
Extendiendo el modelo UTAUT para evaluar los factores que afectan la adopción del Big Data en empresas españolas

• JUAN-PEDRO CABRERA-SÁNCHEZ

• ÁNGEL F. VILLAREJO-RAMOS

Universidad de Sevilla

RESUMEN: La implantación de técnicas de Big Data es una realidad en la toma de decisiones de marketing. Este desarrollo cuestiona qué factores afectan a las empresas en la aceptación de estas tecnologías. En respuesta, extendemos el modelo de aceptación de tecnologías UTAUT al Big Data y añadimos el riesgo percibido como inhibidor. Modelizamos mediante ecuaciones estructurales con Smart-PLS sobre una muestra de empresas que utilizan Big Data. Los resultados muestran la mayor predicción de la extensión del UTAUT planteada y el menor efecto de variables propuestas en el modelo original.

PALABRAS CLAVE: *Big Data, intención de uso, UTAUT, riesgo percibido, PLS*

ABSTRACT: The widespread implementation of Big Data techniques is usual in marketing decision making. This development leads us to question about the factors that affect the acceptance of this technology by companies. To answer this question, we extend the UTAUT technology acceptance model to the Big Data context adding the perceived risk as inhibitor. We use modelling on structural equations by Smart-PLS on a survey of companies that use Big Data. The results highlight that the extending model imply better prediction that original UTAUT model.

KEYWORDS: *Big Data, intention behaviour, UTAUT, perceived risk, PLS*

1. Introducción

La cantidad de datos generada en nuestra actual sociedad de la información no para de crecer exponencialmente. Desde los móviles y su continua geolocalización, a cualquier tipo de transacción entre empresas y consumidores pasando por el in-

ternet de las cosas, redes sociales y todo tipo de dispositivos *wearables* que están generando datos continuamente sobre lo que hacemos, cómo y cuándo. Si las empresas son capaces de transformar estos datos en información en tiempo real sobre clientes, tendrán una gran ventaja competitiva en su sector (Sivarajah, Kamal, Irani & Weerakkody, 2016).

Con la información proveniente de los datos que los usuarios facilitan, hoy podemos saber los momentos de consumo más adecuados, cuándo hacer una promoción y a quién dirigirla, así como conocer los sentimientos hacia la marca y cómo intentar mejorarlos. Técnicas de analítica Big Data (McAfee & Brynjolfsson, 2012) permiten el tratamiento de toda esta gran cantidad de datos, prácticamente en tiempo real, y obtener una gran información que dota a las empresas que las tienen implementadas de un liderazgo frente a su competencia.

El conocimiento y manejo de todas estas técnicas de Big Data llevan consigo la adquisición de nuevas destrezas y competencias para poder implementarlas dentro de las empresas. Nuevos perfiles como el *científico de datos*, que son un híbrido de ingeniería, estadística y profundo conocimiento del negocio, están entre los puestos de trabajo más demandados en la actualidad. Este tipo de perfiles ayudará a exprimir los datos generados por la compañía y cambiarán el proceso de toma de decisiones hacia decisiones basadas en datos y no en experiencias anteriores de las personas encargadas de gestionar la compañía (McAfee & Brynjolfsson, 2012).


El Big Data tiene que dar respuesta a todos los retos que surgen en todo el llamado ciclo de vida de los datos: datos propiamente dichos, su procesado y su gestión (Akerkar, 2014; Zicari, 2014).

Estos retos tienen que ver con las características de:

- Los propios datos: volumen, variedad, velocidad, veracidad, volatilidad, valor y también su visualización.
- Los procesos: todas las técnicas relacionadas con la captura de datos, su integración en bases de datos, cómo limpiarlos y transformarlos, selección correcta de modelos y cómo proporcionar los resultados.
- La gestión: importancia de la privacidad, seguridad y aspectos éticos.

Y todo esto no tendría sentido si no ayudara a que la toma de decisiones empresariales esté basada en datos. Así que por ello las empresas han de ser capaces de sacar información valiosa de forma eficiente de toda esta maraña de datos rápidamente cambiantes. El proceso detallado es el que se muestra en la figura 1 (Agrawal, Bernstein, & Bertino, 2011):

Figura 1. Procesos Big Data



Podemos comprobar que hay dos grandes subprocesos: a) gestión de datos y b) analítica de datos. El primer gran bloque está más relacionado con el ámbito de la ingeniería y el segundo es el que más nos interesa desde el punto de vista del marketing: la analítica. De hecho, esta parte suele conocerse como Big Data Analytics o BDA y es la parte encargada de obtener el valor de los datos, de sacar patrones ocultos y en definitiva de ayudar a la toma de decisiones basada en datos.

No obstante, no es fácil implementar o integrar Big Data en las empresas actuales ya que hay que superar una serie de barreras como son el desconocimiento, los miedos, la resistencia al cambio, entre otros, además de las limitaciones de la propia tecnología (Yaqoob *et al.*, 2016).

En cualquier caso, los beneficios obtenidos son infinitamente superiores a no implementar estas técnicas dentro de la empresa. Además, la mayor parte del software asociado es software libre. Entonces, ¿qué afecta a su adopción? Mientras la mayor parte de la literatura se ha centrado en aspectos técnicos relacionados con todo el ecosistema Big Data, tanto en el desarrollo de aplicaciones y casos de estudio sobre minería de datos, analítica de datos, predicción, prescripción, modelado estadístico y experimentos de todo tipo (Sivarajah *et al.*, 2016), hay poca literatura sobre adopción de dicha tecnología dentro de las empresas (Kwon, Lee, & Shin, 2014; Brünink, 2016; Rahman, 2016).

Con este estudio pretendemos obtener datos sobre los factores que afectan a la adopción y uso de esta nueva tecnología en empresas, así como entender los posibles problemas para su implementación, con lo que podremos dar las recomendaciones pertinentes a los profesionales que toman las decisiones.

El presente capítulo, introducido en este epígrafe, continúa con la justificación teórica de las variables y las relaciones planteadas en el modelo conceptual propuesto que conforman el segundo epígrafe. En el tercero describimos la metodología usada en la investigación. El epígrafe cuarto describe y analiza los resultados obtenidos tras la aplicación del modelo sobre la muestra de empresas observada. Finalmente, presentamos las conclusiones y limitaciones del estudio.

2. Justificación teórica y relaciones del modelo propuesto

Para que una nueva tecnología tenga éxito es determinante su fase de adopción. Para ello se han desarrollado varios modelos como la teoría de acción razonada - TRA (Fishbein & Ajzen, 1975), la teoría de la conducta planificada - TPB (Ajzen, 1991) 1985, 1987 o el muy usado y conocido modelo de aceptación de la tecnología - TAM (Davis, 1985). Se han desarrollado modelos híbridos de estas teorías (Wu & Chen, 2005) e incluso modelos mejorados como el TAM2 (Venkatesh & Davis, 2000). Entendemos que uno de los modelos que mejor ha explicado el proceso de adopción de una nueva tecnología es el modelo propuesto por Venkatesh, Morris, Davis y Davis (2003), la *Unified Theory of Technology Adoption and Use of Technology* (UTAUT) que integra anteriores y diferentes modelos así como las teorías previas que se propusieron para analizar la aceptación de una tecnología.

Una de las principales fortalezas de este modelo es la de identificar cuáles son los principales determinantes de la adopción, incluyendo y considerando el efecto de diferentes moderadores que afectan en la influencia de los constructos claves del modelo (Afonso, Gonzalez, Roldán, & Sánchez-Franco, 2012).

A los constructos del modelo UTAUT añadimos el riesgo percibido (*Perceived Risk*, PR) ya que en la adopción de nuevas tecnologías y sistemas de información también se ha investigado sobre el riesgo percibido como reacción adversa u oposición al cambio o nueva implementación de tecnologías. En este contexto se define el riesgo percibido como la potencial pérdida en la búsqueda de un cierto resultado en la implementación de una nueva tecnología o sistema de información (Featherman & Pavlou, 2003).

Vamos a continuación a proponer las diferentes hipótesis basadas en la ampliación realizada del modelo UTAUT para el caso de aceptación y uso de Big Data por parte de las empresas. Para ello, partimos de las variables inicialmente planteadas en el modelo UTAUT (Venkatesh *et al.*, 2003).

Las **expectativas de resultado** (*Performance Expectancy*, PE), definida como el grado en el que usar una tecnología ofrece beneficios en el desarrollo de ciertas actividades, esto es la percepción sobre el rendimiento que va a tener la tecnología en cuestión. Dentro del UTAUT es uno de los constructos más influyentes en la intención de uso. Diversos trabajos (Brünink, 2016; Chauhan & Jaiswal, 2016; Martins, Oliveira, & Popovič, 2014; Yu, 2012)but the adoption rate of mobile banking is still underused than expected. Therefore, research to enrich current knowledge about what affects individuals to use mobile banking is required. Consequently, this study employs the Unified Theory of Acceptance and Use of Technology (UTAUT

además del propio trabajo original (Venkatesh *et al.*, 2003) sostienen esta relación positiva.

Consecuencia de lo anterior podemos establecer como hipótesis:

H1. *Las expectativas de resultado afectan de forma positiva sobre la intención de comportamiento de uso del usuario de Big Data.*

Las **expectativas de esfuerzo** (*Effort Expectancy*, EE), hace referencia a lo fácil de aprender y de usar que será esta nueva tecnología. Según el propio UTAUT, el Big Data se utilizará más o menos en función de lo fácil o difícil que sea. Otros estudios refuerzan el sentido y el peso de esta relación (Al-Gahtani, Hubona, & Wang, 2007; Arenas-Gaitán, Peral-Peral, & Villarejo-Ramos, 2016; Chauhan & Jaiswal, 2016; Escobar-Rodríguez & Carvajal-Trujillo, 2014; H. W. Kim, Chan, & Gupta, 2007; Lee & Song, 2013; Martins *et al.*, 2014; Yu, 2012) despite its phenomenal growth and although M-Internet essentially provides the same services as stationary Internet, its adoption rate in many countries is very low compared to that of stationary Internet. The well-known Technology Adoption Model (TAM que confirman el efecto que tiene el esfuerzo esperado sobre la intención de uso.

Por ello, enunciamos como segunda hipótesis del modelo:

H2. *Las expectativas de esfuerzo o facilidad de uso afectan positivamente sobre la intención de comportamiento de uso del usuario de Big data.*

La medida de la **influencia social** (*Social Influence*, SI) o cómo los consumidores perciben que amigos y familiares creen que ellos deberían utilizar una tecnología; en la propuesta original de Venkatesh *et al.* (2003) y ampliada en el UTAUT2 (Venkatesh, Thong, & Xu, 2012) ha sido utilizada para medir el efecto de la influencia percibida por los usuarios respecto a lo que otros- amigos, familia- piensan con respecto a la utilización de una tecnología. En un entorno empresarial también es importante lo que piensan los jefes y los colegas (Al-Gahtani *et al.*, 2007; Bozan, Parker, & Davey, 2016; Brünink, 2016; Chauhan & Jaiswal, 2016; Escobar-Rodríguez & Carvajal-Trujillo, 2014; Gupta, Huang, & Niranjan, 2010; H. W. Kim *et al.*, 2007; Lee & Song, 2013; Martins *et al.*, 2014)

Por lo anterior podemos enunciar como hipótesis:

H3. *La influencia social afecta positivamente a la intención de comportamiento de uso de un servicio de Big data.*

El **riesgo percibido** (*Perceived Risk*, PR) ha sido entendido como la potencial pérdida en la búsqueda de un cierto resultado en la implementación de una nueva tecnología. Hay bastante literatura que incluye el riesgo percibido como antecedente negativo en la intención de uso (Kim, Ferrin, & Rao, 2008; Lee & Song, 2013; Martins *et al.*, 2014).

Por ello, podemos enunciar como hipótesis:

H4. *El riesgo percibido influye negativamente sobre la intención de comportamiento de uso de un servicio de Big Data.*

Las **condiciones facilitadoras** (*Facilitating Conditions*, FC) son las percepciones de los consumidores de que los recursos y el apoyo están disponibles para desarrollar un comportamiento y ponen en relieve la facilidad de acceso a los recursos necesarios para usar una nueva tecnología, así como el soporte y apoyo posterior (Venkatesh *et al.*, 2003). En un trabajo posterior, el UTAUT₂, Venkatesh *et al.* (2012) comprobaron que este constructo tiene un efecto significativo en la intención de uso de una tecnología. También estudios más recientes han contrastado este efecto positivo en la intención de uso (Duyck *et al.*, 2010; Escobar-Rodríguez & Carvajal-Trujillo, 2014; Hung, Wang, & Wang, 2007; Martins *et al.*, 2014).

Por ello, podemos enunciar como hipótesis:

H5. *Las condiciones facilitadoras afectan positivamente a la intención de comportamiento de uso de un servicio de Big Data.*

En concordancia tanto con la teoría de la conducta planificada TPB (Ajzen, 1991)1985, 1987 como con el UTAUT original (Venkatesh *et al.*, 2003), podemos comprobar que las condiciones facilitadoras afectan positivamente, no solo sobre la intención, sino también sobre el uso de una nueva tecnología. Trabajos posteriores (Afonso *et al.*, 2102; Al-Gahtani *et al.*, 2007; Brünink, 2016; Chauhan & Jaiswal, 2016; Duyck *et al.*, 2010; H. W. Kim *et al.*, 2007) han contrastado esta hipótesis.

Por ello, podemos enunciar como hipótesis:

H6. *Las condiciones facilitadoras afectan positivamente al uso de un servicio de Big Data.*

Desde la ampliamente utilizada propuesta de Davis, (1985) del Modelo de Aceptación de Tecnologías (TAM), para predecir y evaluar la aceptación y uso de las tec-

nologías hasta la propuesta del modelo UATUT (Venkatesh *et al.*, 2003), que predecía efectos moderadores sobre los antecedentes de la intención de uso de las tecnologías, pasando por la *Theory of Reasoned Action* (TRA) de Fishbein y Ajzen (1975) se contempla la relación directa entre la intención de comportamiento y el uso de las tecnologías. En nuestro caso es indudable que la intención de comportamiento del usuario de Big Data, influido positiva y negativamente por las variables propuestas en nuestro modelo, afecta favorablemente al uso final del servicio.


Esta influencia ha sido contrastada en muchos contextos como, por ejemplo, la adopción de la banca por internet en Portugal (Martins *et al.*, 2014), compra de billetes de avión en España (Escobar-Rodríguez & Carvajal-Trujillo, 2014), uso de sistemas de gestión de documentos electrónicos (Afonso *et al.*, 2102) o adopción de ERPs en la India (Chauhan & Jaiswal, 2016).

Por ello, podemos enunciar como hipótesis:

H7. *La intención de comportamiento del usuario influye favorablemente sobre el uso de un servicio de Big Data.*

En la Figura 2 presentamos el modelo propuesto con las hipótesis enunciadas con anterioridad.

Figura 2. Modelo de aceptación del Big Data en empresas



3. Metodología de la investigación

Para el contraste de las hipótesis planteadas empleamos una muestra proveniente de directivos responsables de áreas funcionales de la empresa o el propio CEO de la compañía.

Los datos fueron recogidos durante el cuarto trimestre de 2017 mediante encuesta online enviada a través de e-mail a una base de datos de empresas y organizaciones. Para eliminar posibles ambigüedades en el cuestionario, previamente se revisó, a modo de pre-test, con 5 directivos voluntarios y otros tantos investigadores.

La elección final de la muestra útil recayó sobre empresas que manifestaron que utilizaban Big Data entre las funciones de gestión de su organización, y obtuvimos 131 observaciones. La clasificación de la muestra final en función de su facturación y sector de actividad se muestra en la Tabla 1.

Tabla 1. Empresas de la muestra según facturación y sector

Muestra	Facturación				Total general
	Menos de 2 millones de €	Entre 2 y 10 millones de €	Entre 10 y 43 millones de €	Más de 43 millones de €	
Agropecuario	1	3	1	1	6
Comercio y distribución	5	3		6	14
Comunicaciones	2	2	4	12	20
Construcción	2		1	3	6
Educación	1	1		2	4
Energético y minero	1			2	3
Financiero	1			7	8
Industrial	3	2	2	4	11
Otros	6	3	3	7	19
Sanitario	3			1	4
Servicios	17	6	6	7	36
Total general	42	20	17	52	131

Las escalas de medida, provenientes en su mayoría del modelo original de Venkatesh *et al.* (2003), han sido adaptadas al Big Data, y ampliadas con diferentes trabajos que han utilizado escalas similares en trabajos anteriores, como los de Moore y Benbasat (1991); McAfee y Brynjolfsson (2012); y Davis *et al.* (1989). La variable riesgo percibido, con la que ampliamos el modelo original, fue medida mediante la escala propuesta por Featherman y Pavlou, (2003). Los ítems de cada escala son recogidos en el Anexo 1.

Para la validación del modelo utilizamos PLS para analizar la fiabilidad y validez de las escalas de medida y valorar el modelo estructural (Chin & Dibbern, 2010; Hair, Sarstedt, Ringle, & Mena, 2012) multi-group comparison of Partial Least Square (PLS. Concretamente, hemos usado el paquete de software Smart-PLS 3 (Ringle, Wende, & Becker, 2015).

También chequeamos previamente que no tuviésemos error por sesgo de medida o *Common Method Bias* (CMB). Para ello seguimos las indicaciones de Kock (2015) y Kock y Lynn (2012) y añadimos una nueva variable latente (variable CMB) como dependiente de las anteriores del modelo, medida con un indicador no usado con anterioridad. Todos los factores de inflación de la varianza (VIF) obtenidos por este método debían ser menores de 3,3 para confirmar que la muestra no tenía error por sesgo de medida. Podemos comprobar que cumplimos estos requisitos en la Tabla 2.

Tabla 2. VIF extraída de los constructos para comprobar el CMB

	Variable CMB
Intención de comportamiento	1,995
Expectativas de esfuerzo	1,432
Condiciones facilitadoras	1,982
Riesgo percibido	1,190
Expectativas de resultado	1,830
Influencia social	1,748
Uso	1,919
Variable_CMB	

4. Resultados

Para el análisis del modelo con PLS vamos a hacer antes un análisis de fiabilidad de los constructos y sus escalas de medida para posteriormente valorar el propio modelo.

Para analizar la fiabilidad y validez del modelo de medida consideramos como aceptable una carga factorial mínima de 0,7 sobre sus propias variables latentes para constructos medidos en modo B como recomienda la literatura (Henseler, Ringle, & Sarstedt, 2014; Roldán & Sánchez-Franco, 2012) the authors propose both the theory underlying PLS and a discussion of the key differences between covariance-based SEM and variance-based SEM, i.e., PLS. In particu- lar, authors: (a. Comprobamos

Procedemos entonces a analizar la fiabilidad de los constructos para lo que empleamos los indicadores de fiabilidad compuesta y alfa de Cronbach. En todos los casos, nuestros indicadores son superiores al 0,7 tal y como sugiere Nunnally (1978). Además, se ha asegurado la validez convergente analizando la varianza media extraída (AVE). En nuestro caso, todos los indicadores ofrecían niveles superiores al 0,5 propuesto por Straub, Detmar-Boudreau y Gefen (2004). Estos indicadores aparecen en la Tabla 4, en la que podemos comprobar que todos los constructos cumplen todos los requisitos.

Tabla 4. Fiabilidad compuesta y validez convergente

	Alfa de Cronbach	rho_A	Fiabilidad compuesta	Varianza extraída media (AVE)
Intención de comportamiento	0,981	0,982	0,986	0,946
Expectativas de esfuerzo	0,906	0,922	0,930	0,726
Condiciones facilitadoras	0,823	0,825	0,894	0,739
Riesgo percibido	0,856	0,875	0,912	0,776
Expectativas de resultado	0,940	0,951	0,952	0,738
Influencia social	0,855	0,917	0,894	0,630
Uso	1,000	1,000	1,000	1,000

Continuamos ahora evaluando la validez discriminante. Lo hemos hecho de dos formas: a) usando el test de Fornell y Larcker donde se compara la raíz cuadrada del AVE de cada variable latente con las correlaciones de dicha variable con el resto (Barclay, Thompson, & Higgins, 1995); y b) mediante el más restrictivo método de la ratio Heterotrait-Monotrait (HTMT) (Henseler *et al.*, 2014) comprobando que en todos los casos ofrecían niveles inferiores a 0,9. Podemos ver los resultados de ambos test, en las Tablas 5 y 6, lo que nos permite comprobar que aseguramos la validez discriminante de todas las variables latentes empleadas.

Tabla 5. Validez discriminante (Test de Fornell-Larcker)


	Intención de comportamiento	Expectativas de esfuerzo	Condiciones facilitadoras	Riesgo percibido	Expectativas de resultado	Influencia social	Uso
Intención de comport.	0,973						
Expectativas de esfuerzo	0,316	0,852					
Condiciones facilitadoras	0,573	0,523	0,860				
Riesgo percibido	-0,336	-0,141	-0,267	0,881			
Expectativas de resultado	0,474	0,509	0,399	-0,197	0,859		
Influencia social	0,494	0,397	0,468	-0,292	0,563	0,794	
Uso	0,618	0,325	0,606	-0,293	0,386	0,436	1,000

Tabla 6. Validez discriminante (Ratio Heterotrait-Monotrait -HTMT)

	Intención de comportamiento	Expectativas de esfuerzo	Condiciones facilitadoras	Riesgo percibido	Expectativas de resultado	Influencia social	Uso
Intención de comport.							
Expectativas de esfuerzo	0,321						
Condiciones facilitadoras	0,636	0,594					
Riesgo percibido	0,363	0,161	0,313				
Expectativas de resultado	0,485	0,534	0,445	0,210			
Influencia social	0,508	0,439	0,542	0,355	0,622		
Uso	0,623	0,327	0,666	0,310	0,389	0,451	

En la Figura 3 podemos ver los valores para cada una de las cargas y el *path* del modelo.

Figura 3: Resultados del modelo



Asimismo, podemos chequear la R-cuadrado de los constructos de segundo orden: intención de comportamiento y uso en la Tabla 7.

Tabla 7. R2 del modelo

	R cuadrado	R cuadrado ajustada
Intención de comportamiento	0,450	0,428
Uso	0,476	0,468

Para la valoración del modelo estructural se analizan los valores de los coeficientes *paths* y la varianza explicada de las variables endógenas (R^2). Los coeficientes *paths* señalan la intensidad de la relación entre las variables dependientes e independientes. Se ha usado una técnica de re-muestreo llamada *bootstrapping* con 10000 muestras para calcular la fiabilidad de los coeficientes *paths* en las relaciones hipotetizadas. Ver Tabla 8.

Tabla 8. Contraste del modelo estructural (Path Coefficients)

	Muestra original (O)	P Valores
Intención de comportamiento → Uso	0,403 ***	0,000
Expectativas de esfuerzo → Intención de comportamiento	-0,114 (ns)	0,066
Condiciones facilitadoras → Intención de comportamiento	0,421 ***	0,000
Condiciones facilitadoras → Uso	0,375 ***	0,000
Riesgo percibido → Intención de comportamiento	-0,144 *	0,014
Expectativas de resultado → Intención de comportamiento	0,244 **	0,002
Influencia social → Intención de comportamiento	0,163 *	0,020

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$. (basado en test de 1 cola y Bootstrap con 10000 muestras).

Además, se calculó el indicador SRMR para la muestra completa. SRMR es una medida del ajuste global del modelo, especialmente adecuada para PLS. En nuestro caso, se obtuvo un valor de 0,076, lo que asegura el ajuste del modelo al ofrecer niveles inferiores a 0,08 propuesto (Henseler *et al.*, 2014).

Los resultados obtenidos indican que se aceptan todas menos una de las hipótesis propuestas, con un elevado nivel de significación. Así, en orden de influencia, vemos cómo las condiciones facilitadoras es el constructo que más aporta a la intención de comportamiento, mientras que el que más aporta al uso es la propia intención. La hipótesis que no puede aceptarse es la H₂, ya que la expectativa de esfuerzo no resulta significativa e incluso de sentido contrario al planteado en el modelo propuesto.

El modelo tiene una potencia explicativa media de un 46'8% sobrepasando el nivel mínimo de un 10% recomendado por Falk y Miller (1992).

Asimismo hemos calculado el Stone-Geisser Q₂ para evaluar la capacidad predictiva del modelo (Gefen, Rigdon, & Straub, 2011) y hemos obtenido los resultados que se muestran en la tabla 9. Con lo que podemos concluir que el modelo tiene

relevancia predictiva al tener todos los valores Q2 de la tabla mayores que o (Roldán & Sánchez-Franco, 2012).

Tabla 9. Resumen de predicción de variables latentes

	RMSE	Q2
Intención de comportamiento	0,573	0,373
Uso	0,525	0,368

5. Conclusiones y limitaciones

5.1. Conclusiones teóricas

La incorporación de la variable riesgo percibido como ampliación del modelo UTAUT pretende mejorar el resultado explicativo del modelo original de aceptación de tecnologías complejas como el Big Data. Los resultados obtenidos al incorporar esta variable, han dado como resultado un modelo altamente predictivo en el que la variable del riesgo percibido influye de forma significativa como freno a la aceptación y uso de las técnicas de Big data en la muestra de empresas analizada. Conocer la aceptación y uso de Big Data por parte de las empresas puede significar un importante avance con relación al uso de la información para la mejora de la gestión de las relaciones con el cliente. Mucho más allá de una herramienta de CRM (*Customer Relationship Management*), Big Data aporta información relevante para las empresas en todas las áreas de gestión.

Centrados en los resultados obtenidos en nuestra investigación, podemos comprobar que la Intención de Uso del Big Data por parte de las empresas viene determinada: 1) por la percepción de obtener buenos resultados con la implementación de esta tecnología (*performance expectancy*); 2) por el efecto positivo que suponen en esta tecnología que otros consideran importante usar (*social influence*); y 3) principalmente, por el hecho de que la empresa facilite el soporte y los recursos para promocionar su uso (*facilitating conditions*). Esta última relación no estaba contemplada en el UTAUT (Venkatesh *et al.*, 2003) original y sí en el UTAUT2 (Venkatesh *et al.*, 2012). Por otra parte, vemos que la Intención de Uso es afectada negativamente por el Riesgo Percibido de adoptar nuevas tecnologías que hay en toda organización, aunque su influencia es un poco menor que las relaciones anteriores. También podemos comprobar que, aunque el uso de Big Data se perciba difícil (*effort expectancy*), su influencia no es significativa sobre la intención de uso. Esto podría explicarse por el hecho que el Big Data es percibido como una tecnología a la que se le presupone

una dificultad en su implementación y que esto no afecta a la intención de uso, resultado que ya hemos obtenido en trabajos anteriores (Cabrera-Sánchez y Villarejo-Ramos, 2018). También hemos podido contrastar una gran influencia positiva de las condiciones facilitadoras sobre el uso de la nueva tecnología, aportando casi la misma carga que la intención de uso.

5.2. Conclusiones prácticas

En cuanto a las implicaciones profesionales, todo esto hace pensar que poco a poco se va asumiendo que cada nueva tecnología tiene su curva de aprendizaje y que influye poco a la hora de adoptarla siempre y cuando se esperen unos grandes resultados, como es en el caso del Big Data. Asimismo, parece que si se tiene la adecuada infraestructura no se pierde nada por probar esta nueva tecnología y que los factores inhibidores de dicha prueba tienen menor peso que todo lo anterior. En este sentido, sería muy relevante que las empresas conocieran que existen herramientas de Big Data de acceso libre y si la empresa cuenta ya con los recursos necesarios de hardware y el personal cualificado, la implantación de esta tecnología es mucho más fácil y con ello su adopción.

5.3. Limitaciones

Entre las principales limitaciones de este trabajo señalamos en primer lugar, que a pesar de la madurez del modelo de base empleado (UTAUT) sólo hemos incluido en nuestra propuesta de modelo una variable precedente más como es el riesgo percibido. Estimamos que, para el caso del Big Data, hay constructos del modelo original, como la expectativa de esfuerzo, que están teniendo un menor peso en su influencia sobre la intención de uso (por lo que podríamos quitarla), lo que nos lleva a pensar que puedan existir más variables que aporten valor al UTAUT y por ello, consideramos necesario en el futuro ir incluyendo estas variables ampliando así nuestro modelo conceptual para medir la aceptación y uso del Big Data en las empresas.

En segundo lugar, parece necesario explorar nuevas variables moderadoras diferentes a las del UTAUT original con el fin de evaluar posibles nuevos efectos no contemplados anteriormente.

Por otra parte, la muestra de empresas es pequeña para poder hacer un buen análisis multi-grupo y poder evaluar posibles diferencias en la intención y el uso del Big Data según sectores de actividad o tamaño de la empresa, entre otras variables de clasificación. Con ello, conseguir una muestra mayor de empresas que utilicen la tecnología Big Data será nuestro reto futuro que a buen seguro permitirá mejorar los resultados de esta investigación.

REFERENCIAS BIBLIOGRÁFICAS

- AFONSO, C., GONZALEZ, M., ROLDÁN, J., & SÁNCHEZ-FRANCO, M. (2012). Determinants of user acceptance of a local eGovernment Electronic Document Management System (EDMS). In Proceedings of the European Conference on e-Government, ECEG (pp. 19-28).
- AGRAWAL, D., BERNSTEIN, P., & BERTINO, E. (2011). Challenges and Opportunities with Big Data 2011-1. Proceedings of the VLDB Endowment, 1-16. Retrieved from <http://dl.acm.org/citation.cfm?id=2367572%5Cnhttp://docs.lib.purdue.edu/cctech/1/>
- AJZEN, I. (1991). The theory of planned behavior. *Organizational Behavior and Human Decision Processes*, 50, 179-211. [https://doi.org/10.1016/0749-5978\(91\)90020-T](https://doi.org/10.1016/0749-5978(91)90020-T)
- AKERKAR, R. (2014). Analytics on big aviation data: Turning data into insights. *International Journal of Computer Science and Applications*, 11(3), 116-127.
- AL-GAHTANI, S. S., HUBONA, G. S., & WANG, J. (2007). Information technology (IT) in Saudi Arabia: Culture and the acceptance and use of IT. *Information and Management*, 44(8), 681-691. <https://doi.org/10.1016/j.im.2007.09.002>
- ARENAS-GAITÁN, J., PERAL-PERAL, B., & VILLAREJO-RAMOS, A.-F. (2016). Grupos de mayores en la banca electrónica. Segmentación de clases latentes con PLS-POS. In Congreso Marketing AEMARK. Madrid.
- BOZAN, K., PARKER, K., & DAVEY, B. (2016). A closer look at the social influence construct in the UTAUT Model: An institutional theory based approach to investigate health IT adoption patterns of the elderly. Proceedings of the Annual Hawaii International Conference on System Sciences, 2016-March, 3105-3114. <https://doi.org/10.1109/HICSS.2016.391>
- BRÜNK, L. (2016). Cross-Functional Big Data Integration : Applying the Utaut Model.
- CABRERA-SÁNCHEZ, J.P. & VILLAREJO-RAMOS, A.F. (2018). Factores que afectan a la adopción del Big Data como instrumento de marketing en las empresas españolas. En H.E. Barroso y V.M. de Sousa (eds.) *Interioridade e Competitividade: Desafios Globais da Gestão*. Ed. Instituto Politécnico da Guarda, Portugal.
- CHAUHAN, S., & JAISWAL, M. (2016). Determinants of acceptance of ERP software training in business schools: Empirical investigation using UTAUT model. *International Journal of Management Education*, 14(3), 248-262. <https://doi.org/10.1016/j.ijme.2016.05.005>
- CHIN, W. W., & DIBBERN, J. (2010). Handbook of Partial Least Squares, 171-193. <https://doi.org/10.1007/978-3-540-32827-8>
- DAVIS, F. (1985). A Technology Acceptance Model for Empirically Testing New End-User Information Systems. Massachusetts Institute of Technology, (December 1985), 291.
- DAVIS, F. D., BAGOZZI, R. P. ., & WARSHAW, P. R. . (1989). User Acceptance of Computer Technology : A Comparison of Two Theoretical Models, 35(8), 982-1003.
- DUYCK, P., PYNOO, B., DEVOLDER, P., VOET, T., ADANG, L., OVAERE, D., & VERCROYSE, J. (2010). Monitoring the PACS implementation process in a large university hospital-discrepancies between radiologists and physicians. *Journal of Digital Imaging*, 23(1), 73-80. <https://doi.org/10.1007/s10278-008-9163-7>
- ESCOBAR-RODRÍGUEZ, T., & CARVAJAL-TRUJILLO, E. (2014). Online purchasing tickets for low cost carriers: An application of the unified theory of acceptance and use of technology (UTAUT) model. *Tourism Management*, 43, 70-88. <https://doi.org/10.1016/j.tourman.2014.01.017>
- FALK, R. F., & MILLER, N. B. (1992). A primer for soft modeling. Akron, OH: University of Akron Press.
- FEATHERMAN, M. S., & PAVLOU, P. A. (2003). Predicting e-services adoption: A perceived

- risk facets perspective. *International Journal of Human Computer Studies*, 59(4), 451-474. [https://doi.org/10.1016/S1071-5819\(03\)00111-3](https://doi.org/10.1016/S1071-5819(03)00111-3)
- FISHBEIN, M., & AJZEN, I. (1975). *Belief Attitude, Intention and Behavior. An Introduction to Theory and Research. Philosophy & Rhetoric*, 10(2), 130-132.
- GEFEN, D., RIGDON, E. E., & STRAUB, D. (2011). An Update and Extension to SEM Guidelines for Administrative and Social Science Research. *MIS Quarterly*, 35(2), iii-A7. <https://doi.org/10.1016/j.lrp.2013.01.001>
- GUPTA, V. K., HUANG, R., & NIRANJAN, S. (2010). A Longitudinal Examination of the Relationship Between Team Leadership and Performance. *Journal of Leadership & Organizational Studies*, 17(4), 335-350. <https://doi.org/10.1177/1548051809359184>
- HAIR, J. F., SARSTEDT, M., RINGLE, C. M., & MENA, J. A. (2012). An assessment of the use of partial least squares structural equation modeling in marketing research. *Journal of the Academy of Marketing Science*, 40(3), 414-433. <https://doi.org/10.1007/s11747-011-0261-6>
- HENSELER, J., RINGLE, C. M., & SARSTEDT, M. (2014). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the Academy of Marketing Science*, 43(1), 115-135. <https://doi.org/10.1007/s11747-014-0403-8>
- HUNG, Y., WANG, Y., & WANG, Y. (2007). User Acceptance of E-Government Services.
- KIM, D. J., FERRIN, D. L., & RAO, H. R. (2008). A trust-based consumer decision-making model in electronic commerce: The role of trust, perceived risk, and their antecedents. *Decision Support Systems*, 44(2), 544-564. <https://doi.org/10.1016/j.dss.2007.07.001>
- KIM, H. W., CHAN, H. C., & GUPTA, S. (2007). Value-based Adoption of Mobile Internet: An empirical investigation. *Decision Support Systems*, 43(1), 111-126. <https://doi.org/10.1016/j.dss.2005.05.009>
- KOCK, N. (2015). Common method bias in PLS-SEM : A full collinearity assessment approach, 1-10.
- KOCK, N., & LYNN, G. S. (2012). Lateral Collinearity and Misleading Results in Variance-Based SEM : An Illustration and Recommendations. *Journal of the Association for Information Systems*, 13(7), 546-580.
- KWON, O., LEE, N., & SHIN, B. (2014). Data quality management, data usage experience and acquisition intention of big data analytics. *International Journal of Information Management*, 34(3), 387-394. <https://doi.org/10.1016/j.ijinfomgt.2014.02.002>
- LEE, J.-H., & SONG, C. (2013). Effects of trust and perceived risk on user acceptance of a new technology service. *Social Behavior and Personality: An ...*, 41(3), 587-598. <https://doi.org/10.2224/sbp.2013.41.4.587>
- MARTINS, C., OLIVEIRA, T., & POPOVIČ, A. (2014). Understanding the internet banking adoption: A unified theory of acceptance and use of technology and perceived risk application. *International Journal of Information Management*, 34(1), 1-13. <https://doi.org/10.1016/j.ijinfomgt.2013.06.002>
- MCÁFEE, A., & BRYNJOLFSSON, E. (2012). Big Data. The management revolution. *Harvard Business Review*, 90(10), 61-68. <https://doi.org/10.1007/s12599-013-0249-5>
- MOORE, G.C., AND BENBASAT, I. (1991). Development of an instrument to measure the perceptions of adopting an information technology innovation. *Information Systems Research*, 2(3), 192-222.
- NUNNALLY, J. C. (1978). *Psychometric Theory* (2nd ed.). McGraw- Hill College.
- RAHMAN, N. (2016). Factors Affecting Big Data Technology Adoption, 0-29. Retrieved from <http://pdxscholar.library.pdx.edu/studentsymposium%5Cnhttp://pdxscholar.library.pdx.edu/studentsymposium/2016/Presentations/10>

- RINGLE, C. M., WENDE, S., & BECKER, J. M. (2015). SmartPLS. «SmartPLS 3.» Boenningstedt: SmartPLS GmbH. Retrieved from <http://www.smartpls.com>
- ROLDÁN, J. L., & SÁNCHEZ-FRANCO, M. J. (2012). Variance-Based Structural Equation Modeling: Guidelines for Using Partial Least Squares in Information Systems Research. *Research Methodologies, Innovations and Philosophies in Software Systems Engineering and Information Systems*. <https://doi.org/10.4018/978-1-4666-0179-6.ch010>
- SIVARAJAH, U., KAMAL, M. M., IRANI, Z., & WEERAKKODY, V. (2016). Critical analysis of Big Data challenges and analytical methods. *Journal of Business Research*, 70, 263-286. <https://doi.org/10.1016/j.jbusres.2016.08.001>
- VENKATESH, V., & DAVIS, F. D. (2000). A Theoretical Extension of the Technology Acceptance Model: Four Longitudinal Field Studies. *Management Science*, 46(2), 186-204. <https://doi.org/10.1287/mnsc.46.2.186.11926>
- VENKATESH, V., MORRIS, M. G., DAVIS, G. B., & DAVIS, F. D. (2003). User Acceptance of Information Technology: Toward a Unified View. *MIS Quarterly*, 27(3), 425-478. Retrieved from <http://www.jstor.org/stable/30036540>
- VENKATESH, V., THONG, J. Y. L., & XU, X. (2012). Consumer Acceptance and Use of Information Technology: Extending the Unified Theory of Acceptance And Use of Technology. *MIS Quarterly*, 36(1), 157-178. <https://doi.org/10.1017/CBO9781107415324.004>
- WU, I. L., & CHEN, J. L. (2005). An extension of Trust and TAM model with TPB in the initial adoption of on-line tax: An empirical study. *International Journal of Human Computer Studies*, 62(6), 784-808. <https://doi.org/10.1016/j.ijhcs.2005.03.003>
- YAQOUB, I., HASHEM, I. A. T., GANI, A., MOKHTAR, S., AHMED, E., ANUAR, N. B., & VASILAKOS, A. V. (2016). Big data: From beginning to future. *International Journal of Information Management*, 36(6), 1231-1247. <https://doi.org/10.1016/j.ijinfomgt.2016.07.009>
- YU, C.-S. (2012). Factors Affecting Individuals to Adopt Mobile Banking: Empirical Evidence from the UTAUT Model. *Journal of Electronic Commerce Research*, 13, 104-121.
- ZICARI, R. (2014). Big data: Challenges and opportunities. *Big Data Computing*. <https://doi.org/doi:10.1201/b16014-5>

ANEXO 1. Escalas de medida

Constructo	Escala	Fuentes
Expectativas de resultado	PE1: Creo que el Big Data es útil para llevar a cabo las tareas de nuestra empresa PE2: Creo que con Big Data se podría hacer las tareas de nuestra empresa más rápidamente PE3: Creo que con Big Data se podría incrementar la productividad de nuestra empresa PE4: Creo que con Big Data mejoraría el rendimiento de nuestra empresa PE5: Creo que con Big Data se puede obtener más información de nuestros clientes PE6: Creo que con Big Data se incrementará la calidad de la información usada en nuestra empresa PE7: Creo que con Big Data se obtendrá nueva información valiosa de nuestros clientes	(Venkatesh <i>et al.</i> , 2003). (Moore, & Benbasat, 1991) (McAfee & Brynjolfsson, 2012)
Expectativas de esfuerzo	EE1: El Big Data le resultaría claro y comprensible a las personas de nuestra empresa EE2: Sería fácil para nuestra empresa familiarizarse con el Big Data EE3: Para nuestra empresa sería fácil usar el Big Data EE4: Creo que aprender Big Data sería fácil para las personas de nuestra empresa EE5: Generar datos valiosos usando Big Data sería fácil para nuestra empresa	(Venkatesh <i>et al.</i> , 2003)
Influencia social	SI1: Las empresas que influyen en la nuestra usan Big Data SI2: Las empresas de referencia para nosotros usan Big Data SI3: Las empresas de nuestro entorno que usan Big Data tienen más prestigio que las que no lo usan SI4: Las empresas de nuestro entorno que usan Big Data son innovadoras SI5: Usar Big Data es un símbolo de estatus en nuestro entorno	(Venkatesh <i>et al.</i> , 2003)
Condiciones facilitadoras	FC1: Nuestra empresa tiene los recursos necesarios para usar Big Data FC2: Nuestra empresa tiene el conocimiento necesario para usar Big Data FC3: El Big Data no es compatible con otros sistemas de nuestra empresa. (QUITADO). FC4: Nuestra empresa tiene disponible una persona (o grupo de ellas) para asistencia con las dificultades que pudieran surgir	(Venkatesh <i>et al.</i> , 2003)
Riesgo percibido	PR1: Usar Big Data es globalmente arriesgado PR2: Es peligroso usar Big Data PR3: Usar Big Data expone a nuestra empresa a un riesgo	(Featherman & Pavlou, 2003)
Intención de comportamiento	BI1: Tenemos la intención de usar Big Data en los próximos meses BI2: Predecimos que usaremos Big Data en los próximos meses BI3: Planificamos usar Big Data en los próximos meses BI4: Tenemos la intención de obtener nuevos y valiosos datos gracias a Big Data en los próximos meses	(Venkatesh <i>et al.</i> , 2003). (Davis, Bagozzi, & Warshaw, 1989)
Comportamiento de uso	UB: ¿Cuál es el actual uso de Big Data en su empresa? <ul style="list-style-type: none"> • Nunca lo hemos usado • Una vez al año • Una vez en 6 meses • Una vez en 3 meses • Una vez al mes • Una vez a la semana • Una vez cada 3-4 días • Cada 2-3 días • A diario 	(Venkatesh <i>et al.</i> , 2003)