, U_{T+1} está determinada por los parámetros μ, τ y ρ . El modelo de independencia se recupera con $\rho = 0$.

$$U_i | U_{i-1} \sim N(\mu + \rho(U_{i-1} - \mu), \tau / (1 - \rho^2))$$

Alternativa Bayesiana

Modelo correlación común

- ▶ El modelo requiere la especificación de una distribución inicial para los tres parámetros μ , τ y ρ .
- ▶ A partir del algoritmo propuesto por Berger & Bernardo (1992) se determinó la distribución inicial de referencia para la parametrización ordenada $\{\rho\}$, $\{\tau\}$, $\{\mu\}$ (invariante ante permutaciones).

$$P(\mu, \tau, \rho) \propto \tau^{-1} \frac{(1+\rho^2)^{1/2}}{(1-\rho^2)}$$

Alternativa Bayesiana

Modelo correlación común

- ▶ La distribución final de μ , τ y ρ no tiene una expresión analítica completa.
- ▶ El efecto se reproduce para la distribución predictiva de U_{T+1} .



Simulación (Gibbs Sampler y Metropolis -Hastings)

Alternativa Bayesiana

Modelo correlaciones diferentes

- ▶ El modelo se puede generalizar

Para $i = 1$:

$$U_1 \sim N(\mu, \tau)$$

mientras que para $i = 2, \dots, T+1$:

$$U_i | U_{i-1} \sim N(\mu + \rho_{i-1}(U_{i-1} - \mu), \tau / (1 - \rho_{i-1}^2))$$

Alternativa Bayesiana

Modelo correlaciones diferentes

- ▶ El modelo, para las $T+1$ observaciones, involucra a los parámetros μ , τ , ρ_1 , ρ_2 , ..., ρ_T . Para eliminar problemas de estimabilidad se introduce una estructura parcialmente jerárquica

$$P(\mu, \tau, \rho_1, \dots, \rho_T | \theta) \propto \tau^{-1} \prod_{i=1}^T P(\rho_i | \theta)$$

en donde

$$P(\rho_i | \theta) = \frac{\theta}{2^\theta} (1 + \rho_i)^{\theta-1}; \quad -1 < \rho_i < 1$$

y, por simplicidad, $P(\theta | \gamma) = \gamma \exp(-\gamma \theta); \quad \theta > 0$

Alternativa Bayesiana

Modelo correlaciones diferentes

- ▶ De nuevo, la distribución final para μ , τ , ρ_1 , ..., ρ_T no tiene una expresión analítica completa.
- ▶ Asimismo, el efecto se reproduce para la distribución predictiva de U_{T+1} .



Simulación (Gibbs Sampler y Metropolis -Hastings)

Mendoza, M. y Nieto-Barajas, L. E. (2006). Bayesian Solvency analysis with auto correlated observations. *Applied Stochastic Models in Business and Industry*, **22**, 169-180.

Alternativa Bayesiana

Propósito del modelado

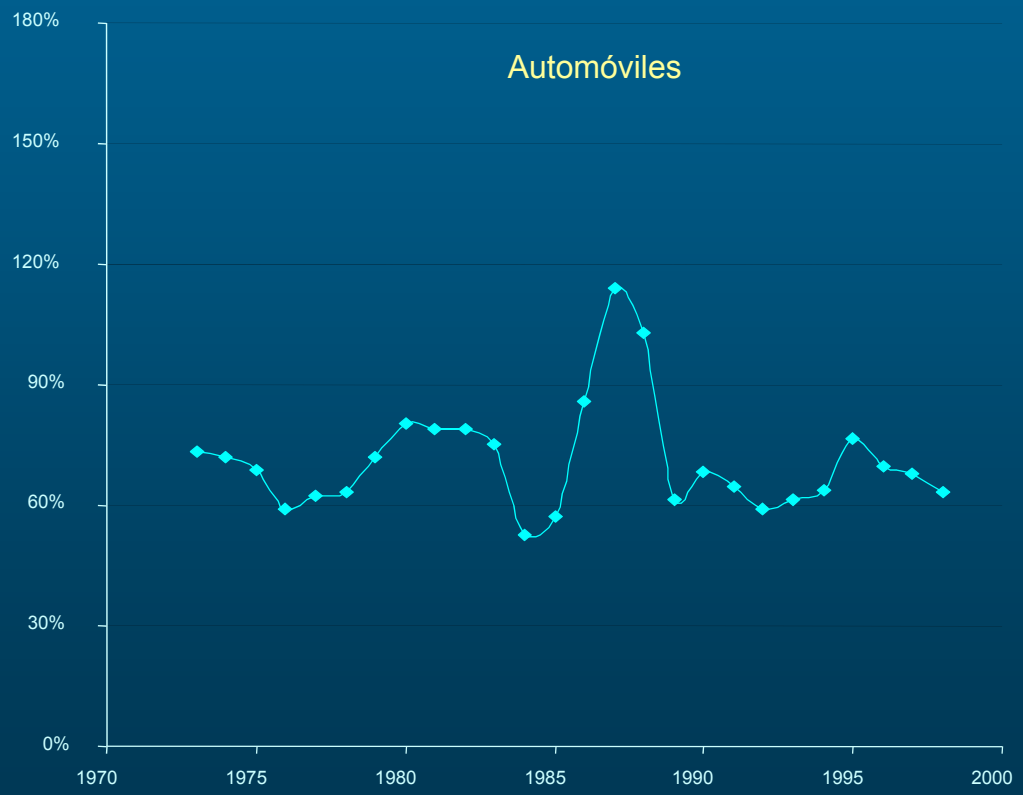
- ▶ Una distribución más flexible y general que la Normal
- ▶ Posibilidad de incorporar patrones de dependencia
- ▶ Empleo de una herramienta de pronóstico general



Procedimientos más robustos
para el cálculo de los factores

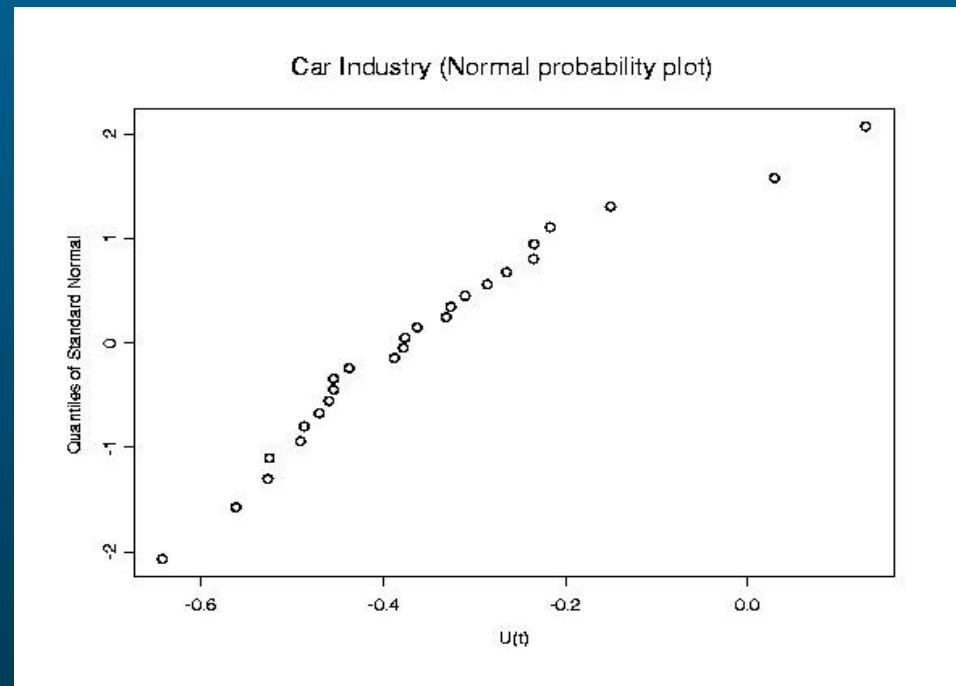
Ejemplos

Severidad
relativa




Año

Ejemplos



Ejemplos

Severidad
relativa

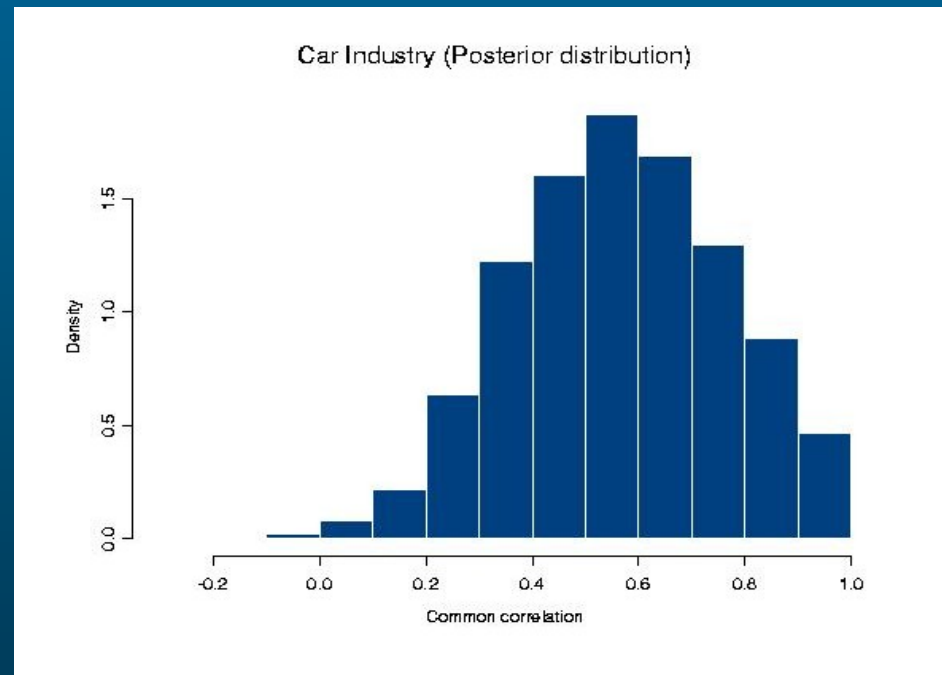


Cuantiles 95%

Independencia


Año

Ejemplos



Ejemplos

Severidad
relativa

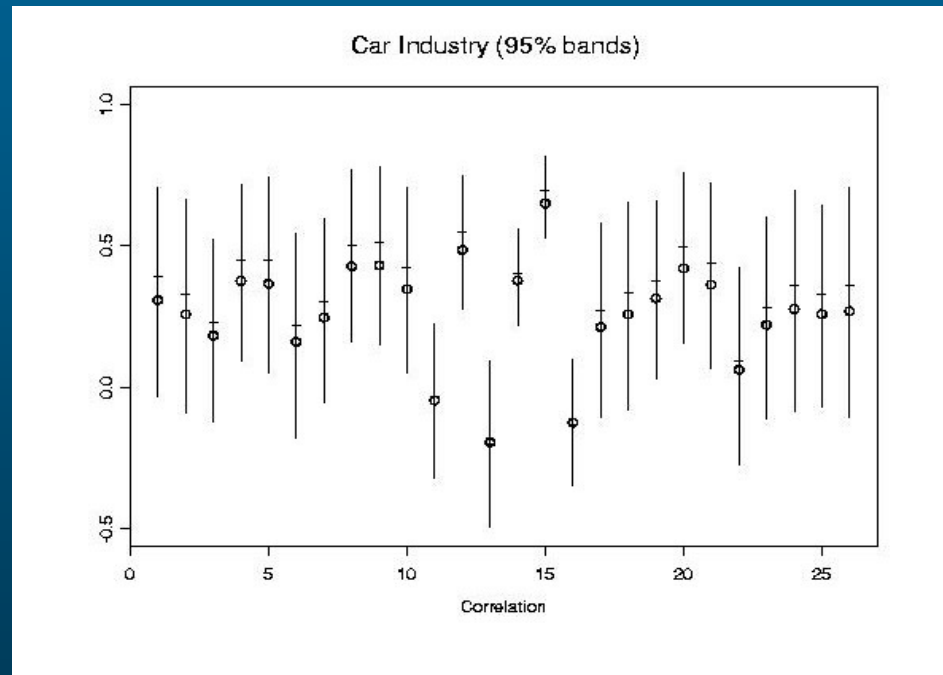


Cuantiles 95%

Independencia
 ρ común


Año

Ejemplos



Ejemplos

Severidad
relativa

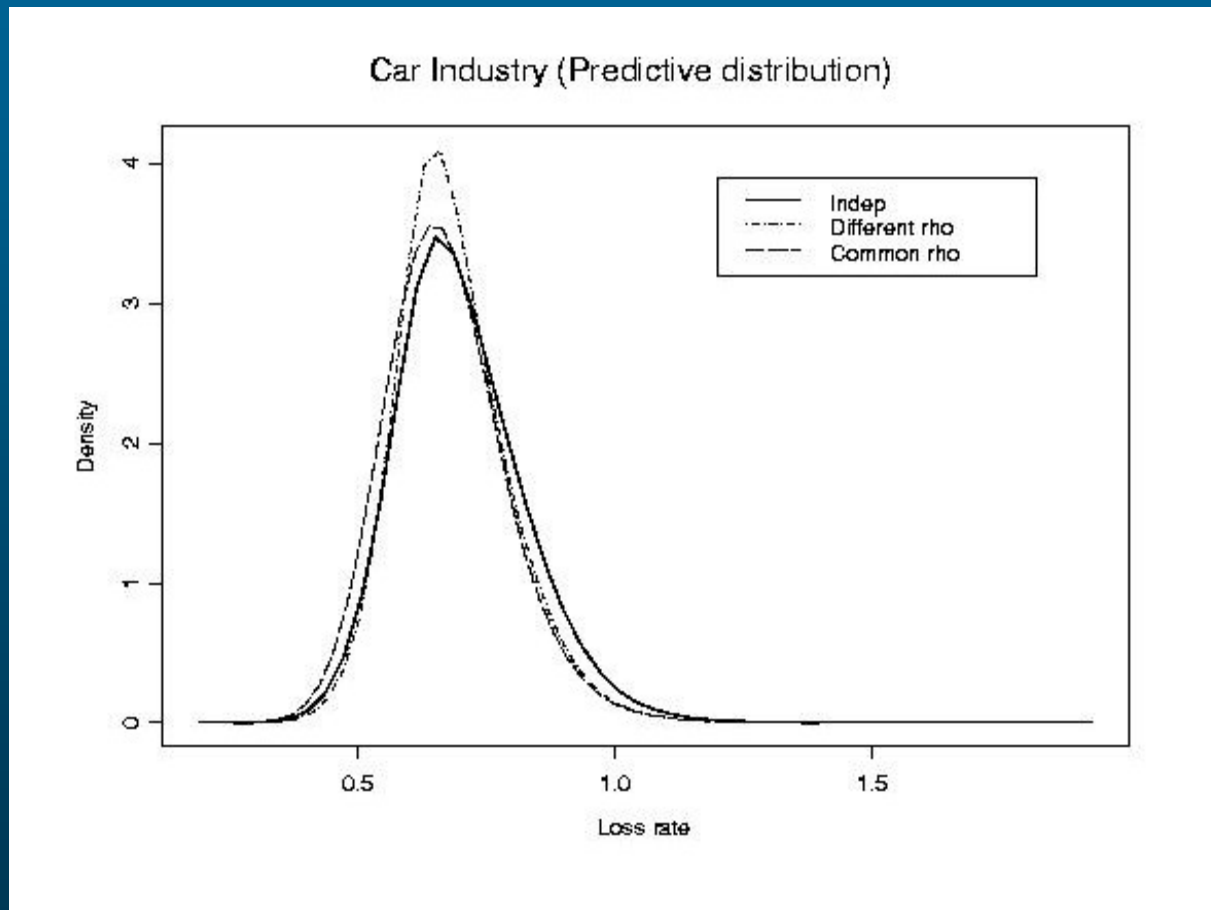


Cuantiles 95%


Independencia
 ρ común
 ρ distintas

Año

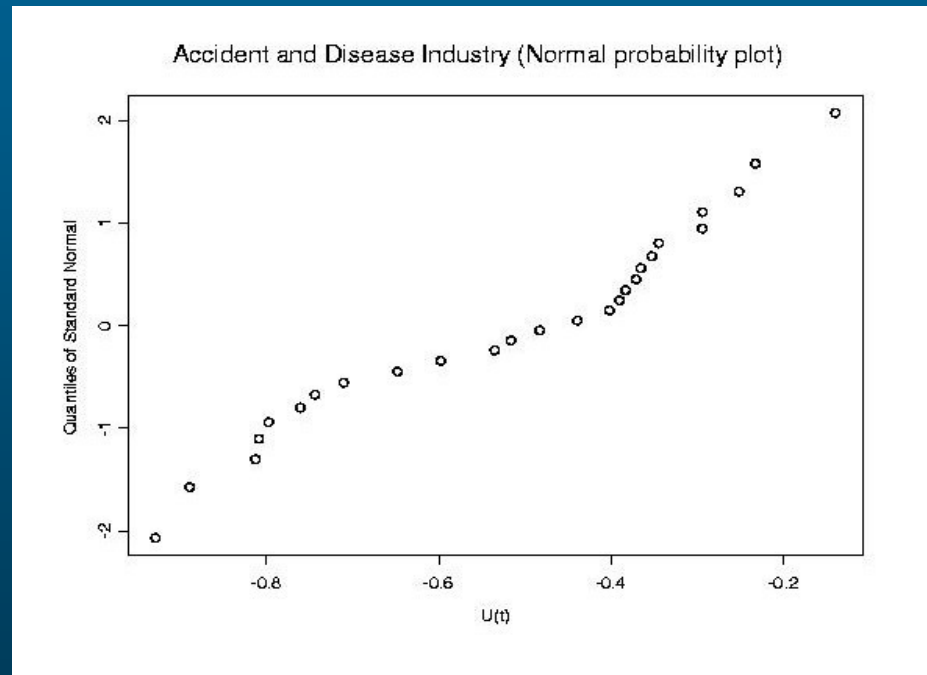
Ejemplos



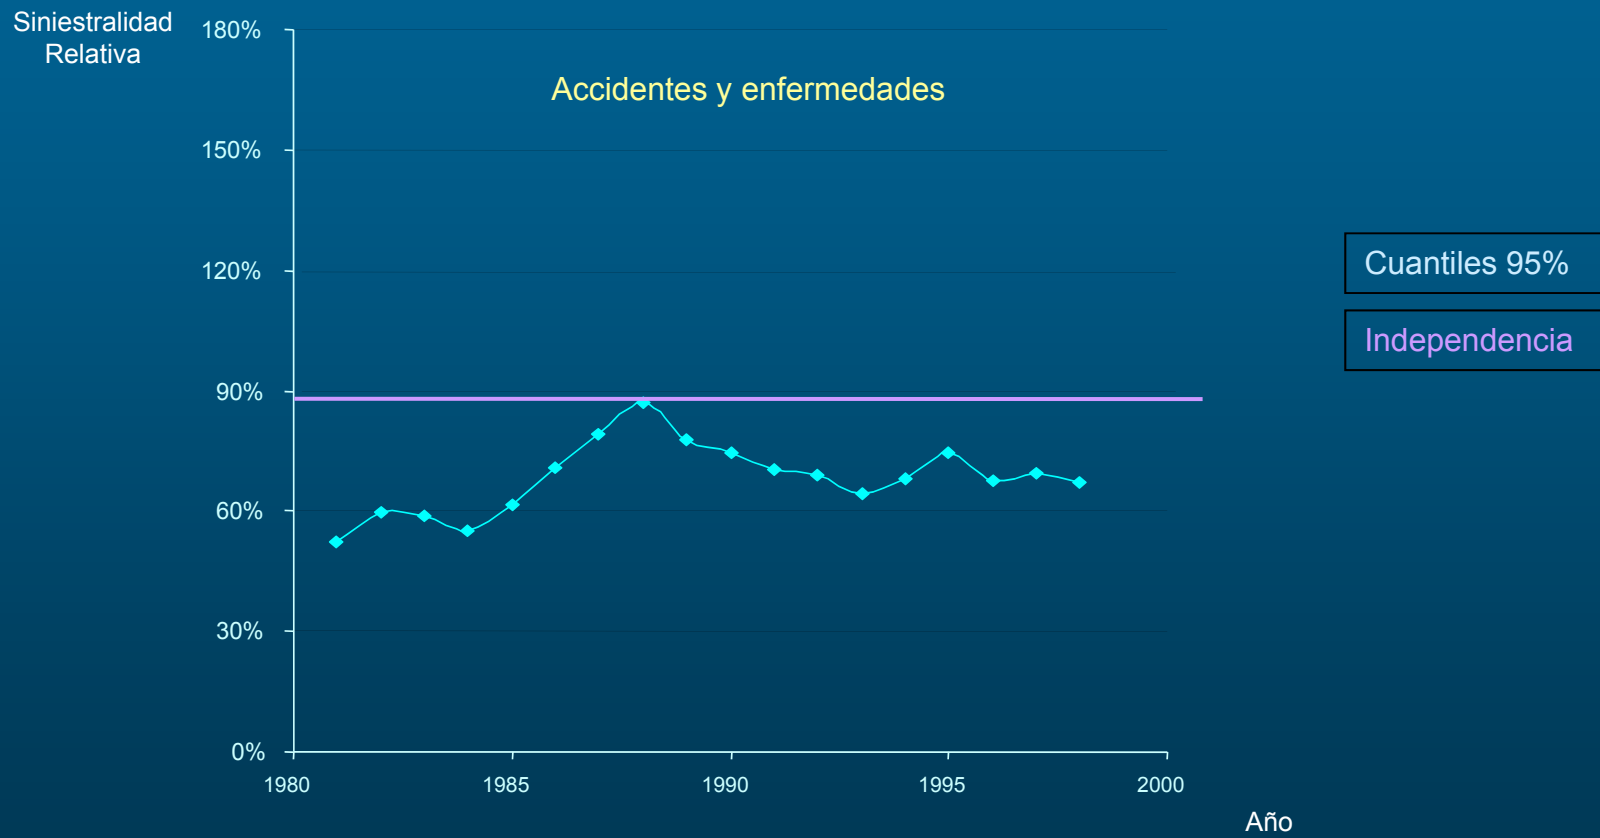
Ejemplos



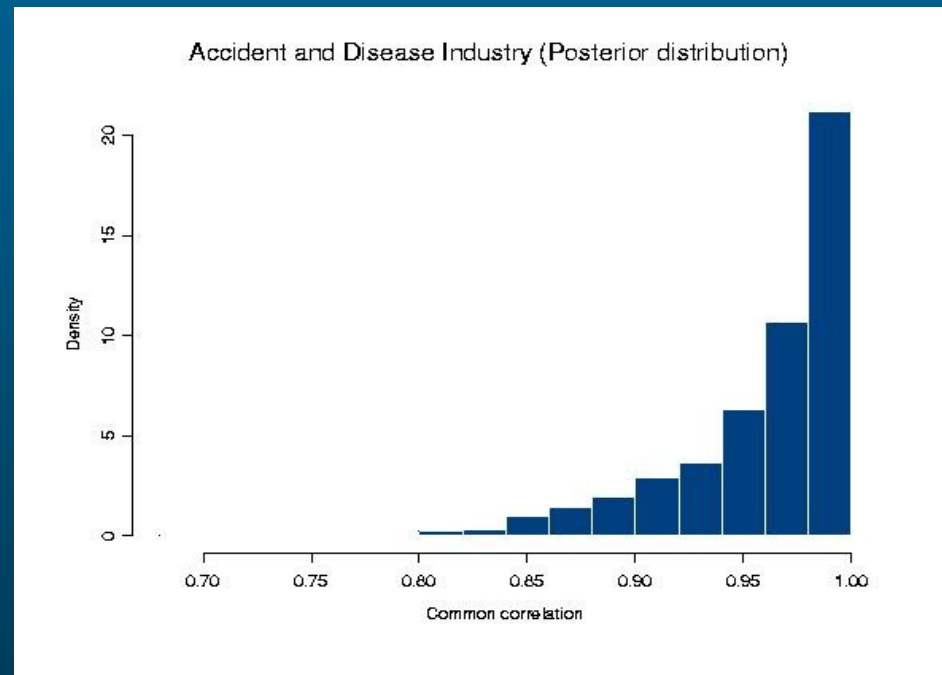
Ejemplos




Ejemplos



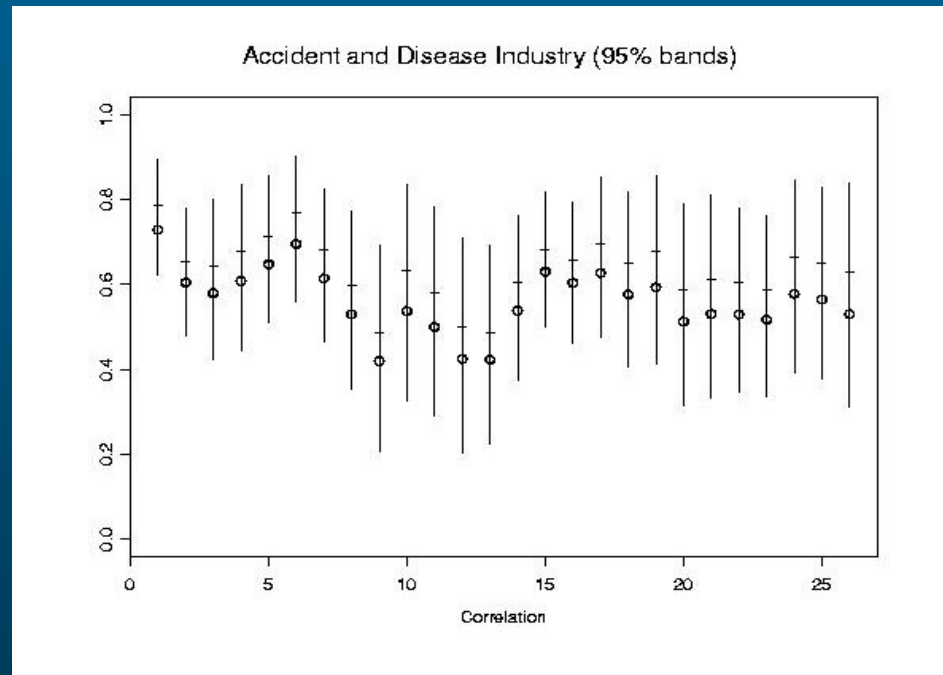
Ejemplos




Ejemplos



Ejemplos




Ejemplos



Ejemplos

Accident and Disease Industry (Predictive distribution)



Consideraciones finales

- ▶ El valor del factor modifica si se cambia el modelo
- ▶ El modelo se debe seleccionar por su capacidad predictiva
- ▶ El análisis hace patente el riesgo de modelo
- ▶ Los modelos se deben evaluar periódicamente
- ▶ Es conveniente considerar modelos alternativos

