

# Un modelo de datos panel dinámico para analizar el tráfico de datos en terabytes per cápita para una selección de países pertenecientes a la OCDE

José Alberto Candelaria Barrera

jose.candelaria@ift.org.mx. Centro de Estudios . Instituto Federal de Telecomunicaciones.

1

## Abstract

Esta investigación analiza de forma empírica la relación entre el tráfico de información en los centros de datos de Internet medidos bajo la unidad de los terabytes en términos per cápita, con variables como el PIB per cápita y el número de suscriptores a tecnologías 3G y 4G. El análisis se lleva a cabo mediante un modelo de datos panel dinámico bajo la metodología del método general de momentos de Arellano y Bond. La frecuencia de las observaciones es del orden trimestral y va del año 2013 al 2016, para 14 países pertenecientes a la Organización para la Cooperación y el Desarrollo Económico (OCDE).

## Palabras clave:

**Clasificación JEL:** C23, C26, L96

## 1 Introducción

De acuerdo con el Global Cloud Index de Cisco<sup>2</sup> está pronosticado que para finales de la presente década el tráfico mundial de datos en Internet alcance los 15.3 zettabytes (ZB), a una razón de 1.3 ZB al mes. Esta cifra es tres veces superior al dato para el año 2015 el cual fue del orden de los 4.7 ZB. Es así que el tráfico de datos a partir de una dirección IP crecerá a una tasa de crecimiento anual del orden del 27%, de 2015 a 2020. En este sentido consideramos relevante analizar a la variable del tráfico de datos en Internet, medida en terabytes (TB) a nivel per cápita, y su relación con una variable de carácter económico como el PIB per cápita y variables de penetración de las

---

<sup>1</sup>**Descargo de responsabilidad:** El contenido de este artículo es completa responsabilidad del autor y no representa la opinión del Instituto Federal de Telecomunicaciones (IFT) o de sus empleados. Cuaquier pregunta referente al artículo se tiene que comunicar de forma directa con el autor.

<sup>2</sup><https://www.cisco.com/c/dam/en/us/solutions/collateral/service-provider/global-cloud-index-gci/white-paper-c11-738085.pdf>

tecnologías como el número de suscriptores a tecnologías 3G y 4G, para una selección de 14 países pertenecientes a la OCDE, incluyendo a México. Para este propósito se hace uso de un modelo de datos panel dinámico (por sus siglas en inglés, DPD) siguiendo la metodología del método general de momentos (por sus siglas en inglés, GMM), de Arellano y Bond (1991). Esta metodología es de utilidad cuando existe la sospecha sobre la existencia de una correlación dinámica entre la variable explicada (el tráfico de datos en TB en este caso) con su propio valor rezagado. Asimismo, se plantea la utilización de una transformación de las observaciones conocida como forward orthogonal deviations (FOD), con el objeto de mitigar la pérdida de datos que usualmente se encuentra asociada con la transformación en primeras diferencias.

Diversos autores como Bruce (1989) y Singh (1999) han reconocido la importancia y el potencial que tiene el sector de las telecomunicaciones para acelerar el ritmo de desarrollo de las naciones, en especial de los países en vías de desarrollo. En este sentido existen cantidad de estudios que analizan el impacto de la penetración de tecnologías como la banda ancha fija sobre la tasa de crecimiento del PIB per cápita (Quiang, Rossotto y Kimura, 2009; Scott, 2012). Por otra parte, problemas como el de endogeneidad o la doble causalidad suelen hacerse presentes, para lo cual varios estudios optan por la selección de variables instrumentales. En este sentido, el modelo DPD-GMM propuesto en el presente trabajo tiene la ventaja de que las variables instrumentales a considerar son “internas” y no “externas”; es decir, éstas se encuentran basadas en los rezagos de las propias variables instrumentadas.

El artículo se encuentra organizado de la siguiente forma. La sección 2 presenta el modelo de datos panel dinámico bajo la metodología del método general de momentos, así como una explicación acerca de la transformación Forward Orthogonal Deviations (FOD). La sección 3 describe nuestra muestra así como las variables utilizadas. La sección 4 se refiere a los resultados de nuestro modelo; en tanto que la sección 5 presenta nuestras conclusiones.

## 2 Modelo de datos panel dinámico - metodología GMM

En el contexto de los modelos de datos panel usualmente se tiene que lidiar con el problema de la heterogeneidad no-observada, lo cual ocurre cuando se utiliza la transformación de las observaciones conocida como *demeaning*. Ésta se refiere a la resta del promedio de las observaciones con respecto a cada observación, i.e.  $x_{it} - \bar{x}$ . La utilización del método *demeaning* genera correlación entre el regresor y el término de error ( $\varepsilon_{it}$ ), a la cual se le otorga el nombre de sesgo de Nickell (1981). Dicho sesgo se presenta particularmente cuando se cuenta con pocas observaciones en el tiempo ( $T$ ) y muchos individuos en el panel ( $N$ ). Particularmente, el sesgo ocurre en la estimación del coeficiente de la variable dependiente rezagada, el cual no tiende a mitigarse ni cuando se incrementa el número de individuos. Asimismo, dicho regresor no se distribuye de forma independiente del término de error ( $\varepsilon_{it}$ ). Por otra parte, Nickell demostró que la inconsistencia del término  $\hat{\beta}_1$  conforme  $N \rightarrow \infty$  es del orden  $1/T$ , el cual es bastante considerable

en un escenario en el que  $T$  es pequeño. Aunado a lo anterior, el sesgo se presenta aún en el caso en el que  $\varepsilon_{it}$  sea independiente e idénticamente distribuido. En tanto que el problema se agravaría aún más si el proceso del término de error ( $\varepsilon_{it}$ ) fuera autocorrelacionado, ya que se incrementaría la dificultad de derivar un estimador consistente.

Una solución a dicho problema consiste en la transformación en primeras diferencias del modelo original, la cual, a su vez, remueve el término constante y el efecto individual fijo.

$$y_{it} = \beta_0 + \beta_1 y_{i,t-1} + \beta_2 X_{it} + u_i + \varepsilon_{it} \quad (1)$$

$$\Delta y_{it} = \beta_1 \Delta y_{i,t-1} + \beta_2 \Delta X_{it} + \Delta \varepsilon_{it} \quad (2)$$

Sin embargo, a pesar de esta transformación sigue existiendo correlación entre la variable dependiente rezagada en diferencias ( $\Delta y_{i,t-1}$ ) y el término de error en diferencias ( $\Delta \varepsilon_{it}$ ). Aún así, sin la presencia de los efectos fijos es posible utilizar como variables instrumentales para el rezago de la variable dependiente en diferencias ( $\Delta y_{i,t-1}$ ) a los propios rezagos de la variable dependiente en niveles o a los rezagos de sus diferencias. Por otra parte, si el término de error es *i.i.d.*, los rezagos de la variable dependiente  $y_{it}$  se encontrarán correlacionados con la variable dependiente rezagada en diferencias ( $\Delta y_{i,t-1}$ ), pero no lo estarán con el término de error.

Una de las mayores virtudes de los modelos DPD es que al contener uno o más rezagos de la variable dependiente permite el modelado de un mecanismo de ajuste parcial. Asimismo, el modelo de datos panel bajo la metodología GMM de Arellano y Bond se basa en la noción de que el enfoque tradicional de variables instrumentales no explota toda la información disponible de la muestra, ni toma en cuenta todas las condiciones de ortogonalidad. En tanto que el método GMM construye estimaciones más eficientes. Es así como Arellano y Bond asumen que las únicas variables instrumentales necesarias son “internas”; es decir, basadas en valores rezagados de las variables instrumentadas. De acuerdo a Roodman (2009) el método DPD-GMM produce estimaciones que hacen muy pocos supuestos acerca del proceso generador de datos subyacente.

En suma, el modelo DPD bajo la metodología GMM de Arellano y Bond está diseñado para aquellos paneles de datos en los que existe una gran cantidad de individuos ( $N$ ) y muy pocas observaciones en el tiempo ( $T$ ); así como cuando la relación existente entre las variables es lineal y la variable dependiente es dinámica, es decir, se encuentra en función de sus propias realizaciones pasadas. Aunado, en el modelo DPD-GMM los regresores no son estrictamente exógenos y pueden encontrarse correlacionados tanto con realizaciones pasadas como presentes del término de error.

Es así que la metodología de Arellano y Bond comienza por transformar a todos los regresores, usualmente mediante primeras diferencias, y, posteriormente, utiliza el método GMM. Esta es la razón por la cual se le conoce como método GMM en diferencias. Posteriormente, Arellano y Bover (1995) y Blundell y Bond (1998) extendieron la idea original de Arellano y Bond asumiendo que las primeras diferencias de las variables instrumentales no se encuentran correlacionadas con los efectos fijos. Ésto permite la introducción de más instrumentos, lo cual incrementa la eficiencia del modelo. Es así como se construye un sistema de dos ecuaciones, la ecuación original y la transformada, al cual se le conoce como “sistema GMM”.

## 2.1 Transformación: Forward Orthogonal Deviation (FOD)

La transformación en primeras diferencias reduce la muestra de datos y amplifica los espacios vacíos en paneles de datos que no se encuentran balanceados. Por ejemplo, si  $y_{it}$  es un dato faltante, entonces tanto  $\Delta y_{it}$  como  $\Delta y_{it+1}$  serían datos faltantes en la muestra de datos transformada mediante primeras diferencias. En función de lo anterior es que se prefiere utilizar a la transformación conocida como *forward orthogonal transformation* (FOD) (Arellano y Bover, 1995). En contraste con la transformación en primeras diferencias, la cual resta el valor anterior del valor actual, la transformación FOD resta el promedio de todas las observaciones futuras disponibles del valor actual. Asimismo, es calculable para todos los periodos con excepción del último periodo, aún bajo la presencia de datos faltantes en el panel, por lo que minimiza la pérdida de observaciones. Hayakawa (2009) demostró que el estimador GMM trabaja mejor cuando se hace uso de una transformación FOD que cuando se utiliza una transformación en primeras diferencias.

La transformación FOD se puede expresar matemáticamente de la siguiente forma suponiendo que  $Z_{it}$  sea una variable:

$$Z_{i,t+1}^F = C_{it} \left( Z_{it} - \frac{1}{T_{it}} \sum_{s>t} Z_{is} \right)$$

La suma se toma con respecto a las observaciones futuras;  $T_{it}$  se refiere al número de dichas observaciones adelantadas. Roodman (2009) establece que una de las propiedades de la transformación FOD es que si  $Z_{it}$  tiene una distribución independiente previo a la transformación FOD, permanece de esa forma posterior a ésta.

## 2.2 Pruebas de especificación para estimadores GMM: AR(1), AR(2) y prueba de Sargan

La consistencia del estimador GMM depende críticamente de la validez de las condiciones de momentos y de la ausencia de correlación de segundo orden en el término de error ( $\varepsilon_{it}$ ). En este sentido se hace uso de la prueba de

Sargan con el fin de examinar la validez de las variables instrumentales seleccionadas. La hipótesis nula de esta prueba se refiere a que las variables instrumentales son exógenas como grupo. La prueba compara el valor dado por la función GMM minimizada, con los valores críticos de una distribución ji-cuadrado cuyos grados de libertad equivalen a la diferencia entre el número de condiciones de momentos y el número de parámetros. Si el número de parámetros excede a las condiciones de momentos, entonces la hipótesis nula no puede ser rechazada. De esta forma, mientras más grande sea el p-valor del estadístico de Sargan, más robustos serán los instrumentos empleados.

Otra prueba relevante es la prueba AR para autocorrelación de los residuales. La consistencia del estimador GMM se encuentra fundamentada en la ausencia de correlación serial de segundo orden. Originalmente, los residuales de la ecuación en primeras diferencias presentan correlación serial, de tal forma que la hipótesis nula es rechazada en todo momento para AR(1). Sin embargo, para garantizar el supuesto de independencia de los errores originales es necesario que los residuos en diferencias no exhiban una correlación de segundo orden significativa. En caso de reportarse un alto p-valor en la prueba AR(2) representaría que las condiciones de momentos son válidas debido a la ausencia de correlación serial de segundo orden en los residuales en niveles. Por el contrario, de obtenerse un estadístico AR(2) estadísticamente significativo, llevaría a la conclusión de que los rezagos de segundo orden de las variables endógenas no serían instrumentos apropiados para los valores corrientes, en cuyo caso se tendría que optar por rezagos mayores.

### 3 Datos

Las variables utilizadas en nuestro modelo de datos panel dinámico son las siguientes: *i*) el logaritmo del tráfico de datos en terabytes, per capita; *ii*) el logaritmo del PIB per capita; *iii*) el logaritmo del número de suscriptores a tecnología 3G; *iv*) el logaritmo del número de suscriptores a tecnología 4G; *v*) el índice Herfindahl-Hirschman (HHI); *vi*) una variable *dummy* para definir a “el que llama paga” (CPP); *vii*) tarifa de terminación para telefonía móvil (MTR) en dólares estadounidenses y en términos corrientes. La muestra de observaciones inicia a partir del primer trimestre del año 2013 hasta el último trimestre del año 2016. La principal fuente de información es la base de datos de Ovum Knowledge Center<sup>3</sup> y la Global Wireless Matrix publicada en diferentes años por Bank of America / Merrill Lynch.

Por otra parte, variables relacionadas con la escolaridad académica o de población fueron excluidas de nuestro análisis debido a que las observaciones de dichas variables se encuentran en una frecuencia anual y no trimestral como el resto de variables; por lo que se desistió de utilizar alguna técnica de imputación de datos como la de splines. Los países pertenecientes a la OCDE para los cuales se cuenta con información estadística son: Alemania,

---

<sup>3</sup><https://www.ovumkc.com/login>

Canadá, Chile, Dinamarca, España, Grecia, Italia, México, Países Bajos, Portugal, Reino Unido, Suecia, Suiza y Turquía.

### 3.1 Captura de los efectos rezagados del PIB per cápita

Si consideramos que los efectos del logaritmo del producto interno bruto per cápita no son inmediatos; se incluyen rezagos de los mismos con el objeto de capturar sus posibles efectos diferidos. En (3) la variable  $X_{it}$  hace referencia al resto de regresores.

$$Y_{it} = \beta_0 + \beta_1 \log terapc_{i,t-s} + \beta_2 \log PIBpc_{i,t} + \beta_3 \log PIBpc_{i,t-s} + \beta_4 X_{it} + u_i + \varepsilon_{it} \quad (3)$$

## 4 Resultados

En primera instancia se realiza una estimación ignorando la naturaleza dinámica del modelo bajo el método de los mínimos cuadrados ordinarios (ver Tabla 1, columna 1). Una de las problemáticas obvias que se presentan bajo este esquema es la presencia de heterogeneidad no-observada a nivel individuo (en nuestro caso se trata de países). A pesar de haber sido tomado en cuenta el problema potencial de correlación entre los términos de error en el horizonte de tiempo, en los modelos de mínimos cuadrados ordinarios es más complicado considerar el impacto potencial de la heterogeneidad no-observada en la media condicional. Es así que se prefiere optar por un modelado del estimador de efectos fijos o estimador *within*, el cual toma en consideración la heterogeneidad no-observada de las observaciones. Sin embargo, la estimación de un modelo de efectos fijos padece el problema del sesgo de Nickell, el cual es severo en nuestro caso dado que nuestra serie de tiempo no es extensa.

En la regresión de MCO el primer rezago de la variable dependiente, logaritmo de los terabytes per capita ( $L1 \log terapc$ ), se encuentra correlacionado de forma positiva con el término de error ( $\varepsilon_{it}$ ), sesgando ligeramente su coeficiente y haciendolo más grande. En cambio, en la regresión de efectos fijos ese mismo coeficiente se encuentra sesgado negativamente derivado del signo negativo del término de error ( $-\varepsilon_{i,t-1}$ ) en la transformación del mismo. Aunado a lo anterior, dicho coeficiente no es estadísticamente significativo. Sin embargo, en esa misma regresión el segundo rezago de la mencionada variable dependiente ( $L2 \log terapc$ ) sí es significativo a un nivel de confianza del 90%. El resto de variables incluyendo el logaritmo del PIB per cápita y sus rezagos no son estadísticamente significativos.

	(1)	(2)
VARIABLES	MCO	Efectos Fijos
<i>L1 logterapc</i>	0.314*** (0.0896)	-0.109 (0.204)
<i>L2 logterapc</i>	0.604*** (0.0835)	0.301* (0.162)
<i>log PIBpc</i>	-0.745 (1.711)	1.048 (2.499)
<i>L1 log PIBpc</i>	1.171 (3.725)	0.221 (2.489)
<i>L2 log PIBpc</i>	-0.340 (2.708)	1.208 (3.880)
<i>log 3Gsubs</i>	0.0179 (0.0320)	0.235 (0.222)
<i>log 4Gsubs</i>	-0.0532** (0.0168)	-0.0529 (0.0464)
<i>mtr</i>	0.0101 (0.00737)	0.0169 (0.0104)
<i>hhi</i>	-0.621* (0.315)	-0.174 (1.083)
<i>Constante</i>	-0.477 (0.463)	-33.62 (49.39)
Observaciones	59	59
R-cuadrada	0.986	0.820
Dummies de tiempo	SI	
Número de países		10
EF por tiempo		SI

Errores estándar robustos entre paréntesis.

\*\*\* p<0.01, \*\* p<0.05, \* p<0.1

**Tabla 1**

Por otra parte, el modelo de datos panel bajo la metodología GMM es capaz de lidiar con el problema de heterogeneidad no-observada por medio de la transformación de las observaciones, la cual remueve los efectos fijos. En el enfoque estándar se aplica la transformación de primeras diferencias, la cual, tal y como fue mencionado anteriormente, remueve el efecto fijo pero introduce correlación entre los términos  $\Delta y_{i,t-1}$  y  $\Delta \varepsilon_{it}$ , debido a que ambos términos contienen un término rezagado un periodo,  $t - 1$ . La transformación en primeras diferencias en cierto sentido es preferible a la transformación *demeaning* o transformación *within*, ya que esta última hace que cada observación transformada se convierta en endógena con respecto a cada una del resto de observaciones para un individuo dado, o país en este caso. Por otra parte, la mayor desventaja de la transformación en primeras diferencias es que magnifica las brechas en los paneles no balanceados. Este es el motivo principal por el cual en este trabajo se utiliza la transformación Forward Orthogonal Deviation (FOD), propuesta por Arellano y Bover (1995).

En principio, las estimaciones de los coeficientes se generaron utilizando un estimador GMM en una etapa (ver Tabla 2, columna 1), con errores estándar asintóticos robustos para heteroscedasticidad. Posteriormente, las estimaciones fueron generadas mediante un estimador GMM en dos etapas (ver Tabla 2, columna 2). Esto último con el propósito de comprobar la robustez de nuestros resultados así como de los signos de los coeficientes. La estimación en dos etapas se llevó a cabo a pesar de las afirmaciones de Bond (2002) quien establece que la estimación de los coeficientes mediante un estimador GMM en dos etapas produce un sesgo descendente en el cálculo de los errores estándar, motivo por el cual es preferible la utilización del estimador GMM en una sola etapa. Por otra parte, Arellano y Bond (1991) encontraron que se obtienen muy pocas ganancias en eficiencia por el hecho de utilizar la versión del estimador GMM en dos etapas, aún en la presencia de heteroscedasticidad.

Por otra parte, en ambos modelos se asume la presencia de endogeneidad en los rezagos de la variable del logaritmo de los terabytes per cápita (*log terapc*) y de la variable del logaritmo del PIB per cápita (*log PIBpc*). Por lo que en ambos modelos se utilizan como instrumentos periodos más rezagados de esas mismas variables. Los resultados del modelo de datos panel utilizando un estimador GMM en una etapa muestran a ambos rezagos de la variable *log terapc* como positivos y estadísticamente significativos. El coeficiente para el primer rezago es igual a 0.380, en tanto que para el segundo rezago es igual a 0.545, por lo que la suma de ambos coeficientes es igual a 0.925, la cual se encuentra por debajo de la unidad, lo que a su vez garantiza la estabilidad dinámica del modelo. En lo referente a los niveles y rezagos de la variable *log PIBpc* no son estadísticamente significativos en ningún caso. Lo mismo ocurre para las variables del logaritmo de los subscriptores a tecnologías 3G y 4G, el índice herfindahl-hirschman y la tasa de interconexión. En lo concerniente al modelo datos panel con un estimador GMM en dos etapas, observamos que en este caso el primer rezago no es estadísticamente significativo; en tanto que el segundo rezago sí lo es al 99% de confianza.

En suma, nuestro modelo DPD-GMM en una etapa muestra que la variable dependiente *logterapc* muestra un mecanismo de ajuste parcial, es decir que sus propios rezagos tienen incidencia sobre la misma, siendo especialmente importante el segundo de ellos ( $L2 \logterapc$ ). Es así que un incremento del 1% en el tráfico de datos en TB per cápita hace dos periodos tendría un efecto positivo del 54.5% sobre el tráfico de datos en el periodo actual. En tanto, que un incremento en el tráfico de datos per cápita hace un periodo tendría un efecto positivo del orden del 38% sobre el actual.  $\hat{A}$

	(1)	(2)
VARIABLES	DPD-GMM (una etapa)	DPD-GMM (dos etapas)
<i>L1 logterapc</i>	0.380*** (0.0545)	0.231 (0.451)
<i>L2 logterapc</i>	0.545*** (0.0372)	0.815*** (0.257)
<i>log PIBpc</i>	-0.923 (2.810)	-5.047 (3.032)
<i>L1 log PIBpc</i>	4.558 (3.732)	4.651 (7.468)
<i>L2 log PIBpc</i>	-3.472 (4.959)	0.838 (7.557)
<i>log 3Gsubs</i>	0.0518 (0.0473)	0.522 (0.500)
<i>log 4Gsubs</i>	-0.0383 (0.0241)	-0.137 (0.0953)
<i>mtr</i>	0.00638 (0.00546)	0.0149 (0.0147)
<i>hhi</i>	0.0490 (0.413)	1.556 (1.325)
<i>Constante</i>	-2.290* (1.254)	-11.19 (9.874)
Observaciones	74	74
Número de países	13	13
EF por tiempo	NO	NO

Errores estándar robustos entre paréntesis.

\*\*\*  $p < 0.01$ , \*\*  $p < 0.05$ , \*  $p < 0.1$

**Table 2**

Por otra parte, la prueba AR(2) reporta un p-valor igual a 0.271, lo cual es indicativo de ausencia de correlación serial de segundo orden para los residuales en niveles, aunado a que las condiciones de momentos del modelo DPD-GMM en una etapa son válidas. En cuanto a la prueba de Sargan que analiza la validez de las variables instrumentales seleccionadas como grupo, se obtuvo un p-valor de 0.188, por lo que la hipótesis nula de que las variables instrumentales son exógenas como grupo no podría ser rechazada.

## 5 Conclusiones

En conclusión, las proyecciones de crecimiento del tráfico de datos en Internet a nivel nacional y mundial, obligan a analizar los determinantes de esta variable. En el presente estudio se optó por un modelo dinámico de datos panel bajo la metodología GMM de Arellano y Bond. Como se explica en el artículo este tipo de modelos hacen pocos supuestos acerca del proceso generador de datos subyacente, aunado a que permite hacer uso de instrumentos “internos”, es decir, basados en los propios rezagos de las variables instrumentadas, lo cual representa una gran ventaja sobre otros métodos econométricos. Asimismo, tal y como el nombre del modelo lo indica, se plantea la existencia de una relación dinámica de la variable dependiente (*logterapc*) con sus propios rezagos. Es así que los resultados de nuestro modelo DPD-GMM en una etapa muestran que tanto el primero como el segundo rezago de la variable dependiente son positivos y estadísticamente significativos, mientras que la suma de ambos se encuentra por debajo de la unidad, lo cual es indicativo de que el modelo es estable. Por otra parte, debido a que nos encontramos con una restricción en la búsqueda de datos no fue posible incluir dentro de nuestras estimaciones variables referentes a escolaridad académica o poblacionales. En suma, el modelo demuestra la existencia de un ajuste parcial dinámico para la variable *logterapc*, el cual es positivo y estadísticamente significativo.

## References

- [1] Arellano, M., y 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.
- [2] Arellano, M., y Bover, O. (1995). Another look at the instrumental variable estimation of error-components models. *Journal of Econometrics*, 68(1), 29-51.
- [3] Blundell, R., y S. Bond. 1998. Initial conditions and moment restrictions in dynamic panel data models. *Journal of Econometrics* 87: 115-143.
- [4] Bond, Stephen R. (2002). Dynamic panel data models: A guide to micro data methods and practice, cemmap working paper, Centre for Microdata Methods and Practice, No. CWP09/02, <http://dx.doi.org/10.1920/wp.cem.2002.0902>

- [5] Bruce R (1989) Options and development in the telecommunications sector. En: Wellenius B, Nulty TE, Stern RD (eds) Restructuring and managing the telecommunications sector: a world bank symposium. The World Bank, Washington
- [6] Hayakawa, K. (2009). First difference or forward orthogonal deviations-which transformation should be used in dynamic panel data models?: a simulation study. *Economics Bulletin*, 29(3), 2008-2017.
- [7] Nickell, S.(1981), Biases in Dynamic Models with Fixed Effects. *Econometrica*, Vol. 49, No. 6 (Nov.), pp. 1417 – 1426.
- [8] Qiang, C., Rossotto, C., and Kimura, K. (2009). Economic Impacts of Broadband. *Information and Communications for Development*. Chapter 3.
- [9] Roodman, D. (2009). How to do xtabond2: An introduction to difference and system GMM in Stata. *Stata Journal*, 9(1), 86.
- [10] Scott, C. (2012). “Does Broadband Internet Access Actually Spur Economic Growth?” Paper. Available at <http://www.eecs.berkeley.edu/~rsc/classes/ictd.pdf>
- [11] Singh JP (1999) Leapfrogging development? The political economy of telecommunications restructuring. State University of New York Press, Albany