

Prognosis de tráfico aéreo mediante DLM (Dynamic Linear Models). Aplicación al caso del Aeropuerto de Bogotá-El Dorado

Yesid Rodríguez¹, Wilmer Pineda¹, Oscar Díaz Olariaga^{2*}

¹Facultad de Estadística; ²Facultad de Ingeniería Civil; Universidad Santo Tomás. Bogotá, Colombia.

*OscarDiazOlariaga@usantotomas.edu.co

Presentación: Oral

Area temática (seleccione una opción):

- | | |
|---|---|
| <input type="checkbox"/> Economía del transporte | <input type="checkbox"/> Transporte multimodal y logística de mercancías |
| <input type="checkbox"/> Infraestructura del transporte | <input type="checkbox"/> Transporte, ambiente y ciudad |
| <input type="checkbox"/> Modelación y sistemas inteligentes de transporte | <input type="checkbox"/> Tránsito y accesibilidad del transporte |
| <input type="checkbox"/> Planificación y políticas de transporte | <input checked="" type="checkbox"/> Modos generales y temas transversales al transporte |
| <input type="checkbox"/> Seguridad Vial | |

RESUMEN

El crecimiento del tráfico aéreo en Colombia ha venido reforzado desde la década de 1990 por una política pública de liberalización del espacio aéreo, y por el re-direccionamiento de la inversión pública y privada hacia la modernización y actualización de las infraestructuras aeroportuarias. En el sector aerocomercial, y en este mismo periodo, se privatizó la línea aérea de bandera e ingresaron al mercado nuevos operadores aéreos. Desde el año 2012 las tarifas aéreas están totalmente desreguladas. Como resultado de las políticas públicas y de inversión en las últimas dos décadas y media el transporte de pasajeros en Colombia creció un 863%. Este importante índice de crecimiento ha sido impulsado y liderado por el Aeropuerto de Bogotá-El Dorado (en adelante BOG). Pero tanto los planes maestros de BOG como varios estudios técnicos, estiman un crecimiento de la demanda que la capacidad del aeropuerto actual (y futura) no podrá acomodar. Esta situación dio curso a la aprobación y planificación de nuevo aeropuerto a las afueras de la ciudad de Bogotá, el cual entrará en fase de diseño en 2020. Entonces, se estima de interés el desarrollo formal y (estadísticamente) riguroso de una prognosis de tráfico para BOG, al menos a corto plazo. Por ello, la presente investigación desarrolla una prognosis del tráfico aéreo para BOG, y como metodología de cálculo se utiliza *Dynamic Linear Models* (DLM), los cuales son utilizados en la modelización de series temporales. Con su uso se busca obtener pronósticos usando distribuciones de variables estocásticas que influyen en las observaciones en el tiempo dada nueva información, y con respecto a las metodologías habituales de cálculo de pronóstico presenta las siguientes ventajas: detecta tendencias estocásticas que se encuentran ocultas en las series de tiempo así como la detección de cambios estructurales que permiten estimar el efecto variable en el tiempo de choques exógenos sin aumentar el número de parámetros. Adicionalmente, la estructura de independencia condicional sobre la que se basa la dinámica del estado, permite considerar predicciones considerando un algoritmo recursivo. Y con el fin de determinar la fortaleza en términos numéricos del modelo propuesto se utilizará el *Mean Absolute Percentage Error* (MAPE), el cual mide el tamaño del error (absoluto) en términos porcentuales. Los datos para la investigación se obtienen de AEROCIVIL.

INTRODUCCIÓN

El transporte aéreo colombiano está experimentado un vertiginoso y dinámico desarrollo que dio inicio aproximadamente hace dos décadas y media. Este periodo coincide con el inicio de una continuada implementación de políticas públicas elaboradas específicamente para el sector del transporte aéreo con el objetivo de impulsarlo y potenciarlo. El crecimiento del tráfico aéreo en Colombia ha venido reforzado desde la década de 1990 por una política pública de liberalización del espacio aéreo en los mercados interno y externo, y por el re-direccionamiento de la inversión pública y privada hacia la modernización y actualización de las infraestructuras aeroportuarias, concesionando los aeropuertos de mayor tráfico del país (Díaz Olariaga and Ávila, 2015). La primera generación de concesiones aeroportuarias se implementó en la mitad de la década de 1990, y a partir de ese momento se han desarrollado otras tres generaciones más (Díaz Olariaga, 2017). En el sector aerocomercial, y en este mismo periodo, se privatizó la línea aérea de bandera e ingresaron al mercado nuevos operadores aéreos (privados), incluidas las líneas aéreas de bajo costo (LCC). Desde el año 2012 las tarifas aéreas están totalmente desreguladas (Díaz Olariaga and Zea, 2018).



Como resultado de las políticas públicas, tanto de privatización como de inversión pública en infraestructura aeroportuaria (acompañadas con políticas de desregulación del sector aero comercial), en las últimas dos décadas y media el transporte de pasajeros en Colombia creció un 863% (Díaz Olariaga, 2018). Este importante índice de crecimiento ha sido impulsado y liderado por el principal aeropuerto del país, el Aeropuerto Internacional de Bogotá-El Dorado (en adelante BOG), en la capital del país. Pero tanto los planes maestros de BOG como varios estudios/informes técnicos, no necesariamente rigurosos (desde el punto de vista estadístico), estiman cierto crecimiento de la demanda que dan a entender que la capacidad del aeropuerto actual (y futura, ya que no se prevé ninguna ampliación más) no podrá acomodar la demanda prevista. Esta situación condujo, al sector público, a la aprobación de la construcción de un nuevo aeropuerto a las afueras de la ciudad de Bogotá, el cual se estima entrará en operación en 2025/2026.

Entonces, el objetivo del presente trabajo es realizar un pronóstico para BOG (pasajeros, carga aérea y operaciones aéreas o movimientos) a corto plazo. Para ello, y como metodología de cálculo (original para este tipo de análisis en tráfico aéreo), se utilizará Dynamic Linear Models (DLM) que con respecto a las metodologías habituales de cálculo de pronóstico presenta las siguientes ventajas: detecta tendencias estocásticas que se encuentran ocultas en las series de tiempo (West and Harrison, 2006) así como la detección de cambios estructurales que permiten estimar el efecto variable en el tiempo de choques exógenos sin aumentar el número de parámetros (Honjo et al., 2018). Adicionalmente, la estructura de independencia condicional sobre la que se basa la dinámica del estado permite considerar predicciones considerando un algoritmo recursivo (Petris et al., 2009).

REVISIÓN DE LA BIBLIOGRAFÍA

Existen muchos estudios que abordan los diversos aspectos de la liberalización del transporte aéreo. Estos estudios tratan temas como los efectos espaciales de la desregulación en la conectividad y la accesibilidad (O'Connor, 2003), la competencia del mercado y la consolidación (Goetz, 2002), configuración y estructuras de red (Díaz Olariaga and Zea, 2018; O'Kelly, 1998), los precios de los pasajes aéreos (Vowles, 2006), y las alianzas de aerolíneas (Fan et al., 2001). Otros estudios se enfocan en el análisis de situaciones diversas (p.e. el comportamiento de la demanda) en el contexto post liberalización, particularizados en determinados países o regiones (Tascon Hoyos and Díaz Olariaga, 2018). Por otro lado, Rolim et al. (2016) analizan el desarrollo de la demanda en aeropuertos recientemente privatizados, aplicado al caso de Brasil. Los cambios en la concentración de tráfico en los aeropuertos como resultado de la liberalización también han sido analizados (Rodrigues et al., 2015).

Y en la línea de investigación del presente artículo se encuentran muy pocos aportes, a saber: Sun and Schonfeld (2014) utilizan programas estocásticos para estimar, por un lado, la demanda futura de tráfico, y por otro lado, para optimizar la toma de decisiones en el futuro desarrollo del aeropuerto (inversiones en capacidad) y donde se tienen en cuenta las incertidumbres en las previsiones de tráfico. Todo ello aplicado a mercados o países donde el transporte aéreo está completamente liberalizado. Suryani et al. (2012) utilizando dinámica de sistemas realizan un pronóstico de la demanda de transporte de carga aérea para determinar la capacidad del terminal de carga y su expansión (el estudio se realizó para un conjunto de aeropuertos de Taiwan). Singh et al. (2016), utilizando un modelo econométrico, realizan un estudio de pronóstico tanto del tráfico aéreo como de la inversión en capacidad aeroportuaria, para un periodo de 20 años, para el conjunto del sistema aeroportuario de la India, y en un contexto de post-liberalización de la industria del transporte aéreo. Scarpel (2013) utiliza modelos expertos para pronosticar la demanda de pasajeros aéreos en el Aeropuerto de Sao Paulo (Brasil), en un contexto de liberalización del transporte aéreo y de privatización de aeropuertos. Díaz Olariaga et al. (2017) estimaron los efectos que ejerce sobre la futura demanda de pasajeros la privatización de los aeropuertos en Colombia, para ello utilizaron la metodología de Box-Jenkins usando modelos ARIMAX. Y finalmente, Carmona-Benítez et al. (2017) utilizan un modelo dinámico econométrico para estimar la demanda de pasajeros, donde el caso de estudio es el sistema de transporte aéreo de México.

METODOLOGÍA Y DATOS

En cualquier aplicación estadística un paso crucial y a menudo difícil es la especificación cuidadosa del modelo. La primera estrategia es un modelo estático donde el efecto del tiempo no desempeña un papel relevante. Para la presente investigación se escogen los Dynamic Models (DMs), que al contrario a los estáticos algunos de los elementos que intervienen en la

construcción del modelo no permanecen invariables, sino que se consideran como funciones del tiempo, describiendo trayectorias temporales (Glynn et al., 2019).

Los Dynamic Models (DMs) tienen la ventaja de tener una “dinámica” en los parámetros del modelo, haciendo que los parámetros no sean fijos sino que cambien o dependan del tiempo. Tienen como principal aplicación el análisis de series temporales, además su ventaja radica en la utilidad a la hora de realizar análisis secuenciales, ya que la actualización de los parámetros se hace en base a datos que han sido obtenidos secuencialmente.

El desarrollo de pronósticos comúnmente se basa en modelos de tipo autoregresivos, medias móviles o su combinación, sin embargo dichos modelos tienen una función de verosimilitud complicada y por lo tanto las distribuciones finales de los parámetros heredan la misma dificultad. Por lo anterior, aparecen los Dynamic Linear Models (DLMs), que son un caso particular de los Dynamic Models (DMs), los cuales son utilizados en la modelización de series temporales, con su uso se busca obtener pronósticos usando distribuciones de variables estocásticas que influyen en las observaciones en el tiempo. Dentro de las ventajas que se tienen con su uso se puede destacar que son modelos más simples, son muy poderosos para ajustar y pronosticar datos, y se pueden incluir variables explicativas de forma simple (Sargan and Bhargava, 1983; Ahn and Schmidt, 1995; Arellano and Bond, 1991; Arellano and Bover, 1995; Gelman et al., 2013; Kenkel, 2018). Los DLMs se definen bajo la siguiente estructura para cada tiempo t (Valencia and Correa, 2013; Bolstad, 2007; Glynn et al., 2019; Asparouhov et al., 2018):

$$\text{Ecuación de observación: } \mathbf{Y}_t = \mathbf{F}_t' \boldsymbol{\theta}_t + \mathbf{v}_t, \mathbf{v}_t \sim N(\mathbf{0}, \mathbf{V}_t)$$

$$\text{Ecuación de sistema: } \boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \mathbf{w}_t, \mathbf{w}_t \sim N(\mathbf{0}, \mathbf{W}_t)$$

donde:

\mathbf{F}_t es una matriz de regresión dinámica conocida.

\mathbf{G}_t es una matriz de estado conocida.

\mathbf{V}_t es una matriz de varianza observacional conocida.

\mathbf{W}_t es una matriz de evolución conocida.

$\boldsymbol{\theta}_t$ es un vector de parámetros.

En el tiempo 0 se postula una distribución a priori para $(\boldsymbol{\theta}_0 | D_0)$ donde D_0 representa la información disponible hasta el tiempo cero. West and Harrison (2006) sugieren: $(\boldsymbol{\theta}_0 | D_0) \sim N(\mathbf{m}_0, \mathbf{C}_0)$, donde \mathbf{m}_0 y \mathbf{C}_0 son el vector de medias y la matriz de varianzas y covarianzas, respectivamente.

La ecuación de observación define el modelo observacional para una respuesta \mathbf{Y}_t y su relación con p covariables o variables explicativas \mathbf{F}_t . La primera variable explicativa es por lo general una constante o intercepto que representa el nivel de la serie. Como \mathbf{F}_t es univariado entonces $\boldsymbol{\theta}_t$ es un vector de la forma $(\theta_{0t}, \theta_{1t}, \dots, \theta_{p-1t})'$. Es posible considerar a \mathbf{Y}_t como multivariado, en cuyo caso $\boldsymbol{\theta}_t$ es una matriz de dimensión $m \times p$.

La ecuación de sistema, presenta la evolución de los parámetros en el tiempo. Si el modelo incluye p coeficientes cambiantes, se tendrá que la evolución se definirá como una matriz de transición \mathbf{G}_t de dimensión $p \times p$.

Por último, los DLMs tienen errores \mathbf{v}_t y \mathbf{w}_t con varianzas dependientes del tiempo \mathbf{V}_t y \mathbf{W}_t que denotan la matriz de varianza observacional y la varianza de evolución respectivamente.

En el tratamiento de las series temporales, es suficiente el considerar que para los DLMs una fuente de variabilidad, que funciona para representar los errores en la ecuación de observación y en la ecuación del sistema, la cual se denomina vector de efectos permanentes. Aunque aparentemente tiene mayores restricciones, se presenta como caso particular a algunos de los modelos clásicos de series temporales, y en particular los modelos ARMA. Su tratamiento se realiza a través del filtro de Kalman cuando los términos de error de la ecuación de observación siguen una distribución normal, son independientes e idénticamente distribuidos de media 0 y varianza conocida.

Con el fin de determinar la fortaleza en términos numéricos del modelo propuesto se utilizará el Mean Absolute Percentage Error (MAPE), el cual mide el tamaño del error (absoluto) en términos porcentuales, el hecho que se estime una magnitud del error porcentual lo hace un indicador frecuentemente utilizado por los desarrolladores pronósticos debido a su fácil

interpretación. Un valor del MAPE pequeño indica que los pronósticos son los adecuados y que tendrán una mayor posibilidad de ser unos pronósticos acertados (Kim and Kim, 2016; Ren and Glasure, 2009).

Del aeropuerto de estudio se dispone datos de tráfico aéreo (pasajeros, carga aérea y operaciones o movimientos aéreos) de las últimas cuatro décadas (1979-2017) (Aerocivil, 2019), situación similar con datos socio-económicos de la ciudad a la que sirve al aeropuerto (PIB, PIB/cápita, población, etc.) (DANE, 2019; Banco de la República de Colombia, 2019). De acuerdo a las variables seleccionadas como covariables, se presentará un pronóstico a corto plazo dado lo cambiante de la economía y sus efectos sobre el tráfico aéreo, para ello se pronosticarán los años 2018 a 2022. Para llegar a dicho pronóstico se debe realizar primero pronósticos utilizando modelos ARIMA (Brooks, 2008) sobre las covariables seleccionadas con el fin de incluir estos nuevos valores en el modelo seleccionado buscando obtener un MAPE relativamente bajo.

CASO DE ESTUDIO

El Colombia la industria de la aviación está liberalizada desde principios de la década de 1990, y las tarifas aéreas están totalmente desreguladas desde el año 2012. Dentro de este contexto nacional se escoge como caso de aplicación del método de pronóstico propuesto el Aeropuerto Internacional de Bogotá-El Dorado (código IATA: BOG; código OACI: SKBO), principal aeropuerto del país (and main country hub), situado en la ciudad de Bogotá (capital de Colombia, y con más de 8 millones de habitantes) a 12 Km del centro de la ciudad. El aeropuerto es de propiedad pública pero con operación concesionada al sector privado desde el año 2007 (Díaz Olariaga, 2017), año en que el aeropuerto desarrolló una primera (e importante) ampliación de su infraestructura e instalaciones (con una inversión de USD 650 millones) que culminó en el año 2013. En el año 2105 inició una segunda ampliación que finalizó a finales de 2018. En el aeropuerto trabajan alrededor de 25.000 personas. BOG es el tercer terminal por transporte de pasajeros y primero por carga aérea transportada de Latinoamérica (Díaz Olariaga and Ávila, 2015).

RESULTADOS

Para el caso de la variable "pasajeros nacionales" se utilizó como variable auxiliar para la estimación del pronóstico a futuro el IPC (Índice de Precios al Consumidor), el resultado se muestra en la Figura 1.

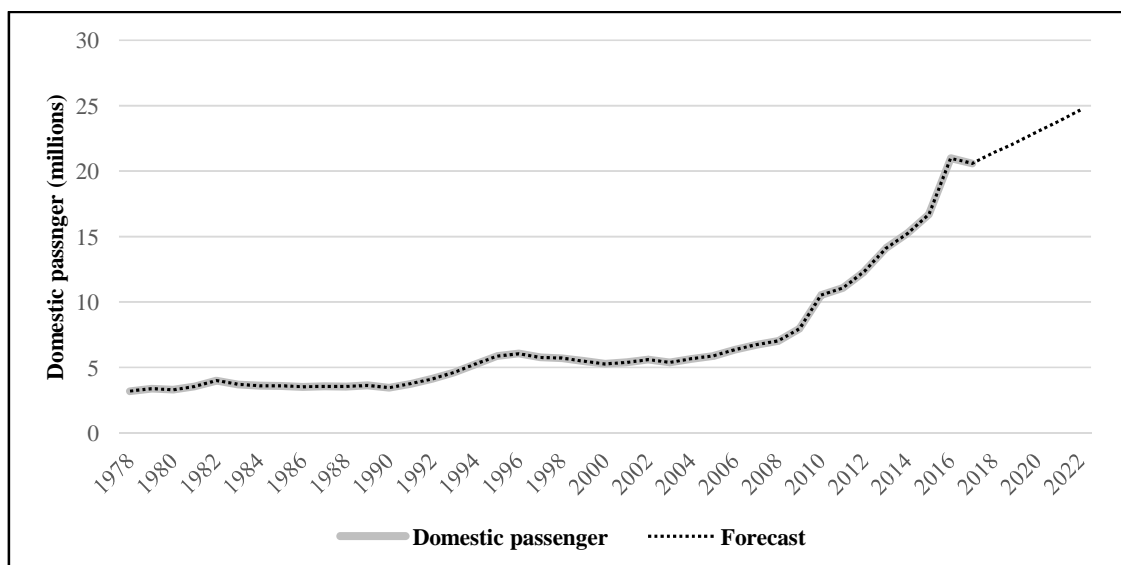


Fig. 1. Modelo 1, pronóstico de la variable pasajeros nacionales.

En la Fig. 1 se presenta el Modelo 1 en el cual se observa el comportamiento de los valores estimados por modelo seleccionado, los cuales se traslapan con el comportamiento de los valores originales, además se cuenta con un MAPE de 1,08% (ver tabla 1). Para la realización de la estimación del pronóstico se utilizó un modelo ARIMA(2,1,0) en la variable IPC con el fin de realizar un pronóstico de 5 años y así poder ser incluidos en el pronóstico de la variable pasajeros nacionales.

Tabla 1. Comparación de valores de MAPE para el Modelo 1.

Modelo	MAPE	Variabes
1	0,01082	Pasajeros nacionales, IPC
2	0,01630	Pasajeros nacionales, PIB per cápita
3	0,02560	Pasajeros nacionales, pasajeros nacionales con rezago t-1
4	0,02884	Pasajeros nacionales, PIB per cápita, IPC

Para el caso de la variable "pasajeros internacionales" se utilizaron como variables auxiliares para la estimación del pronóstico a futuro las variables PIB, Población y TRM (Tasa Representativa del Mercado, es decir el tipo de cambio COP/USD), obteniendo como el resultado el Modelo 2 (ver Fig. 2).

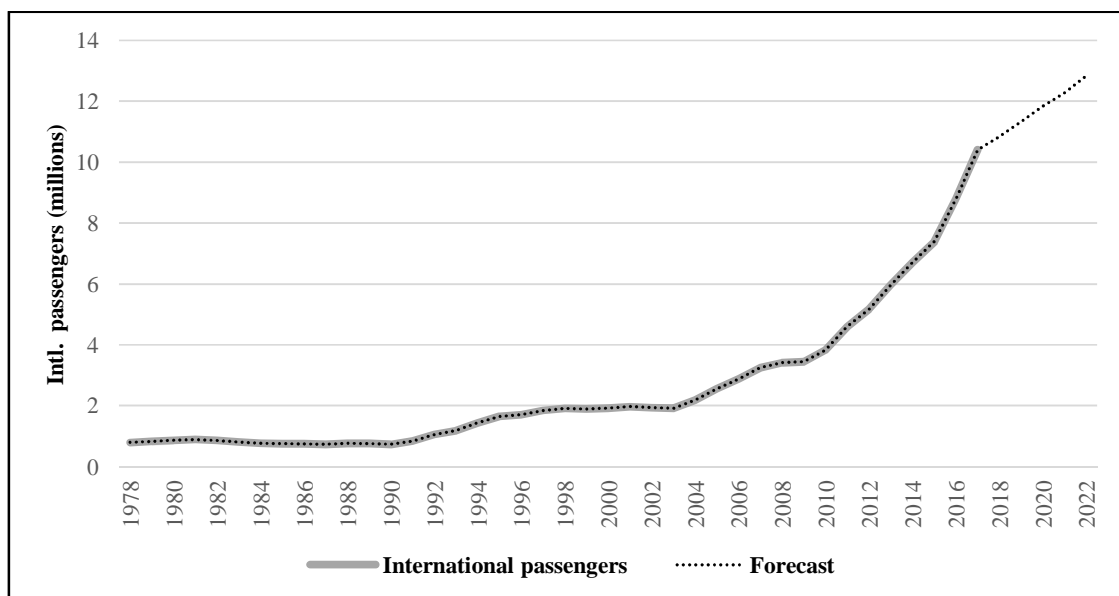


Fig. 2. Modelo 2, pronóstico de la variable pasajeros internacionales.

En la Figura 2 se presenta el Modelo 2 en el cual se observa el comportamiento de los valores estimados por el modelo, los cuales se traslapan con el comportamiento de los valores originales, además se cuenta con un MAPE de 0,97% (ver Tabla 2). Para la realización de la estimación del pronóstico se utilizó un modelo ARIMA(3,1,0) en la variable PIB, un modelo ARIMA(1,1,0) en la variable población y un modelo ARIMA(2,1,0) en la variable TRM, para realizar un pronóstico de 5 años y así ser incluidos en el pronóstico de la variable pasajeros internacionales.

Tabla 2. Comparación de valores de MAPE para el Modelo 2.

Modelo	MAPE	Variables
1	0,0097555	Pasajeros internacionales, PIB, población, TRM
2	0,0111818	Pasajeros internacionales, TRM
3	0,0114201	Pasajeros internacionales, población
4	0,0122443	Pasajeros internacionales, PIB
5	0,0137127	Pasajeros internacionales, PIB, TRM
6	0,0156288	Pasajeros internacionales, PIB, población
7	0,0163126	Pasajeros internacionales, PIB
8	0,0195899	Pasajeros internacionales, Pasajeros internacionales con rezago t-1

Para el caso de la variable "operaciones" (despegues / aterrizajes, donde se incluye tanto las nacionales como las internacionales), se utilizaron como variables auxiliares para la estimación del pronóstico a futuro las variables PIB per cápita, población y TRM, obteniendo el resultado el Modelo 3 (ver Fig. 3). En la Figura 3 se presenta el Modelo 3 en el cual se observa el comportamiento de los valores estimados por el modelo, los cuales se traslapan con el comportamiento de los valores originales, además se cuenta con un MAPE de 0,24% (ver Tabla 3). Para la realización de la estimación del pronóstico se utilizó un modelo ARIMA(3,1,0) en la variable PIB per cápita, un modelo ARIMA(1,1,0) en la variable población y un modelo ARIMA(2,1,0) en la variable TRM, para realizar un pronóstico de 5 años y así ser incluidos en el pronóstico de la variable operaciones.




Fig. 3. Modelo 3, pronóstico para la variable operaciones (o movimientos) (totales: nacionales + intl.).

Tabla 3. Comparación de valores de MAPE para el Modelo 3.

Modelo	MAPE	Variables
1	0,00245412	Operaciones, PIB per cápita, población, TRM
2	0,00259602	Operaciones, población, TRM
3	0,00266953	Operaciones, PIB per cápita, TRM
4	0,00418937	Operaciones, TRM
5	0,00439192	Operaciones, Operaciones con rezago t-1
6	0,0047898	Operaciones, PIB per cápita
7	0,00646659	Operaciones, PIB per cápita, población
8	0,00839123	Operaciones, población

Para el caso de la variable "carga aérea nacional", se utilizaron como variables auxiliares para la estimación del pronóstico a futuro las variables PIB per cápita y población, obteniendo el resultado mostrado el Modelo 4. En la Fig. 4 se presenta el Modelo 4 en el cual se observa el comportamiento de los valores estimados por el modelo, los cuales se traslapan con el comportamiento de los valores originales, además se cuenta con un MAPE de 0,42% (ver Tabla 4). Para la realización de la estimación del pronóstico se utilizó un modelo ARIMA(3,1,0) en la variable PIB per cápita y un modelo ARIMA(1,1,0) en la variable población, para realizar un pronóstico de 5 años y así ser incluidos en el pronóstico de la variable carga aérea nacional.

Tabla 4. Comparación de valores de MAPE para el Modelo 4.

Modelo	MAPE	Variables
1	0,0042948	Carga aérea nacional, PIB per cápita, población
2	0,00438331	Carga aérea nacional, población
3	0,00951284	Carga aérea nacional, PIB per cápita
4	0,01479821	Carga aérea nacional, carga aérea nacional con rezago t-1

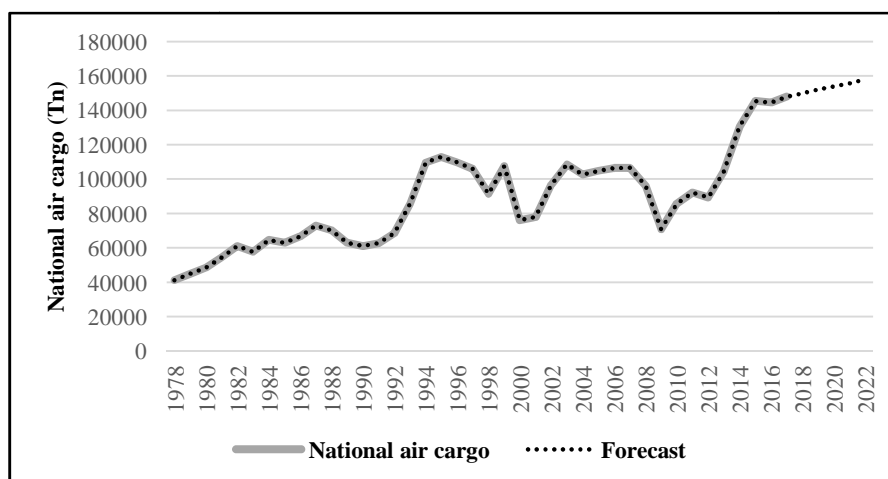


Fig. 4. Modelo 4, pronóstico para la variable carga aérea nacional.



Para el caso de la variable "carga aérea internacional" se utilizaron como variables auxiliares para la estimación del pronóstico a futuro las variables PIB y comercio internacional (importaciones y exportaciones), obteniendo el Modelo 5 (ver Fig. 5).

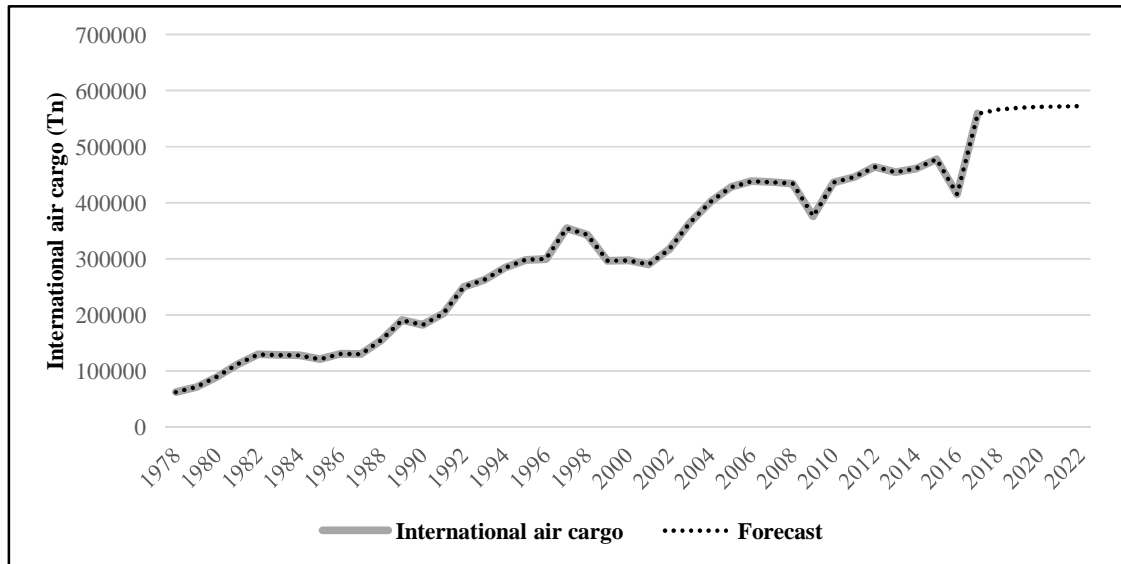


Fig. 5. Modelo 5, pronóstico para la variable carga aérea internacional.

En la Fig. 5 se presenta el modelo 5 en el cual se observa el comportamiento de los valores estimados por el modelo, los cuales se traslapan con el comportamiento de los valores originales, además se cuenta con un MAPE de 0,63% (ver Tabla 5). Para la realización del pronóstico se utilizó un modelo ARIMA(3,1,0) en la variable PIB, un modelo ARIMA(1,1,0) en la variable importaciones y un modelo ARIMA(1,1,0) en la variable exportaciones, para realizar un pronóstico de 5 años y así ser incluidos en el pronóstico de la variable carga aérea internacional.

Tabla 5. Comparación de valores de MAPE para el Modelo 5.

Modelo	MAPE	Variabes
1	0,00633563	Carga aérea internacional, importaciones, exportaciones
2	0,00750094	Carga aérea internacional, PIB, exportaciones
3	0,00762745	Carga aérea internacional, PIB, importaciones, exportaciones
4	0,00840434	Carga aérea internacional, PIB, importaciones
5	0,00891068	Carga aérea internacional , carga aérea internacional con rezago t-1
6	0,01684195	Carga aérea internacional, exportaciones
7	0,02385259	Carga aérea internacional, importaciones
8	0,02820351	Carga aérea internacional, PIB

CONCLUSIONES

Dadas las ventajas del uso de los DLMS en el pronóstico de series de tiempo, primero se realizó una descripción inicial de las variables, las cuales evidenciaron un comportamiento creciente, además de fuertes correlaciones en el tiempo con las covariables. Para las covariables usadas en los modelos, se utilizó un modelo ARIMA con el fin de realizar su pronóstico a futuro y dichos valores ser incluidos en el modelo seleccionado. El resultado de la aplicación de los DLMS, presenta valores de MAPE por debajo del 1%, lo cual garantiza pronósticos de alta predictibilidad. En otro orden, se verificó que al comparar el modelo escogido con los modelos que comparaban la variable con el rezago t-1 (lo cual es el equivalente los modelos AR(1)) los DLMS mostraron superioridad dando una nueva alternativa de modelos para desarrollar pronósticos fiables en transporte aéreo (o pronosis de tráfico aéreo), al menos a corto plazo.

REFERENCIAS

- Aerocivil (2019). Estadísticas. <http://www.aerocivil.gov.co/atencion/estadisticas-de-las-actividades-aeronauticas>
- Ahn, S.; Schmidt, P. (1995). Efficient Estimation of Models for Dynamic Panel Data. *Journal of Econometrics*, 68, 5-27.
- Arellano, M.; Bond, S. (1991). Some tests of specification for panel data: Monte Carlo evidence and an application to employment equations. *The review of economic studies*, 58 (2), 277-297.
- Arellano, M.; Bover, O. (1995), Another Look at the Instrumental Variable Estimation of Error-Components Models, *Journal of Econometrics*, 68, 29-51.
- Asparouhov, T.; Hamaker, E.; Muthén, B. (2018). Dynamic structural equation models. *Structural Equation Modeling: A Multidisciplinary Journal*, 25(3), 359-388.
- Banco de la República de Colombia (2019). Estadísticas. <http://www.banrep.gov.co/es/-estadisticas>
- Bolstad, W. (2007). *Introduction to Bayesian Statistics*. Hamilton (NZ): Wiley.
- Brooks, C. 2008. *Introductory econometrics for finance*. 2a ed. Cambridge University Press. Cambridge, Reino Unido. 648 p
- Carmona-Benítez, R.; Nieto, M.; Miranda, D. (2017). An Econometric Dynamic Model to estimate passenger demand for air transport industry. *Transportation Research Procedia*, 25, 17–29.
- DANE - Departamento Administrativo Nacional de Estadística (2019). <https://www.dane.gov.co/index.php/estadisticas-por-tema>
- Díaz Olariaga, O.; Zea, J.F. (2018). Influence of the liberalization of the air transport industry on configuration of the traffic in the airport network. *Transportation Research Procedia*, 33, 43-50.
- Díaz Olariaga, O. (2018). Prognosis de tráfico aéreo en contexto de post-liberalización del transporte aéreo. El caso de Colombia. *Working Paper*. DOI: 10.13140/RG.2.2.11443.73760
- Díaz Olariaga, O. (2017). Políticas de privatización de aeropuertos. El caso de Colombia. *Documentos y Aportes en Administración Pública y Gestión Estatal*, 29, 7-35.
- Díaz Olariaga, O.; Girón Amaya, E.; Mora-Camino, F. (2017). Pronóstico de la demanda de pasajeros en aeropuertos privatizados. *VI Congreso Internacional de la Red Iberoamericana de Investigación en Transporte Aéreo*. 10-12 octubre 2017, Santiago de Chile.
- Díaz Olariaga, O.; Ávila Álvarez, J. (2015). Evolution of the airport and air transport industry in Colombia and its impact on the economy. *Journal of Airline and Airport Management*, 5(1), 39-66.
- Fan, T.; Vigeant-Langlois, L.; Geissler, C.; Bosler, B.; Wilmaking, J. (2001). Evolution of global airline strategic alliance and consolidation in the twenty-first century. *Journal of Air Transport Management*, 7(6), 349–360.
- Gelman, A., Carlin, J. B., Stern, H. S., Dunson, D. B., Vehtari, A., & Rubin, D. B. (2013). *Bayesian data analysis* (3rd ed.). London, England: Chapman & Hall/CRC Press.
- Glynn, C.; Tokdar, S. T.; Howard, B.; Banks, D. L. (2019). Bayesian Analysis of Dynamic Linear Topic Models. *Bayesian Analysis*, 14(1), 53-80.
- Goetz, A. (2002). Deregulation, competition, and antitrust implications in the US airline industry. *Journal of Transport Geography*, 10(1), 1–19.



- Honjo, K.; Shiraki, H.; Ashina, S. (2018). Dynamic linear modeling of monthly electricity demand in Japan: Time variation of electricity conservation effect. *PLoS one*, 13(4), e0196331.
- Kenkel, J. (2018). *Dynamic Linear Economic Models*. London: *Routledge*.
- Kim, S.; Kim, H. (2016). A new metric of absolute percentage error for intermittent demand forecasts. *International Journal of Forecasting*, 32(3), 669-679.
- O'Connor, K. (2003). Global air travel: toward concentration or dispersal? *Journal of Transport Geography*, 11(2), 83-92.
- O'Kelly, M. (1998). A geographer's analysis of hub-and-spoke networks. *Journal of Transport Geography*, 6(3), 171-186.
- Petris, G.; Petrone, S., Campagnoli, P. (2009). *Dynamic Linear Models with R*. New York: Springer.
- Ren, L.; Glasure, Y. (2009). Applicability of the revised mean absolute percentage errors (mape) approach to some popular normal and non-normal independent time series. *International Advances in Economic Research*, 15(4), 409.
- Rodrigues, R.; Estrada, M.; Fernandes, E. (2015). Spatial concentration and connectivity of international passenger traffic at Brazilian airports. *Journal of Air Transport Management*, 46, 49-55.
- Rolim, P.S.W.; Bettini, H.F.A.J.; Oliveira, A.V.M. (2016). Estimating the impact of airport privatization on airline demand: A regression-based event study. *Journal of Air Transport Management*, 54, 31-41.
- Sargan, J.; Bhargava, A. (1983). Testing Residuals from Least Squares Regression for Being Generated by the Gaussian Random Walk. *Econometrica*, 51, 153-174.
- Scarpel, R.A. (2013). Forecasting air passengers at São Paulo International Airport using a mixture of local experts model. *Journal of Air Transport Management*, 26, 35-39.
- Singh, D.P.; Dalei, N.N.; Raju, B. (2016). Forecasting investment and capacity addition in Indian airport infrastructure: Analysis from post-privatization and post-economic regulation era. *Journal of Air Transport Management*, 53, 218-225.
- Sun, Y.; Schönfeld, P. (2015). Stochastic capacity expansion models for airport facilities. *Transportation Research Part B*, 80, 1-18.
- Suryani, E.; Chou, S-Y; Chen, C-H (2012). Dynamic simulation model of air cargo demand forecast and terminal capacity planning. *Simulation Modelling Practice and Theory*, 28, 27-41.
- Tascón Hoyos, D.; Díaz Olariaga, O. (2018). Analysis of behavior of air passenger demand through system dynamics. *21st EURO Working Group on Transportation Meeting*, 17-19 September 2018, Braunschweig, Germany.
- Valencia, M.; Correa, J. (2013). Un Modelo Dinámico Bayesiano para el Pronóstico de Energía Diaria. *Revista Ingeniería Industrial*, 12(2), 7 - 17.
- Vowles, T. (2006). Airfare pricing determinants in hub-to-hub markets. *Journal of Transport Geography*, 14(1), 15-22.
- West, M.; Harrison, J. (2006). *Bayesian forecasting and dynamic models*. New York: Springer Science & Business Media.