



Estimando el crecimiento regional con redes neuronales de aprendizaje profundo.

Juan de Lucio

Universidad Nebrija

Noviembre 2018

Resumen

El trabajo muestra cómo incorporar las técnicas de Inteligencia Artificial a la caja de herramientas disponibles para el análisis de coyuntura regional. Se compara las estimaciones realizadas con Redes Neuronales (en concreto, mediante la utilización de redes con larga memoria de corto plazo, LSTM por sus siglas en inglés) con los instrumentos más habituales en el análisis de coyunturas (series temporales, indicadores sintéticos y factores dinámicos). Los resultados muestran que los avances en redes neuronales pueden ser incorporados al análisis de coyuntura: son herramientas complementarias a las disponibles, con mayor flexibilidad para captar la diversidad de situaciones en la economía real y con una capacidad de estimación superior. El documento propone expansiones de este tipo de instrumentos para solucionar una diversidad de problemas en economía regional.

Palabras clave. Predicción regional, redes neuronales, inteligencia artificial, LSTM

Introducción

El seguimiento en tiempo real de la evolución de una economía es una tarea de interés y dificultad. Si esta tarea debe llevarse a cabo con detalle territorial el problema se multiplica, no solo por el mayor número de cálculos sino también por la menor disponibilidad de información y la necesidad de cuadrar los resultados obtenidos en un número mayor de dimensiones¹.

El interés del análisis coyuntura a escala regional tiene varios fundamentos. En primer lugar, la mayor parte de los agentes económicos se ven más afectados por lo que suceden en su entorno local que por la evolución agregada². En segundo lugar, muchas de las actuaciones de política económica se toman de manera descentralizada; en este sentido, el seguimiento regional puede orientar las actuaciones de gestión de la coyuntura macroeconómica (pe. política fiscal). Finalmente, dadas las características idiosincráticas de los territorios, es necesario entender el comportamiento local para comprender la evolución agregada³.

Las herramientas clásicas para llevar a cabo el análisis regional, de ciclos y coyuntura, realizan un trabajo bastante satisfactorio. En este campo son habituales los modelos de series temporales, vectores autoregresivos y ARIMA (Ramajo, Márquez y Hewings; 2015 ó Koop, McIntyre y Mitchell; 2018). Igualmente, se utilizan muy frecuentemente los modelos de ecuaciones puente que ponen en relación un conjunto de indicadores con una determinada variable de interés, generalmente el PIB, habitualmente desarrollando indicadores sintéticos (Trujillo, Benítez y López; 1999 o Lopez y Castro; 2004), mediante técnicas de componentes principales o similares. Finalmente, señalar las versiones más sofisticadas de los mismos, como son los modelos de factores dinámicos (Cuevas y Quilis; 2014, o Gil, Leiva-León y Urtasun; 2018).

¹ Cuando se realiza análisis regional también existe la necesidad de proporcionar coherencia (trasversal) interna a los resultados y del análisis de las complejas dinámicas que puede haber entre regiones. La diversidad de modelos subyacentes, de variables representativas del comportamiento y de interrelaciones complica la resolución del problema de seguimiento regional. La dificultad técnica reside tanto en la elaboración de los indicadores necesarios para el análisis como en la utilización de las técnicas.

² El interés por lo local y la importancia creciente de las ciudades está derivando en predicciones de PIB por municipios y otras agrupaciones territoriales subregionales.

³ Como muestran, Bandrés y Gadea (2013), la sincronización de las regiones españolas es mayor en el largo plazo que en el corto aunque también se observan diferencias regionales. Artola et al (2018) también muestran cierta diferencias en el comportamiento regional; señalan que la volatilidad del PIB es mayor que la de la media nacional en 12 regiones, la persistencia del crecimiento menor en todas las regiones que en el conjunto de España y existen diferencia en las características regionales del último ciclo (duración e intensidad de los movimientos cíclicos). Gadea, Gómez-Loscos y Montañés (2012) apuntan ciclos regionales heterogéneos con un cierto grado de sincronización.

Para una revisión más completa de los modelos de predicción regional ver el trabajo de Lehmann y Wohlrabe (2014). Su trabajo pone de manifiesto la escasa utilización de Redes Neuronales (RR.NN. en adelante) a la vez que recomienda su uso⁴. La OCDE (Woloszko 2018) ha empezado a explorar las posibilidades que ofrece.

La inteligencia artificial (IA, en adelante) consigue identificar patrones complejos que resuelven un problema específico Mullainathan Spiess (2017). Igualmente estas técnicas pueden ser útiles por ejemplo para evitar los problemas derivados de sobre ajuste paramétrico (Abadie y Kasy⁵, 2017) y permite enfocarse más en el objetivo de predicción. Varian (2014) destaca el papel de las nuevas posibilidades que ofrece la inteligencia artificial poniendo especial énfasis en la predicción. En general estos modelos tienen como principal objetivo arrojar una estimación o previsión de crecimiento. En este sentido, la calidad de la estimación es el principal objetivo y no en la identificación de los parámetros que subyacen a la relación estimada. Tal y como señalan Kleinberg, Ludwig, Mullainathan y Obermeyer (2015) los problemas de predicción siguen una estrategia de minimizar el error de predicción frente al tradicional enfoque de generar estimadores insesgados⁶. Las técnicas de inteligencia artificial se enfocan en la predicción frente a la econometría clásica más centrada en la identificación de los parámetros específicos que definen de manera inequívoca las relaciones estructurales subyacentes entre variables.

Estos avances y éxitos son susceptibles, como veremos, de trasladarse a la economía. Abadie y Kasy (2017) señalan: “The interest in adopting machine learning methods in economics is growing rapidly.”⁷ La utilización de las técnicas que ofrece la IA descansa en la teoría económica en, al menos, los siguientes aspectos: primero, la formulación de los problemas a analizar; segundo, la incorporación de los datos relevantes para el análisis y tercero, la interpretación de los resultados obtenidos del análisis. La IA es más flexible en las relaciones susceptibles de gobernar el funcionamiento del sistema y, en consecuencia, adecuados para adaptarse a la complejidad de las relaciones económicas y la velocidad de cambio de las mismas, características intrínsecas a las técnicas de IA.

⁴ La utilización de Inteligencia Artificial (IA) y de manera específica de redes neuronales para análisis regional, ha sido muy escasa. solo para regiones alemanas y ha utilizado estructuras de redes no recurrentes (Patuelli et al, 2008; Patuelli et al, 2007 y Longhi et al, 2005).

⁵ Estos autores se enfocan en una serie de aplicaciones concretas de los modelos de inteligencia artificial, no incorporan en su análisis las redes neuronales

⁶ Kleinberg et al (2015) señalan además: “Prediction policy problems are, in sum, important, common, and interesting, and deserve much more attention from economists than they have received. New advances in machine learning can be adapted by economists to work on these problems”

⁷ Para una aplicación del big data en economía ver Glaeser, Edward L., Scott Duke Kominers, Michael Luca, y Nakhil Naik (2016).

Adicionalmente, la generalización del uso y la rápida evolución de estas metodologías han proporcionado resultados destacados en áreas tan diversas como la identificación de fraude como en el reconocimiento del lenguaje⁸.

Este documento propone la incorporación de los avances en materia del IA relativos a las RR.NN. recurrentes mostrando la calidad de los resultados proporcionados por estas herramientas y el potencial de las mismas para abordar nuevas preguntas de interés para el análisis regional de coyuntura. En concreto, propone utilizar la arquitectura de aprendizaje profundo. De manera específica, aborda el análisis utilizando las redes de larga memoria de corto plazo (LSTM, por sus siglas en inglés Long Short-Term Memory) propuestas por Hochreiter y Schmidhuber (1997). Estas técnicas se han mostrado útiles para el análisis de series temporales. Es una de las arquitecturas de aprendizaje profundo más avanzadas y exitosas para predicción de series temporales o reconocimiento de escritura o discurso. El trabajo analiza las posibilidades de las mismas aplicadas a modelos multivariantes para el seguimiento del PIB regional.

Se propone la incorporación de esta metodología para sumar su capacidad de predicción a las herramientas actuales. Bates y Granger (1969) señalan en un trabajo seminal que la combinación de distintas previsiones permite mejorar la capacidad predictiva. En el mismo sentido apunta el trabajo de Stock y Watson (2001), trabajo de referencia en el que entre otros métodos de estimación incorporaron redes neuronales sencillas (univariantes, no recurrentes y feed forward⁹). A nivel regional, para España, Lopez (2016) recomienda igualmente la agregación de varios modelos. En este contexto, los modelos de RR.NN. sumarían una nueva herramienta de análisis y modelización. Deben considerarse herramientas complementarias.

El trabajo muestra la utilidad de las técnicas de IA (RN-LSTM) y ofrece una comparación con otros modelos tradicionales. Adicionalmente pone de manifiesto algunas posibilidades de análisis adicionales que se abren con el uso de estos nuevos instrumentos.

El resto del trabajo se estructura de la siguiente manera. La siguiente sección ilustra el funcionamiento de las RR.NN. y, en concreto, de las LSTM. Se dedica la tercera sección a presentar los datos y otros aspectos relativos a los soportes informáticos que exigen este tipo de técnicas. Los resultados se presentan en la sección 4. El documento finaliza con una sección de conclusiones y vías abiertas de investigación.

⁸ También han sido utilizadas para descripciones verbales de imágenes, creación de texto manuscrito, generación de imágenes, predicción de video

⁹ En este trabajo se utilizan redes recurrentes, multivalentes, de aprendizaje profundo y backpropagation.


Redes neuronales

Las redes neuronales se caracterizan por su flexibilidad y capacidad predictiva de fenómenos complejos. Una red neuronal sencilla permite relacionar la variables de entrada X_i con la de salida H a través de una capa intermedia con pesos de entrada, w_{ji} , y de salida, w_j . Las variables de entrada x_i se conectan con todas las neuronas de la capa intermedia, y está con la variable de salida, y_{jt} a través de los pesos y las funciones de activación, ψ, φ_j , que permiten un cambio gradual en la salida según se modifican las entradas.

$$H = \psi \left[\sum_j w_j \varphi_j \left(\sum_n w_{jn} x_n \right) \right] \quad (1)$$

Los pesos se modifican en cada iteración con objeto de reducir las diferencias entre el valor observado y la estimación obtenida. La figura 1 propone una representación gráfica de esta red sencilla. Tiene una capa de entrada de variables y otra capa de salida. Ambas se relacionan, en este caso, a través de una única capa oculta. El comportamiento de la red está gobernado por los parámetros y funciones de activación ilustrados en la ecuación (1).

Ilustración 1: Red neuronal estándar




Fuente: Elaboración propia

En esta red neuronal sencilla no se pasa información de la fase actual a la siguiente, es decir este tipo de estructura no es capaz de incorporar información previa como input. Las Redes Neuronales Recurrentes (RNN en

adelante, por sus siglas en inglés, Recurrent Neural Networks) reciben como entrada la salida de una de las capas anteriores; inyectan su salida en una de las capas de un nivel anterior a ella. Una red neuronal recurrente se puede considerar como copias múltiples de la misma red, cada red pasando un mensaje a la siguiente. Son redes con bucles internos que permiten que la información persista. Tal y como señala Olah (2015), una red neuronal recurrente se puede considerar como copias múltiples de la misma red en la cada una de las redes anteriores pasa información. La ilustración 2 representa, a la izquierda, una RNN y, a la derecha, su representación desarrollada; cuando se presentan, de manera independiente, las distintas fases del bucle. En cada una de las fases la información de entrada $X_0 \dots X_t$ se transforma en salidas, $h_0 \dots h_t$ mediante una red neuronal. Entre las distintas etapas se traslada información.

Ilustración 2: Red neuronal recurrente. Representación compacta y desarrollada.



Fuente: Elaboración propia

Las RNN han sido exitosas en una variedad de problemas: reconocimiento de voz, traducción, entre otras. En general, son especialmente útiles en tareas que tienen un componente secuencial. Precisamente la aplicación de las técnicas para la predicción de secuencias (pe. lenguaje) tiene unas características de interés en el ámbito de la economía. Tanto en el lenguaje como en la economía es conveniente recordar una serie de características pasadas por ejemplo de carácter gramatical (tiempo, genero, número) o económico (etapa del ciclo, la amplitud y otra serie de elementos económicos). Estos aspectos pueden ser tenidos en cuenta para calcular el valor estimado.

Para la resolución de algunos problemas la información más reciente, la del pasado inmediato, puede ser suficiente. En este contexto las RNN pueden funcionar adecuadamente. En otras situaciones puede ser oportuno recordar información de un pasado más lejano. Bengio et al (1994) identifican algunas razones por las que las RNN no son eficientes para modelos que necesitan mayor memoria a largo plazo, principalmente ponen de manifiesto el trade-off entre recordar información durante periodos de tiempos largos y el

entrenamiento adecuado de la red. El gradiente retropropagados tienden a crecer o disminuir con el tiempo debido a que depende no solo del error presente sino también los errores pasados; esto provoca la dificultad para memorizar dependencias a largo tiempo de las redes neuronales.

Para los modelos económicos necesitamos información que puede estar disponible más allá de los datos recientes. Puede ser oportuno ligar sucesos pasados al comportamiento actual y futuro de la economía. Para solventar este problema de aprendizaje a largo plazo que presentan las RNN, Hochreiter y Schmidhuber (1997) desarrollaron las redes con larga memoria de corto plazo (Long Short-Term Memory - LSTM en adelante). Las LSTM son un tipo de RNN, capaces de aprender las dependencias a largo plazo. Mantienen una capa de memoria en la que almacenan información relevante en el proceso de cálculo.


La estructura de las redes LSTM estaría representada en la ilustración 3. En una RNN la estructura de la función R sería una estructura simple similar a la de la ilustración 1. En una LSTM el modulo R de la ilustración 2 tiene capas interaccionando. En cada capa de la red, utilizando la información de entrada se decide si la nueva información es relevante. La clave en una red neuronal LSTM es la celda de memoria que permite almacenar información pasada que se va actualizando¹⁰. En la ilustración 3 la capa de memoria viene representada por la línea superior. En una primera fase a través de una función de activación sigmoidea, denominada σ , se decide qué información borrar. En una segunda qué información añadir a esta capa de memoria (función sigmoidea para decidir qué información actualizar más una tangente hiperbólica para identificar los valores potenciales a incorporar)¹¹. Finalmente, en la tercera y última fase se decide qué información ofrecer como salida.

¹⁰ Por ejemplo en una frase se podría guardar el número (singular plural) para poder identificar posteriormente la forma correcta del verbo. En nuestro modelo la red podría almacenar si el último evento ha sido un pico o un vale cíclico.

¹¹ $Sigmoide(x) = \frac{1}{1+e^{-x}}$

$Tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$

Ilustración 3: Caracterización de una de las etapas (modulo R) de la redes LSTM



Fuente: Olah Chris (2015)

Aprovechando los desarrollos en materia de RR.NN. - LSTM a continuación se aplican al seguimiento coyuntural regional y comparar su desempeño con modelos más tradicionales, en la sección 4. Antes se presentan los datos utilizados y el soporte informático para realizar el ejercicio de comparación.

Datos

En el marco de las Cuentas Nacionales elaboradas por el INE se publica la Contabilidad Regional de España (CRE). Esta fuente estadística únicamente facilita datos anuales, no presenta datos trimestrales, como sí se realiza para el conjunto de España. Por su parte, no todos los institutos de estadística regionales publican cuentas trimestralizadas ni utilizan metodologías consistentes. La única institución oficial que proporciona datos trimestralizados del PIB regional es la AIREF utilizando la metodología elaborada por Cuevas y Quilis (2015). Las series trimestrales que proporcionan para el PIB regional constituyen nuestras variables de salida, H, a estimar por el modelo.

Las variables de entrada, X, se han seleccionado siguiendo criterios económicos y metodológicos. Desde el punto de vista económico es oportuno que las variables seleccionadas sean similares a los indicadores utilizados por el INE (1993) en la elaboración de las cuentas trimestrales nacionales, estadística que es la referencia para el ejercicio de la AIREF, nuestra variable a estimar. Además, es oportuno que los indicadores mantengan relación con el PIB y, en concreto, con los principales sectores de actividad (perspectiva de la oferta) y el mercado de trabajo, así con otras variables económicas relacionadas con la demanda. Desde el punto de vista metodológico es

necesario que sean indicadores homogéneos para todas las CCAA y que puedan ser utilizados tanto en las técnica propuesta de RR.NN. como en las demás técnicas utilizadas como modelos de referencia (ARIMA, indicador sintético, modelo de factores dinámicos). Otros criterios de calidad estadística y criterios de retardos, disponibilidad y frecuencia (pe. desfase, puntualidad en la difusión) también ha sido tenidos en consideración.

La tabla 1 refleja los indicadores finalmente seleccionados así como algunas características de los mismos como la frecuencia, la fecha de inicio de disponibilidad de la información, la fuente y la transformación realizada para el análisis. La fecha de actualización de la base de datos ha sido 8 de noviembre de 2018. Por lo tanto, se dispone de la estimación del crecimiento regional para el tercer trimestre del año.

Tabla 1: Variables utilizadas.

<i>SERIES DISPONIBLES</i>		<i>Frec.</i>	<i>Inicio</i>	<i>Fuente</i>	<i>Transformación</i>	<i>Pub</i>
<i>Ventas minoristas</i>	ICM	M	2002-1	INE	SA,G,T-M,E	T+28
<i>Producción industrial</i>	IPI	M	2002-1	INE	SA,G,T-M	T+37
<i>Pernoctaciones</i>	PER	M	1999-1	INE	SA,G,T-M	T+22
<i>Afiliados</i>	AFI	M	1982-1	M.Emp	SA,G,T-M,E	T+3
<i>Crédito total a residentes</i>	CRE	T	1995-1	BdE	SA,G,D	T+90
<i>IPC</i>	IPC	M	2002-1	INE		T+14
<i>PIB</i>	PIB	T	2000-1	AIREF	SA,G	T+33

Frecuencia, códigos: M: Mensual, T: Trimestral

Transformación, códigos: SA: Ajuste Estacional, G: Crecimiento, T-M: Trimestralizada a partir de datos mensuales, T-A: Trimestralizada a partir de datos anuales. D: Deflación de variables nominales por IPC. E: Serie enlazada

Hardware y software

El análisis se ha realizado con Python 3.5 (Python Software Foundation, 2016). Se han utilizado los paquetes numpy (Van Der Walt et al, 2011) y pandas (McKinney,2010). Las redes LSTM de aprendizaje profundo han sido desarrolladas con keras (Chollet, 2015) y construidas sobre TensorFlow (Abadi et al 2015), librería de inteligencia artificial desarrollada por Google. El análisis

de RR.NN. es intensivo en cálculo por ello se ha realizado en un ordenador que dispone de dos NVIDIA 1080 GPUs dedicadas al cálculo numérico.

Resultados

Para analizar la validez de las RN-LSTM para el análisis coyuntural se comparan los resultados obtenidos con la estimación utilizando RR.NN. con los que se derivan de otros modelos más tradicionales como son los tres siguientes:

1. Series temporales ARIMA
2. Indicadores sintéticos, componentes principales
3. Factores dinámicos


El ejercicio trata de replicar una situación real en la que se dispondría de información a mediados de un trimestre para estimar el crecimiento del trimestre en curso¹². Como herramienta de comparación de la validez de las estimaciones se utiliza la medida del error cuadrático medio. En todos los modelos estimados se ha programado mecanismos semi-automáticos en las que no es necesaria la intervención directa sobre los cálculos específicos de ninguna CCAA concreta.

La RN-LSTM se construye en una capa de 50 neuronas cada una más una capa de salida¹³. Para cada red se realizan 100 iteraciones, con minibatch de 40. La función de pérdida es el error cuadrático medio con el algoritmo optimizador denominado Adam, propuesto por Kingma y Ba (2014). El conjunto de entrenamiento es del 80% de la información disponible. El gráfico 1 representa la evolución del error cuadrático medio (ECM) según se avanza en el número de iteraciones, tanto para la muestra de entrenamiento como en la de test. Como puede observarse el ECM desciende rápidamente durante las primeras 25 iteraciones y mantiene una pendiente de descenso gradual con posterioridad. A partir de la iteración 40, aproximadamente, la evolución del ECM es bastante similar entre ambas submuestras.

¹² Se estima el crecimiento intertrimestral, variable desconocida y por determinar en el momento de la estimación. El crecimiento interanual es una composición de crecimientos intertrimestrales de trimestres pasado y del correspondiente al trimestre en curso.

¹³ En total, es necesario estimar para cada economía 31.651 parámetros de manera recursiva.

Gráfico 1: Ejemplo de funciones de pérdida (ECM) en función del número de iteraciones.

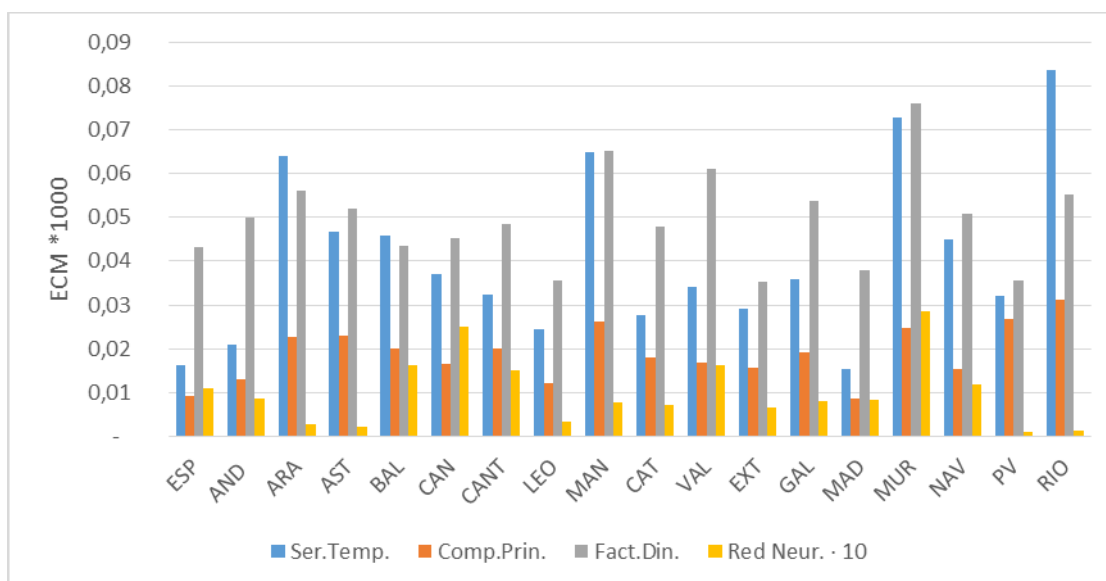


Fuente: elaboración propia.

De acuerdo con esta metodología se ha calculado el ECM de cada una de las CCAA y de la economía española que corresponde a cada una de las técnicas utilizadas. El gráfico 2 presenta los 18 ECM de los distintos modelos. En general los resultados de las distintas metodologías son satisfactorios para todas las economías analizadas. En algunas Comunidades Autónomas uniprovinciales como Murcia o La Rioja, los errores son algo más elevados. Mientras que en Madrid, de mayor dimensión económica, se obtienen estimaciones más ajustadas al dato objetivo.

Se observa que las técnicas de RR.NN. ofrecen ECM inferiores a los de los demás modelos. Los indicadores sintéticos elaborados a partir de componentes principales presentan comportamientos más satisfactorios, que superan en todos los casos los de series temporales y factores dinámicos. No se trata aquí de excluir ninguna técnica todas ellas de utilidad sino de incorporar a la caja de herramientas las herramientas ligadas a la IA, en este caso concreto las RR.NN. – LSTM o variaciones de las mismas.

Gráfico 2: El error cuadrático medio de los cuatro procesos de estimación



Fuente: elaboración propia.

Un indicador de la similitud de la información recogida por las distintas técnicas puede realizarse mediante un cálculo de la correlación entre los errores cuadráticos medios de los distintos modelos. Si dos técnicas proporcionan resultados similares, podemos pensar que recogen variabilidades similares y sus errores tendrán un comportamiento similar entre regiones. En este sentido, la correlación será más elevada. En caso contrario, si los errores tienen comportamientos diferentes los modelos serán complementarios. Las técnicas de series temporales tienen los niveles de correlación más elevados con el resto de técnicas. Por su parte las RR.NN. tienen con el resto de técnicas las correlaciones más reducidas, aunque siempre positivas. Lo que nos estaría indicado que la información que recogen las RRNN es la más complementaria al resto de instrumentos de análisis.

Tabla 2: Correlaciones del error cuadrático medio de los cuatro procesos de estimación

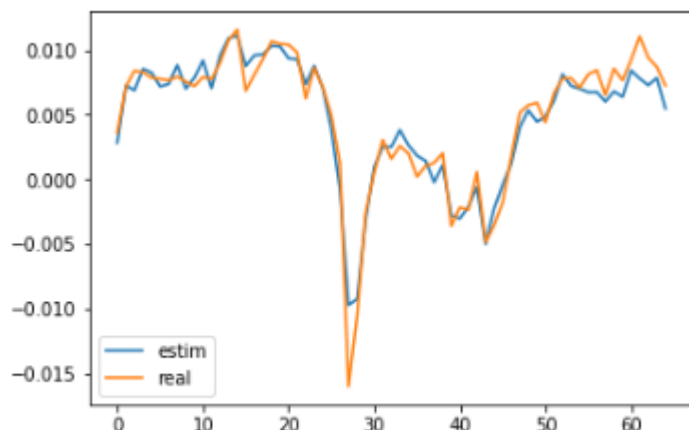
	<i>Ser.Temp.</i>	<i>Comp.Prin.</i>	<i>Fact.Din.</i>
<i>Red Neur.</i>	20,2%	4,2%	40,9%
<i>Fact.Din.</i>	69,6%	48,6%	
<i>Comp.Prin.</i>	83,2%		

Fuente: elaboración propia.

Finalmente, el gráfico 3 presenta la evolución del indicador extraído mediante técnicas de redes neuronales y el crecimiento intertrimestral de la economía española. Como se puede observar la estimación consigue replicar el ciclo regional. En comparación con otras técnicas explica un porcentaje superior de

la varianza y tiene mayor capacidad, inferior error, para estimar la evolución de la economía en tiempo real.

Gráfico 2: Crecimiento intertrimestral España. Evolución de la estimación y el dato AIReF



Fuente: elaboración propia.

Conclusiones

En este trabajo mostramos que las técnicas de RR.NN. y, en concreto, las modelizaciones que incorporan memoria, las denominadas LSTM, pueden ser utilizadas con resultados satisfactorios en el análisis de coyuntura regional. Este tipo de herramientas ofrece resultados competitivos con las herramientas tradicionales y sus estimaciones son complementarias. Mediante este ejercicio se pretende poner de manifiesto la utilidad de estas técnicas. No se propone una sustitución de otras metodologías ya en uso, sino la incorporación de una adicional. Sabemos que la utilización de diversas técnicas de estimación tiene ventajas de cara al análisis económico y, en concreto, para el de coyuntura. Los beneficios son especialmente útiles cuando la información que recogen los distintos instrumentos es más diversa. Las RR.NN. contienen información diferencial respecto a otras aproximaciones metodológicas y los resultados tienen menos desviaciones.

Entre las ventajas de la IA aplicada al seguimiento económico se encuentran las siguientes. La metodología es más flexible y permite captar una mayor variedad de comportamientos cíclicos. Son capaces de recoger comportamientos y relaciones entre variables más complejas. El desarrollo de estos instrumentos permitiría incorporar frecuencias diversas, series con datos ausentes y retardos diversos de difusión e indicadores con sincronía cíclica diversa (adelantados, coincidentes o retrasados). La metodología, por ejemplo,

permitiría estimar simultáneamente, a partir de las variables explicativas de todas las CCAA el crecimiento regional incorporando de forma natural las relaciones y externalidades entre las distintas regiones, sin necesidad de una modelización previa específica. Tampoco exigen la incorporación de técnicas de reparto arbitrarias (por ejemplo, en relación con los plazos de ejecución de una licitación) aunque se pueden incorporar los criterios de consistencia que se consideren oportunos.

En definitiva, la incorporación de las herramientas que se desarrollan en el marco de la IA permite ampliar el número de herramientas disponibles y mejorar la calidad del análisis económico.

Referencias:

- Abadi, M., Agarwal, A., Barham, P., Brevdo, E., Chen, Z., Citro, C., Corrado, G. S., Davis, A., Dean, J., Devin, M., Ghemawat, S., Goodfellow, I., Harp, A., Irving, G., Isard, M., Jia, Y., Jozefowicz, R., Kaiser, L., Kudlur, M., Levenberg, J., Man_e, D., Monga, R., Moore, S., Murray, D., Olah, C., Schuster, M., Shlens, J., Steiner, B., Sutskever, I., Talwar, K., Tucker, P., Vanhoucke, V., Vasudevan, V., Vi_egas, F., Vinyals, O., Warden, P., Wattenberg, M., Wicke, M., Yu, Y., Zheng, X., 2015. TensorFlow: Large-scale machine learning on heterogeneous systems. Software available from tensorflow.org. URL <http://tensorflow.org/>
- Abadie, Alberto, y Kasy, M. (2017): "The Risk of Machine Learning." <https://ideas.repec.org/p/qsh/wpaper/383316.html>.
- Artola, C., Fiorito, A., Gil, M., Pérez, J.J., Urtasun, A. y Vila D. (2018): "Monitoring the Spanish economy from a regional perspective: main elements of analysis" Documento Ocasional Banco de España 1809
- Bandrés, E., y M. D., Gadea (2013), "Crisis Económica y Ciclos Regionales en España". Papeles de Economía Española, 138, pp. 2-30.
- Bates, J.M. and Granger, C.W.J. (1969), "The Combination of Forecasts," Operations Research Quarterly 20, 451–468.
- Bengio, Y., Simard, P., and Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. IEEE Transactions on Neural Networks, 5(2), 157–166.
- Chollet, François et al. (2015) : Keras. <https://github.com/keras-team/keras>. GitHub repository.
- Cuevas, A. y Quilis, E.M. (2015): "Quarterly Regional GDP Flash Estimates for the Spanish Economy (METCAP model)", Autoridad Independiente de Responsabilidad Fiscal AIReF, Working Paper n. 3 / 2015.
- Donaldson, D., y Adam S. (2016): "The View from Above: Applications of Satellite Data in Economics." Journal of Economic Perspectives 30(4): 171–98.
- Einav, L. y Jonathan L. (2014): "Economics in the Age of Big Data." Science 346(6210): 1243089.
- Gadea, M. D., Gómez-Loscos, A. y Montañés A. (2012): "Cycles inside cycles: Spanish regional aggregation", SERIEs Journal of the Spanish Economic Association, 3, pp. 423-456.

- Gil, M., Leiva-León, D., Pérez, J. J. y Urtasun, A. (2018), "An application of dynamic factor models to nowcast regional economic activity", Banco de España, mimeo.
- Glaeser, Edward L., Scott Duke Kominers, Michael Luca, and Nakhil Naik. 2016. "Big Data and Big Cities: The Promises and Limitations of Improved Measures of Urban Life." *Economic Inquiry*, Early View Article, online July 12.
- Hochreiter, Sepp; Schmidhuber, Jürgen (1997). "Long short-term memory". *Neural Computation*. 9 (8): 1735–1780. doi:10.1162/neco.1997.9.8.1735.
- INE (1993) *Contabilidad Nacional Trimestral de España (CNTR). Metodología y serie trimestral 1970-1992*, Instituto Nacional de Estadística.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. arXiv preprint arXiv:1412.6980.
- Kleinberg, J., Ludwig, J., Mullainathan, S., y Obermeyer, Z. (2015): "Prediction policy problems". *American Economic Review*, 105(5), 491-95.
- Koop, G., S. McIntyre, and J. Mitchell (2018), "UK regional nowcasting using a mixed frequency vector autoregressive model", Working Papers 1805, University of Strathclyde Business School, Department of Economics.
- Lehmann, Robert, y Wohlrabe, Klaus (2014): "Regional economic forecasting: state-of-the-art methodology and future challenges". *Economic and Business Letters* 3(4), 218–231
- Longhi, S., Nijkamp, P., Reggiani, A. and Maierhofer, E. (2005) Neural network modeling as a tool for forecasting regional employment patterns, *International Regional Science Review*, 28(3), 330-346.
- López, A. M. (2016). "El papel de la información económica como generador de conocimiento en el proceso de predicción: comparaciones empíricas del crecimiento del PIB regional". *Estudios de Economía Aplicada*, 34, pp. 553-582.
- López, A. M. y R. Castro Núñez (2004). "Valoración de la actividad económica regional de España a través de indicadores sintéticos". *Estudios de Economía Aplicada*, 22, pp. 631-655.
- Mullainathan, S., y Spiess, J. (2017): Machine Learning: An Applied Econometric Approach. *Journal of Economic Perspectives* , 31 (2), 87-106.
- Makridakis S, Spiliotis E, Assimakopoulos V (2018) Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PLoS ONE* 13(3): e0194889. <https://doi.org/10.1371/journal.pone.0194889>

- McKinney, W. (2010). Data structures for statistical computing in Python. In van der Walt, S., & Millman, J. (Eds.) Proceedings of the 9th Python in science conference (pp. 51–56)
- Olah, Chris, (2015): “Understanding LSTM Networks”.
<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- Patuelli, R., Longhi, S., Nijkamp, P. and Reggiani, A. (2008): “Neural networks and genetic algorithms as forecasting tools: a case study on German regions”, *Environment and Planning B: Planning and Design*, 35(4), 701-722.
- Patuelli, R., Longhi, S., Nijkamp, P., Reggiani, A. and Blien, U. (2007): “A rank-order test on the statistical performance of neural network models for regional labor market forecasts”, *The Review of Regional Studies*, 37(1), 64-81.
- Ramajo, J., M. A. Márquez, and G. J. D. Hewings (2015): “Spatiotemporal Analysis of Regional Systems: A Multiregional Spatial Vector Autoregressive Model for Spain”, *International Regional Science Review*, 40, pp. 75-96.
- Stock, J.H. and M. Watson, (2001): “A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series” en R.F. Engle and H. White, eds., *Festschrift in Honour of Clive Granger*. Cambridge University Press, 1-44.
- Trujillo, F., M. D. Benítez, y P. López (1999): “Indicadores Sintéticos Trimestrales de la Actividad Económica No Agraria en Andalucía”, *Revista de Estudios Regionales*, 53, pp. 97-128.
- Van Der Walt, s., Chris Colbert, S. y Varoquaux, g. (2011) The NumPy array: a structure for efficient numerical computation. *Computing in Science and Engineering*, Institute of Electrical and Electronics Engineers, 2011, 13 (2), pp.22-30.
- Varian, Hal R. 2014. “Big Data: New Tricks for Econometrics.” *Journal of Economic Perspectives* 28(2): 3–28.
- Woloszko, N. (2018): “Economic Modeling & Machine Learning”, OECD.
https://techpolicyinstitute.org/wp-content/uploads/2018/02/Woloszko_Macroeconomic-forecasting-with-machine-learning-TPI.pdf
-