

# TÉCNICA BAYESIANA DE PRONÓSTICO PARA LA DEMANDA DE ENERGÍA EN COLOMBIA

## BAYESIAN FORECASTING TECHNIQUE FOR ENERGY DEMAND IN COLOMBIA

JOSÉ FERNANDO TABARES MUÑOZ<sup>a</sup>, CARLOS ANDRÉS VELÁSQUEZ GALVIS<sup>b</sup>,  
MARISOL VALENCIA CÁRDENAS<sup>c</sup>

Recibido 30-10-13, aceptado 20-05-14, versión final 03-06-14.  
Artículo Investigación

**RESUMEN:** El pronóstico de la demanda energética diaria tiene gran importancia para las entidades reguladoras de la energía en Colombia. Es cada vez más necesario usar técnicas innovadoras para pronosticar este tipo de variables. En este trabajo se presenta una aproximación a un pronóstico bayesiano, basado en una técnica de elicitación que permite obtener información de expertos y su integración a una única distribución de probabilidad, midiendo el indicador de error absoluto medio porcentual (MAPE) sobre los pronósticos realizados. Se encontró que el uso del método puede ser enriquecedor para innovar frente a la manera de hacer el pronóstico energético y lograr niveles de acierto adecuados, sin contar con ningún dato histórico.

**PALABRAS CLAVE:** Pronósticos bayesianos, método Delphi.

**ABSTRACT:** The daily energy demand forecast is very important for energy regulators in Colombia. Innovative techniques becomes increasingly necessary to forecast such variables. This paper presents a Bayesian approach to a forecast, based on a technique that enables elicitation of expert information and their integration into a single probability distribution, measuring the mean absolute percentage error indicator (MAPE) on the forecasts presented. We found that the use of the method could be enriching to innovate against the way to forecast energy and achieve appropriate levels of confidence, without any historical data.

**KEYWORDS:** Bayesian forecast, Delphi method.

---

<sup>a</sup>Ingeniero Industrial. Universidad Pontificia Bolivariana Medellín. Colombia.  
E-mail: [Jose.tabares4@gmail.com](mailto:Jose.tabares4@gmail.com)

<sup>b</sup>Ingeniero Industrial. Universidad Pontificia Bolivariana. Medellín. Colombia.  
E-mail: [carlosandres.velasquez91@gmail.com](mailto:carlosandres.velasquez91@gmail.com)

<sup>c</sup>Ph. D. (c) en Ingeniería-Industria y Organizaciones, Universidad Nacional de Colombia, Sede Medellín.  
E-mail: [mvalencia@unal.edu.co](mailto:mvalencia@unal.edu.co)

# 1. INTRODUCCIÓN

Diferentes autores han aportado en la modelación del comportamiento de la energía en Colombia (Gómez *et al.*, 2011; Medina & García, 2005; Rueda *et al.*, 2011). Medina & García (2005) han diseñado un modelo de pronósticos basado en redes neuronales artificiales y en su combinación con lógica difusa, para el pronóstico de energía del país. Sin embargo, se han encontrado en algunas de ellas falencias como: la falta de acierto, falta de integración de variables exógenas, la falta de suficientes datos para estimar modelos, entre otras.

Rueda *et al.* (2011) expresan: “*La predicción de la demanda es un problema de gran importancia para el sector eléctrico, ya que a partir de sus resultados, los agentes del mercado de energía toman las decisiones más adecuadas para su labor*”. Codensa S.A ESP, empresa distribuidora y comercializadora de energía eléctrica en Colombia, ha elaborado pronósticos basados en regresión lineal, suavización exponencial y media móvil (Gómez *et al.*, 2011), comparándolos por medio del criterio el MAPE. Por otro lado, existen regiones donde apenas se ha iniciado la prestación continua del servicio energético, y no existen datos para estimar estos pronósticos.

Frente a la ausencia de datos históricos para pronosticar, a menudo se buscan alternativas que permitan generar un error mínimo, por ello diferentes autores proponen la combinación de pronósticos cualitativos con los cuantitativos, usando por ejemplo, técnicas bayesianas (Barrera & Correa, 2008; Bolstad, 1986; Cogley *et al.*, 2003; Congdon, 2002; Gill, 2007; Harrison & West, 1991; West & Harrison, 1989). La estadística Bayesiana no exige numerosos datos históricos, se puede basar en conocimientos a priori o de expertos frente al tema, facilitando la predicción, como se muestra en diferentes trabajos (Alba & Mendoza, 2007; Andersson & Karlson, 2007; Craig *et al.*, 2001; Duncan *et al.*, 1993; Flora, 2005; Geweke & Whiteman, 2013; Herr & Krzysztofowicz, 2010; Mol *et al.*, 2008; Neelamegham & Chintagunta, 1999; Oracle, 2006; Pezzulli *et al.*, 2004; Putnam, 2007; Weinberg *et al.*, 2005).

Una técnica bayesiana parte de realizar un producto entre una distribución a priori para el (los) parámetro (s) y una función de verosimilitud o de los datos, para obtener una distribución conjunta a posteriori; seguido, se integra el producto entre ésta y la función de datos sobre el rango de parámetros para finalmente obtener la distribución predictiva (Barrera & Correa, 2008; Gill, 2007), que puede usarse para pronosticar. Sin embargo, no siempre se usa este mismo procedimiento para hacer pronósticos; existen, por ejemplo, modelos tipo VAR, o ARIMA, o regresivos, entre otros, pero usando también técnicas bayesianas (Andersson & Karlson, 2007; Pedroza, 2006).

La deducción de una distribución a priori desconocida, o incluso, el comportamiento de los datos puede apoyarse en un proceso de elicitación. Landeta *et al.* (2011) afirman que el método Delphi

es una herramienta que ayuda a la investigación para obtener datos confiables de un grupo de expertos y en varias ocasiones puede proporcionar solución a problemas complejos, además, se ha utilizado desde los años sesenta en los ámbitos académico y empresarial, como una técnica para la planificación y el consenso en situaciones de incertidumbre en los que no es posible utilizar otras técnicas basadas en información objetiva, además afirman que *“su flexibilidad y simplicidad han llevado a su aplicación con éxito en diferentes contextos geográficos y temáticos”*. En este trabajo, el método servirá como un medio para obtener información estadística, siendo coordinado por un grupo de investigadores que eligieron al grupo encuestado, conformado por diez expertos en demanda energética del país de la empresa XM, filial de ISA.

Para este trabajo, las distribuciones de probabilidad de los datos y la a priori del parámetro, se apoyarán en la técnica DELPHI, aplicada a diez expertos de la empresa XM, filial de ISA, con el fin de encontrar una distribución que represente el comportamiento de los datos. Con este proceso se realiza una simulación de las distribuciones a posteriori y predictiva bayesianas, con las que se actualiza una ecuación dinámica que permite obtener el pronóstico de la demanda de energía diaria de diciembre del año 2012. Se medirá la eficiencia de la técnica usada con el indicador MAPE.

## 2. MATERIALES Y MÉTODOS

Se hace una exploración preliminar sobre el comportamiento de la energía, por medio de indagación con los expertos de la empresa XM filial de ISA, con conocimientos en estadística, encontrando con ello que en los días en la semana: lunes a viernes, el consumo energético se comporta diferente a los días del fin de semana: sábado y domingo. Por otra parte, también se encontró que para el transporte de energía influyen variables exógenas, como: Tipo de día y época del año. Se procede con la metodología Delphi, de donde se obtiene la información para el proceso de pronóstico, como se detalla a continuación.

### 2.1. Metodología Delphi

El grupo de expertos pertenecen a la empresa XM, filial de ISA, que tienen conocimientos en pronósticos de la demanda energética del país y de diversas herramientas estadísticas. Se les da a conocer el objetivo de estudio, una descripción metodológica, el número de cuestionarios y de rondas a llevar a cabo (dos). Se usaron dos cuestionarios en cada ronda, uno para los días de semana, otro para el fin de semana. Para el pronóstico de la demanda irregular en diciembre fue pertinente realizar una pregunta más a los expertos, con el fin de establecer la diferencia porcentual que tienen estos días con respecto a la demanda normal diaria.

## *Elicitación*

La invitación a los participantes se les hace llegar oficialmente por medio de un correo con copia oculta, guardando su anonimato; correo en el cual se especificó el objetivo de estudio, la descripción de la metodología y la duración del proceso. Dicho proceso implica la realización de dos rondas, dándoles en la segunda, una retroalimentación de los resultados de la primera, manteniendo el anonimato.

Las preguntas incluidas en el primer cuestionario fueron las siguientes:

- ¿Cuál es la demanda de energía diaria en una semana de lunes a viernes más común? (Mw)
- ¿Cuál cree que es un valor de consumo de energía diaria muy bajo, sin que sea el mínimo de lunes a viernes? (Mw)
- ¿Cuál cree que es el valor de consumo de energía diaria mínimo de lunes a viernes? (Mw)
- ¿Cuál cree que es el valor de consumo de energía diaria por debajo del cual está el 25 % del consumo energético de lunes a viernes? (Mw)
- ¿Cuál cree que es el valor de consumo de energía diaria máximo de lunes a viernes? (Mw)
- ¿Cuál cree que es el valor de consumo de energía diaria alto, sin que sea máximo? (Mw)
- ¿Cuál cree que es el valor de consumo de energía diaria que deja el 75 % por debajo? (Mw)

El segundo cuestionario se orienta a los días del fin de semana, realizando preguntas muy similares sobre el comportamiento del rango de datos.

Luego de la segunda ronda, se encuentran valores de demanda energética diaria con mayor homogeneidad. Las preguntas anteriores llevan a un conjunto de datos que tienen pesos acordes con el percentil respectivo: 5 %, 25 %, 50 %, 75 %, 95 %. A partir de la información obtenida se encontraron variaciones de un día a otro de la semana, para ser incorporadas en una ecuación que introduce un factor diferente por día a pronosticar, para la demanda de energía en el período del 24 al 31 de diciembre.

## **2.2. Proceso para el pronóstico, aproximación bayesiana**

La distribución de probabilidad a posteriori se deriva del producto de la distribución a priori uniforme para la media, y la empírica obtenida de los expertos, sin embargo, esto lleva a que la distribución a posteriori es también una uniforme, pero cuyos límites  $a$  y  $b$  deben ser definidos con

la distribución de los datos, que en este caso, es elicitada. La distribución predictiva debería ser la integral del producto entre la distribución de los datos y la a posteriori, sin embargo, esta función es constante, sin depender de la media, lo cual la hace igual a la distribución a posteriori. Este es entonces, un caso trivial para elaborar una aproximación al pronóstico de la media. El algoritmo utilizado se explica a continuación.

1. Hacer remuestreo de los valores elicitados, acorde con las probabilidades que se asocian a estos.
2. Determinar el intervalo de alta densidad de las distribuciones empíricas del consumo energético de lunes a viernes y de sábado a domingo.
3. Con los intervalos hallados, fijar los límites  $a$  y  $b$  para la distribución de probabilidad a posteriori uniforme.
4. Simular  $n$  variables aleatorias que constituyen la demanda de energía diaria, de lunes a viernes y posteriormente,  $n$  valores para sábado y domingo.
5. Se promedian las  $n$  simulaciones, encontrando la media  $m_i$  respectiva ( $m_1$  para lunes-viernes,  $m_2$  para sábado-domingo). El pronóstico final sale del modelo que incorpora la variación de un día para otro, acorde con la ecuación:

$$y_t = m + m * peso_t.$$

El proceso se repite mil veces y cada vez, se estima el MAPE, dado por:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \left| \frac{Y_t - \hat{Y}_t}{Y_t} \right|,$$

donde:  $\hat{Y}_t$ : Valor pronosticado en el periodo  $t$ ,  $Y_t$ : Valor real en el periodo  $t$ .

### 3. RESULTADOS

Se presentarán las estimaciones de los modelos estadísticos usados, con la respectiva caracterización del consumo energético diario de Colombia, usando criterios de comparación del nivel de error absoluto relativo.

**Distribución empírica elicitada** Las preguntas realizadas permitieron encontrar los percentiles respectivos: 5 %, 25 %, 50 %, 75 %, 95 %. Sin embargo, las probabilidades son la altura de cada dato, no su valor acumulado, por ejemplo, el P95, tiene un peso del 5 %, la mediana, 25 %. Con dichos valores se realiza un remuestreo para hacer una exploración de la distribución empírica encontrada.

En las figuras 1 y 2 se muestran los histogramas de la estimación de demanda energética diaria a partir de este proceso, para lunes a viernes y el fin de semana.

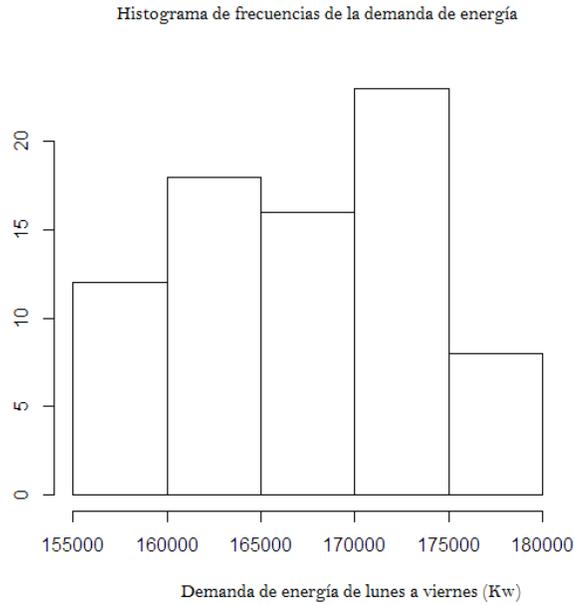


Figura 1: Histograma de frecuencias de la demanda de energía de lunes a viernes.

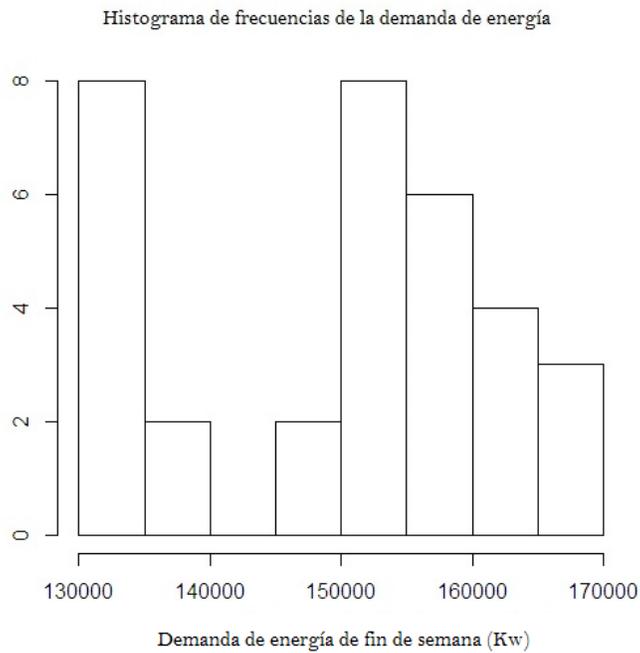


Figura 2: Histograma de frecuencias de la demanda de energía del fin de semana.

El rango de valores entre 165000 MWh y 175000 MWh de la figura 1 tiene más alta frecuencia, por lo que puede ser el intervalo en el que más se presentan los datos de demanda, lo que coincide con los datos proporcionados por los expertos. Por otro lado para el fin de semana, acorde con la figura 2, un intervalo de alta frecuencia se encuentra entre 150000 Mwh y 160000 Mwh. Esto sugiere que el remuestreo sí evidencia la elicitación de expertos realizada. Con esta información se usa la función *hdr.den*, en el algoritmo diseñado en el programa R, de donde se extraen los límites *a* y *b*, según el proceso expuesto en la sección anterior, para usar la distribución uniforme. Los resultados de la simulación final se muestran a continuación.

### Resultados de simulación

En la tabla 1 se muestra el pronóstico energético del 17 al 23 de diciembre, usando el algoritmo propuesto, y se observa un promedio de error porcentual de tan sólo 2.58 %.

Tabla 1: Pronóstico para una semana no atípica.

Fecha	Demanda Real (Mw)	Día	Pronóstico	Error relativo
17/12/2012	169756,92	Lunes	173572,2	2,25 %
18/12/2012	170427,43	Martes	173305,1	1,69 %
19/12/2012	173748,52	Miércoles	167018,3	3,87 %
20/12/2012	173399,14	Jueves	168861,6	2,62 %
21/12/2012	170600,5	Viernes	169007,1	0,93 %
22/12/2012	160288,86	Sábado	154644,4	3,52 %
23/12/2012	145036,17	Domingo	149644,1	3,18 %
			<b>MAPE</b>	<b>2,58 %</b>

En la tabla 2 se muestra el pronóstico energético del 24 al 31 de diciembre, para este proceso, fue necesario recurrir de nuevo a los expertos y preguntarles en qué porcentaje, los días como 24, 25 y 31 podrían disminuir o aumentar la demanda, con respecto a una semana en la que la demanda de energía se comporta de manera normal.

Tabla 2: Pronóstico de demanda de energía para la semana 24-31 diciembre.

Fecha	Demanda Real (Mw)	Día	Pronóstico	% de disminución	Pronóstico real	Error relativo
24/12/2012	147566,05	Lunes	173572,2	15 %	147536,37	0,020 %
25/12/2012	131777,18	Martes	173305,1	20 %	138644,08	5,211 %
26/12/2012	160614,76	Miércoles	167018,3	0 %	167018,3	3,987 %
27/12/2012	162983,71	Jueves	168861,6	0 %	168861,6	3,606 %
28/12/2012	163891,65	Viernes	169007,1	0 %	169007,1	3,121 %
29/12/2012	155519,14	Sábado	154644,4	0 %	154644,4	0,562 %
30/12/2012	143156,82	Domingo	149644,1	0 %	149644,1	4,532 %
31/12/2012	143094,86	Lunes	173572,2	15 %	147536,37	3,104 %
					<b>MAPE</b>	<b>3,018 %</b>

Este valor de MAPE permite ver aciertos en los pronósticos a corto plazo, logrando un error relativo hasta del 0,020 %, como se ve en el día 24 de diciembre. En resumen, el éxito de esta metodología reside en la confianza de los expertos, así como en la manera de asignar probabilidades, de simular la distribución uniforme con base en el intervalo de alta densidad de la distribución elicitada respectiva para los días de la semana y para fin de semana, y el uso de la ecuación que permite asignar la variación de un día a otro para pronosticar.

La información elicitada puede ser modificada con el mismo conocimiento de expertos, por ello, este método muestra flexibilidad y eficiencia a corto plazo y no requiere gran cantidad de datos.

## 4. CONCLUSIONES

Este artículo proporciona una alternativa de pronósticos basados en elicitación a expertos, que evidencia su favorabilidad usando una aproximación bayesiana, así, el Centro Nacional de Despacho (CND) encuentra un método para optimizar el abastecimiento energético diario para Colombia, obteniendo predicciones de demanda muy cerca de los reales, por ser muy acertado para días atípicos, lo que en general les facilita la planeación del abastecimiento de energía.

Este trabajo muestra una parte de un proceso de investigación donde se busca demostrar que existen técnicas bayesianas que no requieren muchos datos o incluso, pueden usarse sin estos, para realizar pronósticos a corto plazo, de manera eficiente.

## AGRADECIMIENTOS

A Colciencias, por proporcionar recursos para la investigación, por medio de la beca 567 de estudios de Doctorado en Colombia, para Marisol Valencia Cárdenas, del Doctorado en Ingeniería-Industria y organizaciones.

## Referencias

- Alba, E. De, & Mendoza, M. (2007), Bayesian forecasting methods for short time series. *Journal of Applied Forecasting*, 1–10. Retrieved from <http://allman.rhon.itam.mx/~mendoza/Foresight.pdf>.
- Andersson, M. & Karlson, S. (2007), Bayesian forecast combination for VAR models. *Sveriges Riskbanc-Working Papers*, 1–17. Retrieved from [http://www.riksbank.se/Upload/Dokument\\_riksbank/Kat\\_publicerat/WorkingPapers/2007/wp216.pdf](http://www.riksbank.se/Upload/Dokument_riksbank/Kat_publicerat/WorkingPapers/2007/wp216.pdf).

- Barrera, C. J. & Correa, J. C. (2008), Distribución predictiva bayesiana para modelos de pruebas de vida vía MCMC. *Revista Colombiana de Estadística*, 31(2), 145–155.
- Bolstad, W. M. (1986), Harrison-Stevens Forecasting and the Multiprocess Dynamic Linear Model. *The American Statistician*, 40(2), 129–135.
- Cogley, T.; Morozov, S. & Sargent, T. J. (2003), Bayesian Fan Charts for U. K. Inflation: Forecasting and Sources of Uncertainty in an Evolving Monetary System (pp. 1–40). Retrieved from <https://files.nyu.edu/ts43/public/research/fantom2.pdf>.
- Congdon, P. (2002), Bayesian Statistical Modelling. (U. of London, Ed.) (p. 529). London, England: Wiley Series in Probability and Statistics.
- Craig, P.; Goldstein, M.; Rougier, J. & Seheult, A. H. (2001), Bayesian forecasting for complex systems using computer simulators. *Journal of the American Statistical Association*, 96(454), 717–729.
- Duncan, G.; Gorr, W. & Szczypula, J. (1993), Bayesian Unrelated Time Forecasting Series: for Seemingly to Local Forecasting Application Government Revenue. *Management Science*, 39(3), 275–293.
- Flora Lu, Q. (2005), Bayesian Forecasting of Stock Prices, Via the Ohlson Model. Master thesis, Worcester Polytechnic Institute.
- Geweke, J. & Whiteman, C. (2013), *Handbook of economic Forecast.* (Graham Elliott and Allan Timmermann, Ed.) (Graham Ell., pp. 2–1324). Retrieved from <http://www.sciencedirect.com/science/handbooks/15740706>.
- Gill, J. (2002), Bayesian Methods-A social and Behavioral Sciences Approach. Second Edition, Chapman & Hall/CRC Statistics in the Social and Behavioral Sciences (p. 459).
- Gómez, G. A.; Carreño, J. C. & Zambrano, J. (2011), Herramienta de software para el pronóstico de demanda horaria de potencia eléctrica en el sistema eléctrico de Codensa S.A. ESP. *Tecnura*, 15(28), 7–22.
- Harrison, P. J. & West, M. (1991), Dynamic Linear model Diagnosis. *Biometrika Trust*, 78(4), 797–808.
- Herr, H. & Krzysztofowicz, R. (2010), Bayesian Ensemble Forecast of River Stages. *Hidrology*, 387, 151–164.
- Landeta, J.; Barrutia, J. & Lertxundi, A. (2011), Hybrid Delphi: A methodology to facilitate contribution from experts in professional contexts. *Technological Forecasting and Social Change*, 78(9), 1629–1641.

- Medina, S. & García, J. (2005), Predicción de demanda de energía en Colombia mediante un sistema de inferencia difuso neuronal. *Energética*, 33, 15–24.
- Mol, C. De; Giannone, D. & Reichlin, L. (2008), Forecasting using a large number of predictors: Is Bayesian shrinkage a valid alternative to principal components? *Journal of Econometrics*, 146(2), 318–328. Retrieved from <http://www.sciencedirect.com/science/article/pii/S0304407608001103>.
- Neelamegham, R. & Chintagunta, P. (1999), A Bayesian model to forecast new product performance in domestic and international markets. *Marketing Science*, 18(2), 115–136. Retrieved from <http://bear.warrington.ufl.edu/centers/mks/articles/684541.pdf>.
- Oracle Corp. (2006), The Bayesian Approach to Forecasting (p. 8). USA. Retrieved from <http://www.oracle.com/us/products/applications/057028.pdf>.
- Pedroza, C. (2006), A Bayesian forecasting model: predicting U.S. male mortality. *Biostatistics* (Oxford, England), 7(4), 530–550. doi:10.1093/biostatistics/kxj024.
- Pezzulli, S.; Frederic, P.; Majithia, S.; Sabbagh, S.; Black, E.; Sutton, R. & Stephenson, D. B. (2004), The seasonal forecast of electricity demand: a simple Bayesian model with climatological weather generator, 1–16. Retrieved from <http://empslocal.ex.ac.uk/people/staff/dbs202/publications/2005/pezzullib.pdf>.
- Putnam, B. H. & Ph, D. (2007), Practical experiences in financial markets using Bayesian forecasting systems (pp. 1–30). Retrieved from .
- Rueda, V.; Velásquez, J. D. & Franco, C. (2011), Avances recientes en la predicción de la demanda de electricidad usando modelos no lineales. *DYNA*, 78(167), 36–43.
- Weinberg, J.; Brown, L. D. & Stroud, J. R. (2005), Bayesian Forecasting of an Inhomogeneous Poisson Process with Applications to Call Center Data. *Journal of the American Statistical Association*, 102(480), 1185–1198.
- West, M. & Harrison, J. (1989), Bayesian Forecasting and Dynamic Models (p. 704). Springer Series in Statistics.