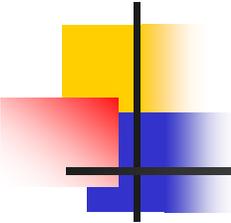


# Gestión de Operaciones

---

Pronósticos de Demanda Bajo Incertidumbre

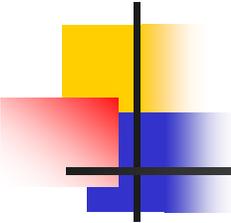


# Regresión Lineal

$$\hat{y} = a + b \cdot x + \varepsilon$$

- $x$  : variable independiente.
- $\hat{y}$  : variable dependiente.
- $\varepsilon$  : perturbación aleatorio

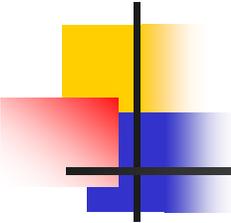
$$a = \frac{\sum_i y_i}{n} - b \cdot \frac{\sum_i x_i}{n}$$
$$b = \frac{n \cdot \sum_i x_i \cdot y_i - \left[ \left( \sum_i x_i \right) \cdot \left( \sum_i y_i \right) \right]}{n \cdot \sum_i x_i^2 - \left( \sum_i x_i \right)^2}$$



# Productos Estacionales

---

- L.L.Bean: Estima en 20MUS\$ sus costos por quiebres de stock y exceso de inventario.
- En un día típico en un supermercado típico, 8.2% de los productos están sin stock y este numero es casi el doble en productos que son promocionados.
- En 34% de los quiebres de stock, los consumidores rehúsan comprar algún sustitutos y usualmente terminan comprando en la competencia.
- Los costos asociados a los quiebres de stock en los supermercados de USA se estiman entre US\$7 a US\$12 billones (Anderson Consulting 1996).

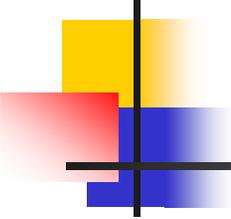


# Productos Estacionales

---

- **Características:**

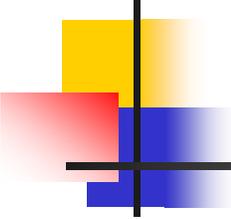
- Ciclos de venta muy cortos.
- Demanda altamente estocástica.
- Rápidos cambios tecnológicos y de modas.
- Ejemplos: ropa de moda, juguetes , juegos computacionales, música, libros, artículos



# Productos Estacionales

---

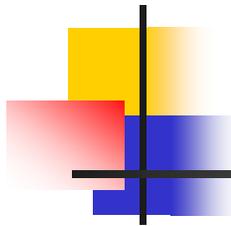
- En muchos de estos ejemplos la demanda puede modelarse como un **variable aleatoria** (e.g., Normal, Weibull, Poisson, etc). En estos casos, el pronóstico de la demanda se reduce a la estimación de la distribución de probabilidades.
- En otros casos, la demanda es mejor modelada por un **proceso estocástico** (e.g., Poisson, Mov. Brownianion, etc).



# Ejemplos

---

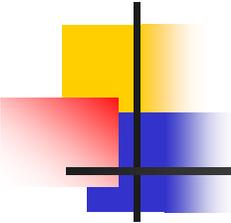
- Uno de los ejemplos más populares es suponer que la demanda está Normalmente distribuida con media  $\mu$  y desviación estándar  $\sigma$ .
- Supongamos que tenemos  $N$  observaciones de la demanda  $\{x_i: i=1, \dots, N\}$ . Como podemos estimar  $\mu$  y  $\sigma$ ?
- En algunos casos la información esta truncada. Por ejemplo, cuando existen quiebres de stock los  $\{x_i\}$  no representan la demanda sino las ventas. Como podemos estimar  $\mu$  y  $\sigma$  en este caso?



# Ejemplos

- **Distribución Empírica:** Cuando es difícil ajustar una distribución de probabilidades se prefiere usar la distribución empírica asociada con los datos

Mes	Ventas	Mes	Ventas	Mes	Ventas	Frecuencia			
						Ventas	Absoluta	Relativa	Acumulada
1	95.7	13	99.6	25	96.3	95	0	0.0%	0.0%
2	100.8	14	95.6	26	97.7	96	3	8.3%	8.3%
3	100.1	15	99.3	27	100.3	97	2	5.6%	13.9%
4	101.6	16	100.5	28	103.4	98	4	11.1%	25.0%
5	96.2	17	98.3	29	97.9	99	2	5.6%	30.6%
6	103.2	18	98.8	30	103.3	100	4	11.1%	41.7%
7	103.1	19	101.6	31	103.2	101	4	11.1%	52.8%
8	98.0	20	104.7	32	101.1	102	5	13.9%	66.7%
9	104.2	21	101.5	33	97.3	103	2	5.6%	72.2%
10	104.1	22	104.4	34	99.5	104	6	16.7%	88.9%
11	101.7	23	103.6	35	102.4	105	4	11.1%	100.0%
12	99.2	24	95.4	36	102.4	106	0	0.0%	100.0%

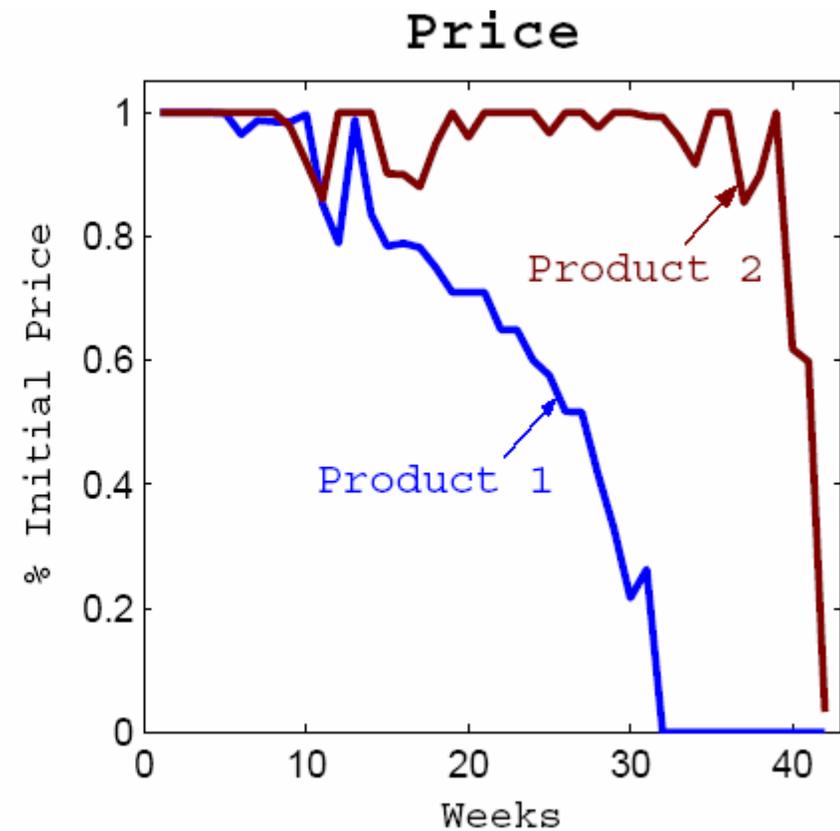
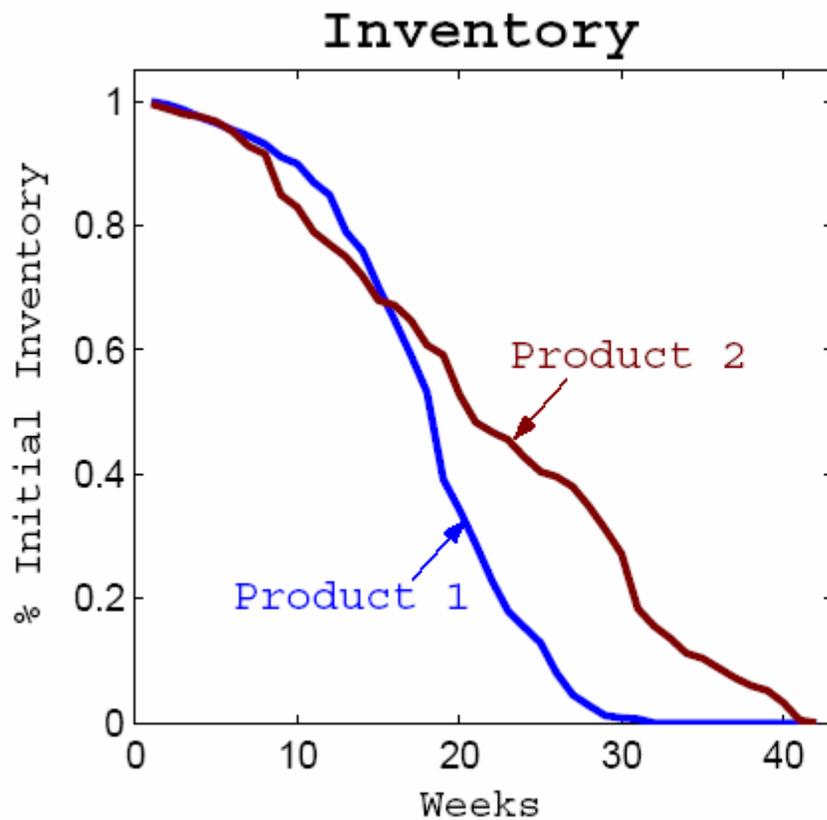


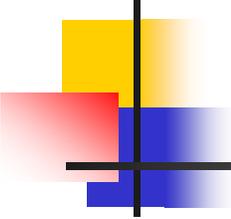
# Ejemplos

---

- La empresa por catálogos LLBean usa la distribución empírica para estimar la demanda de sus distintos productos.
  - En lugar de generar una distribución para cada producto genera una distribución común para todos sus productos de la siguiente manera:
    1. Cada temporada los gerentes de línea generan un pronósticos (F) para cada producto.
    2. Luego durante la temporada se mide las ventas reales (A) de cada producto.
    3. Finalmente, usando los datos F y A se calcula la distribución empírica del cuociente  $A/F$  combinando (en la misma distribución) todos los productos manejados por la empresa.
- Como utilizaría este pronostico empírico para estimar la demanda?
  - Cuáles son las ventajas y desventajas de este método?

# Detección Rápida de Patrones





# Ejemplos

---

- **Detección Rápida de Patrones:**

La demanda por un producto sigue un proceso Poisson con tasa  $\lambda$ . Usando información histórica pensamos que  $\lambda$  tiene igual probabilidad de ser igual a  $\lambda_A$  o  $\lambda_B$ .

Cual es el nuestro mejor estimador de  $\lambda$  si observamos la historia de ventas dada por  $\{N_t : 0 \leq t \leq T\}$ ?