

Predicción del calentamiento global mediante el desarrollo de un modelo de series de tiempo*

Predicting Global Warming by Developing a Time Series Model

Juan Bacilio Guerrero Escamilla,** Yamile Rangel Martínez,***
Sócrates López Pérez****

Recibido: 2016-08-18 // Aprobado: 2016-10-12 // Disponible en línea: 2017-01-30

Cómo citar este artículo: Guerrero Escamilla J. B., Rangel Martínez, Y. y López Pérez, S. (2017). Predicción del calentamiento global mediante el desarrollo de un modelo de series de tiempo. *Am-biente y Desarrollo*, 21(40), 125-139. <https://doi.org/10.11144/Javeriana.ayd21-40.pcgmm>
doi:10.11144/Javeriana.ayd21-40.pcgmm

Resumen

Las alteraciones en los ecosistemas debido al cambio climático han ocasionado que se hagan estudios globales sobre la temperatura promedio del planeta. Se desarrolla un modelo probabilístico de series de tiempo para observar la dinámica de la temperatura en el tiempo y determinar el calentamiento global. Se analiza un periodo de 165 años, desde 1850 a 2015, con base en los reportes de temperatura global de la APA de Estados Unidos, y se observa que desde 1963 esta se ha incrementado en 0.29° C. Sin embargo, es hasta 1996 cuando los efectos negativos sobre el planeta se hacen presentes, ya que la temperatura promedio oscila por arriba de los intervalos establecidos por el modelo. Por otro lado, se realiza una proyección al año 2030, producto de lo cual se obtiene un parámetro entre 14.55 y 16.33° C.

Palabras clave: modelo de series de tiempo; calentamiento global

* Este artículo es resultado del proyecto de investigación *Predicción de gases efecto invernadero del estado de Hidalgo (México)*, financiado por la Secretaría de Medio Ambiente y Recursos Naturales (Semarnat), México.
** Doctor en Ciencias Sociales; investigador, Área Académica de Sociología y Demografía de la Universidad Autónoma del Estado de Hidalgo, México. Correo electrónico: guerreroescamilla@yahoo.com.mx
*** Doctora en Ciencias Ambientales; investigadora, Área Académica de Sociología y Demografía, Universidad Autónoma del Estado de Hidalgo. Correo electrónico: yamilerangelm@gmail.com
**** Doctor en Desarrollo Regional; investigador, Área Académica de Sociología y Demografía, Universidad Autónoma del Estado de Hidalgo. Correo electrónico: lopezsoc@gmail.com

la base fundamental del cambio climático. Los resultados arrojados por estos trabajos de investigación aseguran que duplicar la radiación por gases de efecto invernadero con respecto a lo que se conoce, hace previsible que en el futuro haya más calentamiento que en la actualidad (Ferrero, 2010).

Dichos trabajos también predicen la temperatura en el futuro —de cincuenta a cien años—. La impresión que generan es la de ser una ciencia rigurosa, en la cual la principal aportación es la especulación climática, donde la teoría del calentamiento global es el resultado de la actividad humana (Ferrero, 2010).

Este trabajo tiene la finalidad de construir y desarrollar un modelo probabilístico de series de tiempo sobre el calentamiento global, a partir de un rigor científico, con la premisa de que la dinámica de la temperatura es un fenómeno aleatorio y, por lo tanto, existe incertidumbre sobre su comportamiento.

Asimismo, en esta investigación se hace una comprobación de dicho incremento y, aunado a esto, se pronostica la temperatura promedio del planeta para el año 2030, límite para evaluar las acciones estipuladas en la Agenda 2030 (según el acuerdo de París, que entró en vigor en noviembre de 2016).

Para desarrollar el estado referencial y geográfico del modelo de series de tiempo del calentamiento global, es necesario basarse en la metodología de Box-Jenkins, considerando la demarcación geográfica a escala planetaria. Sus orígenes se encuentran en la década de los setenta, y sus principales precursores fueron G. P. E. Box y G. M. Jenkins. El objetivo central de esta metodología es crear un modelo estadístico que pronostique el comportamiento de un fenómeno —social, económico o ambiental, entre otros— en el tiempo, tomando como herramienta la inferencia estadística (Rosales, 2009).

El calentamiento global se expresaría de la siguiente forma:

$$Tp=f(t)=\beta_0+\beta_1 t+u_i$$

Donde:

- Tp es la temperatura promedio global
- β_0 es la temperatura promedio global cuando el tiempo es constante
- β_1 es tasa de cambio instantánea que experimenta la temperatura promedio global por cada año transcurrido
- t es tiempo en años (1850-2015)
- u_i es el margen de error que no puede ser explicado por el modelo

A partir de esta expresión algebraica, el modelo de series tiempo estará determinado por un objetivo general, una justificación y sus alcances y límites.

En el contexto anterior, el objetivo general de este trabajo es *pronosticar la dinámica de la temperatura promedio del planeta, a partir de los registros de cambio climático global de la Agencia de Protección del Ambiente de los Estados Unidos, en el periodo de 1850 a 2015*. En cuanto a los alcances y limitaciones de esta investigación, se encuentran los siguientes:

Alcances

- Mediante el desarrollo del modelo de series de tiempo se podrá pronosticar el incremento de la temperatura durante los últimos cien años.
- Se obtendrá la predicción de la temperatura promedio del planeta para el año 2030.

Limitaciones

- La información obtenida de la Agencia de Protección del Ambiente de los Estados Unidos en el periodo de 1850 a 2015 es anual, lo cual solamente proporciona 165 observaciones. Lo deseable sería que se obtuviera información mensual de esos 165 años, con ello se tendría una mejor representatividad del fenómeno.

- En síntesis, el desarrollo de este modelo de series tiempo de la temperatura promedio del planeta únicamente va a pronosticar la dinámica del calentamiento global en el tiempo.

Para el análisis de los datos se utilizó el software EViews, un paquete estadístico de lenguaje propio, para Microsoft Windows, usado principalmente para análisis econométrico y que ha sido desarrollado por Quantitative Micro Software (QMS).

Con base en lo anterior, el comportamiento de la serie se muestra en la figura 1.

Con base en la figura 1, se puede observar que la serie de tiempo tiene tendencia. Por tanto, existe la sospecha de no estacionaridad. Esto también se puede corroborar mediante el correlograma de la temperatura de la tabla 1, en la cual se puede ver que la serie tiene un decrecimiento suavizado, lo que quiere decir que no tiene estacionaridad.

A partir de la tabla 1, una opción más formal es mediante la prueba de raíces unitarias de Dickey-Fuller. En el recuadro de las raíces unitarias se puede observar que con un P-valor de 0.9652 no hay suficiente evidencia estadística para rechazar la hipótesis nula. Por tanto, hay raíz unitaria y no existe estacionaridad. Mediante una serie de diferenciaciones, el modelo más adecuado es el Arima.




Figura 1. Comportamiento de la serie de tiempo del calentamiento global

Fuente: Agencia de Protección del Ambiente de los Estados Unidos

Tabla 1. Primera corrida de series de tiempo

Correlogram of TEMPERATURA

Data: 08/24/16
 Sample: 1850 – 2015
 Incuded observations: 166

<i>Autocorrelación</i>	<i>Partial correlation</i>	<i>AC</i>	<i>PAC</i>	<i>Q-Stat</i>	<i>Prob</i>	
		1	0.927	0.927	145.13	0.000
		2	0.862	0.022	271.41	0.000
		3	0.823	0.156	387.37	0.000
		4	0.799	0.102	497.23	0.000
		5	0.773	0.025	600.77	0.000
		6	0.736	-0.053	695.27	0.000
		7	0.707	0.047	783.03	0.000
		8	0.679	-0.018	864.52	0.000
		9	0.653	0.004	940.29	0.000
		10	0.626	-0.007	1010.4	0.000
		11	0.599	-0.007	1074.9	0.000
		12	0.568	-0.044	1133.4	0.000
		13	0.543	0.026	1187.2	0.000
		14	0.521	-0.002	1237.1	0.000
		15	0.502	0.022	1283.6	0.000
		16	0.478	-0.029	1326.2	0.000
		17	0.451	-0.030	1364.2	0.000
		18	0.428	0.001	1398.7	0.000
		19	0.396	-0.082	1428.4	0.000
		20	0.361	0.077	1455.9	0.000
		21	0.338	-0.016	1481.0	0.000
		22	0.307	-0.030	1503.1	0.000
		23	0.297	-0.066	1521.6	0.000
		24	0.287	0.126	1538.9	0.000
		25	0.266	-0.033	1555.2	0.000
		26	0.249	-0.044	1569.2	0.000
		27	0.235	0.044	1581.7	0.000
		28	0.229	-0.004	1592.8	0.000
		29	0.219	0.034	1603.5	0.000
		30	0.205	-0.001	1613.4	0.000
		31	0.193	-0.025	1622.1	0.000
		32	0.192	0.006	1629.8	0.000
		33	0.183	0.071	1637.5	0.000
		34	0.180	-0.049	1644.6	0.000
		35	0.176	0.052	1651.6	0.000
		36	0.170	0.003	1658.2	0.000

Fuente: elaboración propia

Augmented Dickey-Fuller Unit Root Test on TEMPERATURA

Null Hypothesis: TEMPERATURA has a unit root			
Exogenous: Constant			
Lag Length: 2 (Automatic-based on SIC, maxlag=13)			
		t-Statistic	Prob.*
Augmented Dickey-Fuller	test statistic	0.104479	0.9652
Test critical values:	1% level	-3.470679	
	5% level	-2.879155	
	10% level	-2.576241	

*MacKinnon (1996) one-sided p-values.

Augmented Dickey-Fuller Test Equation

Dependent Variable: D(TEMPERATURA)

Method: Least Squares

Date: 08/24/16

Time: 11:31

Included observations: 163 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
TEMPERATURA(-1)	0.002525	0.024170	0.104479	0.9169
D(TEMPERATURA(-1))	-0.075290	0.078597	-0.957931	0.3396
D(TEMPERATURA(-2))	-0.266787	0.077956	-3.422278	0.0008
C	-0.028954	0.358958	-0.080661	0.9358
R-squared	0.074171	Mean dependent var		0.006258
Adjusted R-squared	0.056703	S.D. dependent var		0.085122
S.E. of regression	0.082674	Akaike info criterion		-2.123598
Sum squared resid	1.086754	Schwarz criterion		-2.047678
Log likelihood	177.070	Hannan-Quinn criter.		-2.092775
F-statistic	4.245994	Durbin-Watson stat		2.087012
Prob(F-statistic)	0.006448			

Fuente: elaboración propia

Tabla 2. Análisis de coeficientes del modelo Arima

Correlogram of Residuals

Date: 08/25/16 Time: 10:06

Sample: 1850 2015

Included observations: 131

Q-statistic probabilities adjusted for 3 ARMA terms

<i>Autocorrelation</i>	<i>Autocorrelation</i>		<i>AC</i>	<i>PAC</i>	<i>Q-Stat</i>	<i>Prob</i>
		1	-0.058	-0.058	0.4494	
		2	0.140	0.137	3.1066	
		3	0.008	0.024	3.1155	
		4	-0.026	-0.045	3.2080	0.073
		5	0.204	0.201	8.9816	0.011
		6	-0.222	-0.204	15.7020	0.001
		7	0.113	0.052	17.5030	0.002
		8	-0.052	0.007	17.8810	0.003
		9	-0.086	-0.114	18.9430	0.004
		10	0.094	0.065	20.2130	0.005
		11	-0.154	-0.054	23.6610	0.003
		12	0.094	-0.004	24.9640	0.003
		13	0.011	0.098	24.9820	0.005
		14	0.002	-0.001	24.9830	0.009
		15	0.092	0.025	26.2620	0.010
		16	0.017	0.119	26.3070	0.015
		17	0.186	0.101	31.5690	0.005
		18	0.002	0.001	31.5690	0.007
		19	0.040	0.038	31.8220	0.011
		20	0.072	0.024	32.6390	0.013
		21	-0.067	-0.063	33.3530	0.015
		22	0.058	0.014	33.8820	0.019
		23	-0.090	-0.043	35.1860	0.019
		24	0.002	-0.025	35.1870	0.027
		25	0.010	0.039	35.2030	0.037
		26	-0.102	-0.065	36.9360	0.033
		27	-0.020	-0.079	37.0030	0.044
		28	-0.102	-0.017	38.7630	0.039
		29	0.040	0.005	39.0310	0.048
		30	-0.019	-0.037	39.0910	0.062
		31	-0.066	-0.030	39.8390	0.068
		32	0.045	-0.031	40.1950	0.081
		33	0.039	0.063	40.4620	0.096
		34	0.024	-0.031	40.5660	0.117
		35	-0.006	-0.027	40.5730	0.142
		36	-0.083	-0.087	41.8460	0.139

Fuente: elaboración propia

Dependent Variable: D(TEMPERATURA, 1)

Method: Least Squares

Date: 08/24/16

Time: 21:09

Sample (adjusted): 1885 2015

Included observations: 131 after adjustments

Convergence achieved after 8 iterations

MA Backcast: 1883 1884

<i>Variable</i>	<i>Coefficient</i>	<i>Std. Error</i>	<i>t-Statistic</i>	<i>Prob.</i>
C	0.006303	0.002173	2.90024	0.0044
AR(32)	-0.215325	0.081230	-2.650808	0.0091
AR(34)	-0.174549	0.080281	-2.174236	0.0315
MA(2)	-0.553907	0.074275	-7.457513	0.0000
R-squared	0.175266	Mean dependent var		0.008321
Adjusted R-squared	0.155784	S.D. dependent var		0.081864
S.E. of regression	0.075218	Akaike info criterion		-2.306795
Sum squared resid	0.718533	Schwarz criterion		-2.219002
Log likelihood	155.0951	Hannan-Quinn criter.		-2.271121
F-statistic	8.996354	Durbin-Watson stat		2.094264
Prob(F-statistic)	0.000019			
Inverted AR Roots	.97+.09i	.97-.09i	.93+.27i	.93-.27i
	.86+.44i	.86-.44i	.76+.60i	.76-.60i
	.63+.73i	.63+.73i	.47-.83i	.47+.83i
	.30+.89i	.30-.89i	.13+.91i	.13+.91i
	.00-.87i	-.00+.87i	-.13-.91i	-.13+.91i
	-.30-.89i	-.30+.89i	-.47-.83i	-.47+.83i
	-.63+.89i	-.63-.73i	-.76+.60i	-.76-.60i
	-.86+.44i	-.86-.44i	-.93-.27i	-.93+.27i
	-.97-.09i	-.97+.09i		
Inverted MA Roots	0.74	-0.74		

Validación del modelo

Tabla 3. Análisis de los residuales del modelo Arima

Breusch-Godfrey Serial Correlation LM Test:				
F-statistic	0.831664	Prob. F(36,91)	0.729	
Obs*R-squared	32.42926	Prob. Chi-Square(36)	0.6392	
Dependent Variable: REDID				
Sample: 1885 2015				
Included observations: 131				
Presample missing value lagged residuals set to zero.				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	-0.000533	0.002549	-0.208942	0.8350
AR(32)	-0.043284	0.151649	-0.285426	0.7760
AR(34)	-0.076090	0.149455	-0.509117	0.6119
MA(2)	-0.758406	0.318855	-2.378530	0.0195
RESID(-1)	0.047604	0.103386	0.460450	0.6463
RESID(-2)	0.848816	0.322247	2.634053	0.0099
RESID(-3)	-0.042064	0.102968	-0.408517	0.6839
RESID(-4)	0.430344	0.201121	2.139727	0.0351
RESID(-5)	0.179413	0.102701	1.746944	0.0840
RESID(-6)	0.014014	0.139892	0.100178	0.9204
RESID(-7)	0.121037	0.106796	1.133345	0.2600
RESID(-8)	0.105230	0.116751	0.901316	0.3698
RESID(-9)	-0.121094	0.107395	-1.127558	0.2625
RESID(-10)	0.161863	0.112567	1.437927	0.1539
RESID(-11)	-0.047989	0.108279	-0.443197	0.6587
RESID(-12)	0.012838	0.111165	0.115483	0.9083
RESID(-13)	0.107445	0.108043	0.994466	0.3226
RESID(-14)	0.024768	0.109832	0.225510	0.8221
RESID(-15)	-0.012428	0.108672	-0.114361	0.9092
RESID(-16)	0.167633	0.111571	1.502479	0.1364
RESID(-17)	0.080186	0.110675	0.755035	0.4522
RESID(-18)	0.001891	0.116314	0.016262	0.9871
RESID(-19)	0.080186	0.113853	0.704293	0.4830
RESID(-20)	0.012463	0.122233	0.101962	0.9190
RESID(-21)	-0.073365	0.123172	-0.595632	0.5529
RESID(-22)	0.031081	0.123916	0.250825	0.8025
RESID(-23)	-0.028180	0.127671	-0.233556	0.8159
RESID(-24)	-0.043905	0.126784	-0.346301	0.7299
RESID(-25)	0.044356	0.130373	0.340228	0.7345
RESID(-26)	-0.033435	0.132605	-0.252139	0.8015
RESID(-27)	-0.110207	0.133456	-0.825790	0.4111
RESID(-28)	-0.065362	0.133700	-0.488872	0.6261
RESID(-29)	0.053100	0.134021	0.396207	0.6929
RESID(-30)	-0.043512	0.136550	-0.318654	0.7507
RESID(-31)	-0.090695	0.133754	-0.677756	0.4996
RESID(-32)	0.050927	0.198825	0.256139	0.7984
RESID(-33)	0.087456	0.127413	0.686401	0.4942
RESID(-34)	0.022657	0.194077	0.116745	0.9073
RESID(-35)	-0.047765	0.121657	-0.392622	0.6955
RESID(-36)	-0.081654	0.123434	-0.661519	0.5100
R-squared	0.247552	Mean dependent var	0.000250	
Adjusted R-squared	-0.074926	S.D. dependent var	0.074345	
S.E. of regression	0.077079	Akaike info criterion	-2.041611	
Sum squared resid	0.540653	Schwarz criterion	-1.163688	
Log likelihood	173.725500	Hannan-Quinn criter.	-1.684871	
F-statistic	0.767655	Durbin-Watson stat	1.968384	
Prob(F-statistic)	0.820883			

Fuente: elaboración propia

Tabla 5. Homocedasticidad y normalidad los residuales del modelo IV

Heteroskedasticity Test: ARCH				
F-statistic	1.078829	Prob.F(1,128)	0.3009	
Obs*R-squared	1.086528	Prob.Chi-Square(1)	0.2972	
Test Equation:				
Dependent Variable: RESID^2				
Method: Least Squares				
Date: 08/25/16 Time: 11:40				
Included observations: 130 after adjustments				
Variable	Coefficient	Std. Error	t-Statistic	Prob.
C	0.0049	0.0009	5.5822	0.0000
RESID^2(-1)	0.0912	0.0088	1.0387	0.3009
R-squared	0.008358	Mean dependent var		0.00544
Adjusted R-squared	0.000611	S.D. dependent var		0.00846
S.E. of regression	0.008458	Akaike info criterion		-6.69206
Sum squared resid	0.009158	Schwarz criterion		-6.64794
Log likelihood	463.9837	Hannan - Quinn criter		-6.67413
F-statistic	1.078829	Durbin - Watson stat		2.03577
Prob(F-statistic)	0.300918			

Fuente: elaboración propia




Tabla 4. Histograma de normalidad

Fuente: elaboración propia

Proyecciones

Para hacer las proyecciones de cualquier modelo es fundamental que se analicen los siguientes conceptos:

- Sesgo de proporción: describe la magnitud de equivocación del modelo en estudio.
- Variancia de proporción: puntualiza la diferenciación de la varianza generada por el modelo en estudio con la varianza de la serie de tiempo original.
- Covarianza de proporción: mide la magnitud de lo no sistemático de la serie de tiempo que explica el modelo.
- Coeficiente de Theil: resume qué tan bueno es el modelo para pronosticar. Toma valores entre 0 y 1.

- 0 es buen ajuste.
- 1 es mal ajuste.

El mejor modelo, es aquel que cumpla con lo siguiente:

- Sesgo de proporción 0
- Variancia de proporción 0
- Covarianza de proporción 1
- Coeficiente de Theil 0

Con base en lo anterior, en la figura 2 se puede observar lo siguiente:




Figura 2. Predicción de la temperatura promedio del modelo IV

Fuente: elaboración propia

Si se realizan proyecciones con el modelo IV, sus indicadores serían los siguientes:

- Sesgo de proporción = 0.5147 ----- (regular)
- Variancia de proporción = 0.1665 ----- (bueno)
- Covarianza de proporción 0.3186 ----- (regular)
- Coeficiente de Theil = 0.008 ----- (excelente)

Con este resultado se podría decir que el modelo es bueno para hacer predicciones sobre el calentamiento global.

A través de esta evaluación, podríamos decir lo siguiente: con un nivel de significancia del 95 %, un margen de error del 5 % y un R2 ajustado del 15.57 %, la temperatura promedio del planeta oscilaría entre 14.55 y 16.33° C, pues para ese año se espera que la temperatura promedio del planeta fuese en promedio de 15.44° C.

Por otro lado, en el modelo se puede ver que en el año 1850 la temperatura era de 14.71° C y que en la actualidad (2016) sería de 15.43° C, con lo cual se diría que la temperatura promedio del planeta durante 166 años se ha incrementado en 0.72° C.

En la figura 3 se puede observar que en el año 1963 la temperatura promedio del planeta presentó fuertes aumentos: era de 15.14° C. Si se compara con la de la actualidad (15.43° C), en 53 años la temperatura promedio se ha incrementado en 0.29 °C.




Figura 3. Comportamiento de la temperatura promedio

Fuente: elaboración propia

Por otro lado, en la figura 4 se observa que en el año 1995 la temperatura promedio del planeta se ha salido fuertemente de sus intervalos. Ello indica que hay sobreexplotación de los recursos, lo cual ha provocado el sobrecalentamiento global, y este a su vez a dado lugar al efecto invernadero.




Figura 4. Descompensación de la temperatura promedio

Fuente: elaboración propia

Conclusiones

Este modelo permite tener un panorama general de las variaciones que ha experimentado el fenómeno del cambio climático, como un fenómeno aleatorio, con un manejo de incertidumbre.

Con este modelo probabilístico se pudo demostrar que la temperatura promedio del planeta se ha incrementado en 0.72°C en 165 años, de 1850 a diciembre de 2016, muy cercano a lo estipulado por el IPCC, con sus modelos estadísticos, que es de 0.74°C .

Adicionalmente, desde 1963, la temperatura promedio del planeta ha tenido un comportamiento creciente, tanto que se ha incrementado en 0.29°C , sin embargo, es hasta 1996 cuando los efectos del incremento de la temperatura promedio han generado efectos negativos sobre el planeta, ya que a partir de esa fecha la temperatura promedio ha oscilado por arriba de los intervalos establecidos por el modelo, posiblemente esto se debe a la sobre explotación de los recursos naturales y a las altas emisiones de gases de efecto invernadero (principalmente el dióxido de carbono y el metano) como resultado de la actividad humana.

Con este modelo de series de tiempo se pudo pronosticar la temperatura promedio del planeta para el año 2030, la cual va a oscilar entre los 14.55 y 16.33°C . La temperatura promedio es de 15.44°C . A modo de comparación, la temperatura en el año 1850 era de 14.71°C y en 2016 fue de 15.43°C . Contando con que las actividades humanas no cambien —pero podemos asegurar que las actividades humanas se irán incrementando, aun exponencialmente—, el modelo nos da un escenario de hasta 16.33°C .

En este contexto, se puede decir que el acelerado crecimiento que ha experimentado la temperatura promedio del planeta a partir del 1963, y que se ha agudizado desde 1996, es resultado de la forma en que han crecido las economías de todo el mundo, las cuales se han sustentado en la sobreexplotación de los recursos naturales.

El medio ambiente, los modelos matemáticos estadísticos y la presente propuesta sobre un modelo matemático probabilístico contribuyen a comprender los fenómenos ambientales, a medir los resultados y a tomar decisiones sobre ellos. Para los ambientalistas, estos modelos no son la solución definitiva sobre un fenómeno, sin embargo, pueden constituir una buena herramienta para conocer los procesos medioambientales y, si es necesario, intervenir en ellos.

Referencias

- Arya, J. y Lardner, R. (2009). *Matemáticas aplicadas a la administración y la economía*. s. l.: Prentice Hall.
- Caballero, M., Lozano, S. y Ortega, B. (2007). *Efecto invernadero, calentamiento global y cambio climático: una perspectiva desde las Ciencias de la Tierra*. México: Revista Digital Universitaria.
- Collazo, A. (2010). *Apuntes sobre el método simplex de programación lineal*. San Juan: Universidad de Puerto Rico.
- Costeau, J. (1992). *Impacto ambiental. El planeta herido*. Recuperado de <http://assets.mheducation.es/bcv/guide/capitulo/84448167155.pdf>
- Eschenhagan, M. (2006). Las cumbres ambientales internacionales y la educación ambiental. *OASIS*, (12), 39-76.
- Ferrero, J. (20 10). *Del calentamiento global al cambio climático ¿una teoría más?* Recuperado de [file:///C:/Users/DELL/Downloads/DialnetDelCalentamientoGlobalAlCambioClimaticoUnaTeoriaMa-3800498%20\(1\).pdf](file:///C:/Users/DELL/Downloads/DialnetDelCalentamientoGlobalAlCambioClimaticoUnaTeoriaMa-3800498%20(1).pdf)
- García, J. y Maheut, J. (2015). *Modelado y resolución de problemas de organización industrial mediante programación matemática lineal (modelos y métodos de investigación de operaciones. Procedimientos para pensar)*. s. l.: Universidad Politécnica de España.

