

Pronóstico del Precio de Acciones Empleando Modelos Ocultos de Markov

Congreso Interamericano de Estadística 2017

Luis Damiano

damiano.luis@gmail.com

<https://luisdamiano.github.io>

20 de octubre de 2017

Modelos Ocultos de Markov

Especificación (1)

Representa \mathbf{x}_t (observaciones, emisiones o salidas) mediante dos modelos interconectados.

- **Estados latentes:** Cadena de Markov para tiempo discreto y estados discretos $z_t \in \{1, \dots, K\}$. Transición según $p(z_t|z_{t-1})$.
- **Observaciones:** Densidad $p(\mathbf{x}_t|z_t)$. En el caso Gaussiano, $p(\mathbf{x}_t|z_t = k, \theta) = \mathcal{N}(\mathbf{x}_t|\mu_k, \sigma_k)$.

La función de densidad conjunta está dada por

$$p(\mathbf{z}_{1:T}, \mathbf{x}_{1:T}) = p(\mathbf{z}_{1:T})p(\mathbf{x}_{1:T}|\mathbf{z}_{1:T}) = \left[p(z_1) \prod_{t=2}^T p(z_t|z_{t-1}) \right] \left[\prod_{t=1}^T p(\mathbf{x}_t|z_t) \right].$$

Cantidades:

- **No estocásticas:** la secuencia de observaciones \mathbf{x}_t , el largo de la secuencia T y la cantidad de estados ocultos K .
- **Parámetros:** $\theta = (\pi_1, \theta_h, \theta_o)$
 - Distribución del estado inicial: vector de dimensión K π_1 .
 - Parámetros del modelo oculto: matriz $K \times K$ de transición $\theta_h = \mathbf{A} = \{a_{ij} = p(z_t = j | z_{t-1} = i)\}$.
 - Parámetros del modelo observacional: $\theta_o = \{\mu_k, \sigma_k\}$, $k \in \{1, \dots, K\}$.

A los fines de generar un conjunto de datos $\mathbf{x}_t^{(0)}$:

1. Generar los parámetros en función de las densidades a priori $\theta^{(0)} \sim p(\theta)$.
2. Generar el camino oculto $\mathbf{z}_{1:T}^{(0)}$ en función de los $K^2 - 1$ parámetros libres.
3. Generar las observaciones en función de la densidad muestral $\mathbf{x}_t^{(0)} \sim p(\mathbf{x}_t | \mathbf{z}_{1:T}^{(0)}, \theta^{(0)})$.

Existe un gran número de cantidades ocultas y algoritmos de inferencia asociados.¹

Table 1: Resumen de las cantidades ocultas y sus correspondientes algoritmos de inferencia.

*Cuando va de izquierda hacia derecha. **Cuando la matriz es dispersa.

Nombre	Cantidad oculta	Disponibilidad	Algoritmo	Complejidad
Filtering	$p(z_t \mathbf{x}_{1:t})$	t (online)	Forward	$O(K^2 T)$ $O(KT)$ *
Smoothing	$p(z_t \mathbf{x}_{1:T})$	T (offline)	Forward-backward	$O(K^2 T)$ $O(KT)$ *
Fixed lag smoothing	$p(z_{t-\ell} \mathbf{x}_{1:t}), \ell \geq 1$	$t + \ell$ (lagged)		
State prediction	$p(z_{t+h} \mathbf{x}_{1:t}), h \geq 1$	t		
Observation prediction	$p(x_{t+h} \mathbf{x}_{1:t}), h \geq 1$	t		
MAP Estimation	$p(z_t \mathbf{x}_{1:T})$	T	Viterbi encoding	$O(K^2 T)$ $O(KT)$ **
Prob. of the evidence	$p(\mathbf{x}_{1:T})$	T	Forward	$O(K^2 T)$ $O(KT)$ *

¹Leonard E Baum and Petrie (1966); Leonard E. Baum and Eagon (1967); Leonard E Baum and Sell (1968); Leonard E. Baum et al. (1970); Leonard E. Baum (1972).

Input-Output HMM (Bengio and Frasconi 1995)

- Mapea una secuencia de entradas (señal de control) hacia una secuencia de salida.
- Probabilístico.
- Admite la producción, clasificación y predicción de datos.
- A diferencia de HMM (aprendizaje no supervisado), no aprende la distribución de las salidas sino la secuencia de salidas en sí misma.
- Especialmente efectivo para modelar memoria entre subconjuntos de una misma serie con grandes separaciones de tiempo.

$$z_t = f(z_{t-1}, \mathbf{u}_t)$$

$$\mathbf{x}_t = g(z_t, \mathbf{u}_t).$$

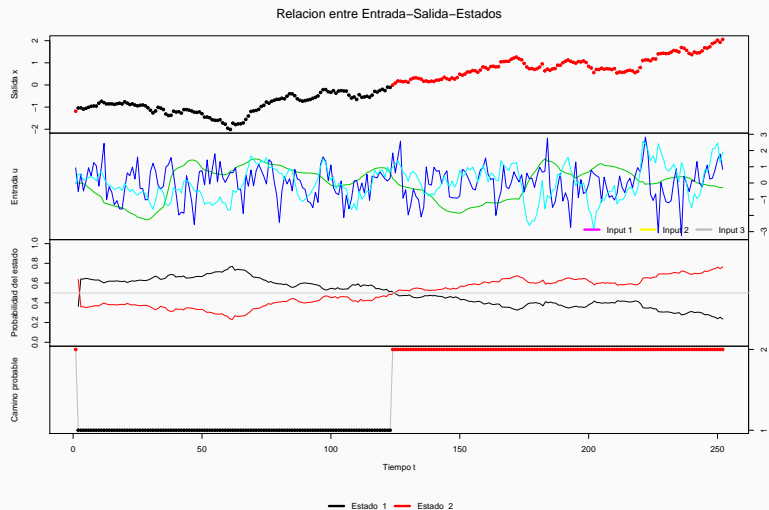
$$p(z_t | \mathbf{x}_t, \mathbf{u}_t, z_{t-1} = i) = \text{softmax}^{-1}(\mathbf{u}_t \mathbf{w}_i),$$

Aplicación


- BCBA:GGAL.
- Desde 2012-01-01 hasta 2017-09-30 (412 observaciones).
- Output: Precio de cierre.
- Inputs (lag = 1):
 - Tendencia en el precio de cierre.
 - Tendencia en el volumen negociado.
 - Volatilidad Parkinson (1980).

- Feature engineering: medias móviles, medias móviles exponenciales y ponderadas, transformación logarítmica, omisión de datos faltantes.
- Estados ocultos: $K = 2$.
- Estructura jerárquica en las medias (facilita convergencia).
- Priors²: débilmente informativas (facilita convergencia).
- Walk-forward: pronóstico un paso hacia adelante para 160 ventanas rodantes con 252 observaciones cada una.


²Se recomienda la lectura de [Prior Choice Recommendations](#) para una guía informal pero muy práctica sobre la elección de densidades a priori.



Real versus pronóstico (fuera de la muestra)



Estimación puntual (fuera de la muestra)



Estadístico	Valor
1 Razón aciertos (negativo)	0.8939
2 Razón aciertos (positivo)	0.9560
3 Razón aciertos (ambos signos)	0.9182
4 RMSE	0.5566
5 MAE	0.3888
6 MAPE	0.0057
7 R^2	0.9967

- Enfoque de Machine Learning: foco en la predicción.
- Las variables de entrada incorporan información en la detección de los estados latentes.
- Los inputs admiten estados latentes persistentes, una característica difícil de observar en los HMM.
- Especialmente útil para series con memoria en observaciones muy distanciadas (ej. crisis).

Stan (Carpenter et al. 2016)

- Monte Carlo Hamiltoniano.
- Muy rápido como algoritmo y además como implementación.
- Pensado para parámetros muy correlacionados (modelos jerárquicos).
- Gran conjunto de herramientas de diagnóstico.
- Excelente soporte de los desarrolladores.
- Conclusión: la vanguardia.

- Equipo de Desarrolladores de Stan (Aaron Goodman, Ben Bales y Bob Carpenter por sus opiniones en [1](#) y [2](#)).
- Brian Peterson y Michael Weylandt por ser mentores del proyecto [Bayesian Hierarchical Hidden Markov Models applied to financial time series](#) bajo el programa Google Summer of Code 2017.

- Baum, Leonard E, and Ted Petrie. 1966. "Statistical Inference for Probabilistic Functions of Finite State Markov Chains." *The Annals of Mathematical Statistics* 37 (6). JSTOR: 1554–63.
- Baum, Leonard E, and George Sell. 1968. "Growth Transformations for Functions on Manifolds." *Pacific Journal of Mathematics* 27 (2). Mathematical Sciences Publishers: 211–27.
- Baum, Leonard E. 1972. "An Inequality and Associated Maximaization Technique in Stattistical Estimation for Probablistic Functions of Markov Process." *Inequalities* 3: 1–8.
- Baum, Leonard E., and J. A. Eagon. 1967. "An Inequality with Applications to Statistical Estimation for Probabilistic Functions of Markov Processes and to a Model for Ecology." *Bulletin of the American Mathematical Society* 73 (3). American Mathematical Society (AMS): 360–64. doi:[10.1090/s0002-9904-1967-11751-8](https://doi.org/10.1090/s0002-9904-1967-11751-8).
- Baum, Leonard E., Ted Petrie, George Soules, and Norman Weiss. 1970. "A Maximization Technique Occurring in the Statistical Analysis of Probabilistic Functions of Markov Chains." *The Annals of Mathematical Statistics* 41 (1). Institute of Mathematical Statistics: 164–71. doi:[10.1214/aoms/1177697196](https://doi.org/10.1214/aoms/1177697196).
- Bengio, Yoshua, and Paolo Frasconi. 1995. "An Input Output Hmm Architecture."
- Carpenter, Bob, Andrew Gelman, Matt Hoffman, Daniel Lee, Ben Goodrich, Michael Betancourt, Michael A Brubaker, Jiqiang Guo, Peter Li, and Allen Riddell. 2016. "Stan: A Probabilistic Programming Language." *Journal of Statistical Software* 20.
- Parkinson, Michael. 1980. "The Extreme Value Method for Estimating the Variance of the Rate of Return." *Journal of Business*. JSTOR, 61–65.