

Un modelo de espacio de estados para la electricidad eólica generada en España: 2008-2015

A model state space for the wind electricity generated in Spain: 2008-2015

Dr. Agustín ALONSO RODRÍGUEZ
Real Centro Universitario
“Escorial-María Cristina”
San Lorenzo del Escorial

Resumen: España es uno de los grandes productores de energía eólica en Europa. Los beneficios de esta fuente de energía para el Medio Ambiente son brevemente reseñados, para luego pasar a establecer y estimar un modelo dinámico de espacio de estados para la generación mensual de la electricidad eólica en España, desde 2008 a 2015.

Abstract: Spain is in Europe, one of the countries with the highest wind power capacity installed. In a few lines, the benefits of this source of energy for the World Climate are presented, and a dynamic model of state space type is estimated for the Spanish monthly generation of wind electricity, from 2008 to 2015.

Palabras clave: La Gran Transición, Medio ambiente, generación de energía eólica, modelos dinámicos de espacio de estados, filtro de Kalman, Asociación empresarial eólica (AEE), EWEA (European Wind Energy Association), GWEC (Global Wind Energy Council), Red Eléctrica de España (REE). Programa RATS.

Keywords: The Great Transition, World Climate, wind energy, state space models, Kalman filter, AEE, (Spanish Association of wind energy producers), EWEA (European Wind Energy Association), GWEC(Global Wind Energy Council), REE, (Spanish administrator of the electrical system). RATS, software.

Sumario:

I. Introducción.

- II. La generación de electricidad eólica en España: datos.**
- III. El Modelo dinámico de Espacio de Estados.**
- IV. Previsiones.**
- V. Simulación.**
- VI. Conclusiones.**
- VII. Bibliografía.**

Recibido: octubre 2015.

Aceptado: noviembre 2015.

I. INTRODUCCIÓN

Una nueva economía de la energía está emergiendo. Las fuentes fósiles de los carburantes están declinando; la polución del aire está empeorando, y la conciencia sobre la conservación del clima se está imponiendo a nivel mundial. El futuro sobre el carbón, el petróleo e incluso el gas natural se está ensombreciendo, dando paso a las energías solar y eólica. Estamos ante “la Gran Transición” de la que hablan Lester Brown y colaboradores en el *Earth Policy Institute* (Brown, 2015)

Y en la transición global desde las fuentes fósiles a la energía eólica y solar, la energía eólica ha tomado la delantera. (Brown, 2015, p. 84)

El viento es abundante, libre de carbón, e inagotable. No utiliza agua, ni combustibles, y ocupa poco suelo. Además, permite ser incorporado en línea rápidamente. Estas y otras ventajas, como la decidida política de subvenciones, explican su rápida expansión.

Y los pasos ya dados en esta nueva senda son muy sólidos.

Ya en 2013 Dinamarca generaba el 34% de su electricidad a partir del viento, porcentaje que en enero del 2014 llegaba al 62%.

Para el final del 2013 la potencia eólica instalada en más de 85 países tenía una capacidad generativa de electricidad de 318000 megavatios, potencia suficiente para abastecer las necesidades residenciales de electricidad de los 506 millones de habitantes de la Unión Europea. (J. Matthew Roney, abril 2014)

Los países que encabezan la lista de mayor capacidad generadora de electricidad eólica son China y Estados Unidos. A comienzos de 2014 China tenía una capacidad generadora de 91000 megavatios de electricidad eólica, seguida por Estados Unidos con 61000 megavatios. Siguen luego Alemania con más de 30000 megavatios, y España e India con cerca de 20000 megavatios, cada una. Reino Unido, Italia y Francia entran en el rango de 8000 a 10000 megavatios. (J. Matthew Roney, abril 2014)

A la vista de estos datos resulta claro el avance de la nueva economía de la energía.

Michael Renner, en el *Worldwatch Institute*, septiembre 30, 2014, mostraba el siguiente gráfico sobre la evolución de las energías nuclear, eólica y solar, desde 1956 a 2013. Reproducido aquí como figura 1.




Figura 1.

A la vista de este gráfico, sobran los comentarios.

La Asociación de la Energía Eólica Europea, EWEA, en su nota de prensa del 15/06/2015 señala como las empresas multinacionales están volviéndose a esta fuente de energía limpia, segura y rentable, y con este motivo invita a celebrar cada 15 de junio como el Día Mundial de la Energía Eólica.

En Europa, Alemania y España son los países con mayor potencia generadora de electricidad eólica.

Según la nota de prensa de la AEE (Asociación Empresarial Eólica) España fue en 2013 el primer país en el que la energía eólica fue la fuente primaria de electricidad para el año entero. 15/01/2014.

Y según este informe de Red Eléctrica de España, REE, la demanda de energía cubierta por la energía eólica, en 2013 fue del 20.9%, comparada con el 20.8% cubierta por fuentes nucleares.

No es este el lugar para ahondar en más detalles sobre las posibilidades de la energía eólica. El lector interesado puede encontrar todo tipo de detalles en la ya mencionada obra de Lester Brown y colaboradores en el *Earth Policy Institute* (Brown, 2015).

II. LA GENERACION DE ELECTRICIDAD EOLICA EN ESPAÑA: DATOS

Red Eléctrica de España, REE, es desde 29 de enero de 1985 la empresa encargada de la gestión del sistema eléctrico español.

Con los datos mensuales, en megavatios, desde 2008 hasta agosto de 2015, un total de 92 observaciones, se establece y estima un modelo dinámico de espacios de estados para estos datos. Fuente: <http://www.ree.es/es/publicaciones/sistema-electrico-espanol/indicadores-nacionales>.

La serie en estudio viene representada en la figura 2.




Figura 2

A simple vista, la serie presenta una ligera tendencia creciente, con estacionalidad, por lo que el modelo teórico aplicable inicialmente es el modelo local con tendencia, *local trend model*, más estacionalidad.

III. EL MODELO DINAMICO DE ESPACIO DE ESTADOS

Para facilitar la lectura del trabajo, se presenta un mínimo de terminología.

Una serie temporal y_t es una serie de observaciones: y_1, y_2, \dots, y_n ordenadas en el tiempo.

El modelo básico, aditivo, permite escribir

$$y_t = \mu_t + \gamma_t + \varepsilon_t \quad (1)$$

Siendo

μ_t : componente lentamente variante en el tiempo, con el nombre de tendencia o *trend*.

γ_t : componente periódico representante de la variación estacional.

ε_t : componente irregular o término de error de la serie.

Para establecer un modelo tanto para μ_t como para γ_t tenemos que acudir al concepto de *random walk* o paseo aleatorio.

Si en (1) se hace $\mu_t = x_t$, siendo x_t un *random walk*, y, por el momento, prescindimos del componente estacional, al sustituir tenemos

$$\begin{aligned} y_t &= x_t + \varepsilon_t; \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \\ x_t &= x_{t-1} + \zeta_t; \quad \zeta_t \sim N(0, \sigma_\zeta^2) \end{aligned} \quad (2)$$

Modelo denominado de nivel local, *local level model*. No es una simpleza y pone de relieve la estructura característica de un modelo de espacio de estados, en el que están presentes una serie de valores inobservables: x_1, x_2, \dots, x_n que representan el desarrollo o estados en el tiempo de la serie, junto con el conjunto de observaciones y_1, y_2, \dots, y_n que se relacionan con las x_t mediante el modelo de espacio de estados (2), y se trata de inferir las características de las x_t , a partir de las observaciones de y_t . Los *random walks* son procesos no estacionarios, y, en consecuencia, las distribuciones de y_t y x_t varían en el tiempo.

Si del modelo de nivel local pasamos al modelo de nivel local con tendencia, *local trend model*, tendríamos el siguiente conjunto de ecuaciones:

$$\begin{aligned} y_t &= x_t + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_\varepsilon^2) \quad (3) \\ x_t &= x_{t-1} + \tau_{t-1} + \zeta_t, \quad \zeta_t \sim N(0, \sigma_\zeta^2) \quad (4) \\ \tau_t &= \tau_{t-1} + \varsigma_t, \quad \varsigma_t \sim N(0, \sigma_\varsigma^2) \quad (5) \end{aligned}$$

La variable y_t en (3) es la variable de interés, y ahora se supone compuesta de un nivel o media cambiante, la variable x_t , variable que representa el nivel medio alcanzado por y_t , más una perturbación o error ε_t que se supone tiene distribución normal, con media cero y varianza σ_ε^2 .

El nivel medio de y_t , x_t , es cambiante y evoluciona como un *random walk*, al que se añade la tasa de variación, *rate*, tasa de cambio, pendiente o drift, τ_{t-1} más su correspondiente término de error ζ_t con distribución normal, con media cero y varianza σ_ζ^2 .

A su vez, la tasa de cambio τ_t evoluciona como un *random walk*, al que se añade el correspondiente término de error ς_t con distribución normal, media cero y varianza σ_ς^2 . Por principio, los tres términos de error se consideran incorrelacionados.

Este modelo tiene dos ecuaciones de estado, la (4) y (5), para modelizar el nivel y la tasa de cambio, respectivamente. La ecuación (3), recibe el nombre de ecuación de observaciones.

El modelo, pues, descompone cada una de las observaciones de la serie de observaciones y_t en tres componentes, separables en función de su persistencia. Los cambios en la tasa de cambio de la tendencia, ξ_t , tienen el mayor efecto en la evolución de la serie. La perturbación ε_t en la ecuación de observaciones tiene el menor efecto en la evolución de la serie, y la perturbación ζ_t tiene un efecto intermedio entre los dos anteriores. Por esta razón, a veces se asigna el valor cero a ζ_t como punto de partida, o como consecuencia de que al estimar su varianza por máxima verosimilitud, ésta resulta negativa. (cf. Thomas A. Doan, RATS Handbook for State Space Models, p. 27).

Por último, para hacer estacional este modelo, se añade el componente estacional (cf. Durbin y Koopman, 2012, p. 45)

$$\gamma_{t-1} = -\sum_{j=1}^{s-1} \gamma_{t-1-j} + \omega_t; \quad \omega_t \sim N(0, \sigma_\omega^2)$$

con $s=12$ si se trata de datos mensuales. Al añadir el componente estacional, Harvey (1989) denomina el modelo resultante como el modelo básico estructural: BSM. Esta descomposición de la serie temporal en sus elementos estructurales o estados, resultado de la aplicación del filtro de Kalman (1960), ha permitido, en el ámbito de la ingeniería, la solución de un amplio abanico de problemas, que van desde el tratamiento de órbitas espaciales, hasta problemas de oceanografía, reconocimiento de voz, etc.

La estimación de las varianzas de los cuatro términos de error es el primer paso a realizar: son los hiperparámetros y el método a utilizar es no lineal.

Con ayuda del paquete RATS, y utilizando el método BFGS (Broyden, Fletcher, Godfard, Shano, cf. *RATS User's Guide*, p. 115, versión 8), obtenemos el resultado:

```

DLM - Estimation by BFGS
Convergence in 17 Iterations. Final criterion was 0.0000060 <= 0.0000100
Monthly Data From 2008:01 To 2015:08
Usable Observations                92
Rank of Observables                 79
Log Likelihood                      -90.7663

```

Variable	Coeff	Std Error	T-Stat	Signif
1. SIGSQEPS	0.2674668590	0.0687738541	3.88908	0.00010063
2. SIGSQXI	0.0132482838	0.0139820741	0.94752	0.34337427
3. SIGSQZETA	0.0000134856	0.0000417072	0.32334	0.74643776
4. SIGSQOMEGA	0.0111845168	0.0166499863	0.67174	0.50174713

Al no ser ninguna estimación negativa, las cuatro estimaciones se incorporan a la estimación del modelo.

El modelo estimado presenta los residuos recurrentes que aparecen en la figura 4.




Figura 4.

Residuos no autocorrelacionados, normales y homoscedásticos, como aparecen en la figura 5 y se deduce de la tabla adjunta: Tabla 1.




Figura 5

State Space Model Diagnostics		
	Statistic	Sig. Level
Q(12-3)	9.86	0.3617
Normality	6.10	0.0474
H(26)	1.56	0.2624

Tabla 1

De este modelo estadísticamente válido, se extrae la serie de valores del *trend*, representada en la figura 6 junto con las observaciones de la serie original:




Figura 6

Por su parte, los datos desestacionalizados, junto con las observaciones originales, se muestran en la figura 7.




Figura 7

Por último el componente estacional se muestra en la figura 8.




Figura 8

Los anteriores gráficos muestran cómo un modelo dinámico de espacio de estados descompone la serie en estudio en sus distintos elementos estructurales.

Podemos también extraer y representar la tasa de cambio, *rate*, de la tendencia. Junto a los datos y al *trend*, aparece en la figura 9.




Figura 9

IV. PREVISIONES

Habiendo alcanzado un modelo estadísticamente aceptable, se puede pasar a pronosticar los valores de los últimos meses del 2015: septiembre, octubre, noviembre y diciembre.

Primero, numéricamente. He aquí el resultado, con los límites del intervalo del 50% de confianza: tabla 2.

Fechas	Datos	Lim. inf	Previsión	Lim. sup
2015:01	4.950	NA	NA	NA
2015:02	5.988	NA	NA	NA
2015:03	4.903	NA	NA	NA
2015:04	3.933	NA	NA	NA
2015:05	4.840	NA	NA	NA
2015:06	2.902	NA	NA	NA
2015:07	3.112	NA	NA	NA
2015:08	3.285	NA	NA	NA
2015:09	NA	2.60894467129	3.06176419907	3.51458372685
2015:10	NA	3.26226118476	3.72016068926	4.17806019377
2015:11	NA	4.75516716213	5.2223040770	5.68929365327
2015:12	NA	4.49990645559	4.97646236839	5.45301828119

Tabla 2

Y gráficamente, figura 10

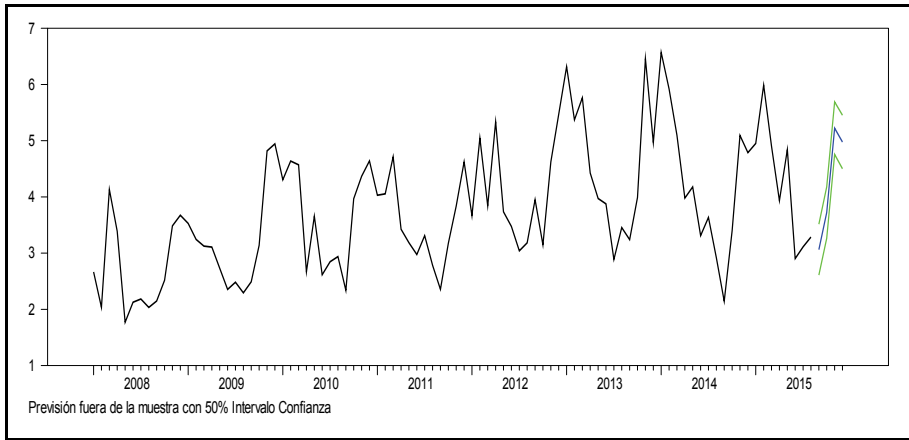


Figura 10

V. SIMULACION

Con ayuda del paquete RATS, cabe simular nuevos resultados con el modelo alcanzado, induciendo shocks aleatorios independientes en los errores de las ecuaciones, y también induciendo shocks sujetos a las condiciones de las observaciones y de los parámetros. Son los resultados de dos funciones TYPE=SIMULATE y TYPE=CSIMULATE del paquete RATS. La primera se utiliza normalmente en operaciones para fuera-de-la muestra.

Al utilizar la primera instrucción, primero se aplica el filtro de Kalman sobre la totalidad de la serie para obtener las estimaciones de la media y varianza de los estados. Luego se generan 10000 realizaciones del proceso sobre 5 periodos, agosto-diciembre 2015, y los percentiles son calculados tras las simulaciones. La simulación genera la variable MAXvats, máximo de megavatios. Los resultados se muestran en la tabla 3.

Statistics on Series MAXvats			
Monthly Data From 2008:01 To 2841:04			
Observations	10000		
Minimum	0.116780	Maximum	10.908898
01-%ile	1.728954	99-%ile	6.986357
05-%ile	2.311961	95-%ile	5.967492
10-%ile	2.644623	90-%ile	5.498677
25-%ile	3.267387	75-%ile	4.746473
Median	3.969354		

Tabla 3

VI. CONCLUSIONES

La descomposición de una serie temporal en sus elementos estructurales o estados, gracias al filtro de Kalman, es de la mayor importancia para el análisis de las series temporales. En el ámbito de la estadística y la econometría, han sido las dificultades de orden técnico las que han retrasado la aplicación del filtro de Kalman al análisis de las series temporales de carácter económico. Sin embargo, conviene también señalar que el influjo que tienen las decisiones humanas en el ámbito de la economía, tiene repercusiones en el análisis de las respectivas series y en su descomposición mediante el filtro de Kalman. El tema de las subvenciones es de gran importancia para este sector, si bien la conciencia de la sociedad ante los problemas del cambio climático, puede que neutralice los recortes, que se pronostican, de las subvenciones.

A la hora de cerrar este artículo, 30 de octubre de 2015, REE ha hecho público el dato de electricidad eólica generada en el mes de septiembre: 3.026 megavatios; nuestra previsión: 3.062 megavatios. La producción real ha descendido, y este descenso también lo ha detectado el modelo.

VII. BIBLIOGRAFIA

- AEE: Asociación Empresarial Eólica (Spanish Wind Energy Association), nota de prensa: 15/01/2014.
- BROWN, L. R., *The Great Transition, Shifting from Fossil Fuels to Solar and Wind Energy*. New York: W. W. Norton 2015. Datos y fuentes adicionales para este libro en: www.earth-policy.org.
- COMMANDEUR, J. J. F., y KOOPMAN, S. J., *An Introduction to State Space Time Series Analysis*, Oxford University Press, Oxford 2007.
- DOAN, Th. A., *RATS Handbook for State Space Models*, draft version, Estima, Evanston, Illinois 2010.
- DURBIN, J., y Koopman, S.J., *Time Series Analysis by State Space Methods*, (2a ed.), Oxford University Press, Oxford 2012.
- ESTIMA, RATS software, version 9, Evanston, Illinois 2014.
- EWEA: European Wind Energy Association, press release: 15/06/2015.
- GWEC: Global Wind Energy Council, datos estadísticos, 2015.
- GRANGER, C. W. J., y Newbold, P., *Forecasting economic time series* (2a ed.). San Diego: Academic Press, 1986.

- HAMILTON, J. D., *Time Series Analysis*, Princeton, New Jersey: Princeton University Press, 1994.
- HARVEY, A. C., *Forecasting, structural time series models and the Kalman filter*, Cambridge University Press, Cambridge 1989.
- LÜTKEPOHL, H., *New Introduction to Multiple Time Series Analysis*, Berlin: Springer, 2007.
- LÜTKEPOHL, H., and KRÄTZIG, M., *Applied Time Series Econometrics*, New York: Cambridge University Press, 2004.
- KALMAN, R. E., “A new approach to linear filtering and prediction problems”, en *Journal of Basic Engineering, Transactions ASME, Series D 82*: 35-45, 1960.
- KALMAN, R. E., y BUCY, R.S., “New results in linear filtering and prediction theory”, en *Journal of Basic Engineering, Transactions ASME, Series D 83*: 95-108, 1961.
- MARTIN, V.; HURN, S., and HARRIS, D., *Econometric Modelling with Time Series, Specification, Estimation and Testing*, New York: Cambridge University Press, 2013.
- PEÑA, D.; TIAO, G. G., y TSAY, R. S. (eds.), *A Course in Time Series Analysis*, John Wiley, New York 2001.
- REE: Red Eléctrica de España, press release: 15/01/2014.
- REE: Red Eléctrica de España, www.ree.es/es.
- RENNER, M., *Wind, Solar Generation Capacity Catching Up with Nuclear Power*, 30 September 2014.
- RONEY, J. M., *World wind power poised to bounce back after slowing in 2013*. @JMattRoney, April 10, 2014.
- TSAY, R. S., *Analysis of Financial Time Series*, Hoboken: Wiley, 2010.
- TSAY, R. S., *Multivariate Time Series Analysis*, Hoboken: Wiley, 2014.