

FACTORES QUE AFECTAN A LA ADOPCIÓN DEL BIG DATA COMO INSTRUMENTO DE MARKETING EN EMPRESAS ESPAÑOLAS

Juan-Pedro Cabrera-Sánchez
jcabrera10@us.es
Departamento de Administración de Empresas y Marketing (España)

Ángel F. Villarejo-Ramos
curro@us.es
Universidad de Sevilla
Departamento de Administración de Empresas y Marketing (España)

RESUMEN:

El uso masivo de los smartphones, la gran cantidad de aparatos y sensores conectados a internet y el abaratamiento de la computación y almacenamiento de datos han permitido que se generalice el Big Data. Hoy día, las empresas que sean capaces de obtener nuevos datos sobre su negocio y clientes tendrán una ventaja competitiva sobre las demás y justo por eso, las empresas de éxito están tomando sus decisiones más importantes basadas en datos y no en la jerarquía empresarial. Además, casi todo el software asociado a tecnologías Big Data es software libre por lo que nos preguntamos: “si es libre y aporta mucho valor, ¿por qué no lo usan?”. Así, en este estudio pretendemos evaluar los factores que afectan a la aceptación de esta nueva tecnología por parte de las empresas. Con ese fin, adaptamos el modelo de aceptación de tecnologías UTAUT al contexto del Big Data al que añadimos un inhibidor; la resistencia al uso de las nuevas tecnologías. El modelo estructural fue valorado mediante PLS con un adecuado ajuste global. Entre los resultados destacamos que tiene más relevancia una buena infraestructura para poder usar Big Data que la dificultad de su implantación aceptando por necesario hacer un esfuerzo en su implementación. Aportamos beneficios académicos por lo innovador y para la gestión, el beneficio que reportará a las empresas españolas el desarrollo de esta tecnología para una mejor gestión de la relación con los clientes.

PALABRAS CLAVE: Big Data, intención de uso, UTAUT, aceptación tecnologías, resistencia al uso, PLS.

ABSTRACT:

Massive use of smartphones, great quantity of connected apparels and sensors to internet and low prices of computing and data storage have allowed the Big Data adoption. Nowadays, companies that can get new data about their business and customers will have a competitive advantage over other companies and because of that, successful companies are taking their decisions data-driven and not management-driven. Moreover, almost all this software is free and because of that, we question ourselves: “if it is free and very valuable, why is not being used by all companies?”. That is why in this study, we intend to find the factors that drive this new technology acceptance from companies. We will use an adaptation of the UTAUT to the Big Data context with a new inhibitor such as the use resistance to new technologies. The structural model was evaluated by PLS with an adequate global fit. Among the most remarkable results is the fact that is more important to have a good infrastructure than the difficulties to implement it. So the effort to use it is taken for granted. This research will be useful for scholars and practitioners because of its innovativeness and to have an approach of this technology development influencing on CRM program in Spanish companies.

KEY WORDS: Data, intention behaviour, UTAUT, technology acceptance, use resistance, PLS.

1. INTRODUCCIÓN

El cambio que ha traído el Big Data sobre la forma de analizar los datos ha sido revolucionario. Estas tecnologías suponen un antes y un después en la forma de obtener información valiosa para la empresa ya que permiten gestionar una gran cantidad de datos, prácticamente en tiempo real y obtener una gran información que dota a las empresas que las tienen implementadas de una gran ventaja competitiva.(Sivarajah, Kamal, Irani, & Weerakkody, 2016).

Las empresas están recolectando tal cantidad de datos de sus clientes que para poder tratarlos bien hacen falta nuevas destrezas y competencias como los “*Data Scientist*” que son un híbrido de ingeniería, estadística y profundo conocimiento del negocio. 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)

Sin embargo, para implementar o integrar Big Data en las empresas actuales 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).

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) dejando de lado su integración y uso dentro de la empresa. Salvo un trabajo sobre la intención de adoptar analítica Big Data (Kwon, Lee, & Shin, 2014) y otros dos sobre adopción de la tecnología Big Data (Brünink, 2016; Rahman, 2016) hay poca literatura al respecto.

Hoy día se están produciendo datos constantemente con nuestra mera actividad de usar el móvil. El móvil está geolocalizado y tiene acceso a internet, a la que están conectados millones de dispositivos. Las empresas tienen toda esta información a su disposición junto con los productos comprados, momentos de consumo (días y horas), sentimientos hacia su marca, actividad en redes sociales, formas de pago y mucha más información que supone que el tratamiento de toda esta gran cantidad de datos haya que hacerlo con novedosas técnicas como el Big Data (McAfee & Brynjolfsson, 2012).

Todos estos datos, muchos de ellos generados en tiempo real, no tienen la misma estructura por lo que las bases de datos SQL no sirven para almacenarlos y aquí es donde surge el término Big Data. Se usa para describir grandes conjuntos de datos, no estructurados y que en muchos casos necesitan ser capturados casi en tiempo real. Para manejarlos es necesario un nuevo conjunto de tecnologías y herramientas liderados por la fundación Apache (Hashem et al., 2015; Sivarajah et al., 2016; Yaqoob et al., 2016). Y aunque no existe una definición unánime de Big Data podríamos usar la siguiente: “tecnología que permite almacenar, procesar y combinar enormes cantidades de diferentes tipos de datos obtenidos de diferentes fuentes” (Brünink, 2016).

Como principales características del Big Data podemos hablar del modelo de las tres V’s propuesto por Gartner (2012):

- Volumen: grandes cantidades de datos creados por humanos y máquinas que continúa creciendo exponencialmente.
- Variedad: hace referencia a los diferentes tipos de datos, desde imágenes a tuits pasando por datos de venta o geo posicionamiento.
- Velocidad: los datos llegan por diferentes flujos con especial hincapié por los generados en tiempo real.

Trabajos posteriores como los de Fan y Bifet (2013) o Gandomi y Haider (2015) añaden dos nuevas características:

- Veracidad: los datos han de ser veraces y las fuentes confiables.
- Valor: los datos han de aportar y generar valor para obtener ventajas competitivas.

Y como principal uso de estas técnicas podemos tener la analítica de datos que correctamente usada nos va a permitir sacar nuevos patrones y valiosas ideas que nos permitirán hacer una analítica descriptiva (Joseph, State, & Johnson, 2013), predictiva (Waller & Fawcett, 2013) e incluso, prescriptiva (Joseph et al., 2013).

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.

La estructura del trabajo recoge en el siguiente epígrafe la justificación teórica de las relaciones del modelo causal propuesto: El tercer epígrafe describe la metodología usada en la investigación. El epígrafe cuarto

describe y analiza los resultados obtenidos tras la aplicación del modelo a la muestra observada. Finalizamos el trabajo presentando las principales conclusiones y limitaciones del mismo.

2. PROPUESTA DE MODELO Y PLANTEAMIENTO DE HIPÓTESIS

La adopción de una tecnología es determinante para su éxito. Desde la teoría de la conducta planificada -TPB (Ajzen, 1991) hasta el muy usado modelo de aceptación de la tecnología-TAM (Davis, 1985) se han desarrollado y testado muchos modelos de aceptación de tecnología. Pero sin duda, el modelo propuesto por la *Unified Theory of Technology Adoption and Use of Technology*, o UTAUT (Venkatesh, Morris, Davis, & Davis, 2003) integra diferentes modelos y teorías previos que se han propuesto para analizar la aceptación de una tecnología.

Los determinantes del modelo son: 1) 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; 2) las expectativas de esfuerzo (*Effort Expectancy*, EE), que miden el grado de facilidad asociado al uso de la tecnología; 3) la influencia social (*Social Influence*, SI) o como los consumidores perciben que amigos y familiares creen que ellos deberían utilizar una tecnología; y 4) las condiciones facilitadoras (*Facilitating Conditions*, FC), percepciones de los consumidores de que los recursos y el apoyo están disponibles para desarrollar un comportamiento. El modelo propone una influencia directa de las tres primeras sobre la intención de uso (*Behavior Intention*, BI). Las condiciones facilitadoras influyen sobre el uso de la nueva tecnología (*Usage Behavior*, UB).

Como señalan Arenas-Gaitán, Peral-Peral, & Villarejo-Ramos,(2016), el valor de este modelo está en su capacidad de identificar cuáles son los principales determinantes de la adopción, y permite incluir y considerar el efecto de diferentes moderadores que afectan en la influencia de los constructos claves del modelo.

A los constructos del modelo UTAUT añadimos la resistencia al uso (*Resistance Use*, RE) ya que en la adopción de nuevas tecnologías y sistemas de información también se ha investigado sobre la resistencia al uso como reacción adversa u oposición al cambio o nueva implementación de tecnologías. En este contexto se define la resistencia como la oposición al cambio asociado a la implementación de una nueva tecnología o sistema de información (Kim & Kankanhalli, 2009).

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

Las **expectativas de resultado** (*Performance Expectancy*, PE) hacen referencia a 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; Yu, 2012) además del propio trabajo original (Venkatesh et al., 2003) sostiene esta relación positiva.

Consecuencia de lo anterior podemos establecer como hipótesis:

- *Hipótesis 1: Las expectativas de resultado afectan de forma positiva sobre la intención de comportamiento 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; Chauhan & Jaiswal, 2016; H. W. Kim, Chan, & Gupta, 2007; Lee & Song, 2013; Yu, 2012) que confirman el efecto que tiene el esfuerzo esperado sobre la intención de uso.

Por ello, enunciarnos como segunda hipótesis del modelo:

- *Hipótesis 2: La expectativa de esfuerzo afecta negativamente sobre la intención de comportamiento del usuario de Big data*

La medida de la **influencia social** (*Social Influence*, SI) 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; Brünink, 2016; Chauhan & Jaiswal, 2016; Gupta, Huang, & Niranjan, 2010; H. W. Kim et al., 2007; Lee & Song, 2013).

Por lo anterior podemos enunciar como hipótesis:

- *Hipótesis 3: La influencia social afecta positivamente a la intención de comportamiento en el uso de un servicio de Big data.*

La **resistencia al uso** (*Resistance Use, RU*) ha sido entendida como oposición o reacción negativa ante la implementación de una nueva tecnología. Como señala Gibson (2004), la puesta en marcha de muchas nuevas tecnologías han resultado fallidas por la oposición de los usuarios a su implementación. Y aunque la resistencia al uso está bastante estudiada en la literatura (Kim & Kankanhalli, 2009; Lapointe & Rivard, 2007) hay muy pocos estudios que la usen integrándolas en el modelo UTAUT. No obstante sí que hay precedentes de la resistencia al uso con la intención de uso (Hsieh, 2015).

Por ello, podemos enunciar como hipótesis:

- *Hipótesis 4: La resistencia al uso influye negativamente sobre la intención de uso de un servicio de Big Data.*

Las **condiciones facilitadoras** (*Facilitating Conditions, FC*) 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; Hung, Wang, & Wang, 2007; Wu, Tao, & Yang, 2007).

Por ello, podemos enunciar como hipótesis:

- *Hipótesis 5: Las condiciones facilitadoras afectan positivamente a la intención de comportamiento en el uso de un servicio de Big Data.*

En concordancia tanto con la teoría de la conducta planificada TPB (Ajzen, 1991) y por tanto con el UTAUT original (Venkatesh et al., 2003), podemos comprobar que las condiciones facilitadoras afectan positivamente al uso de una nueva tecnología. Trabajos posteriores (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:

- *Hipótesis 6: Las condiciones facilitadoras afectan positivamente a la intención de comportamiento en el 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 tecnologías 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) (Fishbein & 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, Oliveira, & Popovič, 2014), compra de billetes de avión en España (Escobar-Rodríguez & Carvajal-Trujillo, 2014), uso de sistemas de gestión de documentos electrónicos (Afonso, Gonzalez, Roldán, & Sánchez-Franco, 2102) o adopción de ERPs en la India (Chauhan & Jaiswal, 2016).

Por ello, podemos enunciar como hipótesis:

- *Hipótesis 7: La intención de comportamiento del usuario influye favorablemente sobre el uso de un servicio de Big Data.*

En la Figura 1 presentamos el modelo propuesto con las hipótesis enunciadas con anterioridad.

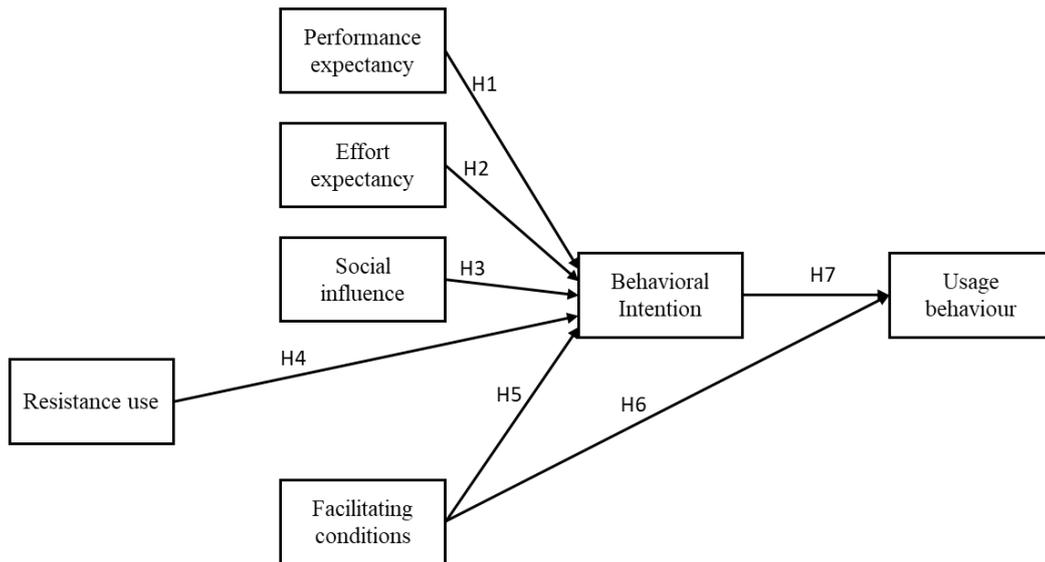


Figura 1. Modelo de aceptación del Big data en empresas

3. METODOLOGÍA DE LA INVESTIGACIÓN

3.1 DESCRIPCIÓN DE LA MUESTRA

La muestra empleada en este trabajo proviene de directivos responsables de un área como RRHH, Financiero, Marketing y Ventas o el propio CEO de la compañía.

Los datos fueron recogidos durante los meses de septiembre y octubre de 2017 mediante una encuesta autoadministrada realizada por internet. Para eliminar posibles ambigüedades en el cuestionario, previamente se revisó, a modo de pre-test, con 5 directivos voluntarios y otros tantos investigadores.

El número de encuestas validas fue de 128 y las podemos clasificar en función de su facturación y sector de actividad tal y como se muestra en la Tabla 1.

Tabla 1. Empresas de la muestra según facturación y sector

Sector	(en blanco)	Menos de 2 Millones de €	Entre 2 y 10 Millones de €	Entre 10 y 43 Millones de €	Más de 43 Millones de €	Total general
Agropecuario		1	2	2		5
Comercio y distribución		2	1		6	9
Comunicaciones	1	4	2	2	10	19
Construcción		2			1	3
Educación		2	1		2	5
Energético y minero		1				1
Financiero		1			6	7
Industrial		4	3		5	12
Otros	1	7	8	2	9	27
Sanitario		3			2	5
Servicios		11	9	6	8	34
(en blanco)	1					1
Total general	3	38	26	12	49	128

3.2 ESCALAS DE MEDIDA

Las escalas de medida, provenientes en su mayoría del modelo original de Venkatesh et al. (2003), han sido adaptadas al Big Data, según los trabajos recogidos en la Tabla 2. La variable Resistencia al Uso fue medida mediante la escala propuesta por Bhattacharjee y Hikmet (2007).

Tabla 2. Escalas de medida

Constructo	Escala	Fuentes
Performance expectancy	PE1: Creo que el Big Data es útil para llevar a cabo las tareas de nuestra empresa	(Venkatesh et al., 2003).
	PE2: Creo que con Big Data se podría hacer las tareas de nuestra empresa más rápidamente	(Moore, & Benbasat, 1991).
	PE3: Creo que con Big Data se podría incrementar la productividad de nuestra empresa	(McAfee & Brynjolfsson, 2012)
	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	
Effort Expectancy	EE1: El Big Data le resultaría claro y comprensible a las personas de nuestra empresa	(Venkatesh et al., 2003)
	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	
Social Influence	SI1: Las empresas que influyen en la nuestra usan Big Data	(Venkatesh et al., 2003)
	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	
Facilitating conditions	FC1: Nuestra empresa tiene los recursos necesarios para usar Big Data	(Venkatesh et al., 2003)
	FC2: Nuestra empresa tiene el conocimiento necesario para usar Big	

	Data	
	FC3: El Big Data no es compatible con otros sistemas de nuestra empresa	
	FC4: Nuestra empresa tiene disponible una persona (o grupo de ellas) para asistencia con las dificultades que pudieran surgir	
Resistance to use	RU1: No queremos usar Big Data para cambiar el modo en el que analizamos nuestros datos	(Bhattacharjee & Hikmet, 2007)
	RU2: No queremos usar Big Data para cambiar el modo en el que tomamos decisiones	
	RU3: No queremos usar Big Data para cambiar el modo en el que interactuamos con otras personas en nuestro trabajo	
	RU4: Sobre todo, no queremos usar Big Data para cambiar nuestra actual forma de trabajar	
Behavioural intention	BI1: Tenemos la intención de usar Big Data en los próximos meses	(Venkatesh et al., 2003).
	BI2: Predecimos que usaremos Big Data en los próximos meses	
	BI3: Planificamos usar Big Data en los próximos meses	(Davis, Bagozzi, & Warshaw, 1989)
	BI4: Tenemos la intención de obtener nuevos y valiosos datos gracias a Big Data en los próximos meses	
Usage behaviour	UB: ¿Cuál es el actual uso de Big Data en su empresa?	(Venkatesh et al., 2003)
	(i) Nunca lo hemos usado	
	(ii) Una vez al año	
	(iii) Una vez en 6 meses	
	(iv) Una vez en 3 meses	
	(v) Una vez al mes	
	(vi) Una vez a la semana	
	(vii) Una vez cada 3-4 días	
	(viii) Cada 2-3 días	
	(ix) A diario	

3.3 HERRAMIENTAS ESTADÍSTICAS

Hemos empleado diversas técnicas estadísticas de cara a lograr los objetivos planteados. Hemos usado 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). Concretamente, hemos usado el paquete de software SmartPLS 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 & Lynn (2012) y añadimos una nueva variable latente llamada 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 CMB. Podemos comprobar que cumplimos estos requisitos en la Tabla 3.

Tabla 3. VIF extraída de los constructos para comprobar el CMB

	Variable CMB
Behavioral Intention	2,351
Effort Expectancy	1,621
Facilitating Conditions	2,027
Performance Expectancy	1,971
Resistance use	1,611
Social Influence	1,710
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 vamos a basarnos en la literatura existente (Henseler, Ringle, & Sarstedt, 2014; Roldán & Sánchez-Franco, 2012), en la que se nos propone una carga factorial mínima de 0,7 sobre sus propias variables latentes para constructos medidos en modo B. Comprobamos que todos los indicadores, excepto FC3, cumplen dicha condición. Por ello, decidimos eliminar este indicador manteniendo el resto en la escala original y procedimos a recalcular las cargas factoriales. Dichos resultados se exponen en la Tabla 4.

Tabla 4. Fiabilidad individual de las escalas de medida (cargas factoriales)

	Behavioral Intention	Effort Expectancy	Facilitating Conditions	Performance Expectancy	Resistance use	Social Influence	Usage Behaviour
BI1	0,969						
BI2	0,983						
BI3	0,984						
BI4	0,977						
EE1		0,735					
EE2		0,862					
EE3		0,880					
EE4		0,819					
EE5		0,758					
FC1			0,890				
FC2			0,898				
FC4			0,856				
PE1				0,924			
PE2				0,914			
PE3				0,914			
PE4				0,950			
PE5				0,835			
PE6				0,853			
PE7				0,783			
RU1					0,918		
RU2					0,959		
RU3					0,929		
RU4					0,880		
SI1						0,744	
SI2						0,888	
SI3						0,813	

SI4						0,810	
SI5						0,728	
UB							1,000

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 (Straub, DetmarBoudreau & Gefen, 2004). Estos indicadores aparecen en la Tabla 5, en la que podemos comprobar que todos los constructos, incluido el constructo Condiciones Facilitadoras, cumplen todos los requisitos.

Tabla 5. Fiabilidad compuesta y validez convergente

	Alfa de Cronbach	rho_A	Fiabilidad compuesta	Varianza extraída media (AVE)
Behavioral Intention	0,985	0,986	0,989	0,957
Effort Expectancy	0,878	0,910	0,907	0,661
Facilitating Conditions	0,856	0,856	0,913	0,777
Performance Expectancy	0,953	0,960	0,961	0,781
Resistance use	0,941	0,946	0,958	0,850
Social Influence	0,858	0,874	0,898	0,638
Usage Behaviour	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 tests, en las Tablas 6 y 7, lo que nos permite comprobar que aseguramos la validez discriminante de todas las variables latentes empleadas.

	Behavioral Intention	Effort Expectancy	Facilitating Conditions	Performance Expectancy	Resistance use	Social Influence	Usage Behaviour
Behavioral Intention	0,978						
Effort Expectancy	0,356	0,813					
Facilitating Conditions	0,625	0,519	0,882				
Performance Expectancy	0,587	0,480	0,380	0,884			
Resistance use	-0,529	-0,281	-0,407	-0,547	0,922		
Social Influence	0,496	0,517	0,482	0,456	-0,246	0,799	
Usage Behaviour	0,663	0,336	0,670	0,423	-0,429	0,491	1,000

Tabla 6. Validez discriminante (Test de Fornell-Larcker)

Tabla 7. Validez discriminante (Ratio Heterotrait-Monotrait -HTMT)

	Behavioral Intention	Effort Expectancy	Facilitating Conditions	Performance Expectancy	Resistance use	Social Influence	Usage Behaviour
Behavioral Intention							
Effort Expectancy	0,332						
Facilitating Conditions	0,681	0,560					
Performance Expectancy	0,600	0,478	0,411				
Resistance use	0,548	0,280	0,451	0,574			
Social Influence	0,530	0,573	0,559	0,496	0,276		
Usage Behaviour	0,667	0,311	0,724	0,426	0,440	0,522	

En la Figura 2 podemos ver los valores para cada una de las cargas y el *path* del modelo. Asimismo, podemos chequear la R2 de los constructos de segundo orden: Intención de Comportamiento y Uso en la Tabla 8.

Tabla 8. R² del modelo

	R cuadrado	R cuadrado ajustada
Behavioral Intention	0,584	0,566
Usage Behaviour	0,546	0,539

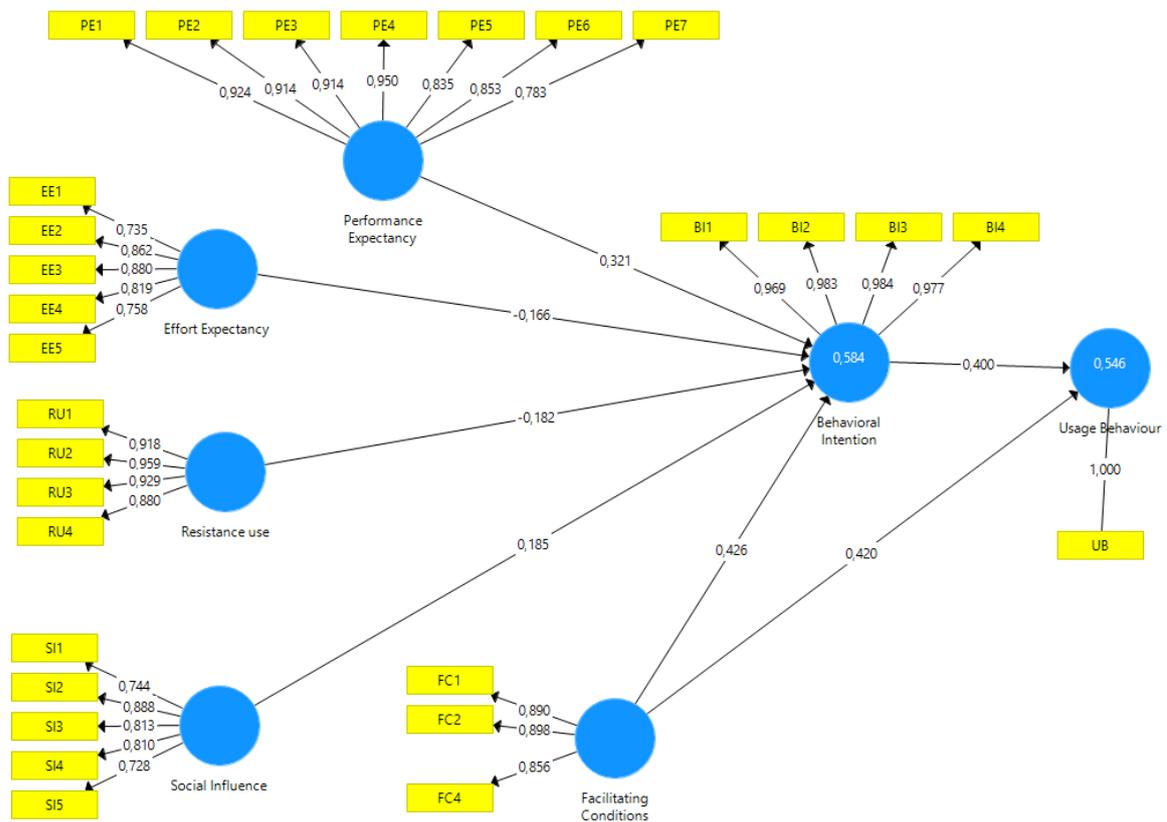


Figura 2: Resultados del modelo.

Para la valoración del modelo estructural se analizan los valores de los coeficientes *paths* y la varianza explicada de las variables endógenas (R²). 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 5000 muestras para calcular la fiabilidad de los coeficientes *paths* en las relaciones hipotetizadas. Ver Tabla 9.

Tabla 9. Contraste del modelo estructural (*Path Coefficients*)

	Muestra original (O)	P Valores
Behavioral Intention -> Usage Behaviour	0,400 ***	0,000
Effort Expectancy -> Behavioral Intention	-0,166 *	0,016
Facilitating Conditions -> Behavioral Intention	0,426 ***	0,000
Facilitating Conditions -> Usage Behaviour	0,420 ***	0,000
Performance Expectancy -> Behavioral Intention	0,321 ***	0,000
Resistance use -> Behavioral Intention	-0,182 *	0,011
Social Influence -> Behavioral Intention	0,185 **	0,007

*** $p < 0,001$, ** $p < 0,01$, * $p < 0,05$. (basado en test de 1 cola y Bootstrap con 5000 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 0,078, 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 las hipótesis propuestas, con un elevado nivel de significación. Así, en orden de influencia, vemos como las Condiciones Facilitadoras es el constructo que más aporta a la Intención y al Uso seguido de la Expectativas de Resultado. Se comprueba también la relación entre la intención y el uso, significativa al máximo nivel de exigencia.

El modelo tiene una potencia explicativa media de un 54,6% sobre pasando el nivel mínimo de un 10% recomendado por Falk y Miller (1992).

Asimismo hemos calculado el Stone-Geisser Q^2 para evaluar la capacidad predictiva del modelo (Gefen, Rigdon, & Straub, 2011) y hemos obtenido los resultados de la tabla 10.

Tabla 10. Resumen de predicción de variables latentes

	RMSE	Q^2
Behavioral Intention	0,583	0,545
Usage Behaviour	0,543	0,508

Con lo que podemos concluir que el modelo tiene relevancia predictiva al tener todos los valores Q^2 de la tabla mayores que 0 (Roldán & Sánchez-Franco, 2012).

5. CONCLUSIONES Y LIMITACIONES

5.1 CONCLUSIONES TEÓRICAS

Nuestro trabajo amplía el modelo UTAUT incorporando una nueva variable, Resistencia al Uso, que pretende mejorar el resultado del modelo original de aceptación de tecnologías complejas como el Big Data. Esto contribuye a la generalización de este modelo, a su conocimiento y en definitiva, a un mejor entendimiento de la aceptación de nuevas tecnologías, en nuestro caso particular el Big Data. La utilización 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 la Resistencia al Uso de nuevas tecnologías que hay en toda organización, aunque su influencia es menor que las relaciones anteriores. También podemos comprobar que, aunque el uso de Big Data se perciba difícil (*Effort Expectancy*), su influencia es muy baja y poco 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. También hemos podido contrastar una gran influencia positiva de las condiciones facilitadoras sobre el uso de la nueva tecnología, aportando más carga incluso que la Intención de Uso.

Por tanto, y tras la contrastación del modelo, observamos que todas las hipótesis planteadas en la ampliación propuesta del modelo UTAUT, han sido aceptadas, lo que puede trasladarse al diseño de un modelo que aporta cierta mejora al modelo original.

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 conocer por parte de las empresas que mucho software asociado al uso del Big Data es libre y si la empresa cuenta ya con los recursos necesarios de hardware y de personal cualificado es mucho más fácil su adopción por lo que ahí es donde enfocaríamos nuestro esfuerzo de comunicación.

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 la Resistencia al Uso. 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, 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 Big Data.

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 multigrupo 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.

6. 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).
- 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)
- 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.
- Bhattacharjee, A., & Hikmet, N. (2007). Physicians' resistance toward healthcare information technology: a theoretical model and empirical test. *European Journal of Information Systems*, 16(6), 725–737. <https://doi.org/10.1057/palgrave.ejis.3000717>
- Brünink, L. (2016). *Cross-Functional Big Data Integration: Applying the Utaut Model*.
- 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., & Vercruysse, 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.

Fan, W., & Bifet, A. (2013). Mining Big Data : Current Status , and Forecast to the Future. *ACM SIGKDD Explorations Newsletter*, 14(2), 1–5. <https://doi.org/10.1145/2481244.2481246>

Fishbein, M., & Ajzen, I. (1975). Belief Attitude, Intention and Behavior. An Introduction to Theory and Research. *Philosophy & Rhetoric*, 10(2), 130–132.

Gartner. (2012). What Is Big Data? - Gartner IT Glossary - Big Data. Retrieved May 22, 2017, from <http://www.gartner.com/it-glossary/big-data/>

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., & Niranjana, 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>

Hashem, I. A. T., Yaqoob, I., Anuar, N. B., Mokhtar, S., Gani, A., Ullah Khan, S., ... Popovič, A. (2015). Education and training for successful career in Big Data and Business Analy...: EBSCOhost. *International Journal of Information Management*, 34(1), 1–16. <https://doi.org/10.1080/12460125.2015.994333>

Hashem, I. A. T., 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>

Hsieh, P. J. (2015). Healthcare professionals' use of health clouds: Integrating technology acceptance and status quo bias perspectives. *International Journal of Medical Informatics*, 84(7), 512–523. <https://doi.org/10.1016/j.ijmedinf.2015.03.004>

Hung, Y., Wang, Y., & Wang, Y. (2007). User Acceptance of E-Government Services. *IEEE Computer Society*, 43–48.

Joseph, R. C., State, P., & Johnson, N. A. (2013). Big data and transformational government.pdf. *IEEE Computer Society*, 43–48. Retrieved from computer.org/ITPro

Kim, H.-W., & Kankanhalli, A. (2009). Investigating user resistance to implementation: a status quo bias perspective. *MIS Quarterly*, 33(3), 2009. <https://doi.org/Article>

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>

Lapointe, L., & Rivard, S. (2007). A Triple Take on Information System Implementation. *Organization Science*, 18(1), 89–107. <https://doi.org/10.1287/orsc.1060.0225>

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>

McAfee, 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>

Straub, DetmarBoudreau, M., & Gefen, D. (2004). Validation Guidelines for IS Positivist Validation Guidelines for IS Positivist. *Communications of the Association for Information Systems*, 13, 380–427. <https://doi.org/Article>

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>

Waller, M. A., & Fawcett, S. E. (2013). Data Science , Predictive Analytics , and Big Data: A Revolution That Will Transform Supply Chain Design and Management. *Journal of Business Logistics*, 34(2), 77–84. <https://doi.org/10.1111/jbl.12010>

Wu, Y. L., Tao, Y. H., & Yang, P. C. (2007). Using UTAUT to explore the behavior of 3G mobile communication users. *IEEM 2007: 2007 IEEE International Conference on Industrial Engineering and Engineering Management*, 199–203. <https://doi.org/10.1109/IEEM.2007.4419179>

Yaqoob, 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.