



Facultad de Ciencias Económicas y Empresariales (ICADE)

# **Investigación en la aplicación de técnicas de Inteligencia Artificial (IA) en la industria de la auditoría**

Clave: 201813819

MADRID | JUNIO 2020

## **Índice**

### **Sección Uno Introducción**

- Tema de Investigación.....4
- Justificación del Tema escogida.....5
- Pregunta de Investigación.....5
- Objetivos del Trabajo.....5
- Estructura del Trabajo.....6

### **Sección Dos Marco Teórico**

- Marco Teórico.....7

### **Sección Tres Metodología**

- Metodología.....12

### **Sección Cuatro Hallazgos y Discusión**

- Introducción.....14
- Parte (a) – Efecto de la IA en las fases de la auditoría
  - Etapa 1 - Pre-Planificación y Contratación.....16
  - Etapa 2 - Comprensión de la entidad y la evaluación de los controles internos.....19
  - Etapa 3 - Pruebas sustantivas.....23
  - Etapa 4 – Informe de auditoría.....32
- Parte (b) - La inversión de las grandes empresas de contable pública en la IA.....34
- Parte (c) – La inversión de universidades en la IA.....41

### **Sección Cinco Conclusiones**

- Conclusiones.....43

- Referencias.....46**

- Anexo.....54**

## **Resumen**

El siguiente TFG lleva a cabo una investigación y análisis sobre la Inteligencia Artificial y su efecto en la industria de contable, con un enfoque particular en la auditoría y el proceso de auditoría. Con base en la tecnología cognitiva, la IA ha facilitado y seguirá facilitando la improvisación y automatización de la auditoría. El impacto potencial de la IA en la industria de la auditoría y lo que ya ha logrado no sólo se ha discutido por los investigadores académicos y contables por igual, sino también en un sentido económico, ya que las grandes empresas de auditoría comienzan a darse cuenta del impacto monumental que la IA podría tener en sus procesos de negocio. Este trabajo transmite al lector las diferencias que la IA está haciendo con los pasos individuales en el proceso de auditoría y los efectos de repercusión de esos cambios, mostrando a través del análisis estadístico la validez de estos cambios para que se justifique la automatización adicional de la auditoría. A través de un análisis económico, tecnológico y social, se presentará la situación que rodea a la IA en la auditoría desde el pasado, el momento presente y el futuro, tanto desde el marco como desde los tecnicismos del mundo tecnológico y del mundo contable.

**Terminología clave: Inteligencia Artificial, Contable, Tecnología, Aprendizaje Automático, Auditoría, Automatización**

## **Abstract**

The following project carries out an investigation and analysis on Artificial Intelligence and its effect on the accounting industry, with a focus on auditing and the audit process. Based on cognitive technology, AI has and will continue to facilitate the improvement and automatization of auditing. The potential impact of AI on the auditing industry and what it has already achieved has not only become blatantly obvious to academic researchers and accountants alike, but also in an economic sense as large auditing firms begin to realise the monumental impact that AI could have on their business processes. This work conveys to the reader what differences AI is making to individual steps in the auditing process and the knock-on effect of those changes, showcasing through statistical analysis the validity of these changes so that further automatization of auditing is justified. Through an economic, technological and social analysis, the situation surrounding AI in auditing from the past, the present moment and the future will be presented, both from the framework and technicalities of the technological world and the accounting world.

**Key Words: Artificial Intelligence, Accountancy, Technology, Machine Learning, Auditing, Automatization**

## 1. Introducción

### Tema de investigación

El tema del trabajo girará en torno al uso de la Inteligencia Artificial en contable con un enfoque en la auditoría. Se ha observado que los auditores modernos se ocupan de una cantidad sustancial de trabajo con limitaciones de tiempo que garantizan un entorno presurizado (Hanson, 2013). También se ha examinado la calidad de la auditoría, con sistemas de revisión por pares que detectan el 62% de las contrataciones no conformes en 2017, frente al 47% en 2016, lo que indica un aumento en la revisión de auditorías (AICPA, 2018). La competencia por las tasas de auditoría entre los mayores profesionales también ha puesto un control en la calidad de la auditoría en los últimos años (Asthana, Khurana y Raman, 2019). Con el fin de hacer frente a estos desafíos relacionados con la calidad de la auditoría, las empresas de contable pública se han comenzado a reconocer la utilidad de la Inteligencia Artificial (IA) y, por lo tanto, han integrado técnicas en sus herramientas analíticas de software y auditoría más recientes (Shah, 2018). Ha habido sugerencias de que las estadísticas informáticas avanzadas y las técnicas de aprendizaje automático deben integrarse en un nuevo plan de estudios contable (PwC, 2015) y las empresas más grandes de las industrias (KPMG, PwC, EY & Deloitte) están trabajando actualmente en soluciones de IA a sus auditorías (Kepes, 2016) exhiben los grandes cambios que se avecinan en la industria, algo que será examinado en más detalle. Según la encuesta milenaria de Deloitte en 2017, el 40% ve la automatización como una amenaza a sus puestos de trabajo; la mayoría cree que tendrá que volver a entrenarse un 51%; y el 53% ve el lugar de trabajo cada vez más impersonal y menos humano (Deloitte, 2017a). Estos resultados son particularmente relevantes para los auditores debido a su alta susceptibilidad a la automatización (véase la encuesta a la que se hace referencia en el párrafo siguiente) y muestran la necesidad de que las empresas de contable pública estén tecnológicamente alfabetizados y listos para afrontar la realidad de un lugar de trabajo automatizado moderno. Con la auditoría que representa el 39% de los ingresos de KPMG en 2018, una gran parte de esta automatización de las empresas más grandes se centrará en esta parte del negocio, algo que este trabajo pretende ilustrar mediante el análisis de la aplicación de técnicas de IA a la auditoría.

### **Justificación del Tema Escogida**

Un estudio realizado por Frey & Osborne en 2013 sobre la informatización de las ocupaciones encontró que la probabilidad de que los auditores fueran reemplazados por la automatización era del 94%, una cifra que muestra la necesidad de que los auditores se eduquen en la IA y la prueba de que la industria se verá bajo enormes refinamientos en el futuro. La susceptibilidad de la auditoría a ser reemplazado por la IA me ha motivado a llevar a cabo un estudio e investigar cómo diversas técnicas de IA han alterado el papel del auditor, cómo se han llevado a cabo las auditorías en los últimos años, y cómo se llevarán a cabo en el futuro. La creciente probabilidad de un proceso de auditoría totalmente inducido por la IA en el futuro, (una encuesta del Foro Económico Mundial 2015 de 800 ejecutivos encontró que el 75% de esos ejecutivos creen que el 30% de cada auditoría corporativa será realizada por IA para 2025), también me ha inspirado a formular por mí mismo cómo podría verse este proceso de auditoría, con especial énfasis en el análisis estadístico que demuestra que la Inteligencia Artificial puede adelgazar y mejorar aspectos del proceso de auditoría complementado de IA tanto para el auditor.

### **Pregunta de investigación**

- ¿Cómo cambiará la Inteligencia Artificial el proceso de auditoría en el futuro?
- ¿Mejora la Inteligencia Artificial la velocidad, la calidad y la fiabilidad de una auditoría, en comparación con el sistema tradicional?

### **Objetivos del estudio**

- Comprender las capacidades modernas y potenciales de la IA y contextualizar cómo podrían aplicarse a la auditoría junto con los seres humanos
- Mostrar que la IA es superior al auditor humano tradicional en ciertos roles al mostrar pruebas válidas de que puede mejorar las distintas fases de la auditoría
- Investigar hasta qué punto las grandes empresas y universidades públicas están invirtiendo en la IA o análisis de auditoría para facilitar este cambio

### **Metodología**

El enfoque de investigación utilizado fue la investigación secundaria o la investigación documental. Esta forma de investigación implicaba el análisis de la literatura académica y el uso de los resultados asumidos por estos estudios para llegar a conclusiones sobre el tema pertinente.

## **Resultados**

Los resultados de la investigación indican que la inteligencia artificial tiene y seguirá teniendo un efecto positivo en el proceso de auditoría en términos de rapidez, calidad y fiabilidad en tres de las cuatro etapas de auditoría descritas en este documento. La viabilidad de la inteligencia artificial también está respaldada por el aumento de las inversiones realizadas por las mayores empresas de contable pública y universidades.

## **Estructura del Trabajo**

Una vez introducidas y justificadas las razones para elegir el tema, el resto del documento se estructurará de la siguiente manera:

- Sección 2 - Marco teórico
- Sección 3 - Sección de metodología.
- La sección 4 se divide aproximadamente en tres partes. La parte a) explica cada etapa del proceso de auditoría y compara los procedimientos de auditoría tradicionales con la IA para mostrar la superioridad de los procedimientos de auditoría inducidos por IA. La parte b) describe la inversión de las grandes empresas de contable pública en los últimos años. La parte c) examina si las grandes universidades de Irlanda y el Reino Unido están integrando el análisis de IA en sus programas de Máster de contable.
- Sección 5 – Conclusiones

## 2. Marco Teórico

El marco teórico definirá los conceptos clave en este TFG, es decir, "Inteligencia Artificial" y "Auditoría" y propondrá la relación entre ellos mientras discute las teorías y modelos relevantes que rodean los dos conceptos basados en una revisión de la literatura en las dos áreas. A partir de esta revisión, el objetivo del estudio se pondrá en contexto, el de un proceso/marco de auditoría mejorado a través de técnicas de IA.

La IA se puede definir como el campo científico y estadístico que permite a las computadoras imitar la inteligencia similar a la humana (es decir, producir información y análisis replicados por los seres humanos (IEEE, 2017)). Esto se logra a través de las diversas definiciones que se definen a continuación. Hay otros académicos que creen que la IA va más allá de la inteligencia humana y por lo tanto se define como sistemas que tienen un pensamiento racional y logístico superior al de los seres humanos (Rich, 2000)

Algunas de las técnicas más comunes de Inteligencia Artificial se han enumerado y definido en la Tabla 1 a continuación con el fin de resumir los diversos subconjuntos del término paraguas "IA";

**Tabla 1: Definiciones de las técnicas de IA**

Aprendizaje automático	Software de IA que utiliza algoritmos para interpretar datos pasados con el fin de predecir resultados y encontrar relaciones entre variables. Puede aprender del éxito y el fracaso sin intervención humana (Marr, 2019)
Análisis de regresión	Análisis estadístico que investigan las relaciones entre una variable dependiente y variables independientes (a menudo llamadas 'predictores' o 'covariables',). También se usa para para la predicción y previsión que se superpone con el aprendizaje automático (Sykes, 1993)
Análisis Discriminante Lineal	Método utilizado para reconocer patrones, mediciones estadísticas y aprendizaje automático con el fin de encontrar combinaciones lineales de entidades que clasifique objetos o eventos. También se utiliza para la reducción de la dimensionalidad (reducción del número de variables aleatorias) (Balakrishnama & Ganapathiraju, 1998)
Aprendizaje profundo	Desarrolla redes neuronales artificiales jerárquicas (ver definición a continuación) y características de datos no estructurados mediante la recopilación de conocimientos a través de la extracción de patrones de datos sin procesar (Bengio, Courville & Goodfellow, 2016)

Sistemas Expertos	Uno de los primeros sistemas de IA que podría emular la capacidad de toma de decisiones y el proceso de pensamiento de un experto en un campo particular con el fin de resolver problemas complejos mediante el razonamiento y las reglas-enfoque basado (Jackson, 1999)
Redes Neuronales Artificiales	Sistemas informáticos inspirados en redes neuronales biológicas. Estos sistemas de red son capaces de observar ejemplos y aprender a llevar a cabo tareas a través de esta observación, sin un programa establecido o reglas específicas que se aplican a la tarea (Chen, 2019)
Visión por ordenador	La visión por ordenador permite a los equipos obtener información de datos que implican varias dimensiones, como vídeos o imágenes a través de modelos de aprendizaje profundo (SAS).
Procesamiento del lenguaje natural	La PNL ayuda a las computadoras a comprender, aclarar el significado y manipular el lenguaje humano. Los usos incluyen categorizar y contextualizar datos, análisis de opiniones, descubrimiento y modelado de temas, conversión de voz a texto y viceversa, así como documentos de resumen (SAS)

Fuente: Elaboración Propia

Cada subconjunto tiene varias funciones (sobre todo el Aprendizaje automático y aprendizaje profundo) que según los investigadores que publicaron en la Conferencia Internacional sobre Aprendizaje Automático y Conferencia sobre Sistemas de Procesamiento de Información Neural de 2015, tienen un 50% de probabilidades de eclipsar el rendimiento humano en todas las tareas en los próximos 45 años y de automatizar todos los trabajos humanos por 2040 (Grace, Salvatier, et.al, 2018).

El argumento de que la IA podría ser intrínsecamente mejor que los humanos fue apoyado por investigaciones en la literatura de las ciencias sociales que sugirieron que el rendimiento humano tiende a ser subóptimo en situaciones en las que tienen que reunir y procesar grandes cantidades de información de una amplia gama de fuentes (Kleinmuntz, 1990). La literatura de auditoría ha señalado que la exposición a grandes cantidades de información contenida en grandes datos puede conducir a un proceso de análisis problemático para un auditor. Brown-Liburud, Issa y Lombardi (2015) señalaron que la escala de “Big Data” podría conducir a una mayor incertidumbre e indecisión para los auditores debido a la sobrecarga de información y las dificultades que tendrían para reconocer patrones relevantes dentro de los datos debido a su gran tamaño y naturaleza no estructurada (los datos no estructurados no tienen un formato u organización predefinidos, lo que hace mucho más difícil su recopilación, procesamiento y análisis. Los ejemplos incluyen vídeo,



texto y audio. Esto es en comparación con los datos estructurados, que están bien formateados y altamente organizados para que se puedan buscar fácilmente en las bases de datos. Entre los ejemplos se incluyen direcciones, fechas o números de tarjetas de crédito (Pickell, 2018). Estas preocupaciones conducirían inevitablemente a decisiones de auditoría por debajo del nivel requerido.

Esto es un problema para los auditores, ya que la capacidad de proporcionar una alta garantía de calidad depende de su desempeño de juicio (Sanusi, 2011). Otros problemas como el exceso de carga de trabajo y el endurecimiento de las limitaciones de tiempo (Hanson, 2013) también se ven agravados por la introducción generalizada de “Big Data” y la naturaleza intrincada y no estructurada de ciertas tareas de auditoría, como la comprensión del cliente con el fin de probar y evaluar su sistema de control. Con más datos que examinar, los procedimientos tradicionales de auditoría basados en el juicio humano se han vuelto menos fiables, lo que ha provocado la necesidad de reexaminar la mejor manera de completar una auditoría (Dai y Vasarhelyi, 2016).

Este replanteamiento viene en forma de IA. Kokina y Davenport (2017) afirman que hay software tanto fácilmente disponible y siendo desarrollado que pueden realizar tareas cognitivas que antes eran realizadas por auditores humanos. Los seres humanos serán reemplazados por la tecnología de la IA a lo largo del tiempo (Grace, Salvatier, et.al, 2018), y el 75% de los ejecutivos creen que el 30% de las auditorías se completarán con IA para el año 2025 (Foro Económico Mundial, 2015), por lo que está justificado investigar y analizar cómo la IA ha cambiado y cambiará el proceso de auditoría en el futuro, y verificar si estos cambios impulsados por la IA mejorarían la velocidad y la calidad de una auditoría, en comparación con el sistema tradicional.

Un estudio realizado por Abdolmohammadi (1999) encontró que el 39% de las tareas de auditoría estaban estructuradas. El 67% de estas tareas estructuradas pertenecen a la fase de pruebas sustantivas, lo que sugiere que esta fase es la más adecuada para el desarrollo de la ayuda cognitiva. Investigación en IA y su aplicación a la auditoría comenzó con sistemas expertos y redes neuronales (ver tabla 1 para las definiciones) y mostró algunos resultados positivos, entre ellos, la mejora de la coherencia en la toma de decisiones y la reducción del tiempo en la toma de decisiones en comparación con los auditores humanos (Brown & Murphy, 1990). Odom & Sharda (1990) predijo la bancarrota a través de redes neuronales utilizando cinco variables de entrada y los datos de 129 empresas con redes neuronales identificando correctamente el 81,81% de los casos en comparación con el 74,28% alcanzado por múltiples análisis discriminantes.

Sin embargo, aprendizaje automático (referenciado en la tabla 1), es la forma moderna de IA que se puede aplicar mejor a estas tareas estructuradas. El uso más frecuente para el aprendizaje automático gira en torno a la resolución de problemas para los que los seres humanos no tienen una fórmula o solución definitiva como la transformación de entrada-salida y son incapaces de idear un algoritmo adecuado para sí mismos (Alpaydin, 2014). Un ejemplo de este problema sería clasificar los correos electrónicos no deseados de los legítimos y filtrarlos a través de las reglas de clasificación de mensajes de correo electrónico preclasificado (Gbenga Dada, et.al, 2019).

Cuando se utiliza como algoritmo de aprendizaje automático, la regresión lineal es un método de aprendizaje supervisado que realiza predicciones basadas en la relación lineal entre la salida numérica y los atributos de entrada numéricos (Obispo, 2006). Estos algoritmos de aprendizaje automático también pueden aplicarse a la auditoría y mejorar las estimaciones contables (por ejemplo, el deterioro de los activos a largo plazo o la asignación de cuentas de dudoso cobro) y las previsiones (Ding, Peng, Lev, Sun y Vasarhelyi, 2019). Por lo tanto, esto hace que tales predicciones y estimaciones sean auditables. La IA tiene la capacidad de generar estas predicciones a través del análisis de las opiniones de los medios sociales que muestran que el interés por los productos/marcas y las revisiones de satisfacción online están correlacionados con el rendimiento de las ventas de las empresas (Tang, 2017).

A pesar de que las tareas de auditoría son más susceptibles a tareas estructuradas y repetitivas, la IA ha evolucionado hasta el punto en que el aprendizaje profundo (ver tabla 1) se puede aplicar a la auditoría, lo que significa que algunos de los datos analizados por la IA en la auditoría no necesitan ser estructurados (Agnew, 2016). Por ejemplo, la herramienta de aprendizaje profundo que extrae las características de opinión de documentos empresariales internos, conferencias de prensa, publicaciones o cuentas de redes sociales puede proporcionar a los auditores pruebas adecuadas que les ayuden a predecir informes financieros fraudulentos (Sun, 2018a), las tasas de auditoría (Sun, 2018a) y la debilidad del control interno (Sun, 2018b). Aprendizaje profundo es también una técnica adecuada para el análisis de “Big Data” debido a la extensión de sus capas y el número superior de neuronas a la de una red neuronal tradicional (Mhaskar, Liao, y Poggio 2017).

En investigaciones anteriores se ha investigado la posibilidad de que la información no financiera se utilice como prueba de auditoría. Appelbaum y Nehmer (2017) sugirieron que el valor comercial de los bienes inmuebles podría estimarse identificando cualquier daño o deterioro de un edificio a partir de vídeos e imágenes captadas por un avión teledirigido gracias a la tecnología de aprendizaje

en profundidad, mientras que las redes neuronales profundas pueden entrenarse para comprender una escena a través del examen de los clips, de modo que puedan interpretar lo que está sucediendo y explicar el razonamiento que subyace a la acción (Husain, Dellen y Torras, 2017). Por lo tanto, esta tecnología podría ser adecuada para llevar a cabo procedimientos de auditoría, como la auditoría de inventario.

Chukwudi (2018) examinó el impacto de la IA en la realización de operaciones contables entre varias empresas de contabilidad del sudeste de Nigeria. Los datos reunidos mediante una encuesta a 185 profesionales de la auditoría llegaron a la conclusión de que la aplicación de la IA repercute favorablemente en el desempeño de las funciones de contabilidad y recomendaron que las empresas de contabilidad actualizaran continuamente sus conocimientos y competencias en materia de IA para mejorar el desempeño de las funciones de contabilidad. En la sección 4, esta afirmación se examinará más a fondo con un análisis particular en cada etapa de la auditoría a fin de verificar la validez de la afirmación de la investigación anterior de que la AI está cambiando la auditoría, y que este cambio dará lugar a una auditoría más precisa, eficiente y fiable.

Además de las investigaciones anteriores que indican los beneficios positivos de la IA para la auditoría, poniendo en contexto lo importante que será la IA en la industria en el futuro, el compromiso de KPMG, PwC & EY en 2019 de invertir 9.000 millones de dólares en automatización, tecnología de IA y capacitación de empleados (Pymnts, 2019) muestra el compromiso de las empresas líderes para impulsar nuevas soluciones dirigidas por la IA y su voluntad de sumergir sus propias auditorías en la tecnología artificial.

### 3. Metodología

Para alcanzar los objetivos y responder a las preguntas de investigación propuestas, el enfoque de investigación utilizado fue la investigación secundaria/de escritorio. Esta forma de investigación implica el análisis de la literatura académica y las investigaciones publicadas por los estudiosos y el uso de los resultados asumidos por estos estudios para llegar a conclusiones sobre el tema pertinente. Los datos existentes se reunieron, cotejaron y examinaron de modo que sólo se utilizaron las fuentes más pertinentes.

Etapas de la investigación;

1. Identificación del tema de investigación: Antes de iniciar la investigación secundaria, se determinó el tema de investigación: el de la "Inteligencia Artificial" y "la aplicación de la IA a la auditoría". Se solicitaron pruebas estadísticas de que la IA superaba a la tecnología más tradicional o a los seres humanos de estudios anteriores en la materia, a fin de aplicar estos resultados al estudio para poder definir un proceso de auditoría más eficiente.

2. Identificar las fuentes de investigación: A continuación se identificó la base de datos de información, de modo que se redujo la búsqueda de información, lo que permitió proporcionar los datos y la información más pertinentes y aplicarlos a la investigación. Estos artículos se obtuvieron de Google Scholar & Elsevier, fuentes de información académica de renombre, y se encontraron a través de una búsqueda de obras clave como "Contabilidad", "Inteligencia Artificial" "Auditoría", "Aprendizaje automático", etc. En 2016, Elsevier contenía 147 resultados para estas palabras clave, mientras que Google Scholar contenía 248 artículos. También se analizaron las fuentes citadas por los 395 artículos. La otra base de datos identificada fue la de los informes de instituciones mundiales reconocidas. Por ejemplo, los informes compilados por los "4 grandes" o el Foro Económico Mundial. Para la investigación de las grandes empresas de contabilidad y sus departamentos de investigación y desarrollo que invierten en la IA, se utilizaron los informes de las empresas pertinentes en los que se detallaban sus últimas novedades. También se utilizaron como fuente los sitios web de las universidades que ofrecían formación en materia de IA para futuros contadores en su programa de maestría.

3. Recopilar los datos existentes: Tras reducir las posibles fuentes, se analizaron y aplicaron a este estudio los datos anteriormente disponibles de los artículos de Elsevier y Google Fellow que estaban estrechamente relacionados con el tema de la IA y su papel en tareas o asignaciones similares a las de la auditoría. Estas fuentes, que indicaban que la IA es y seguirá teniendo un profundo efecto en la industria de la auditoría, se basaban en pruebas reunidas por investigadores académicos que trabajan para universidades u otras organizaciones académicas.

4. Combinar y comparar: Una vez reunidos los datos del estudio y las pruebas de fuentes como los informes de grandes empresas de contabilidad o del Foro Económico Mundial, se resumieron, combinaron y cotejaron para asegurarse de que no se duplicaran antes de ser ensamblados en un formato utilizable. Este formato implicaba dividir el proceso de auditoría en varios pasos y aplicar en cada uno de ellos técnicas de IA estadísticamente probadas y compararlas con la ruta tradicional.
5. Analizar los datos: Una vez presentados los datos, era el momento de identificar si las preguntas de la investigación habían sido contestadas, si se habían cumplido los objetivos y si se habían recogido las percepciones.

#### Limitaciones:

Dado que este GFT se basa sólo en fuentes secundarias, la calidad del trabajo depende de la calidad de otros trabajos. Otro problema que este GFT encontró fue que no todos los estudios o informes sobre "IA" o "Auditoría" estaban actualizados o eran exactamente lo que este estudio necesitaba para responder a la pregunta de la investigación, ya que no fueron hechos por el propio investigador. Incluso cuando los datos se consideraron fiables y exactos, puede que no fueran lo suficientemente recientes como para abordar cuestiones aparentes en 2020.

Como alternativa a la metodología utilizada en este estudio, el investigador podría haber realizado técnicamente más investigaciones primarias para apoyar las conclusiones del GFT (como encuestas o entrevistas con socios de empresas de contabilidad pública). Sin embargo, esa tarea sería sumamente costosa, exigente y difícil de obtener para el investigador, dado el clima actual, mientras que su impacto probablemente habría sido insignificante debido a la correspondencia y respuesta parcial que se esperaba de esos esfuerzos para organizar una entrevista para discutir un tema tan profundo y futurista.

#### 4. Hallazgos y discusión

##### Introducción

Sobre la base de las evaluaciones de los directores y asociados de 332 asignaciones de auditoría divididas en varias fases y subfases, se presentaron pruebas estadísticas de la estructura de las asignaciones de auditoría (Abdolmohammadi, 1999).

Este estudio, que dividió las asignaciones de auditoría en subconjuntos estructurados, semiestructurados y no estructurados, proporciona un marco creíble para que esta labor divida las fases y asignaciones de auditoría, permitiendo el análisis de las tareas estructuradas, semiestructuradas o no estructuradas al tiempo que se aplican las técnicas de inteligencia artificial a cada etapa.

**Tabla 2: Estructura de las tareas de auditoría**


<b>Fase de auditoría</b>	<b>Número de tareas</b>	<b>Estructurados</b>	<b>Semi-estructurados</b>	<b>Desestructurado</b>
<b>Orientación</b>	45	7	14	24
<b>Estructura de control</b>	75	10	58	7
<b>Pruebas Sustantivas</b>	141	114	54	3
<b>Formación de una opinión y presentación de los financieros</b>	41	0	9	32
<b>Total</b>	332	131	135	66

Fuente: Adaptado de Abdolmohammadi (1999)

Cada auditoría que se realice, aunque actúe dentro del mismo marco reglamentario, se diferenciará de las demás en función del nivel de riesgo percibido y de la eficacia del sistema de control interno del cliente. Sin embargo, aunque el alcance puede variar, a los efectos de esta labor las fases de la auditoría se dividirán en cuatro etapas aproximadas: planificación, identificación de los riesgos mediante la comprensión del cliente y sus controles internos, ejecución/pruebas sustantivas y presentación de informes. Según Appelbaum (2017), tras examinar 301 documentos entrelazados

en la literatura financiera y contable, el 88,3% de los artículos que se refieren a la utilización del análisis son aplicables a las fases 2 y 3, como se define a continuación.

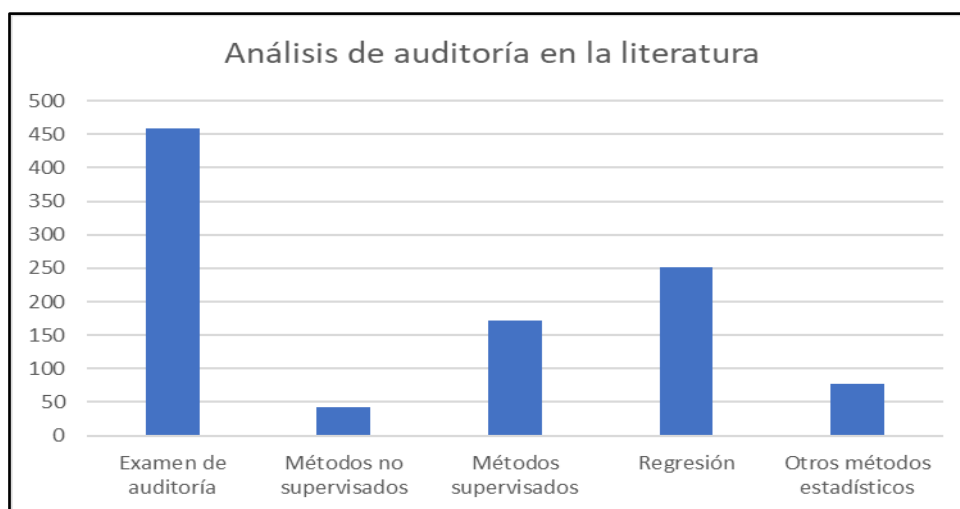
**Tabla 3: Número de artículos por fase de auditoría**



Fuente: Adaptado de Appelbaum (2017)

Por lo tanto, no es sorprendente que la mayor parte de las pruebas para este GFT se presenten a partir de estas dos fases. En lo que respecta a las técnicas analíticas más frecuentemente aplicadas, Appelbaum (2017) indica que después del examen de auditoría (técnicas como el análisis de ratio, el análisis de tendencias o el muestreo) la siguiente técnica más popular que se discute es el análisis de regresión, que es en lo que se basan muchos de los casos de aprendizaje automático que se discutirán, mientras que los estudios de aprendizaje profundo se basan en técnicas no supervisadas.

**Tabla 4: La técnica analítica de auditoría más popular en la literatura**



Fuente: Adaptado de Appelbaum (2017)

### **Parte (a) - Etapas del proceso de auditoría con la IA**

Se realizará una comparación de algunas de las tareas estructuradas, semiestructuradas y no estructuradas entre antes y después de la aplicación de la IA en cada etapa del proceso de auditoría utilizando estadísticas medibles de otros estudios académicos. Esto establecerá cuál es la forma más eficiente de completar una auditoría y mostrar cómo se puede aplicar la IA a la auditoría.

#### **Etapa 1 - Pre-Planificación y Contratación:**

De acuerdo con la Norma Internacional de Auditoría (ISA) 300, la etapa de preplanificación implica "establecer una estrategia de auditoría general que establezca el alcance, el calendario y la dirección de la auditoría, y que guíe el desarrollo del plan de auditoría".

Al establecer la estrategia global de auditoría y evaluar el riesgo inicial, el auditor debe realizar pruebas analíticas que consideren las siguientes características (ISA,2009);

- El marco de presentación de informes financieros para el que se han adherido los estados que se van a auditar (incluida la necesidad de conciliaciones)
- El tamaño y la complejidad del área que necesita ser auditada
- La disponibilidad del personal del cliente
- La disponibilidad de los datos del cliente
- Escala de las operaciones del cliente

con el fin de revelar cualquier actividad o relación peculiar que pueda ser indicativo de declaraciones erróneas materiales. Las normas de la ISA aceptan que en esta etapa el objetivo principal es simplemente recopilar los datos que pueden dar lugar a un procedimiento analítico menos preciso.

#### **Antes de la IA:**

Durante las etapas de planificación de la auditoría, el equipo de auditoría debe interactuar con el cliente y llevar a cabo sesiones de “brainstorming” para evaluar y comprender el riesgo empresarial del cliente y planificar la auditoría en consecuencia. La auditoría intentará comprender las condiciones económicas del cliente y su industria a través de la revisión de la reunión de la Junta de Directores y las discusiones con la dirección y el personal utilizando una lista de verificación. Este es estructuralmente restrictivo porque hay criterios utilizados para guiar la revisión de la sesión de “brainstorming” (Bellovary y Johnstone, 2007). Las ayudas estructuralmente restrictivas a la toma de decisiones limitan la toma de decisiones e inducen sesgo porque la evaluación del riesgo de los auditores tiene que coincidir con la de la lista de verificación guiada (Seow, 2011). Esto reduce la capacidad del auditor para identificar nuevos elementos que no están incluidos o



provocados por la lista de verificación, lo que significa que no consideran adecuadamente todas las posibilidades. Las notas de la reunión también serán tomadas, pero serán limitadas.

#### Después de la IA:

IA podría proporcionar al auditor la capacidad de evaluar el riesgo en su totalidad y no sólo limitarse a una lista de verificación o cumplir con los límites a través de la tecnología de asistente cognitivo. Un estudio realizado por Li (2019) propone cómo se podría desarrollar un asistente de inteligencia artificial para sesiones de “brainstorming” durante el plan de auditoría para mejorar el proceso. Esta herramienta de apoyo a las decisiones puede evaluar los conocimientos adquiridos en la sesión de intercambio de ideas y prepararlos en un formato legible por máquina utilizando técnicas de procesamiento del lenguaje natural (PLN) y de aprendizaje automático a través de un sistema de descubrimiento de conocimientos planificado por auditoría.

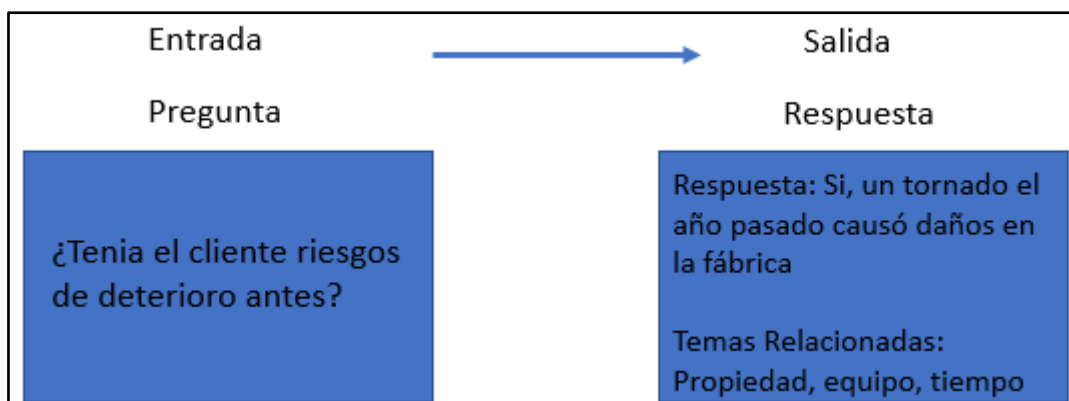
En el estudio de Li (2019), se utilizó spaCy, un paquete de código abierto Python/(PLN) que tiene una precisión de clasificación de texto de hasta 92,6% utilizando el analizador de dependencia (Choi et al. 2015) para extraer una amplia información de las secuencias de texto convertidas a partir de las grabaciones de audio de la discusión de la auditoría.

Se definen dos cosas para el entrenamiento de modelos de Li (2019):

- ¿Qué tema quiere el modelo para encontrar información sobre?
- Relaciones de dependencia (extrayendo un análisis de dependencia de una frase que representa su estructura gramatical y define las relaciones entre las palabras de la "cabeza" y las palabras, que modifican esas cabezas para comprender su significado (NLP-Progress, 2020)

Este modelo identificó 10 frases que fueron etiquetadas con "deterioro", las vinculó a un determinado tema mediante el análisis de su naturaleza semántica y relación de dependencia y luego las guardó para su análisis futuro. Si un futuro auditor quiere saber si el tema "deterioro" fue discutido previamente y qué conocimientos se recopilaron al respecto, pueden plantear preguntas al módulo de Preguntas y Respuestas propuesto por Li (2019). (Anexo -1).

**Figura 1: Ejemplo del prototipo del modelo de preguntas y respuestas**



Fuente: Adaptado de Li (2019)

Este módulo de control de calidad permite a un usuario futuro introducir consultas. En el ejemplo anterior, si un auditor pregunta el modelo de P&R "¿El cliente tenía algún riesgo de deterioro antes?" después del proceso de prueba, el sistema analizará las palabras clave y reconocerá el tema de la consulta "deterioro" y luego buscará conocimientos relacionados. Usando el modelo, Si el tema se discutió antes, el módulo emitiría las discusiones de "Brainstorming" anteriores. Utilizando el método-basado en la dependency - para el deterioro que vincula la relevancia de las palabras, proporciona un apoyo de conocimiento más rápido y profundo para los auditores durante las discusiones de "brainstorming" en comparación con la era anterior a la IA de analizar las actas de las reuniones.

La IA también se puede utilizar para proporcionar al auditor pruebas complementarias al decidir sobre la tasa de auditoría e identificar la probabilidad de comportamiento fraudulento mediante el análisis del tono de gestión en divulgaciones cualitativas en presentaciones 10-K (informe anual exigido por la Comisión de Valores y Bolsa de los Estados Unidos (SEC), que resume exhaustivamente los resultados financieros de una empresa) y 8-K (formulario utilizado para notificar a los inversores de las empresas públicas de EE.UU. de los acontecimientos que afectan a las cuentas o a los precios de las acciones), incluyendo declaraciones de prensa. Por ejemplo, Yoon (2016) utilizó presentaciones de 10-K y 8-K en 696 empresas para analizar palabras textuales específicas de diccionarios de sentimientos financieros utilizando un modelo basado en el Kit de Herramientas de Lenguaje Natural de Python.

Los resultados empíricos en la tabla de correlaciones univariadas (Anexo - 2) comparando variables individuales de la información textual y la variable dependiente (optimismo) muestran que el tono de optimismo en las revelaciones cualitativas está correlacionado negativamente con las tasas de

auditoría. En (Anexo - 3), Los modelos explican las tasas de auditoría iniciales relativamente suficientemente ( $R^2$ / coeficiente de determinación - 0.81).

En la columna 3 del Grupo A del (Apéndice - 3) se muestra la correlación negativa entre el optimismo10K (-0,38, valor t -2,19, optimismo8k (-0,17, valor t -5,43) y la tasa de auditoría, lo que demuestra que cuanto mayor es el volumen de palabras optimistas, menor es la tasa de auditoría una vez más.

El análisis estadístico de cada modelo sugiere que el Kit de Herramientas de Lenguaje Natural de Aprendizaje automático de Python puede complementar al auditor al tomar decisiones sobre qué tarifa cobrar a un cliente. El nivel de optimismo presente en los informes se puede utilizar como una variable adicional a la hora de decidir una tasa dada la correlación negativa entre el optimismo y la tasa de auditoría. Esto se debe a que cuanto mayor sea el riesgo que un cliente, mayor será la cuota de auditoría (Shiyi & Jeyaraj, 2017), lo que sugiere que el optimismo en los estados financieros tiene una relación inversa con el riesgo. Este análisis textual en lenguaje natural proporciona información independiente además de la información numérica tradicional e indica que las nuevas variables inducidas por la IA desempeñan un papel importante en la comprensión y la toma de la decisión sobre los honorarios de la auditoría.

### **Etapa 2 - Identificación del riesgo mediante la comprensión de la entidad y la evaluación de los controles internos:**

De acuerdo con la Norma Internacional de Auditoría (ISA) 315, el objetivo del auditor en esta etapa es "identificar y evaluar los riesgos de la declaración errónea material, ya sea por fraude o error, a nivel de estado financiero y afirmación, mediante la comprensión de la entidad y su entorno, incluido el control interno de la entidad a través de consultas, procedimientos analíticos e inspección".

Al realizar procedimientos de evaluación de riesgos en los controles internos (los procesos diseñados para garantizar el logro de los objetivos de un cliente en materia de eficiencia de las operaciones, cumplimiento de la ley aplicable y fiabilidad de los informes financieros), el auditor debe comprender las siguientes características del cliente;

- Factores de la industria (competencia, actividad cíclica)
- Factores reguladores (impuestos, políticas gubernamentales)

- Tipo de modelo de negocio (fuentes de ingresos, dispersión geográfica, inversiones) (ISA, 2009)

#### Antes de la IA:

El auditor tenía que entender la información cualitativa que rodea al sistema de control interno mediante la comprensión de la actitud de la empresa, la ideología, el papel de ciertas partes interesadas, etc. Con la ausencia de pruebas habilitadas para la IA en el pasado, la forma más común de evaluar los sistemas de control interno era simplemente utilizar el consenso de los auditores sobre la calidad a través de entrevistas. Sin embargo, se demostró que los auditores sólo tenían un nivel de acuerdo del 57,58 por ciento, lo que sugiere ambigüedad y la necesidad de más medidas estadísticas (Srinidhi & Vasarhelyi, 1986).

#### Después de la IA:

Después de grandes escándalos contables, incluyendo Enron & WorldCom, un acto de 2002 del Congreso de los Estados Unidos llamado "Ley Sarbanes-Oxley" requirió que la administración revelar cualquier cambio material en la condición financiera de la compañía en el momento de ocurrir con el fin de proteger a los inversores y mejorar la exactitud y fiabilidad de las revelaciones corporativas (United States House of Representatives, 2002). Esta legislación ha impulsado a las empresas progresivamente hacia la garantía continua y por 2006 una encuesta de PwC concluyó que el 50% de las empresas estadounidenses ya habían integrado una forma de auditoría continua en sus empresas (PwC, 2006).

El papel de los auditores internos es importante para los auditores externos, y las técnicas de IA podrían ayudar a los auditores externos a utilizar a través de un modelo de regresión logística ordenado (Issa, 2013). Al permitir que el modelo revise la evaluación del riesgo de los controles internos por parte de los propietarios de negocios y los auditores internos, los auditores tienen más tiempo para centrarse en las anomalías, es decir, el evento registrado que se ha desviado del rango de riesgo aceptable designado. Los valores predichos del modelo se utilizan para clasificar y clasificar los valores atípicos en términos de riesgo mediante el uso de dos medidas de desacuerdo entre los niveles previstos y asignados (Issa, 2013).

Por ejemplo, en Tabla 5, la primera célula, Bajo-Bajo, muestra que el 88,38% de las instancias que se predijo que eran de bajo riesgo por el modelo fueron clasificadas por los auditores para estar en la misma clase de riesgo, el 75,72% de los casos medios (Medio-Medio) y el 77,78% de los casos de alto riesgo (Alto-Alto). Las celdas restantes (17%) son los valores atípicos, riesgos que el auditor

interno ha clasificado de manera diferente en comparación con las predicciones del modelo de regresión. Estos representan "excepciones" que el auditor externo puede examinar con más detalle, mostrando la capacidad de los modelos para actuar como una herramienta de revisión de calidad.

**Tabla 5: Modelo de Matriz de Confusión - El porcentaje de las evaluaciones de riesgo del modelo de aprendizaje automático que corresponden al auditor humano**

Nivel (Modelo)	Nivel Previsto	Nivel Asignado (Auditor)			Total
		Bajo	Medio	Alto	
Bajo	327 (88.38%)	43 (11.62%)	0 (0.00%)	370	
Medio	40 (16.46%)	184 (75.72%)	19 (7.82%)	243	
Alto	0 (0.00%)	8 (22.22%)	28 (77.78%)	36	
Total	367	235	47	649	

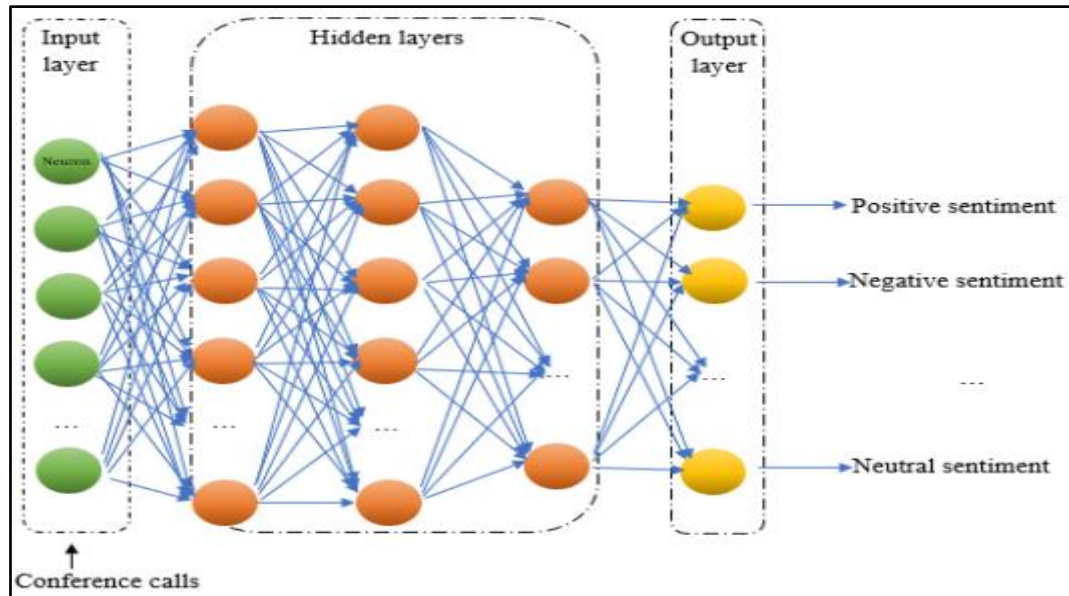
Fuente: Adaptado de Issa (2013)

Por ejemplo, la célula Alta-Media muestra que el 22,22% de los que el modelo predijo como de alto riesgo sólo fueron considerados de riesgo medio por los auditores humanos. Esas "excepciones" dieron lugar a una investigación de los auditores internos que no se habría llevado a cabo de otro modo y se descubrió que estas diferencias ocurrieron porque los registros no se documentaron adecuadamente debido a preocupaciones de privacidad relacionadas con el fraude.

Esto demuestra la eficacia del modelo de aprendizaje automático propuesto en este estudio, ya que la tecnología fue capaz de identificar las discrepancias provocando así una investigación que podría no haber ocurrido de otra manera. Este modelo podría presentarse a los clientes de auditoría y les daría la oportunidad de explicar aquellos casos que no se alinean con el modelo predictivo de forma más continua. Esto mejoraría la capacidad del auditor externo para evaluar los niveles de riesgo de control interno, ya que sólo tienen que concentrarse en anomalías, al tiempo que les permite juzgar por qué había una diferencia entre el modelo y la clasificación del auditor interno, utilizando efectivamente el modelo como una comprobación de coherencia y un punto de referencia.

El aprendizaje profundo podría utilizarse para proporcionar información complementaria a los auditores mientras se predicen las debilidades del control interno utilizando una Herramienta de aprendizaje profundo de IBM Watson (Alchemy Language API). Sun (2018) fue capaz de identificar el sentimiento y la emoción de las discusiones mantenidas entre la administración y presentar los resultados del sentimiento en una partitura.

**Figura 2: Ilustración de una red neuronal profunda para el análisis de opiniones de llamadas de conferencia**



Fuente: (Sun, 2018)

Como se ha visto anteriormente, la red neuronal profunda permite a la herramienta de análisis de opiniones conocer y comprender qué representan los datos sin procesar con varios niveles de abstracción: la primera capa de entrada recibe datos sin procesar, en este caso transcripciones de llamadas de conferencia, la segunda etapa se compone de varias capas ocultas para procesar datos y extraer entidades, y la última capa o "salida" proporciona el resultado del sentimiento.

Al analizar los resultados en (Anexo - 4), el modelo mostró que durante las llamadas de conferencia los gerentes de empresas con debilidades de control interno transmitieron menos "alegría" ( $0.1822 < 0.2254$ ) (Sun, 2018). En otras palabras, cuanto mayor sea la puntuación de "alegría", menos probable es que una empresa tenga debilidades de control interno. Este es un indicador útil que los auditores podrían utilizar al analizar.

Además, como podemos ver en (Anexo -5) con la mejora tanto de los ratios de probabilidad como de los valores  $p$ , el poder de predicción del modelo mejora después de integrar las variables de "sentimiento" de aprendizaje profundo en comparación con el modelo de base que contiene sólo los determinantes financieros sugeridos por la literatura anterior (Collins, Ashbaugh-Skaife, y Kinney, 2007; Sun, 2018). En otras palabras, el uso del tono administrativo para predecir la debilidad del control interno mediante el uso del aprendizaje profundo mejora aún más la capacidad del auditor para evaluar los controles y comprender el negocio de un cliente.

Un beneficio para la empresa de auditoría es que es más probable que eviten consecuencias como multas frontales a los directores generales de hasta 5 millones de dólares por certificar controles internos engañosos (SOX 906, 2002), o un aumento del costo de capital ajustado al mercado (precio de las acciones \* acciones en circulación) de unos 93 puntos básicos debido a deficiencias en el control interno (Collins, Ashbaugh-Skaife y Lafond 2009).

### **Etapa 3 -Pruebas sustantivas:**

De acuerdo con la norma internacional sobre auditoría (ISA) 330, el objetivo del auditor es "obtener pruebas de auditoría suficientes apropiadas con respecto a los riesgos evaluados de la declaración errónea material, mediante el diseño y la aplicación de respuestas adecuadas a esos riesgos". Estas pruebas implican procedimientos sustantivos que consiste en:

- Pruebas de detalles (de clases de transacciones, saldos de cuentas y divulgaciones)
- Procedimientos analíticos sustantivos
- Prueba de controles – Un procedimiento de auditoría diseñado para evaluar la eficacia operativa de los controles en la prevención, o la detección y corrección, de declaraciones erróneas de material en el nivel de aserción. (ISA, 2009)

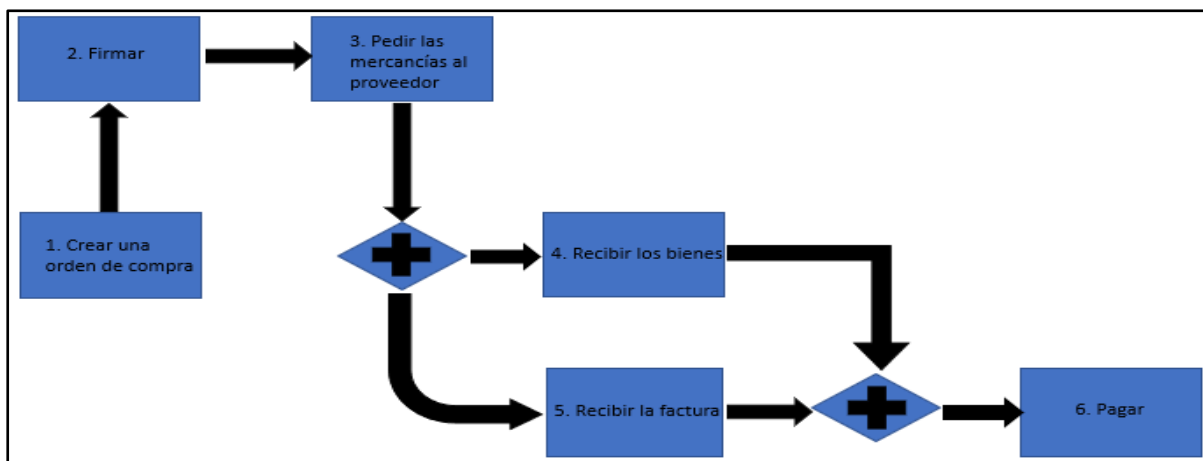
### **Antes de la IA:**

En esta etapa, los auditores recopilan y analizan tanto el origen de los datos como la calidad a través de una serie de pruebas periódicas. La principal diferencia es que estas pruebas solo son capaces de evaluar la muestra de transacciones de una población.

### **Después de la IA:**

Los clientes de auditoría normalmente tienen un sistema de control rígido para transacciones como el que se ilustra a continuación para asegurar un funcionamiento fluido del negocio:

**Figura 3: El diagrama de flujo describe las principales actividades que intervienen en la adquisición de bienes de una empresa.**



Fuente: Adaptado de (Jans, et.al, 2014)

Sin embargo, en la práctica, estos procesos pueden desviarse a menudo. Por ejemplo, el pedido de compra podría modificarse después del inicio, lo que daría lugar a la necesidad de otra transacción de "firma". Por lo tanto, además de las pruebas de control, se requieren pruebas detalladas, como la inspección de la factura. La minería de procesos, una especie de técnica de aprendizaje automático con más estructura presente, puede ayudar al auditor a realizar estas pruebas de detalle más a fondo mediante la identificación basada en hechos de las debilidades del proceso comercial (Huser, 2019) a través de registros de eventos que permiten la comparación entre los procesos reales y el proceso de diseño.

Jans, et.al, (2014) utilizaron la minería de procesos para analizar las actividades reales y los registros de eventos realizados durante la compra de bienes para identificar las diferencias con el modelo de proceso diseñado previamente. Esto también se conoce como "pista de auditoría". Todos los patrones de actividad que existen en el registro de eventos se extraen mediante el análisis de la secuencia de rendimiento y se revelaron 304 patrones diferentes.

**Tabla 6: Los 6 patrones de "pista de auditoría" más comunes**

Patrón	Secuencia	Frecuencia de patrón		Total Acumulado
		#	%	%
1	Crear la orden de compra -> firmar -> liberar -> mercancía recibida -> factura recibida -> pagar	11608	44.30%	44.30%



2	Crear la orden de compra -> cambiar la línea -> firmar -> liberar -> mercancía recibida -> factura recibida -> pagar	6955	26.60%	70.90%
3	Crear la orden de compra -> cambiar la línea -> liberar -> factura recibida -> pagar	2488	9.50%	80.40%
4	Crear la orden de compra -> liberar -> factura recibida -> pagar	640	2.40%	82.80%
5	Crear la orden de compra -> cambiar la línea -> firmar -> liberar -> factura recibida -> pagar	491	1.90%	84.70%
6	Crear la orden de compra -> cambiar la línea -> firmar -> liberar -> factura recibida -> mercancía recibida -> pagar	393	1.50%	86.20%

Fuente: Adaptado de (Jans, et.al, 2014)

Dado el gran número de patrones, la observación visual no es adecuada para analizar los rastros de auditoría y, por lo tanto, se utiliza un algoritmo de software para evaluarlos.

Para poner de relieve los flujos de actividades que requieren una investigación más a fondo, se utiliza el algoritmo lógico de tiempo lineal para comprobar si los flujos y actividades adicionales de la tabla 6 prevalecen realmente en este orden y para confirmar qué pautas violan el protocolo de registro de sucesos. La meta-deta se explota en sellos de tiempo y actividades para que se pueda realizar la verificación en el 100% de la población.

La minería de procesos se comparó entonces con el examen manual de los auditores internos antes de la aplicación de su sistema SAP. El protocolo de minería de procesos identificó numerosos casos que justificarían una investigación de seguimiento en la etapa de pruebas sustantivas para los auditores, lo que no ocurría con el enfoque de auditoría más tradicional (Jans,et.al, 2014). Estos casos incluían:

- 3 órdenes de compra que eludieron el sistema de control interno para el proceso de adquisición sin ninguna señal o liberación, violando los procedimientos de control establecidos en table 6
- 265 pagos que no correspondían a una factura
- 175 violaciones del principio de separación de funciones que exige que la recepción de las mercancías y la función de liberación sean realizadas por personas diferentes,
- 742 casos no registrados como firmados.

Esto proporciona prueba de la capacidad de la minería de procesos para mejorar la auditoría y aumentar la eficacia en comparación con los procedimientos de auditoría más tradicionales. El evento registra la capacidad de registrar automáticamente las entradas de los procesos y mostrar metadatos sin depender de los datos introducidos manualmente por un trabajador (Jans et al, 2012) y la capacidad de la minería de procesos de examinar a toda la población en lugar de los procesos, en lugar de verse obligados a utilizar sólo una muestra debido a las limitaciones de tiempo, son las razones de esta superioridad.

Ding, Peng y Wang (2019) propusieron un método de selección por pares basado en el aprendizaje automático (k-means cluster analisis) basado en ratios financieros que podrían utilizarse en procedimientos analíticos sustantivos en la evaluación del riesgo. Los coeficientes financieros, como el margen de beneficio neto, el capital de la deuda, la capitalización, el margen de flujo de caja, que muestran cómo opera una empresa y cómo aplica los métodos contables en sus informes, se utilizaron para identificar empresas similares agrupándolas a la media más cercana y separándolos de otras entidades para la evaluación comparativa. Esta herramienta se compara con una era antes de la IA en la que las empresas se clasificaron en grupos homogéneos utilizando esquemas de clasificación de la industria como SIC, NAICS & GICS (Kile & Phillips, 2009). (Véase el anexo – 6)

(Anexo - 7) compara la dispersión de grupos del SIC y la clasificación de agrupaciones de empresas. Como resultado de este análisis, de 144 ratios, 95 son  $> 1$  y por lo tanto estadísticamente significativas porque la varianza compuesta del denominador (análisis de conglomerados) es inferior a uno, lo que indica que la homogeneidad es superior a los esquemas de clasificación tradicionales.

R-cuadrado, también llamado coeficiente de determinación, se utiliza para explicar el grado en que las variables de entrada explican la variación de las variables de salida en un modelo de regresión (Hayes, 2020). Va de 0 a 1. Para demostrar aún más que el método de agrupación en clústeres crea más grupos adhesivos, se aplicó una relación R cuadrada ajustada que tiene en cuenta los predictores que no son significativos en un modelo de regresión (Ding, Peng y Wang, 2019). El R cuadrado ajustado aumenta sólo si el nuevo término mejora el modelo más de lo que se esperaría por casualidad (Nair, 2019). En la tabla siguiente, podemos ver que el R-cuadrado ajustado era en promedio 0.03858 para las clasificaciones SIC, lo que indica que el 3,858% de la variación en las variables de salida se explica por las variables de entrada. Esto mejoró a un promedio de 0.17863 para la clasificación de “clustering” R-cuadrado.

**Tabla 7: Comparación de la cohesión de la clasificación por “clustering” y el esquema de clasificación tradicional**

<b>Relaciones</b>	<b>Clasificación de Clustering</b>	<b>Clasificación SIC de 2 dígitos</b>	<b>Diferencia</b>
<b>Margen de Beneficio Neto</b>	6.12%	2.62%	3.50%
<b>Margen de Flujo de Efectivo</b>	7.33%	1.98%	5.35%
<b>Beneficio/ Activos Totales</b>	26.21%	4.76%	21.45%
<b>Relacion de Capitalizacion</b>	23.49%	4%	19.49%
<b>Deudo a Largo Plazo/ Capital Social</b>	19.13%	2.87%	16.26%
<b>Deuda Total/ Capital</b>	16.89%	2.67%	14.22%
<b>I&amp;D/ Ventas</b>	10.44%	2.21%	8.23%
<b>Ventas/ Patrimonio Neto</b>	18.69%	9.29%	9.40%
<b>Ventas/ Capital Invertido</b>	32.47%	4.33%	28.14%

Fuente: Adaptado de (Ding, Peng y Wang, 2019)

Este método de agrupación de k-means podría servir como una herramienta práctica para los auditores al comparar un cliente con una empresa de características operativas similares. Este punto de referencia más comparable podría ayudar a los auditores a decidir si la capacidad de las empresas para pagar la deuda, el rendimiento operativo, el nivel de declaraciones financieras erróneas o el análisis predictivo de las dificultades financieras, la adquisición y el riesgo de la empresa son razonables cuando se comparan con los del mismo grupo de agrupación en función de los coeficientes financieros, un mejor punto de referencia e indicador de rendimiento estadísticamente probado. Este aumento es la capacidad de los auditores para contextualizar y evaluar las pruebas de las pruebas sustantivas.

Los procedimientos de auditoría eficaces en la etapa de pruebas sustantivas son hechos estadísticos que pueden validarse, como los recuentos de inventario o la confirmación del activo y el pasivo por parte de terceros. Sin embargo, las estimaciones de la administración/contabilidad son opiniones subjetivas propensas al sesgo, por ejemplo, Dechow, Ge, Larson y Sloan (2007) mostraron que el 25% de las estimaciones de la administración sobre el costo de los bienes vendidos y el inventario estaban manipuladas. Esto demuestra que las opiniones subjetivas dificultan una auditoría. Los algoritmos de autoaprendizaje pueden utilizarse para hacer predicciones y análisis superiores de las

estimaciones contables y, por lo tanto, actuar como un generador independiente de estimaciones sesgadas que podrían, por lo tanto, ser auditadas y actuar como un mejor punto de referencia que las estimaciones de la dirección. Por ejemplo, Ding, Peng, Lev, Sun y Vasarhelyi (2019) indicaron que, sobre la base de un gran conjunto de pérdidas de las compañías de seguros (pagos de reclamaciones futuras), las estimaciones de pérdidas generadas por el aprendizaje automático son más elevadas y precisas que las estimaciones reales de la administración en que se basan los informes financieros.

Ding, Peng, Lev, Sun y Vasarhelyi (2019) desarrollaron modelos de aprendizaje automático con y sin estimaciones de pérdidas de los directivos, junto con predictores independientes como variables operativas, características independientes de la empresa y factores ambientales exógenos como atributos de entrada, y los compararon utilizando el error absoluto medio (EAM) y el error absoluto medio raíz (EAMR)


Se examinaron cinco líneas de negocio y el (EAM) (EAMR) de las estimaciones de aprendizaje automático fueron inferiores a las de los directivos en 4 de las 5 líneas de negocio, lo que indica la mayor precisión de predicción del aprendizaje automático. Por ejemplo, el promedio (EAM) (EAMR) de la estimación de pérdidas de la IA de la responsabilidad civil de los automóviles privados de pasajeros (línea 1) es del 17% (6,33%). Esto se compara con un promedio del 24% (15%) para el modelo cuando se incluyen las estimaciones de la dirección (anexo -14).

Esta mejora de la calidad y la fiabilidad de las estimaciones contables aumentará la pertinencia y la utilidad de la información financiera para los auditores a la hora de evaluar las transacciones, completar los procedimientos analíticos y poner a prueba los controles. En la práctica, los auditores podrían utilizar las estimaciones contables producidas por la IA para analizar y auditar las estimaciones de los administradores mediante la comparación, ya que las pruebas estadísticas señalarán grandes desviaciones que podrían conducir a un nuevo examen de las estimaciones de los administradores. Alternativamente, la IA podría utilizarse para generar las estimaciones de los directivos en primer lugar, mejorando la fiabilidad y coherencia de estas estimaciones para las empresas, lo que reduce su riesgo de fraude y proporciona pruebas empíricas y más fiables para el auditor en su evaluación y sus pruebas.

Según las proyecciones de IDC, el 80% de los datos mundiales no estarán estructurados para 2025 y el 30% de la esfera de datos mundial estará en tiempo real (IBM, 2018). Realizar análisis de sentimientos, un proceso automatizado de aprendizaje automático que identifica y extrae

información subjetiva que subyace a un texto a través del procesamiento de lenguaje natural, puede realizar esto en datos en tiempo real de Twitter. Twitter, con 330 millones de usuarios activos a partir del Q12019 (Twitter, 2019) y 500 millones de tweets por día, puede ayudar a las empresas a entender cómo la gente habla de su marca y cómo se comportará.

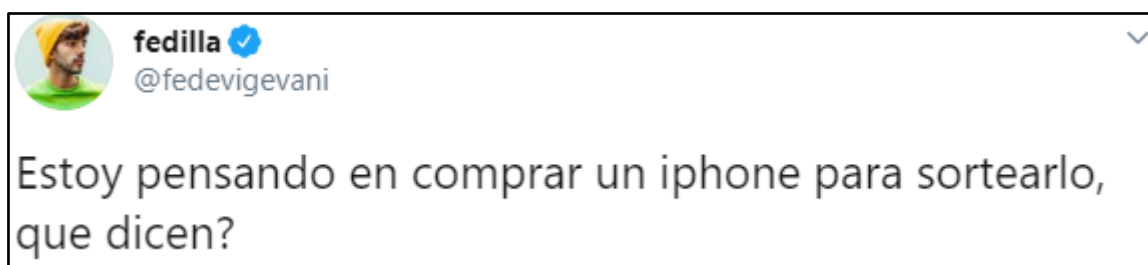
**Tabla 8: ¿Cuánto de la esfera de datos global está en tiempo real?**



Fuente: (IBM, 2018)

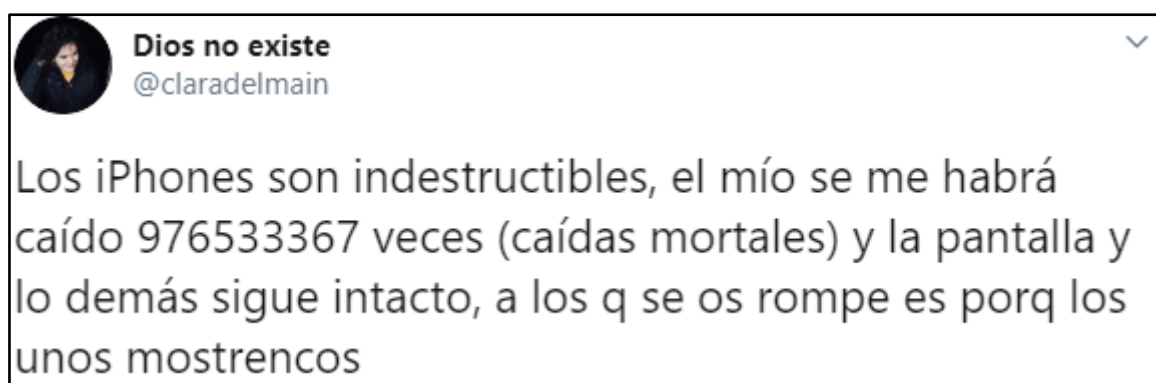
Rozario (2019) muestra que al incorporar medidas de interés para los consumidores de Twitter (ICT) (el volumen de comentarios en Twitter que indican una compra reciente futura) y el sentimiento positivo del consumidor de Twitter (SPCT) (la relación entre el número total de comentarios de usuarios de Twitter que expresan un sentimiento positivo al número total de comentarios de usuarios de Twitter que indican sentimientos negativos) a través del análisis de sentimientos en modelos analíticos, la capacidad predictiva de los procedimientos analíticos sustantivos se puede mejorar en comparación con los modelos de referencia que no contienen análisis de las redes sociales, lo que hace que la empresa sea más auditable.

**Figura 4: Ejemplo de interés del consumidor para comprar (ICT):**



Fuente: (Twitter.com)

**Figura 5: Ejemplo de Sentimiento Positivo del Consumidor (SPCT):**



Fuente: (Twitter.com)

(Anexo - 8) muestra el número medio de Tweets de interés para el consumidor y sentimiento del consumidor para 24 industrias. Rosario (2019) utiliza modelos de regresión univariante y multivariante para predecir los saldos de las cuentas utilizando la información obtenida del análisis de los Tweets anteriores, y luego compara los resultados con los procedimientos analíticos sustantivos tradicionales que sólo contienen estimaciones de las ventas, el crédito y el PIB por calculando el error medio porcentual absoluto (EMPA).

(Anexo - 9) muestra que los modelos analíticos con (ICT) incorporados, generan un EMPA más pequeño que los modelos tradicionales para 15,5/24 industrias en promedio, mientras que (Anexo - 10) indica que los modelos analíticos con (SPCT) incorporados generan un EMPA más pequeño que los modelos tradicionales para 14/24 industrias en promedio.

Los resultados se mejoran aún más cuando se introducen en el modelo indicadores continuos/mensuales. (Anexo - 11) muestra que los modelos (ICT) tienen un promedio de EMPA más bajo para 20/24 y los modelos de (SPCT) (Anexo - 12) tienen un promedio de EMPA más bajo para 17,5/24 industrias en promedio, lo que sugiere que las medidas basadas en Twitter tienen un mayor poder de predicción para períodos de tiempo más cortos. Estos resultados indican que cuanto más continuo sea el modelo analítico sustantivo, más superior será a los modelos de predicción que no utilizan el análisis del sentimiento de redes sociales. Este análisis continuo será útil para los auditores en su evaluación de los datos en tiempo real (30% de todos los datos para 2025), ya que proporciona una fuente continua de pruebas de auditoría externa que mejora la eficacia de los procedimientos de auditoría.

Completar esta "evidencia razonable" mediante el análisis de las redes sociales podría utilizarse para complementar la información macroeconómica, como las tendencias de la industria utilizadas para el análisis de un cliente o los activos corrientes del balance de una empresa, como el efectivo o las cuentas por cobrar, al tiempo que se ayuda a los auditores a comparar las expectativas con las de la administración, mejorando así su evidencia sustantiva. Los resultados indican que los auditores pueden beneficiarse de la inclusión de información de redes sociales inducida por la IA como prueba de auditoría para hacer pronósticos durante esta fase.

Cristo,et.al (2019) examinaron si la utilización de programas informáticos de recuento automatizados y de aviones teledirigidos que evocan la visión computadorizada puede mejorar la calidad de la auditoría y, por consiguiente, mejorar la presentación de informes financieros y la gestión de los activos en comparación con los recuentos manuales tradicionales. PWC (2016) mostró que las empresas invierten 127.300 millones de dólares anuales en la gestión de inventarios, de los cuales 36.000 millones de dólares se concentran en la industria agrícola o minera. Para mostrar cómo los aviones no tripulados pueden mejorar la auditoría del inventario, el estudio voló un avión no tripulado sobre los activos (animales de granja en este caso) y envió las imágenes a un software integrado con algoritmos de aprendizaje automático para calcular el número de animales (Anexo – 13).

**Tabla 9: Comparación entre el recuento manual de la auditoría interna y el recuento de drones**

	<b>Auditoría Interna</b>	<b>Pruebas iniciales de aviones teledirigidos</b>	<b>Pruebas de aviones teledirigidos con algo de experiencia</b>
<b>Vacas posibles de contar</b>	32.598	32.598	32.598
<b>En realidad las vacas contaron</b>	3.35	32.628	7.169
<b>Porcentaje auditado</b>	10,3%	100%	22,0%
<b>Tasa de error</b>	-0,1493%	-0,0306%	-0,0698%
<b>Mejora de la tasa de error relativa a la Auditoría Interna</b>	-	487,3%	213,8%

<b>Tiempo para realizar la auditoría</b>	70 horas (40 horas de tiempo de auditoría interna + 30 horas de tiempo de vaquero)	45 horas (incluido un tiempo considerable debido a las precauciones adicionales como fotografiando y usando el software)	4,97 horas (incluye tiempo de reconciliación con cliente)
<b>Tiempo estimado para contar el 100% de ganado (en horas)</b>	681,2	45	19,1
<b>Mejora del recuento de tiempo relativa a la Auditoría Interna</b>	-	1413,8%	3473,7%

Fuente: Adaptado de (Christ,el.al, 2019)

Los resultados de la tabla anterior muestran que los auditores realizaron el recuento de activos con el software de aprendizaje automático hasta un 3474% más eficientemente que el recuento manual. La tasa de detección de errores en relación con la técnica de auditoría más tradicional también mejora significativamente (hasta un 487%), proporcionando una documentación de auditoría de mayor calidad. Un conteo manual toma 70 horas para contar sólo el 10% de la manada, mientras que un dron experimentado y de alta calidad puede contar el 100% en poco menos de 5 horas. Este estudio proporciona pruebas estadísticas de que el proceso de recuento de activos se mejora a través del aprendizaje de la máquina y la visión por ordenador. De esta manera, se mejora la eficiencia y la calidad de la auditoría al reducir la cantidad de tiempo necesario para completar la tarea y al reducir la tasa de error.

#### **Etapa 4 - Informe de auditoría:**

El último paso en el proceso de auditoría es la emisión de un informe basado en los hallazgos de los pasos anteriores. De acuerdo con la norma internacional de auditoría (ISA) 700, los objetivos del auditor son:

- Formar una opinión sobre los estados financieros sobre la base de una evaluación de las conclusiones extraídas de las pruebas de auditoría obtenidas
- Expresar claramente esa opinión a través de un informe escrito.



Antes de la IA:

Para compilar las conclusiones del informe, los auditores tendrían que reunir toda la información de auditoría pertinente de los pasos anteriores y formar una opinión basado en las pruebas más subjetivas obtenidas en gran medida.

Después de la IA:

A pesar de la capacidad de la IA para superar a los seres humanos en los pasos anteriores descritos anteriormente, no hay suficiente evidencia en este momento para sugerir que la IA tendrá el poder de reemplazar completamente el complejo proceso de toma de decisiones que viene con hacer una evaluación de auditoría. Esto se debe a que, aunque la tecnología de IA puede imitar las funciones humanas, no puede sustituir el intelecto del auditor en la toma de decisiones, ya que la auditoría es una profesión que requiere una base de conocimiento rigurosa (Knechel et al., 2013). Esto significa que la competencia y experiencia del auditor es necesaria para hacer juicios debido a los profundos conocimientos teóricos y la experiencia.


Técnicamente, un modelo predictivo de aprendizaje automático podría calcular automáticamente una puntuación basada en el nivel de errores de material del cliente, el número de errores en el procedimiento de auditoría y su efecto potencial basado en los otros procesos de IA durante la auditoría. Sin embargo, incluso si la IA pudiera reemplazar a los auditores en estos aspectos del informe de auditoría, los clientes todavía pueden exigir la comunicación de los auditores humanos a la hora de concluir una auditoría. Por ejemplo, la comunicación es una habilidad que actualmente carecen los auditores y ha sido identificado como el cuarto competencia técnica más necesaria para los futuros auditores (ACCA, 2016). Aunque los auditores pueden utilizar las estadísticas producidas por la IA para llegar a su conclusión, su capacidad para gestionar las relaciones al entregar el informe y asesorar al cliente es indispensable y por qué la IA sólo puede tener un impacto mínimo en esta etapa.

En general, sobre la base del análisis de la aplicación de la IA en diversos procedimientos de auditoría en diferentes etapas del proceso de auditoría, las pruebas empíricas tienden a coincidir con la encuesta de Forbes Insights/KPMG 2018 de 250 ejecutivos de finanzas corporativas menores de 40 años, en la que se afirma que más del 94% de los encuestados creían que estas tecnologías mejoran la calidad de la auditoría. Al menos en las tres primeras etapas, esto ha demostrado ser cierto.

### Parte (b) - La inversión de las grandes empresas de contable pública en la IA en los últimos años

Una encuesta de 2019 de empresas estadounidenses y británicas encontró que el 33% ya estaba delegando sus procesos de auditoría con el fin de reducir los costos, con otro 44% pensando en adoptar la misma política. Alrededor del 45% dijo que esto significaría más partes de la auditoría que iban a las empresas de tecnología (Source Global Research, 2019). Con los "Big 4" auditando el 99% de las empresas en el FTSE 100 y el 96% de las empresas en el índice FTSE 250, está claro que la inversión en IA por parte de las firmas de contable más grandes es necesaria para mantener esta supremacía e impedir que las empresas tecnológicas se conviertan en rivales de auditoría a medida que la industria se digitaliza. Esta inversión sin precedentes en tecnología de IA está teniendo un efecto transformador en sus identidades y cómo funcionan mientras tratan de aprovechar los beneficios que la IA aporta a la auditoría.

**Figura 6: El porcentaje de auditorías de las empresas cotizadas en el Reino Unido (capital y deuda) realizadas por los “Big 4”.**

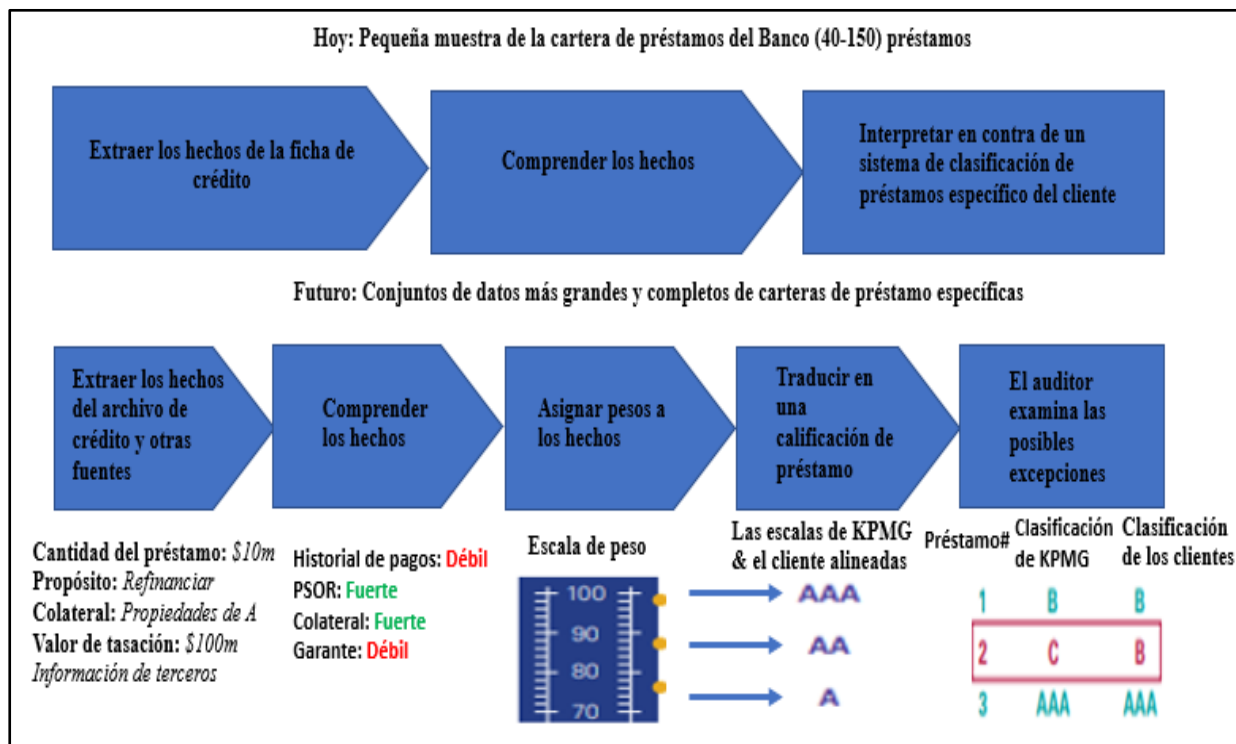


(Fuente: Financial Reporting Council, 2019).

Por ejemplo, KPMG anunció que invertiría \$5 mil millones entre 2019-2024 con el fin de hacer que la automatización y IA sean fundamentales para su futuro y mejorar su transformación digital (KPMG, 2019). KPMG ha colaborado con IBM para desarrollar 'IBM Watson', un sistema de IA que permite a los clientes compilar todos los contratos de arrendamiento e informes contables electrónicamente con el fin de cumplir con la nueva norma de leasing contable IFRS 16 introducida en 2019. Para satisfacer las nuevas demandas de divulgación, firmas deben extraer y analizar una gran cantidad de datos de sus acuerdos y contratos, que es donde esta herramienta de extracción de contratos puede ayudar. Utilizando el modelo de aprendizaje automático "Knowledge Studio" completa el proceso en el 25% del tiempo que los esfuerzos manuales requieren de acuerdo con Stephen Rinck, Consultor de Soluciones de Negocio Cognitivos (IBM, 2020).

KPMG también ha estado trabajando con IBM Watson para desarrollar herramientas de automatización cognitiva para auditores que utilizan análisis predictivo, minería de datos, reconocimiento de patrones e imágenes y aprendizaje automático para evaluar la evidencia y complementar el juicio del auditor (KPMG, 2016).

**Figura 7: Ilustración de un marco de cómo su tecnología cognitiva podría ser utilizada para auditar la cartera de préstamos de un banco.**

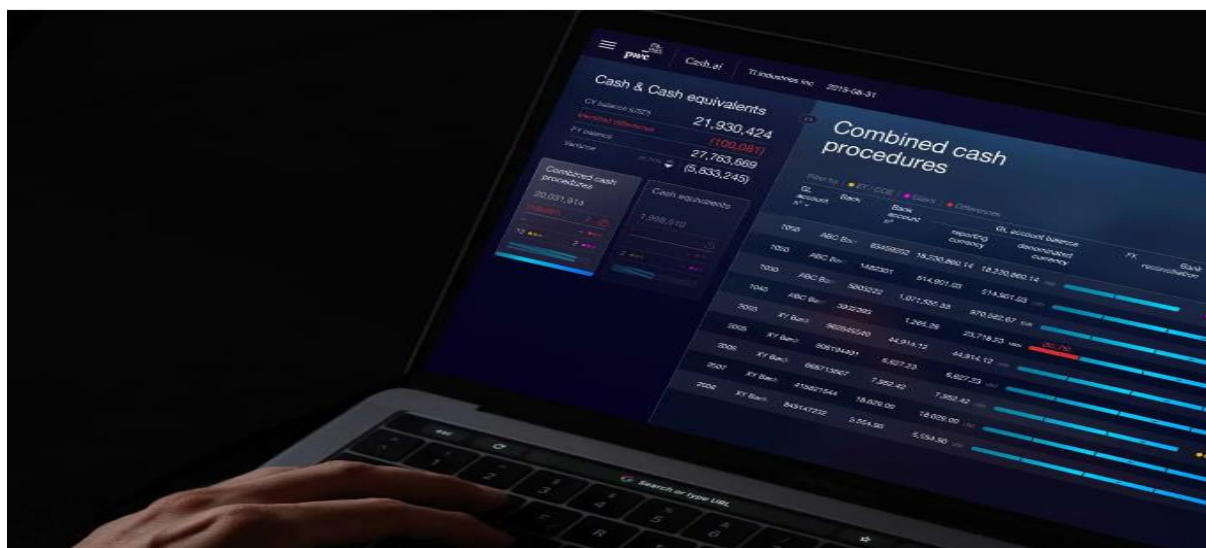


Fuente: Adaptado de (KPMG, 2016)

Este nuevo marco proporciona al auditor una comprensión más completa y profunda del riesgo crediticio y las posibles anomalías basadas en la capacidad inherente de los sistemas para calificar los préstamos, dando al auditor una mejor comprensión de los controles internos y el entorno de riesgo del banco.

En 2018, el 36 por ciento de las tareas rutinarias en el sector de los Servicios Financieros están siendo realizadas por máquinas y algoritmos, con esta cifra aumentando al 61% para 2022 (Foro Económico Mundial, 2018). Entonces no es de extrañar que los rivales de KPMG también estén invirtiendo en IA. PwC se ha comprometido a gastar \$3 mil millones en tecnología y capacitación entre 2019-2023 (PwC, 2019a). PwC ha ganado el premio "Audit Innovation of the year" para los años 2017, 2018 & 2019 - la victoria más reciente con "Cash.ai" usa a IA para monitorear el tesoro de un cliente para aumentar el flujo de efectivo y leer automáticamente, entender y probar documentos como saldos de efectivo, conciliaciones bancarias y confirmación de banco y cartas y divisas (PwC, 2019b).

**Figura 8: “Cash.ai” de PwC**



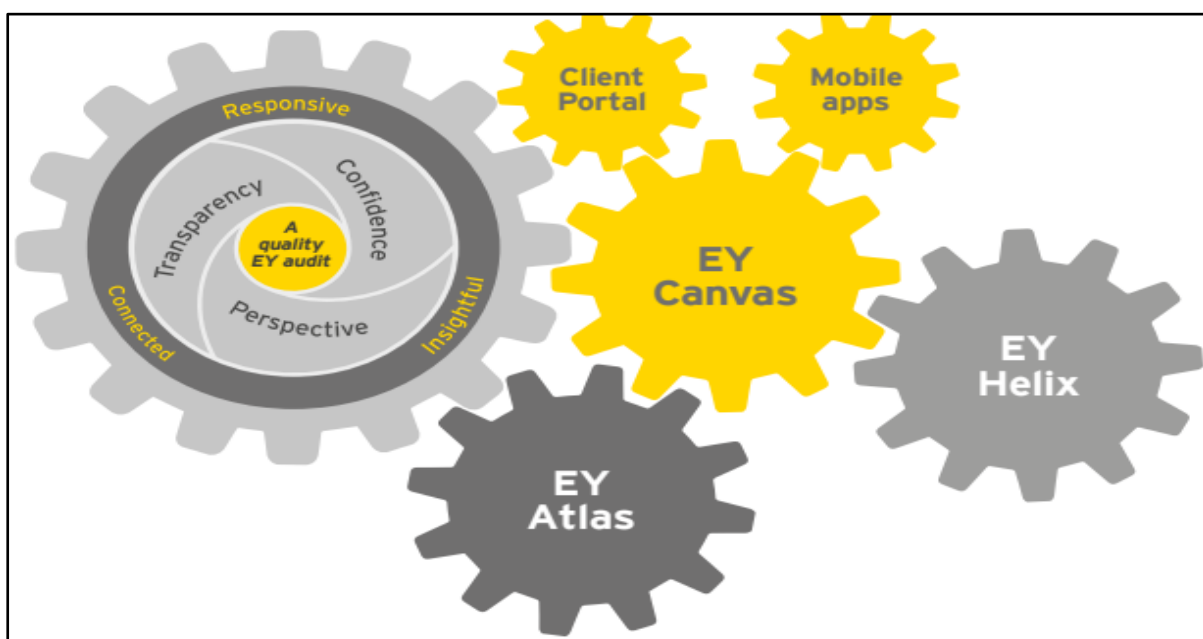
Fuente: (PwC, 2019b)

En 2017, 88,5% de los altos ejecutivos de la fortuna 1000 creyeron que la IA tendría un impacto disruptivo en su empresa en la próxima década (New Vantage Partners, 2017). Al reflejar este sentimiento, EY anunció una inversión de mil millones de dólares en tecnología de IA "disruptiva" en 2018 (EY, 2018a). Parte del trabajo de EY en este campo ha incluido la transformación de sus servicios de impuestos y aseguramiento utilizando IA, por ejemplo, mediante el desarrollo de un clasificador de impuestos que utiliza modelos de aprendizaje automático para clasificar las transacciones imponibles. Según Martin Fiore, socio director de EY "el 80% del tiempo de la

función tributaria se dedica a recopilar datos y al 20% analizarlo. " La IA nos permite casi invertir eso, creando una ganancia masiva de valor", dice y evita una situación en la que un auditor humano tarda una media de 75 horas en analizar 10.000 líneas de datos de pérdidas y ganancias (EY, 2019).

La inversión de 1.000 millones de dólares de EY se ha centrado en las principales tecnologías que están digitalizando su auditoría: EY Canvas, EY Helix & EY Atlas (EY, 2018b);

**Figura 9: La tecnología de auditoría de Ey**



Fuente: Leading-edge digital technology powering the EY audit (EY, 2018b)

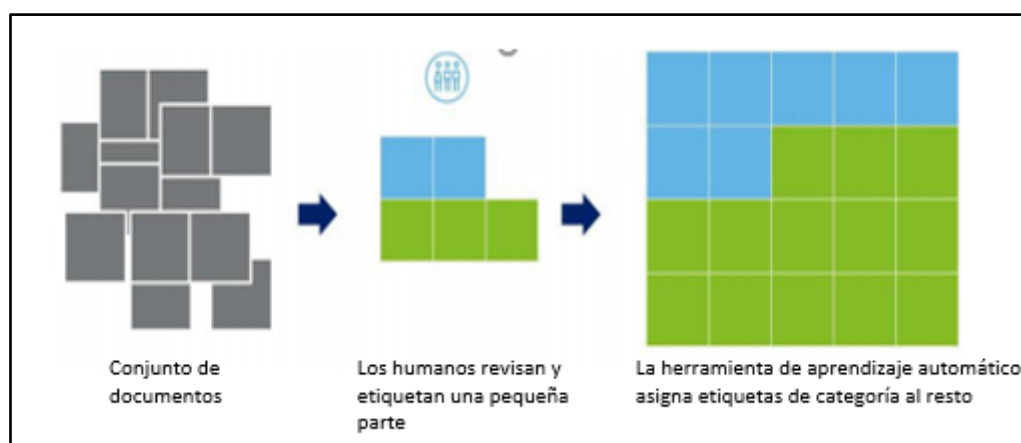
EY Canvas es su plataforma global de auditoría en línea que integra su Portal de Clientes y conecta a los clientes directamente con los auditores a través de su aplicación móvil, proporcionando actualizaciones de estado en tiempo real. EY Helix es su conjunto de análisis de datos donde han desarrollado el detector de anomalías EY Helix GL. Esta solución aprovecha el análisis de datos para crear visualizaciones de las entradas marcadas y el motivo de su detección a través del aprendizaje automático y se esperaba que se utilizara en 100 interacciones de auditoría en 2019 (EY, 2018c). La tercera tecnología en la que han invertido, EY Atlas, es una plataforma basada en la nube incorporada con IA y capacidades de reconocimiento de voz disponibles para los clientes para acceder al contenido de auditoría.

Además, "EY Fraud Investigations & Dispute Services" ha ayudado a las empresas farmacéuticas con revisiones de correos de voz y documentos utilizando tecnologías de IA y análisis avanzados y también ha ayudado a una empresa internacional de alimentos y bebidas con facturas fraudulentas

a identificar el 97% de los casos mediante el uso de tecnologías de aprendizaje automática (Mazzal & Duffy, 2017).

Deloitte, a diferencia de las otras 3 grandes firmas de contable, no ha publicado una cifra relativa a la inversión en la IA. Sin embargo, hay numerosos ejemplos concretos de Deloitte implementando con éxito soluciones de IA para sus clientes. Por ejemplo, Deloitte innovación EE.UU ha desarrollado una plataforma de revisión de documentos que ha automatizado el revisión y extracción de información clave de los contratos a través de la categorización de textos (Deloitte, 2018). Esta categorización de texto divide los documentos en tokens (palabras) y utiliza estas palabras para asignar automáticamente los documentos divididos en categorías predefinidas mediante el aprendizaje supervisado, es decir, el modelo predictivo de aprendizaje automático se basa en la etiqueta de los auditores humanos de documentos;

**Figura 10: Diagrama de flujo del examinador de documentos de Deloitte**



Fuente: Adaptado de (Deloitte, 2018)

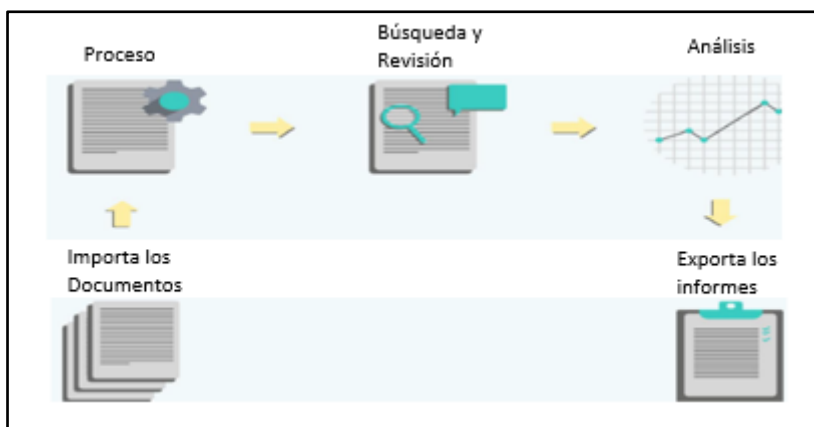
Según (Deloitte, 2018), esta innovación de auditoría puede priorizar, ordenar y revisar 250 documentos por hora y ahorra alrededor del 60% de los costos, en comparación con una revisión lineal tradicional del mismo volumen de documentos debido a la reducción de los costos de mano de obra humana.

Un ejemplo de una de las compañías de IA más exitosas de Deloitte que ya está en producción es "Argus". En marzo de 2016, la solución basada en Kira se había aplicado a más de 100.000 documentos (Kepes, 2016). Argus utiliza el aprendizaje automático y el procesamiento de lenguaje natural para ayudar a los auditores a identificar y visualizar los elementos que pueden requerir una inspección más detallada. Los exámenes también segmentan los documentos, por ejemplo, separando los contratos que incluyen ciertas cláusulas en un contrato inmobiliario de los que no las

incluyen. Se pueden añadir capacidades de visualización para demostrar qué documentos difieren de una línea de base estándar (Deloitte, 2017b).

Esto puede ser útil para los auditores de Deloitte en situaciones en las que se espera que todos los documentos sean los mismos para un determinado tipo de transacción. Argus también revisa los documentos en una fracción del tiempo que solía tomar, lo que permite a los auditores echar un ojo sobre muestras más grandes, incluso hasta el 100% de los documentos. (Raphael, 2017). En consecuencia, los auditores gozan de un papel mejorado, donde pueden concentrarse en tareas de mayor valor, como revisar el resultado de las tareas automatizadas y evaluar las implicaciones de los hallazgos en lugar de realizar la revisión repetitiva ellos mismos.

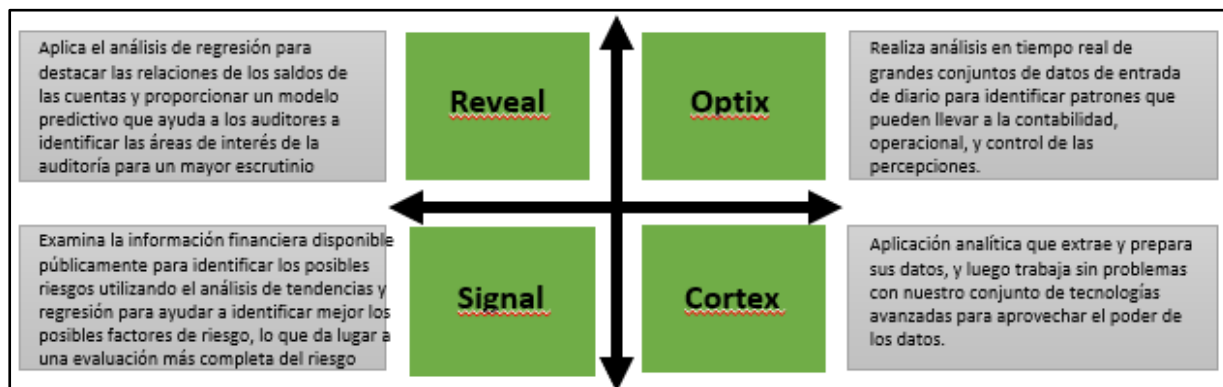
**Figura 11: Línea de tiempo de "Argus" de Deloitte**



Fuente: Adaptado de <https://kirasystems.com/how-it-works>

Deloitte también tiene como objetivo mejorar la calidad de la auditoría a través de Illumnia, su plataforma de análisis global.

**Figura 12: Resumen de Illumnia de Deloitte y sus aplicaciones**



Fuente: Adaptado de (Deloitte, 2017c)

Fuera de los "Big 4", otras grandes firmas de contable pública también están invirtiendo en IA con el fin de mejorar sus auditorías. BDO y MindBridge Analytics Inc., se han combinado para aumentar el análisis de datos de BDO y las capacidades forenses globales a través del uso de MindBridge, una plataforma de IA que les permite identificar transacciones y detectar patrones de actividad anómalos (BDO, 2017). Una reciente inversión de Mazars – la compra de la firma de análisis prescriptivo Zettafox, también muestra cómo el aprendizaje automático integral se ha convertido para las empresas fuera del "Big 4" que quieren una ventaja competitiva y aceleran el despliegue de este nuevo enfoque analítico en fraude, riesgo y forenses (Mazars, 2017). Otra firma de los "Big 10", Grant Thornton, se ha comprometido a mejorar su proceso de auditoría a través de análisis de datos avanzados. "Lumen" utiliza modelado predictivo, análisis de tendencias y regresión, análisis de contable completo y puntuación transaccional para lograrlo (Grant Thornton, 2017).



### Parte (c) - Investigación sobre la inversión de las universidades en la IA

Para adaptarse a este cambio en la forma en que los auditores funcionarán en el futuro debido a las capacidades de la IA y a la voluntad de las grandes empresas de invertir en ella, las universidades han comenzado a preparar a los estudiantes que ingresan a la profesión de auditor con módulos y capacitación más centrados en la IA. Para demostrar esto, se investigaron los programas de máster de contable ofrecidos por los 5 programas universitarios más importantes de Reino Unido y los 5 de Irlanda también, según la clasificación de la Universidad Mundial QS. Se eligió el Reino Unido porque dos de las mayores empresas de contable tienen su sede en Londres (EY & Deloitte) ([big4accountingfirms.com](http://big4accountingfirms.com), 2020), lo que sugiere que los contables principiantes recibirán allí la formación más actualizada y porque Londres es la capital financiera de Europa, mientras que se eligió Irlanda por su proximidad y sus estrechos vínculos con el Reino Unido en lo que respecta a la educación y las normas de contable ([charteredaccountants.ie](http://charteredaccountants.ie)).

**Tabla 10: Las 5 mejores universidades del Reino Unido y las 5 mejores universidades de Irlanda y los módulos centrados en el análisis de datos o en la IA que se ofrecen**

Universidad	Clasificación del Mundo	Módulos centrados en el análisis de datos o en la IA
University of Oxford (UK)	4	No se ofrece ningún módulo de análisis de datos o la IA
University of Cambridge (UK)	7	Ofrece un curso moderno empapado en técnicas analíticas inducidas por la IA. Los módulos incluyen: Análisis descriptivo, análisis predictivo, datos estructurados y no estructurados, analítica para la contable financiera y la gestión de riesgos, analítica para la contable de gestión y la gestión de operaciones ( <a href="http://www.jbs.cam.ac.uk">www.jbs.cam.ac.uk</a> )
UCL (UK)	8	No se ofrece ningún módulo de análisis de datos o la IA
Imperial College London (UK)	9	No se ofrece ningún módulo de análisis de datos o la IA
The University of Edinburgh (UK)	20	Ofrecer un módulo de análisis de datos llamado "Gobernando la toma de decisiones a través de visualizaciones de datos" ( <a href="http://studylink.com">studylink.com</a> )
Trinity College Dublin (Irlanda)	108	No se ofrece ningún módulo de análisis de datos o la IA
University College Dublin (Irlanda)	185	Ofrece módulos de dos semestres de duración en módulos de "Analítica contable" que proporcionan a los estudiantes la capacidad de crear modelos financieros sofisticados en Excel y

		utilizar módulos de planificación de recursos empresariales (Smurfitschool.ie)
Nui Galway (Irlanda)	259	Lo único máster de contable específicos de análisis de datos. Está dirigido por KPMG e incluye módulos como Ciencia de los Datos y Analítica de “Big Data”, Inteligencia de Negocios con SAP y Desarrollo de Habilidades Analíticas y de Comunicación (NUIG, 2018)
University College Cork (Irlanda)	310	No se ofrece ningún módulo de análisis de datos o la IA
Dublin City University (Irlanda)	429	Ofrece un módulo de un año de duración en "Análisis de datos" con el objetivo principal del curso de enseñar a los estudiantes a utilizar herramientas analíticas de “Big Data” y técnicas de modelado estadístico para apoyar las decisiones empresariales (www.101.dcu.ie)

Tras el análisis, se reveló que 5 de las 10 principales universidades del Reino Unido y Irlanda ofrecían el módulo de análisis de datos en sus programas de Máster para ayudar a los futuros auditores a comprender las tecnologías emergentes. El módulo de Dublín City University sólo se integró en el curso en 2019, mientras que el curso específico de análisis de datos de NUIG que centra en SAP & análisis de auditoría, introducido en 2018, fue el primero de este tipo en Irlanda o el Reino Unido (NUIG, 2018).

La reciente integración de módulos y cursos de análisis de datos en los principales programas de contable de postgrado de Reino Unido y Irlanda, así como una mayor inversión en herramientas y plataformas de IA por parte de las empresas más grandes indican que tanto las universidades como las empresas aceptan que los auditores del futuro deben ajustar sus habilidades y adaptarse para que puedan analizar los datos producidos por IA y no solo organizarlos y procesarlos manualmente. Para poder manejar las nuevas herramientas de IA que se introducen en la auditoría, los auditores graduados deben aprender estas nuevas tecnologías, entender cómo funcionan los sistemas y ser capaces de utilizar estos sistemas para traducir datos de forma rápida y precisa con el fin de mejorar la eficacia de la auditoría.

## 5. Conclusiones

El objetivo principal de este TFG era investigar el efecto que la Inteligencia Artificial tiene y tendrá en el proceso de auditoría. Las conclusiones de este TFG indican que la IA ya ha comenzado a mejorar varias etapas de la auditoría y que al aplicar algunos de los marcos sugeridos por la investigación citada por este TFG, estas mejoras continuarán ocurriendo en los próximos años. En reconocimiento de esto, las mayores firmas de contable pública y los programas de Máster de las universidades han comenzado a incorporar análisis de auditoría mejorados por IA en sus departamentos relevantes.

Tras el análisis de las conclusiones relativas a la etapa de planificación de la auditoría, que se refiere a la comprensión del cliente y la determinación de la tasa de auditoría, las pruebas sugirieron que IA podría tener un impacto positivo en esta etapa por:

- Resumir las sesiones de “brainstorming” con la administración mediante técnicas de procesamiento de lenguaje natural y reconocimiento de voz, lo que permite que una herramienta del módulo de preguntas y respuestas proporcione un análisis más rápido
- Usar la emoción citada de las presentaciones de 8-K & 10-K como una variable adicional que hace que el precio de una auditoría sea más preciso

Como se esperaba debido al alto nivel de estructura involucrado en estas etapas, la etapa del proceso de auditoría en la que IA puede tener el mayor impacto es la etapa de ejecución. Esto se refiere a las etapas 2 y 3 (probar los controles internos y realizar procedimientos sustantivos) en el marco utilizado en la sección 4. Estas etapas se utilizan para comprobar que las pruebas de auditoría recopiladas son confiables. Las pruebas estadísticas mostraron que la respuesta a la pregunta de la investigación "¿Mejora la IA la velocidad, calidad y fiabilidad de una auditoría, en comparación con el sistema tradicional?" es sí.

Algunas de las mejoras observadas en la fase de ejecución fueron:

- Modelos de aprendizaje automático que proporcionan a los auditores puntos de referencia superiores para predecir las debilidades del control interno, permitiéndoles centrarse en las "anomalías".
- Modelos de aprendizaje profundo que mejoran la precisión de las predicciones de las debilidades de control interno a través del análisis de los sentimientos.

- Minería de procesos evaluando una población entera de registros de eventos en lugar de una muestra, que demostró ser más precisa en la detección de debilidades de control interno y en la prueba de detalles más precisos en torno a estos controles
- La agrupación K significa que proporciona un mejor punto de referencia para el auditor al comparar un cliente con características operativas similares a los métodos de clasificación tradicionales, mejorando así la capacidad del auditor para decir si los coeficientes financieros, el nivel de riesgo, etc. de los clientes son razonables o no.
- Aprendizaje automático que aumenta la calidad y la fiabilidad de las estimaciones contables, haciendo que esta información sea más útil para los auditores al evaluar las transacciones, completar los procedimientos analíticos y probar los controles.
- Análisis del sentimiento de rendimiento y procesamiento del lenguaje natural incorporando las redes sociales como pruebas de auditoría, lo que mejoró las predicciones sobre el rendimiento de las ventas, haciendo así la empresa más auditable.
- Los aviones teledirigidos inducidos por la inteligencia artificial, que han demostrado ser más eficientes en el tiempo y más precisos a la hora de contar los activos, mejorando la gestión de los activos y la presentación de informes financieros.

La etapa del proceso de auditoría que se encontró que tenía la menor susceptibilidad a IA es el informe de auditoría o la etapa de conclusión. No hay suficiente evidencia que sugiera que IA ayude a los auditores a comunicarse con los clientes sobre cuestiones ambiguas que giran en torno a la conclusión del informe, o reemplazar la capacidad de toma de decisiones de un auditor altamente competente al hacer determinaciones o juicios de alto riesgo, sin embargo, debido a la superioridad de IA con los métodos tradicionales en las fases anteriores, ayuda a los auditores a determinar qué información es relevante para informar. Teóricamente, los auditores podrían incorporar puntuaciones calculadas a través de técnicas de aprendizaje automático sobre el riesgo, las declaraciones erróneas y el número de errores y evaluar automáticamente el riesgo de auditoría a través de un algoritmo, pero la opinión experta de un auditor todavía estaría obligada a interpretar el resultado y hacer una llamada de juicio final.

En general, la evidencia estadística sugiere que la calidad de la auditoría aumenta con una mayor aplicación de IA. La auditoría inducida por IA tiene la capacidad de disminuir los errores en el proceso, asegurando así clientes más reacios al riesgo porque los algoritmos de IA muestran cifras exactas en lugar de depender de observaciones subjetivas de discusiones con la administración, etc. Esta disminución de errores hará que el proceso de auditoría sea más rápido debido a su capacidad para reducir la cantidad de pruebas sustantivas que deben completarse.

En relación con cómo se aprovecharán las ventajas de la IA para el proceso de auditoría, es necesario una tasa más alta de auditores con la alfabetización de la IA que ingresan a la industria en los próximos años. Esta investigación encontró que las grandes firmas de contable han estado invirtiendo en el desarrollo tecnológico en el campo de la auditoría y han comenzado a capacitar a los graduados con el fin de entender el nuevo software. Esta inversión refleja el hecho de que las empresas de auditoría tienen como objetivo mantenerse competitivas a través del desarrollo tecnológico y están interesadas en mejorar su propio sistema de auditoría para que puedan atender los cambios esperados en los sistemas de sus clientes. Este tipo de inversión también se ha llevado a las universidades, con muchas instituciones reconociendo la necesidad de tener graduados que son expertos en IA con el fin de satisfacer esta demanda en los próximos años mediante la integración de análisis de auditoría en sus programas de Máster. Sin embargo, a pesar de toda la inversión y beneficios enumerados, la integración de IA al proceso de auditoría siempre se limitará a un cierto grado debido a la exigencia de juicio profesional.

## Referencias;

Abdolmohammadi, M. J. (1999). A comprehensive taxonomy of audit task structure, professional rank and decision aids for behavioural research.

ACCA. (2016) Professional accountants – the future: Drivers of change and future skills. Recuperado de: <https://www.accaglobal.com/content/dam/members-beta/images/campaigns/pa-tf/pi-professional-accountants-the-future.pdf>

Accounting and Finance (MSc) The University of Edinburgh Business School, University of Edinburgh. (No Hay Fecha). Recuperado de: <https://studylink.com/institutions/the-university-of-edinburgh-business-school/courses/cid-si-18368>

Agnew, H. (2016). Auditing: Pitch battle. Financial Times (May 9). Recuperado de: <https://www.ft.com/content/268637f6-15c8-11e6-9d98-00386a18e39d>

AICPA. (2018). Enhancing Audit Quality: 2018 highlights and progress. Recuperado de: <https://www.aicpa.org/content/dam/aicpa/eaq/eaq-highlights-report-2018.pdf>

Alpaydin, E. (2014). Introduction to Machine Learning (3rd ed.). The MIT Press.

Appelbaum, D., & Nehmer, R. A. (2017). Using drones in internal and external audits: An exploratory framework. Recuperado de: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3335204](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3335204)

Appelbaum, Deniz. (2017). Public Auditing, Analytics, and Big Data in the Modern Economy Graduate School. Newark Rutgers, the State University of New Jersey. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/54072/PDF/1/play/>

Asthana, S., Khurana, I., and Raman, K. K. (2019). Fee competition among Big 4 auditors and audit quality. Review of Quantitative Finance and Accounting. Recuperado de: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3325251](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3325251)

Balakrishnama, A., Ganapathiraju, A. (1998). LINEAR DISCRIMINANT ANALYSIS - A BRIEF TUTORIAL. Institute for Signal and Information Processing Department of Electrical and Computer Engineering Mississippi State University. Recuperado de: [https://www.isip.piconepress.com/publications/reports/1998/isip/lda/lda\\_theory.pdf](https://www.isip.piconepress.com/publications/reports/1998/isip/lda/lda_theory.pdf)

BDO. (2017). BDO USA AND MINDBRIDGE™ ANALYTICS INC. ANNOUNCE STRATEGIC RELATIONSHIP. Recuperado de: <https://www.bdo.com/news/2017-july/bdo-usa-and-mindbridge%E2%84%A2-analytics-inc-announce-st>

Bellovary, J. L., & Johnstone, K. M. (2007). Descriptive evidence from audit practice on SAS No. 99 brainstorming activities. American Accounting Association Current Issues in Auditing Volume One 2007 Pages A1–A11

Big 4 Accounting Firms | Largest Accounting Firms In The World. (2020). Recuperado de: <https://big4accountingfirms.com/> (2020)

Bishop, C. M. (2006). Pattern recognition and machine learning: Springer

Brown, C; Murphy, D. (1990) The Use of Auditing Expert Systems in Public Accounting. Recuperado de: [https://www.researchgate.net/profile/David\\_Murphy32/publication/286784718\\_The\\_use\\_of\\_audi](https://www.researchgate.net/profile/David_Murphy32/publication/286784718_The_use_of_audi)

ting\_expert\_systems\_in\_public\_accounting/links/56d0504a08ae4d8d64a37555/The-use-of-auditing-expert-systems-in-public-accounting.pdf

Brown-Liburd, H., H. Issa, and D. Lombardi. (2015). Behavioral implications of Big Data's impact on audit judgment and decision making and future research directions. Recuperado de: [http://raw.rutgers.edu/docs/wcars/31wcars/helen\\_brown\\_presentation.pdf](http://raw.rutgers.edu/docs/wcars/31wcars/helen_brown_presentation.pdf)

Chen, Yung-Yao; Lin, Yu-Hsiu; Kung, Chia-Ching; Chung, Ming-Han; Yen, I.-Hsuan. (2019). "Design and Implementation of Cloud Analytics-Assisted Smart Power Meters Considering Advanced Artificial Intelligence as Edge Analytics in Demand-Side Management for Smart Homes". Recuperado de: [https://www.researchgate.net/publication/332818798\\_Design\\_and\\_Implementation\\_of\\_Cloud\\_Analytics-Assisted\\_Smart\\_Power\\_Meters\\_Considering\\_Advanced\\_Artificial\\_Intelligence\\_as\\_Edge\\_Analytics\\_in\\_Demand-Side\\_Management\\_for\\_Smart\\_Homes](https://www.researchgate.net/publication/332818798_Design_and_Implementation_of_Cloud_Analytics-Assisted_Smart_Power_Meters_Considering_Advanced_Artificial_Intelligence_as_Edge_Analytics_in_Demand-Side_Management_for_Smart_Homes)

Choi, J. D., Tetreault, J., & Stent, A. (2015). It depends: Dependency parser comparison using a web-based evaluation tool. Recuperado de: <https://www.aclweb.org/anthology/P15-1038/>

Christ, M.H, Emmett, S.A, Summers, S.L, Wood, D.A. (2019). Prepare for Takeoff: Improving Asset Measurement and Audit Quality with Drone-Enabled Inventory Audit Procedures. Recuperado de: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3335204](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3335204)

Chukwudi, C.I. (2008). Artificial Intelligence in Accountancy Firms. Recuperado de: [https://www.researchgate.net/publication/327802327\\_Artificial\\_Intelligence\\_in\\_Accounting\\_firms](https://www.researchgate.net/publication/327802327_Artificial_Intelligence_in_Accounting_firms)

Collins, H., Ashbaugh-Skaife, D. W., and Kinney, W. R. (2007). The discovery and reporting of internal control deficiencies prior to SOX-mandated audits. *Journal of Accounting and Economics*, 2007, vol. 44, issue 1-2, 166-192

Collins, H., Ashbaugh-Skaife, D.W. and Lafond, R. (2009). The effect of SOX internal control deficiencies on firm risk and cost of equity. Recuperado de: <https://onlinelibrary.wiley.com/doi/full/10.1111/j.1475-679X.2008.00315.x>

Dai, J., and M. Vasarhelyi. (2016). Imagineering Audit 4.0. Recuperado de: <https://aaapubs.org/doi/pdf/10.2308/jeta-10494>

DCU. (2019) Programme Academic Structure for 2019 - 2020, MSc in Accounting. Recuperado de: [https://www101.dcu.ie/registry/module\\_contents.php?function=4&programme=MBS&yr=2020](https://www101.dcu.ie/registry/module_contents.php?function=4&programme=MBS&yr=2020)

Dechow, P. M., W. Ge, C. R. Larson, and R. G. Sloan. (2011). Predicting material accounting misstatements. Recuperado de: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1911-3846.2010.01041.x>

Deloitte. (2017a). 2017 Deloitte Millennial Survey Apprehensive millennials: seeking stability and opportunities in an uncertain world. Recuperado de: <https://www2.deloitte.com/content/dam/Deloitte/global/Documents/About-Deloitte/gx-deloitte-millennial-survey-2017-executive-summary.pdf>

Deloitte. (2017b). Creating a Cognitive Audit. Recuperado de: <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/audit/us-audit-creating-cognitive-audit.pdf>

- Deloitte (2017c) Delivering smarter audits Insights through innovation. Recuperado de: <https://www2.deloitte.com/content/dam/Deloitte/us/Documents/audit/us-audit-smarter-audits-dynamic-insights-through-innovation.pdf>
- Deloitte. (2018). Dynamic Review: Document review in new perspective. Recuperado de: <https://www2.deloitte.com/us/en/pages/advisory/articles/dynamic-review.html>
- Ding, K., Peng, X., and Wang, Y. (2019). A Machine Learning-Based Peer Selection Method with Financial Ratios. <http://raw.rutgers.edu/docs/wcars/40wcars/Presentations/KexingXuanYunsen.pdf>
- Ding, K., Peng, X., Lev, B., Sun, T., and Vasarhelyi, M. A. (2019). Machine Learning Improves Accounting Estimates. Recuperado de: [https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=3253220](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=3253220)
- Rich, E. (1983). Artificial Intelligence. McGraw-Hill, Inc. Professional Book Group 11 West 19th Street New York, United States
- EY. (2018a). EY to spend US\$1 billion as part of its innovation drive. Recuperado de: [https://www.ey.com/en\\_ie/news/2018/08/ey-to-spend-us-1-billion-as-part-of-its-innovation-drive](https://www.ey.com/en_ie/news/2018/08/ey-to-spend-us-1-billion-as-part-of-its-innovation-drive)
- EY. (2018b). Leading-edge digital technology powering the EY audit. Recuperado de: <https://cdn.ey.com/echannel/gl/en/services/assurance/digital-audit/EY-Digital-Audit-v4.pdf>
- EY (2018c). How do you teach an algorithm to think like an auditor? Recuperado de: [https://www.ey.com/en\\_ie/better-begins-with-you/how-an-ai-application-can-help-auditors-detect-fraud](https://www.ey.com/en_ie/better-begins-with-you/how-an-ai-application-can-help-auditors-detect-fraud)
- Farzad Husain, Babette Dellen, and Carme Torras. (2016). Action Recognition Based on Efficient Deep Feature Learning in the Spatio-Temporal Domain. Recuperado de: <https://ieeexplore.ieee.org/document/7406684>
- Financial Reporting Council. (2019). Key Facts and Trends in the Accountancy Profession. Recuperado de: <https://www.frc.org.uk/getattachment/109373d4-abc2-424f-84d0-b80c2cec861a/Key-Facts-and-Trends-2019.pdf>
- Frey, C., and M. Osborne. (2013). The future of employment: How susceptible are jobs to computerization? Technological Forecasting & Social Change. Recuperado de: [https://www.oxfordmartin.ox.ac.uk/downloads/academic/The\\_Future\\_of\\_Employment.pdf](https://www.oxfordmartin.ox.ac.uk/downloads/academic/The_Future_of_Employment.pdf)
- Gbenga Dada, E., Bassi, J.S, Chiroma, H., Hamid, S.M.A, Olusola, A., Opeyemi, A., Ajibuwae, E. (2019) Machine learning for email spam filtering: review, approaches and open research problems. Recuperado de: <https://www.sciencedirect.com/science/article/pii/S2405844018353404>
- Grace, K; Salvatier, J; Dafoe, A; Zhang, B; Evans, O. (2018) When Will AI Exceed Human Performance? Evidence from AI Experts Journal of Artificial Intelligence Research. Recuperado de: <https://arxiv.org/abs/1705.08807>
- Grant Thornton. (2017). Lumen: Enlightened Financial Audits. Recuperado de: <https://www.grantthornton.com/services/audit-services/audit-data-analytics.aspx>
- Hanson, J. D. (2013). PCAOB Hanson Concerned about Auditor Hours. Accounting Today. Recuperado de: <https://www.accountingtoday.com/news/pcaobs-hanson-concerned-about-auditor-hours>



Hayes, A. (2020). R-Squared Definition. Recuperado de:  
<https://www.investopedia.com/terms/r/r-squared.asp>

CharteredAccountants.ie. Irish and UK Financial Reporting. Recuperado de:  
[https://www.charteredaccountants.ie/Member/Technical/Irish-and-UK-Financial-Reporting#:~:text=The%20main%20financial%20reporting%20frameworks,in%20the%20UK%20\(FRC\).&text=Irish%20and,IFRS](https://www.charteredaccountants.ie/Member/Technical/Irish-and-UK-Financial-Reporting#:~:text=The%20main%20financial%20reporting%20frameworks,in%20the%20UK%20(FRC).&text=Irish%20and,IFRS)

Marr, B. (2016). What Everyone Should Know About Cognitive Computing. Recuperado de:  
<https://www.forbes.com/sites/bernardmarr/2016/03/23/what-everyone-should-know-about-cognitive-computing/#479097f25088>

Huser, V. (2019). Process Mining: Discovery, Conformance and Enhancement of Business Processes (Book Review). Recuperado de:  
[https://www.researchgate.net/publication/275535045\\_Process\\_Mining\\_Discovery\\_Conformance\\_and\\_Enhancement\\_of\\_Business\\_Processes](https://www.researchgate.net/publication/275535045_Process_Mining_Discovery_Conformance_and_Enhancement_of_Business_Processes)

IBM. (2018). The Digitization of the World From Edge to Core: Data age 2025 report. Recuperado de: <https://www.seagate.com/files/www-content/our-story/trends/files/idc-seagate-dataage-whitepaper.pdf>

IBM. (2020). KPMG AG Wirtschaftsprüfungsgesellschaft. Recuperado de:  
<https://www.ibm.com/case-studies/kpmg-ag-ai-watson-cloud>

IEEE Corporate Advisory Group (CAG). (2017). IEEE Guide for Terms and Concepts in Intelligent Process Automation. The Institute of Electrical and Electronics Engineers Standards Association. Recuperado de: <https://standards.ieee.org/standard/2755-2017.html>

INTERNATIONAL STANDARD ON AUDITING 300 PLANNING AN AUDIT OF FINANCIAL STATEMENTS. (2009). Recuperado de: <https://www.ifac.org/system/files/downloads/a016-2010-iaasb-handbook-isa-300.pdf>

INTERNATIONAL STANDARD ON AUDITING 315 IDENTIFYING AND ASSESSING THE RISKS OF MATERIAL MISSTATEMENT THROUGH UNDERSTANDING THE ENTITY AND ITS ENVIRONMENT. (2009). Recuperado de:  
<https://www.ifac.org/system/files/downloads/a017-2010-iaasb-handbook-isa-315.pdf>

INTERNATIONAL STANDARD ON AUDITING 330 THE AUDITOR'S RESPONSES TO ASSESSED RISKS. (2009). Recuperado de: <https://www.ifac.org/system/files/downloads/a019-2010-iaasb-handbook-isa-330.pdf>

INTERNATIONAL STANDARD ON AUDITING 700 FORMING AN OPINION AND REPORTING ON FINANCIAL STATEMENTS (2009). Recuperado de:  
<https://www.ifac.org/system/files/downloads/a036-2010-iaasb-handbook-isa-700.pdf>

Jackson, Peter (1999), Introduction To Expert Systems (3 ed.) Recuperado de:  
<https://www.semanticscholar.org/paper/Introduction-to-Expert-Systems-Jackson/719e4e1328be9487b33a13dc38b6120993999ed5>

Jans, M.J., Alles, M.G., Vasarhelyi, M.A. (2014) A FIELD STUDY ON THE USE OF PROCESS MINING OF EVENT LOGS AS AN ANALYTICAL PROCEDURE IN AUDITING. Recuperado de:  
[https://www.researchgate.net/profile/Miklos\\_Vasarhelyi/publication/273111802\\_A\\_Field\\_Study\\_on\\_the\\_Use\\_of\\_Process\\_Mining\\_of\\_Event\\_Logs\\_as\\_an\\_Analytical\\_Procedure\\_in\\_Auditing/link](https://www.researchgate.net/profile/Miklos_Vasarhelyi/publication/273111802_A_Field_Study_on_the_Use_of_Process_Mining_of_Event_Logs_as_an_Analytical_Procedure_in_Auditing/link)

s/5550a74708ae12808b39034a/A-Field-Study-on-the-Use-of-Process-Mining-of-Event-Logs-as-an-Analytical-Procedure-in-Auditing.pdf

Jans, Mieke, Michael Alles, and Miklos Vasarhelyi. (2012). The Case for Process Mining in Auditing: Sources of Value Added and Areas of Application. Recuperado de: <https://www.sciencedirect.com/science/article/pii/S1467089512000462>

Kepes, B. (2016). Big four accounting firms delve into artificial intelligence. Computerworld (March 16). Recuperado de: <http://www.computerworld.com/article/3042536/big-data/big-four-accounting-firms-delve-into-artificial-intelligence.html>

Kile, C. O., Phill M.E., (2009) Using Industry Classification Codes to Sample High-Technology Firms: Analysis and Recommendations. Recuperado de: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.882.9748&rep=rep1&type=pdf>

Kleinmuntz, B. 1990. Why we still use our heads instead of formulas: Toward an integrative approach. <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.467.874&rep=rep1&type=pdf>

Knechel, W. R., Krishnan, V. G., Pevzner, M., Shefchik, B. L. & Velury, K. U. (2013). Audit Quality: Insights from the Academic Literature. Recuperado de: <https://www.semanticscholar.org/paper/Audit-Quality%3A-Insights-from-the-Academic-Knechel-Krishnan/7c17cef66b98413d71c0f494661a73361d241df3>

Kokina, J; Davenport, T. (2017). The Emergence of Artificial Intelligence: How Automation is Changing Auditing. Recuperado de: [https://www.researchgate.net/publication/315955305\\_The\\_Emergence\\_of\\_Artificial\\_Intelligence\\_How\\_Automation\\_is\\_Changing\\_Auditing](https://www.researchgate.net/publication/315955305_The_Emergence_of_Artificial_Intelligence_How_Automation_is_Changing_Auditing)

KPMG. (2016.) Report: Harnessing the power of cognitive technology to transform the audit. Recuperado de: <https://home.kpmg/content/dam/kpmg/us/pdf/2017/02/harnessing-the-power-of-cognitive-technology-to-transform-the-audit.pdf>

KPMG. (2019). KPMG expects to invest US\$5 billion on digital leadership in professional services. Recuperado de: <https://home.kpmg/xx/en/home/media/press-releases/2019/12/kpmg-expects-to-invest-5-billion-on-digital-leadership-in-professional-services.html>

KPMG/Forbes Insight (2018) Report: Next Generation Audit: How advanced technologies are transforming the audit. Recuperado de: <https://home.kpmg/us/en/home/insights/2018/09/next-gen-audit.html>

Marr, B. (2016). What Everyone Should Know About Cognitive Computing. Recuperado de: <https://www.forbes.com/sites/bernardmarr/2016/03/23/what-everyone-should-know-about-cognitive-computing/#684c7dd75088>

Marr, B. (2019) Machine Learning, Artificial Intelligence - And The Future Of Accounting. Recuperado de: <https://www.bernardmarr.com/default.asp?contentID=1142>

Mazars. (2017). MAZARS KEEPS DEVELOPING DIGITAL TRANSFORMATION SERVICES WITH THE ACQUISITION OF PRESCRIPTIVE ANALYTICS SPECIALIST ZETTAFOX. Recuperado de: <https://www.mazars.com/Home/News-and-Insights/Media/Press-releases/Mazars-keeps-developing-digital-transformation>

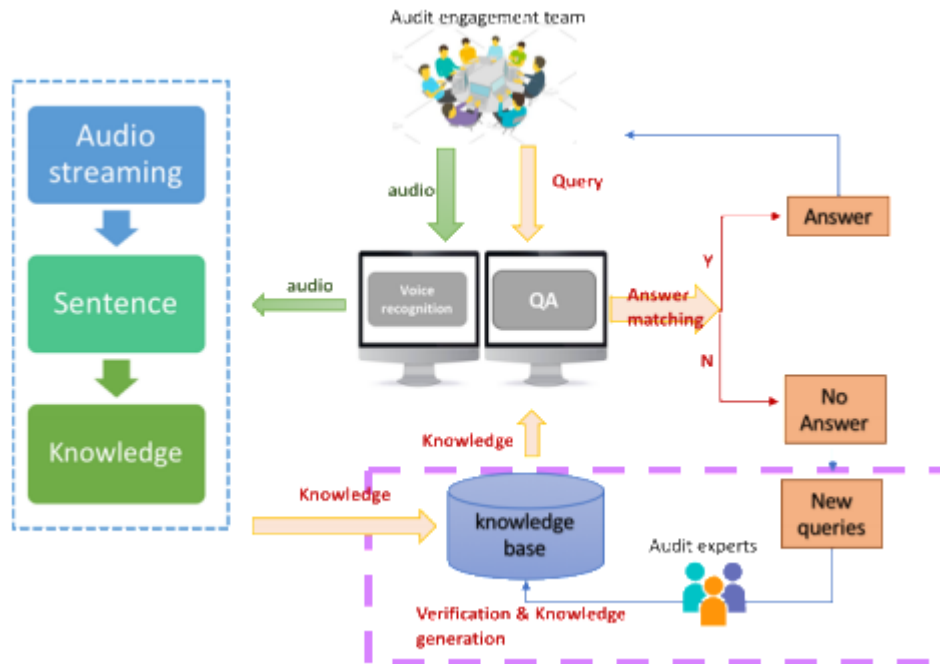
- Mazzal, C. Duffy, N. (2017) EY Report - Putting artificial intelligence (AI) to work Innovation matters: insights on the latest disruptive technologies. Recuperado de: [https://www.ey.com/Publication/vwLUAssets/ey-putting-artificial-intelligence-to-work/\\$File/ey-putting-artificial-intelligence-to-work.pdf](https://www.ey.com/Publication/vwLUAssets/ey-putting-artificial-intelligence-to-work/$File/ey-putting-artificial-intelligence-to-work.pdf)
- Mhaskar, H; Liao, Q and Poggio T (2017) When and Why Are Deep Networks Better Than Shallow Ones? Thirty-First AAAI Conference on Artificial Intelligence. Recuperado de: <https://aaai.org/ocs/index.php/AAAI/AAAI17/paper/view/14849/14414>
- Mohd-Sanusi, Z. (2011). Assessing the effects of self-efficacy and task complexity on internal control audit judgment. Recuperado de: [https://www.researchgate.net/publication/286562308\\_Assessing\\_the\\_effects\\_of\\_self-efficacy\\_and\\_task\\_complexity\\_on\\_internal\\_control\\_audit\\_judgment](https://www.researchgate.net/publication/286562308_Assessing_the_effects_of_self-efficacy_and_task_complexity_on_internal_control_audit_judgment)
- NAIR, A. (2019). R SQUARED VS ADJUSTED R SQUARED: EXPLAINING THE KEY DIFFERENCES. Recuperado de: <https://analyticsindiamag.com/r-squared-vs-adjusted-r-squared/>
- New Vantage Partners. (2017). Big Data Executive Survey 2017. Recuperado de: <http://newvantage.com/wp-content/uploads/2017/01/Big-Data-Executive-Survey-2017-Executive-Summary.pdf>
- NLP-progress. 2020. Dependency Parsing. [online] Recuperado de: [http://nlpprogress.com/english/dependency\\_parsing.html](http://nlpprogress.com/english/dependency_parsing.html)
- NUIG. (2018). MSc in International Accounting & Analytics. Recuperado de: <http://www.nuigalway.ie/accounting-analytics.html>
- Odom, M.,D. Sharda, R. (1990) A Neural Network Model for Bankruptcy Prediction 1990 IJCNN International Joint Conference on Volume: 163 - 168 volume 2. Recuperado de: [https://www.researchgate.net/publication/224755073\\_A\\_Neural\\_Network\\_Model\\_for\\_Bankruptcy\\_Prediction](https://www.researchgate.net/publication/224755073_A_Neural_Network_Model_for_Bankruptcy_Prediction)
- Pickell, D. (2018). Structured vs Unstructured Data – What's the Difference?. Recuperado de: <https://learn.g2.com/structured-vs-unstructured-data#:~:text=What%20is%20the%20difference%20between,collect%2C%20process%2C%20and%20analyze.>
- PwC. (2006). State of the Internal Audit Profession Study: Continuous Auditing Gains Momentum. Recuperado de: <https://www.accountingtoday.com/news/pwc-study-continuous-auditing-a-growing-trend>
- PwC. (2019a). Recuperado de: <https://www.pwc.com/gx/en/issues/upskilling.html>
- PwC. (2019b). Harnessing AI to pioneer new approaches to the. Recuperado de: <https://www.pwc.com/gx/en/about/stories-from-across-the-world/harnessing-ai-to-pioneer-new-approaches-to-the-audit.html>
- PwC. (2015). Data driven: what students need to succeed in a rapidly changing business world. Recuperado de: <https://cpb-us-w2.wpmucdn.com/sites.gsu.edu/dist/1/1670/files/2015/08/pwc-data-driven-paper-1wdb00u.pdf>
- PwC. (2016). Clarity from Above: PwC Global Report on the Commercial Applications of Drone Technology. Recuperado de: <https://www.pwc.pl/pl/pdf/clarity-from-above-pwc.pdf>

- Pymnts. (2020.) KPMG, PwC, EY To Put \$9B Toward AI, Data Tech. Recuperado de: <https://www.pymnts.com/news/b2b-payments/2020/kpmg-pwc-ey-investment-artificial-intelligence-data-tech/>
- Li, Q. (2019). Developing an Intelligent Assistant for the Audit Plan Brainstorming Session. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/60018/PDF/1/play/>
- QS Ranking Mundial de Universidades. (2020). Recuperado de: <https://www.topuniversities.com/university-rankings/world-university-rankings/2020>
- Raphael, J. (2017). Rethinking the Audit. Recuperado de: <https://www.journalofaccountancy.com/issues/2017/apr/rethinking-the-audit.html>
- ROZARIO, A. M. (2019). THREE ESSAYS ON AUDIT INNOVATION: USING SOCIAL MEDIA INFORMATION AND DISRUPTIVE TECHNOLOGIES TO ENHANCE AUDIT QUALITY. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/60551/>
- Sarbanes-Oxley Act of 2002 report for section 906: Corporate Responsibility for Financial Reports. (2002). Recuperado de: <https://www.sarbanes-oxley-101.com/SOX-906.htm>
- SAS Analytic Software & Solutions. (No Hay Fecha) Computer Vision: What it is and why it matters. Recuperado de: [https://www.sas.com/en\\_ie/insights/analytics/computer-vision.html](https://www.sas.com/en_ie/insights/analytics/computer-vision.html)
- SAS: Analytic Software & Solutions. (No Hay Fecha) Natural Language Processing (NLP): What it is and why it matters. Recuperado de: [https://www.sas.com/en\\_us/insights/analytics/what-is-natural-language-processing-nlp.html](https://www.sas.com/en_us/insights/analytics/what-is-natural-language-processing-nlp.html)
- Seow, P. S. (2011) The effects of decision aid structural restrictiveness on decision making outcomes. International Journal of Accounting Information Systems. Recuperado de: [https://www.researchgate.net/publication/228221820\\_The\\_Effects\\_of\\_Decision\\_Aid\\_Structural\\_Restrictiveness\\_on\\_Decision-Making\\_Outcomes](https://www.researchgate.net/publication/228221820_The_Effects_of_Decision_Aid_Structural_Restrictiveness_on_Decision-Making_Outcomes)
- Shah, S (2018). How accounting firms can tap into benefits of AI. Recuperado de: <https://www.journalofaccountancy.com/news/2018/may/how-cpa-firms-can-tap-ai-benefits-201818949.html>
- Shiyi, F & Jeyaraj, S. (2017) RELATION BETWEEN AUDIT RISK AND AUDIT FEES - EVIDENCE FROM LISTED FIRMS IN THE US European Journal of Accounting, Auditing and Finance Research Vol.5, No.5, pp.78-110. Recuperado de: <http://www.eajournals.org/wp-content/uploads/Relation-between-Audit-Risk-and-Audit-Fees-Evidence-from-Listed-Firms-in-the-U.S.pdf>
- Smurfit School. (2019). Master's of Accounting Modules. Recuperado de: <https://www.smurfitschool.ie/programmes/masters/masterofaccounting/curriculumlearning/>
- Source Global Research. (2019). The Challenger Audit Brand: Impossible or inevitable? Recuperado de: <https://reports.sourceglobalresearch.com/report/5071/the-challenger-audit-brand-impossible-or-inevitable>
- Srinidhi, B., & Vasarhelyi, M. (1986). Auditor judgment concerning establishment of substantive tests based on internal control reliability. Recuperado de: <http://raw.rutgers.edu/MiklosVasarhelyi/Resume%20Articles/MAJOR%20REFEREED%20ARTICLES/M12.%20auditor%20judgment.pdf>

- Sun, T. (2018a). Deep Learning Applications in Audit Decision Making. Rutgers Business. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/57390/PDF/1/play/>
- Sun, T. (2018b). The Incremental Informativeness of the Sentiment of Conference Calls for Internal Control Material Weaknesses. Recuperado de: <https://www.semanticscholar.org/paper/The-Incremental-Informativeness-of-the-Sentiment-of-Sun/62da372a76d6b8acbcf72139942d9fbf047c5d5f>
- Sykes, A.O. (1993). An Introduction to Regression Analysis University of Chicago Law School. Recuperado de: [https://chicagounbound.uchicago.edu/cgi/viewcontent.cgi?article=1050&context=law\\_and\\_economics](https://chicagounbound.uchicago.edu/cgi/viewcontent.cgi?article=1050&context=law_and_economics)
- Tang, V.W., 2017. Wisdom of Crowds: Cross-sectional Variation in the Informativeness of Third-Party-Generated Product Information on Twitter. Recuperado de: <https://onlinelibrary.wiley.com/doi/abs/10.1111/1475-679X.12183>
- Ting, Sun. (2018). DEEP LEARNING APPLICATIONS IN AUDIT DECISION MAKING. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/57390/PDF/1/play/>
- Twitter. (2019). Q1 2019 Earnings Report. Recuperado de: <https://investor.twitterinc.com/financial-information/quarterly-results/default.aspx>
- U.S. House of Representatives. (2002). The Sarbanes-Oxley Act of 2002. Public Law 107-204 [H. R. 3763]. Washington, D.C. Recuperado de: <https://www.govinfo.gov/content/pkg/PLAW-107publ204/pdf/PLAW-107publ204.pdf>
- University of Cambridge Judge Business School. Master of Accounting programme overview. Recuperado de: [https://www.jbs.cam.ac.uk/programmes/macc/programme-overview/#:~:text=The%20Master%20of%20Accounting%20is%20a%2024%2Dmonth%20programme%20delivered,Virtual%20Learning%20Environment%20\(VLE\).](https://www.jbs.cam.ac.uk/programmes/macc/programme-overview/#:~:text=The%20Master%20of%20Accounting%20is%20a%2024%2Dmonth%20programme%20delivered,Virtual%20Learning%20Environment%20(VLE).)
- World Economic Forum (2015): Deep Shift Technology Tipping Points and Societal Impact Survey Report. Recuperado de: [http://www3.weforum.org/docs/WEF\\_GAC15\\_Technological\\_Tipping\\_Points\\_report\\_2015.pdf](http://www3.weforum.org/docs/WEF_GAC15_Technological_Tipping_Points_report_2015.pdf)
- World Economic Forum. (2018). The Future of Jobs Report 2018. Recuperado de: [http://www3.weforum.org/docs/WEF\\_Future\\_of\\_Jobs\\_2018.pdf](http://www3.weforum.org/docs/WEF_Future_of_Jobs_2018.pdf)
- Y. Bengio, A. Courville and Goodfellow, I., (2016). Deep Learning. Recuperado de: [https://books.google.ie/books?hl=en&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=deep+learning&ots=MMU4epnHOQ&sig=Oy0bkwdqxekkcDtN412ij2Lf6I&redir\\_esc=y#v=onepage&q=deep%20learning&f=false](https://books.google.ie/books?hl=en&lr=&id=omivDQAAQBAJ&oi=fnd&pg=PR5&dq=deep+learning&ots=MMU4epnHOQ&sig=Oy0bkwdqxekkcDtN412ij2Lf6I&redir_esc=y#v=onepage&q=deep%20learning&f=false)
- Yoon, K. (2016). Auditing Revenue Account: Chapter 2 Initial Audit Fees and the Tone of Management Qualitative Disclosure, Dissertation: Three Essays On Unorthodox Audit Evidence. Rutgers Business School, Newark. Recuperado de: <https://rucore.libraries.rutgers.edu/rutgers-lib/50579/PDF/1/play/>

Anexos

Anexo 1 - (Marco del módulo de preguntas y respuestas), (Li, 2019)



(Anexo -2) - Tabla de Correlaciones Univariadas (Yoon, 2016)

**Table 2.4 Correlation among targeted variables and the dependent variables in audit feel models**

	Log-AuditF ee	OptimismI ok	OptimismS K	ROAearnin ges	Size	Invrec	NumSeg	Foreign	Merge	Special	Leverage	Loss	BTM	Growth	CurrentRat io	Big4	DF	GC
OptimismIok	-0.23																	
OptimismSK	-0.06	0.25																
ROAearnings	0.20	0.02	0.02															
Size	0.84	-0.16	0.01	0.32														
Invrec	-0.03	0.06	0.13	-0.11	-0.11													
NumSeg	0.40	-0.04	0.01	0.07	0.42	0.01												
Foreign	0.44	-0.09	0.08	0.08	0.40	0.13	0.23											
Merge	0.33	-0.10	-0.03	0.05	0.30	-0.08	0.17	0.18										
Special	0.25	-0.16	-0.13	0.01	0.15	0.00	0.08	0.18	0.35									
Leverage	-0.06	0.01	-0.02	-0.04	-0.16	-0.01	-0.04	-0.07	-0.03	0.01								
Loss	-0.30	-0.12	-0.23	-0.11	-0.45	-0.07	-0.26	-0.22	-0.14	0.08	0.09							
BTM	0.08	-0.09	-0.04	0.05	0.16	-0.09	0.03	0.05	0.01	-0.02	-0.06	-0.06						
Growth	-0.06	-0.02	-0.03	-0.01	-0.08	0.03	0.05	-0.05	-0.02	-0.04	-0.02	0.06	-0.01					
CurrentRatio	-0.06	0.07	0.03	0.07	0.05	-0.10	-0.05	0.01	-0.06	-0.11	-0.09	-0.13	0.07	0.01				
Big4	0.61	-0.15	-0.02	0.07	0.53	-0.04	0.21	0.31	0.25	0.21	-0.03	-0.22	0.01	0.04	0.01			
DF	0.21	-0.13	-0.01	0.03	0.18	-0.04	0.05	0.07	0.08	0.05	-0.01	-0.08	0.03	-0.02	0.02	0.19		
GC	-0.45	-0.01	-0.12	-0.19	-0.58	0.00	-0.21	-0.26	-0.16	0.04	0.16	0.41	-0.13	0.10	-0.21	-0.31	-0.05	
Resignation	-0.11	0.04	0.11	0.04	-0.10	0.09	-0.03	-0.09	-0.09	-0.11	0.00	-0.04	0.01	-0.02	-0.04	-0.24	-0.01	0.02

## (Anexo – 3) - Los resultados del modelo de regresión multivariante (Yoon, 2016)

		Model1		Model2		Model3	
		(1)		(2)		(3)	
	Pred	Est.	t-stat	Est.	t-stat	Est.	t-stat
<i>Optimism10k</i>	H(-)	-0.45	-2.60**			-0.38	-2.19**
<i>Optimism8k</i>	H(-)			-0.19	-6.66***	-0.17	-5.43***
<i>ROAearnings</i>	(-)	-0.00	-1.22	-0.00	-1.27	-0.00	-1.21
<i>Size</i>	(+)	0.37	21.28***	0.38	21.83***	0.37	21.27***
<i>Invrec</i>	(+)	0.28	1.67*	0.29	1.74*	0.28	1.71*
<i>NumSeg</i>	(+)	0.06	4.63***	0.06	5.15***	0.06	4.56***
<i>Foreign</i>	(+)	0.24	3.42***	0.25	3.79***	0.25	3.59***
<i>Merge</i>	(+)	0.08	0.93	0.08	1.04	0.08	0.98
<i>Special</i>	(+)	0.12	1.53	0.12	1.55	0.11	1.46
<i>Leverage</i>	(+)	0.06	1.09	0.06	1.16	0.06	1.13
<i>CurrentRatio</i>	(-)	-0.02	-2.10**	-0.02	-2.19**	-0.02	-2.24**
<i>Loss</i>	(+)	0.21	2.08**	0.21	2.15**	0.19	1.99**
<i>BTM</i>	(-)	-0.01	-4.26***	-0.01	-4.80***	-0.01	-4.66***
<i>Growth</i>	(-)	0.00	-1.45	0.00	-1.39	0.00	-1.53
<i>Big4</i>	(+)	0.53	16.05***	0.53	15.44***	0.53	15.06***
<i>Resignation</i>	(+)	0.06	0.86	0.08	1.10	0.07	1.00
<i>GC</i>	(+)	0.02	0.26	0.02	0.26	0.02	0.19
<i>IW</i>	(+)	0.22	1.27	0.25	1.31	0.22	1.25
Intercept		9.97	63.01***	10.04	67.34***	10.00	69.40***
Firm/ Year		Included		Included		Included	
R <sup>2</sup>		0.81		0.81		0.81	
# observation		696		696		696	

\*, \*\*, \*\*\*denote the significance levels of 0.1, 0.05, and 0.01 (two –tailed), respectively, using t statistics adjusted for firm and year clustering (Petersen 2009).

## (Anexo – 4) Análisis de correlación entre el grupo de control y el grupo con debilidades de control interno (Sun, 2018)

	Mean	Std.dev.	25%	Median	75%
<i>Sentiment:</i> MW group Control group	0.1544 0.1527	0.1110 0.1292	0.0787 0.0725	0.1617 0.1611	0.2292 0.2370
<i>Joy:</i> MW group Control group	0.1882 0.2254***	0.1854 0.2008	0.0654 0.0700	0.0838 0.0887	0.3027 0.4443
<i>Marketvalue:</i> MW group Control group	5.6820 6.3925***	1.5909 2.0056	4.7246 5.0263	5.7173 6.3254***	6.4711 7.6036
<i>Zscore:</i> MW group Control group	2.5524 3.3752	13.4819 11.6202	1.4528 1.4580	2.4460 2.9782***	4.0049 5.3032
<i>Segments:</i> MW group Control group	1.4099 1.3573	0.6707 0.7850	1.0986 0.6931	1.3863 1.3863	1.9459 1.9459
<i>Inventory:</i> MW group Control group	0.0971 0.0880	0.1242 0.1233	0.0015 0.0000	0.0567 0.0424	0.1409 0.1309
<i>Growth:</i> MW group Control group	0.5288 0.2676**	2.4284 1.5891	0.0046 0.0034	0.0884 0.0925	0.3344 0.2187
<i>Aggregate loss:</i> MW sample Control sample	0.1542 0.1651	0.3656 0.3809	0 0	0 0	0 0
<i>Foreign:</i> MW sample Control sample	0.9900 0.9872	0.1023 0.1176	1 1	1 1	1 1
<i>Restructure:</i> MW sample Control sample	0.3184 0.3404	0.4639 0.4757	0 0	0 0	1 1

(Anexo - 5) Regresión logística sobre la probabilidad de debilidades de control interno (Modelo con y sin característica de sentimiento) (Sun, 2018)

**Table 2.6 Logistic Regression of the Probability of ICMW**

	Predicted sign	Estimate coefficients of group A		Estimate coefficients of group B	
		Baseline model A (1)	Sentiment model A (2)	Baseline model B (3)	Sentiment model B (4)
Intercept	+/-	-1.6784**	-1.6211*	-2.1248*	-2.0097*
<i>Sentiment</i>	-		0.6243		0.2979
<i>Joy</i>	-		-1.3762***		-1.5264**
<i>Marketvalue</i>	-	-0.2551***	-0.2495***	-0.2591***	-0.2537***
<i>Aggregateloss</i>	+	-0.3105	-0.3137	-0.1360	-0.1379
<i>Zscore</i>	-	-0.0040	-0.0008	-0.0047	-0.0035
<i>Segments</i>	+	0.3424***	0.3547***	0.2512	0.2559
<i>Foreign</i>	+	0.3927	0.4047	0.5328	0.5575
<i>Inventory</i>	+	0.1535	0.1585	0.5008	0.5555
<i>Growth</i>	+			-0.0193	-0.0286
<i>Restructure</i>	+	-0.1366	-0.1330	-0.1187	-0.1420
<i>Acquisition</i>	+	0.0601	0.0935	0.2901	0.3429
<i>Resign</i>	+	2.2631***	2.2322***	2.3476***	2.3188***
<i>Big4</i>	-	-0.1079	-0.0984	-0.0007	0.0260
<i>Litigation</i>	+	0.1908	0.2211	0.2760	0.3119
Industry indicator variables		Included	Included	Included	Included
Number of total observations		1651	1651	1228	1228
Likelihood ratio, $\chi^2$ (p-value)		89.85 (0.0001)	98.17 (0.0001)	63.42 (0.0001)	70.44 (0.0001)
Pseudo $R^2$		0.0757	0.0827	0.0785	0.0872
Likelihood-ratio test: Likelihood		8.32** (0.0156)		7.02** (0.0300)	

(Anexo – 6) - Ilustración de diferentes industrias divididas por códigos SIC de 2 dígitos (Ding, Peng y Wang, 2019)

2012-2017

Descriptive Statistics - Financial Information - Firm-Quarter Observations from 2012-2017				
2-Digit SIC Code	Industry Name	Number of Firm-Quarter Observations	Revenue	Accounts Receivable
20	Food and Kindred Products	288	4120.78	1951.53
21	Tobacco Manufacturing	24	4616.67	161.38
23	Apparel and Other Textile Products	72	1361.76	527.65
28	Chemicals and Allied Products	144	4539.45	1592.93
29	Petroleum and Coal Products	48	29763.38	10859.92
30	Rubber/Misc. Plastic Products	24	7498.13	3441.46
31	Leather and Leather Products	48	939.78	303.24
35	Industrial and Commercial Machinery and Computer Equip	48	1680.86	975.20
36	Electrical Equipment and Components	96	17770.89	7541.23
37	Transportation Equipment	168	29908.22	36176.99
39	Misc. Manufacturing Industries	72	937.04	753.35
42	Motor Freight Transportation	24	14705.75	6303.17
44	Water Transportation	48	3034.01	423.68
45	Transportation By Air	192	6150.74	1521.82
47	Transportation Services	24	1669.62	1090.61
48	Communications	48	1052.82	398.55
53	General Merchandise Stores	24	28794.04	1269.33
55	Automobile Dealers & Gasoline Service Stations	48	2904.34	299.55
57	Home Furniture, Furnishings and Equipment Stores	48	5219.94	647.29
58	Eating & Drinking Places	360	1401.46	220.35
59	Miscellaneous Retail	72	22690.37	5330.04
70	Hotels, Rooming Houses, Camps and Other Lodging Places	48	2475.56	800.65
73	Business Services	120	8571.81	5371.53
75	Automotive Repair Services & Parking	24	772.17	401.16



(Anexo – 7) Dispersión de grupos de la clasificación de empresas de SIC y clustering (Ding, Peng y Wang, 2019)

## Ratio of composite variances SIC V.S. Clustering

Ratio of composite SIC (2-digit) variances to composite clustering variances									
Fiscal year	NPM	CFM	GPROF	CAPITAL RATIO	DEBT_BE	DEBT_CAP ITAL	RD_SALE	SALE_EQU ITY	SALE_INV CAP
1999	338.23	274.25	8.70	8.67	0.62	22.51	3555.49	0.11	5.42
2000	81.06	59.58	1.81	5.01	19.05	12.74	1.62	1.28	40.04
2001	0.28	0.36	0.68	1.09	4.59	1.70	0.00	1.81	0.39
2002	293.30	267.52	2.88	1.50	5.18	4.19	0.03	3.64	1.66
2003	0.76	0.76	1.79	2.38	3.67	5.92	0.46	5.14	3.95
2004	140.53	113.42	2.62	4.97	2.50	12.69	0.41	2.53	2.75
2005	15.43	6.67	6.72	5.25	0.78	5.99	1.69	16.68	58.29
2006	0.62	0.63	0.35	0.57	1.39	1.53	0.00	3.14	0.72
2007	0.68	0.38	2.30	2.25	6.66	1.65	0.02	6.89	2.38
2008	9.05	12.39	1.57	1.82	4.92	2.82	1.14	2.65	0.98
2009	1.30	1.26	0.18	0.95	3.74	1.01	2.93	3.11	0.28
2010	237.95	222.96	11.87	2.50	0.52	15.36	55.32	1.73	13.49
2011	0.00	0.00	2.64	1.19	1.06	1.24	1.14	5.75	3.38
2012	237.25	276.46	4.65	6.31	9.12	6.68	0.04	4.93	2.99
2013	791.97	875.54	8.19	4.76	34.39	32.02	51.51	16.43	23.30
2014	1.41	1.40	1.72	3.03	1.42	10.63	4.86	1.01	2.22
D>1 year #	12	11	13	12	12	14	8	13	12

(Anexo – 8) El promedio de Tweets de interés del consumidor, positivo y negativo para las 24 industrias que componen la muestra (Rozario, 2019)

Descriptive Statistics - Twitter Information - Firm-Quarter Observations from 2012-2017

2-Digit SIC Code	Industry Name	Number of Firm- Quarter Observations	Tweet Consumer Interest	Tweet Positive Sentiment	Tweet Negative Sentiment
20	Food and Kindred Products	288	844.53	795.42	305.39
21	Tobacco Manufacturing	24	7.48	22.87	13.17
23	Apparel and Other Textile Products	72	53.35	87.38	33.57
28	Chemicals and Allied Products	144	85.12	214.77	89.52
29	Petroleum and Coal Products	48	3.63	13.27	7.10
30	Rubber/Misc. Plastic Products	24	773.07	1715.88	789.19
31	Leather and Leather Products	48	35.61	68.98	20.25
35	Industrial and Commercial Machinery and Computer Equip	48	34.53	72.03	18.30
36	Electrical Equipment and Components	96	2677.05	3580.18	2293.22
37	Transportation Equipment	168	113.05	368.76	170.54
39	Misc. Manufacturing Industries	72	168.91	435.87	162.30
42	Motor Freight Transportation	24	52.68	119.44	117.17
44	Water Transportation	48	8.37	44.97	8.36
45	Transportation By Air	192	86.84	150.66	155.65
47	Transportation Services	24	43.35	770.62	40.76
48	Communications	48	63.39	92.70	28.99
53	General Merchandise Stores	24	238.85	284.32	111.43
55	Automobile Dealers & Gasoline Service Stations	48	2.96	7.49	3.71
57	Home Furniture, Furnishings and Equipment Stores	48	288.42	303.17	43.65
58	Eating & Drinking Places	360	851.55	1020.33	473.72
59	Miscellaneous Retail	72	95.58	97.85	52.81
70	Hotels, Rooming Houses, Camps and Other Lodging Places	48	62.60	138.94	22.49
73	Business Services	120	4600.11	5333.26	2265.66
75	Automotive Repair Services & Parking	24	22.08	19.48	21.92

(Anexo – 9) Presenta los resultados de los modelos analíticos tradicionales con TCI, modelos 5, 7, 9 y 11 frente a los modelos de referencia tradicionales 1, 2, 3 y 4. (Rozario, 2019)

**Table 4: Prediction Performance of Traditional Substantive Analytical Models with TCI and without TCI (Models 5, 7, 9 and 11 and 1, 2, 3, and 4)**

		(1) (5)				(2) (7)				(3) (9)				(4) (11)			
		Sales-12		Salest-12+Twee	tCI	Sales-12+GDPt-12+Twee		Salest-tCI+GDP	Sales-12+AR		Salest-12+AR+Twee	tCI	Sales-12+AR+GDPt-12		Salest12+AR+Twee	tCI+GD	
2-Digit	SIC	MAPE1	MAPE5	Difference B/W	p-value	MAPE2	MAPE7	Difference B/W	p-value	MAPE3	MAPE9	Difference B/W	p-value	MAPE4	MAPE11	Difference B/W	p-value
	20	0.0827	0.0729	0.0099 B	0.000	0.061	0.056	0.005 B	0.000	0.0531	0.0485	0.0046 B	0.001	0.044	0.041	0.003 B	0.000
	21	0.0247	0.0211	0.0037 B	0.001	0.025	0.020	0.005 B	0.001	0.0203	0.0187	0.0016 B	0.001	0.020	0.019	0.001 B	0.001
	23	0.0877	0.0703	0.0174 B	0.000	0.059	0.057	0.002 B	0.000	0.0664	0.0536	0.0129 B	0.000	0.044	0.045	-0.001 W	0.077
	28	0.0450	0.0468	-0.0018 W	0.098	0.036	0.035	0.002 B	0.005	0.0311	0.0318	-0.0007 W	0.014	0.030	0.031	0.000 W	0.224
	29	0.1176	0.1307	-0.0131 W	0.034	0.161	0.129	0.033 B	0.000	0.0776	0.0794	-0.0019 W	0.034	0.074	0.080	-0.006 W	0.034
	30	0.0225	0.0224	0.0000 NoDiff	0.001	0.021	0.021	0.001 B	0.001	0.0234	0.0235	-0.0001 W	0.001	0.022	0.022	0.001 B	0.001
	31	0.0903	0.0968	-0.0065 W	0.000	0.081	0.084	-0.002 W	0.000	0.0838	0.0853	-0.0015 W	0.000	0.063	0.065	-0.002 W	0.034
	35	0.0962	0.0593	0.0369 B	0.000	0.051	0.051	0.000 NoDiff	0.034	0.0721	0.0465	0.0256 B	0.034	0.044	0.044	0.000 B	0.034
	36	0.0635	0.0584	0.0051 B	0.003	0.045	0.042	0.003 B	0.137	0.0318	0.0281	0.0038 B	0.003	0.042	0.041	0.001 B	0.420
	37	0.1201	0.1033	0.0168 B	0.000	0.088	0.082	0.005 B	0.000	0.0873	0.0801	0.0072 B	0.015	0.072	0.071	0.001 B	0.005
	39	0.0912	0.0686	0.0226 B	0.000	0.073	0.072	0.001 B	0.077	0.0946	0.0697	0.0249 B	0.000	0.073	0.075	-0.002 W	0.000
	42	0.0278	0.0234	0.0044 B	0.001	0.020	0.020	0.001 B	0.001	0.0243	0.0212	0.0031 B	0.001	0.022	0.021	0.002 B	0.001
	44	0.0318	0.0242	0.0075 B	0.034	0.019	0.018	0.000 B	0.000	0.0219	0.0217	0.0002 B	0.034	0.019	0.019	0.000 NoDiff	0.034
	45	0.0574	0.0559	0.0014 B	0.114	0.054	0.053	0.001 B	0.062	0.0480	0.0450	0.0030 B	0.000	0.048	0.045	0.003 B	0.000
	47	0.0381	0.0392	-0.0011 W	0.001	0.040	0.041	-0.001 W	0.001	0.0441	0.0405	0.0036 B	0.001	0.038	0.039	0.000 W	0.001
	48	0.0254	0.0243	0.0010 B	0.000	0.020	0.020	-0.001 W	0.034	0.0200	0.0203	-0.0002 W	0.034	0.020	0.020	0.000 W	0.034
	53	0.0393	0.0407	-0.0014 W	0.001	0.041	0.042	-0.001 W	0.001	0.0384	0.0434	-0.0050 W	0.001	0.044	0.042	0.002 B	0.001
	55	0.0343	0.0277	0.0067 B	0.034	0.028	0.030	-0.002 W	0.000	0.0556	0.0402	0.0154 B	0.034	0.039	0.039	0.000 W	0.034
	57	0.0802	0.0800	0.0002 B	0.034	0.068	0.068	0.000 W	0.034	0.0808	0.0814	-0.0005 W	0.034	0.070	0.070	0.000 B	0.034
	58	0.0533	0.0502	0.0031 B	0.009	0.041	0.040	0.001 B	0.000	0.0457	0.0453	0.0004 B	0.000	0.039	0.038	0.001 B	0.000
	59	0.0867	0.0860	0.0008 B	0.000	0.072	0.071	0.001 B	0.000	0.0659	0.0658	0.0001 B	0.077	0.065	0.064	0.001 B	0.000
	70	0.1159	0.1058	0.0101 B	0.034	0.070	0.065	0.005 B	0.034	0.0488	0.0466	0.0021 B	0.034	0.047	0.045	0.001 B	0.034
	73	0.0387	0.0376	0.0011 B	0.054	0.032	0.029	0.003 B	0.000	0.0407	0.0394	0.0013 B	0.003	0.034	0.029	0.005 B	0.000
	75	0.0153	0.0153	0.0000 NoDiff	0.001	0.014	0.014	0.000 B	0.001	0.0131	0.0130	0.0000 NoDiff	0.001	0.011	0.010	0.001 B	0.001

(Anexo – 10) Comparando los modelos de satisfacción del consumidor de Twitter (6, 8, 10, 12) con el punto de referencia original (Rozario, 2019)

**Table 5: Prediction Performance of Traditional Substantive Analytical Models with TCS and without TCS (Models 6, 8, 10 and 12 and 1, 2, 3, and 4)**

		(1) (6)				(2) (8)				(3) (10)				(4) (12)			
		Sales-12		Salest-12+Twee	tCS	Sales-12+GDPt-12+Twee		Salest-tCS+GD	Sales-12+AR		Salest-12+AR+Twee	tCS	Sales-12+AR+GDPt-12		Salest12+AR+Twee	tCS	
2-Digit	SIC	MAPE1	MAPE6	Difference B/W	p-value	MAPE2	MAPE8	Difference B/W	p-value	MAPE3	MAPE10	Difference B/W	p-value	MAPE4	MAPE12	Difference B/W	p-value
	20	0.0827	0.0760	0.0067 B	0.000	0.0613	0.0575	0.0038 B	0.000	0.0531	0.0490	0.0042 B	0.000	0.0442	0.0427	0.0015 B	0.000
	21	0.0247	0.0237	0.0011 B	0.001	0.0252	0.0241	0.0011 B	0.001	0.0203	0.0190	0.0013 B	0.001	0.0204	0.0199	0.0005 B	0.001
	23	0.0877	0.0765	0.0111 B	0.000	0.0587	0.0574	0.0013 B	0.000	0.0664	0.0537	0.0127 B	0.000	0.0441	0.0435	0.0006 B	0.000
	28	0.0450	0.0422	0.0028 B	0.014	0.0363	0.0339	0.0023 B	0.000	0.0311	0.0321	-0.0011 W	0.437	0.0302	0.0296	0.0006 B	0.000
	29	0.1176	0.1184	-0.0008 W	0.034	0.1613	0.1622	-0.0009 W	0.000	0.0776	0.0789	-0.0013 W	0.000	0.0738	0.0741	-0.0003 W	0.000
	30	0.0225	0.0224	0.0000 NoDiff	0.001	0.0214	0.0215	0.0000 NoDiff	0.001	0.0234	0.0234	0.0000 NoDiff	0.001	0.0224	0.0224	0.0000 NoDiff	0.001
	31	0.0903	0.0913	-0.0010 W	0.034	0.0813	0.0809	0.0004 B	0.034	0.0838	0.0841	-0.0004 W	0.034	0.0630	0.0640	-0.0011 W	0.034
	35	0.0962	0.0942	0.0020 B	0.034	0.0512	0.0483	0.0029 B	0.034	0.0721	0.0694	0.0027 B	0.000	0.0442	0.0436	0.0006 B	0.034
	36	0.0635	0.0480	0.0155 B	0.000	0.0449	0.0518	-0.0068 W	0.000	0.0318	0.0441	-0.0122 W	0.022	0.0422	0.0454	-0.0032 W	0.022
	37	0.1201	0.1075	0.0126 B	0.000	0.0877	0.0844	0.0033 B	0.883	0.0873	0.0800	0.0073 B	0.000	0.0721	0.0674	0.0047 B	0.000
	39	0.0912	0.0778	0.0134 B	0.000	0.0729	0.0621	0.0108 B	0.000	0.0946	0.0805	0.0141 B	0.000	0.0734	0.0620	0.0114 B	0.000
	42	0.0278	0.0269	0.0008 B	0.001	0.0202	0.0160	0.0041 B	0.001	0.0243	0.0248	-0.0005 W	0.001	0.0224	0.0206	0.0018 B	0.001
	44	0.0318	0.0299	0.0019 B	0.034	0.0186	0.0192	-0.0006 W	0.000	0.0219	0.0225	-0.0006 W	0.000	0.0187	0.0196	-0.0009 W	0.000
	45	0.0574	0.0537	0.0036 B	0.017	0.0542	0.0511	0.0031 B	0.000	0.0480	0.0478	0.0002 B	0.000	0.0477	0.0466	0.0011 B	0.001
	47	0.0381	0.0398	-0.0017 W	0.001	0.0405	0.0456	-0.0051 W	0.001	0.0441	0.0423	0.0018 B	0.001	0.0382	0.0453	-0.0071 W	0.001
	48	0.0254	0.0351	-0.0097 W	0.034	0.0196	0.0242	-0.0046 W	0.034	0.0200	0.0250	-0.0050 W	0.000	0.0199	0.0243	-0.0043 W	0.000
	53	0.0393	0.0408	-0.0015 W	0.001	0.0411	0.0406	0.0005 B	0.001	0.0384	0.0400	-0.0016 W	0.001	0.0439	0.0413	0.0027 B	0.001
	55	0.0343	0.0356	-0.0013 W	0.000	0.0282	0.0301	-0.0019 W	0.000	0.0556	0.0495	0.0061 B	0.034	0.0392	0.0351	0.0040 B	0.034
	57	0.0802	0.0719	0.0083 B	0.000	0.0683	0.0588	0.0095 B	0.034	0.0808	0.0735	0.0073 B	0.000	0.0697	0.0580	0.0117 B	0.034
	58	0.0533	0.0503	0.0030 B	0.000	0.0406	0.0400	0.0006 B	0.326	0.0457	0.0430	0.0027 B	0.000	0.0392	0.0384	0.0008 B	0.027
	59	0.0867	0.0979	-0.0111 W	0.000	0.0718	0.0671	0.0047 B	0.000	0.0659	0.0662	-0.0002 W	0.599	0.0646	0.0638	0.0008 B	0.077
	70	0.1159	0.0598	0.0561 B	0.000	0.0703	0.0576	0.0127 B	0.000	0.0488	0.0460	0.0028 B	0.000	0.0469	0.0456	0.0013 B	0.000
	73	0.0387	0.0347	0.0040 B	0.000	0.0322	0.0312	0.0010 B	0.000	0.0407	0.0355	0.0052 B	0.000	0.0339	0.0333	0.0006 B	0.437
	75	0.0153	0.0168	-0.0015 W	0.001	0.0142	0.0163	-0.0021 W	0.001	0.0131	0.0154	-0.0023 W	0.001	0.0112	0.0144	-0.0032 W	0.001

(Anexo – 11) Predicción realización de procedimientos sustantivos continuos con y sin interés del consumidor de twitter (Rozario, 2019)

Table 7: Prediction Performance of Continuous Substantive Analytical Models with TCI and without TCI (Models 5, 7, 9 and 11 and 1, 2, 3, and 4)

2-Digit	(1)				(2)				(3)				(4)				(11)			
	SIC	MAPE1	MAPE5	Difference B/W	p-value	MAPE2	MAPE7	Difference B/W	p-value	MAPE3	MAPE9	Difference B/W	p-value	MAPE4	MAPE11	Difference B/W	p-value			
20	0.1015	0.0921	0.0094 B	0.000	0.0855	0.0545	0.0310 B	0.000	0.083	0.078	0.005 B	0.000	0.079	0.040	0.039 B	0.000				
21	0.0577	0.0565	0.0012 B	0.001	0.0492	0.0199	0.0292 B	0.001	0.058	0.056	0.001 B	0.001	0.047	0.019	0.028 B	0.001				
23	0.1439	0.1370	0.0069 B	0.000	0.1271	0.0576	0.0695 B	0.000	0.101	0.086	0.015 B	0.000	0.091	0.045	0.046 B	0.000				
28	0.0735	0.0733	0.0001 B	0.224	0.0547	0.0346	0.0200 B	0.000	0.045	0.046	-0.001 W	0.000	0.043	0.046	0.030	0.016 B				
29	0.0578	0.0573	0.0005 B	0.034	0.0825	0.1403	-0.0578 W	0.000	0.055	0.058	-0.003 W	0.000	0.055	0.079	-0.024 W	0.000				
30	0.0498	0.0508	-0.0010 W	0.001	0.0349	0.0211	0.0137 B	0.001	0.037	0.037	0.000 B	0.001	0.035	0.022	0.013 B	0.001				
31	0.1686	0.1681	0.0005 B	0.034	0.1411	0.0816	0.0595 B	0.000	0.128	0.124	0.003 B	0.000	0.107	0.064	0.042 B	0.000				
35	0.1193	0.1105	0.0088 B	0.000	0.1057	0.0493	0.0564 B	0.000	0.070	0.072	-0.002 W	0.000	0.066	0.043	0.022 B	0.000				
36	0.1020	0.0955	0.0064 B	0.000	0.1090	0.0385	0.0705 B	0.000	0.095	0.094	0.002 B	0.000	0.137	0.104	0.039	0.065 B				
37	0.1122	0.1121	0.0001 B	0.254	0.0879	0.0808	0.0071 B	0.137	0.106	0.105	0.001 B	0.000	0.841	0.080	0.071	0.009 B				
39	0.3305	0.3007	0.0298 B	0.000	0.3411	0.0723	0.2688 B	0.000	0.213	0.209	0.004 B	0.000	0.077	0.180	0.075	0.105 B				
42	0.0754	0.0415	0.0339 B	0.001	0.0560	0.0182	0.0378 B	0.001	0.060	0.044	0.016 B	0.001	0.053	0.020	0.033 B	0.001				
44	0.1499	0.1396	0.0103 B	0.034	0.1525	0.0184	0.1341 B	0.000	0.155	0.144	0.011 B	0.000	0.152	0.018	0.134 B	0.000				
45	0.0745	0.0647	0.0098 B	0.000	0.0646	0.0540	0.0106 B	0.000	0.070	0.062	0.008 B	0.000	0.062	0.045	0.016 B	0.000				
47	0.1753	0.1294	0.0459 B	0.001	0.1318	0.0404	0.0914 B	0.001	0.128	0.126	0.002 B	0.001	0.125	0.040	0.084 B	0.001				
48	0.0305	0.0288	0.0018 B	0.000	0.0301	0.0200	0.0101 B	0.000	0.030	0.029	0.002 B	0.000	0.030	0.020	0.010 B	0.000				
53	0.1947	0.1184	0.0764 B	0.001	0.1801	0.0418	0.1383 B	0.001	0.190	0.125	0.065 B	0.001	0.181	0.043	0.138 B	0.001				
55	0.1088	0.0978	0.0110 B	0.034	0.1212	0.0336	0.0875 B	0.000	0.093	0.076	0.017 B	0.000	0.069	0.041	0.028 B	0.000				
57	0.1206	0.1042	0.0163 B	0.034	0.0986	0.0673	0.0313 B	0.034	0.102	0.103	-0.001 W	0.034	0.106	0.068	0.038 B	0.034				
58	0.0687	0.0669	0.0017 B	0.000	0.0555	0.0416	0.0139 B	0.000	0.063	0.058	0.005 B	0.000	0.055	0.039	0.016 B	0.000				
59	0.2546	0.2515	0.0031 B	0.000	0.2451	0.0740	0.1710 B	0.077	0.253	0.251	0.002 B	0.000	0.243	0.063	0.180 B	0.000				
70	0.0530	0.0543	-0.0013 W	0.000	0.0498	0.0639	-0.0141 W	0.034	0.053	0.052	0.001 B	0.034	0.049	0.045	0.004 B	0.034				
73	0.0849	0.0800	0.0049 B	0.437	0.0732	0.0300	0.0431 B	0.000	0.076	0.075	0.001 B	0.003	0.071	0.031	0.040 B	0.000				
75	0.1525	0.0922	0.0602 B	0.001	0.1469	0.0143	0.1326 B	0.001	0.090	0.075	0.015 B	0.001	0.092	0.011	0.081 B	0.001				

(Anexo – 12) Predicción realización de procedimientos sustantivos continuos con y sin sentimiento del consumidor de twitter (Rozario, 2019)

Table 8: Prediction Performance of Continuous Substantive Analytical Models with TCS and without TCS (Models 6, 8, 10 and 12 and 1, 2, 3, and 4)

2-Digit	(1)				(2)				(3)				(4)				(12)			
	SIC	MAPE1	MAPE6	Difference B/W	p-value	MAPE2	MAPE8	Difference B/W	p-value	MAPE3	MAPE10	Difference B/W	p-value	MAPE4	MAPE12	Difference B/W	p-value			
20	0.1015	0.0883	0.0132 B	0.000	0.0855	0.0576	0.0280 B	0.000	0.0828	0.0797	0.0031 B	0.000	0.0792	0.0421	0.0372 B	0.000				
21	0.0577	0.0591	-0.0014 W	0.001	0.0492	0.0242	0.0249 B	0.001	0.0576	0.0584	-0.0008 W	0.001	0.0472	0.0201	0.0271 B	0.001				
23	0.1439	0.1364	0.0075 B	0.000	0.1271	0.0577	0.0694 B	0.000	0.1013	0.0977	0.0036 B	0.000	0.0908	0.0435	0.0473 B	0.000				
28	0.0735	0.0706	0.0028 B	0.224	0.0547	0.0336	0.0211 B	0.000	0.0455	0.0453	0.0001 B	0.000	0.398	0.0459	0.0291	0.0168 B				
29	0.0578	0.0463	0.0116 B	0.000	0.0825	0.1715	-0.0889 W	0.000	0.0551	0.0558	-0.0006 W	0.000	0.0553	0.0730	-0.0178 W	0.000				
30	0.0498	0.0449	0.0049 B	0.001	0.0349	0.0216	0.0132 B	0.001	0.0372	0.0370	0.0002 B	0.001	0.0351	0.0222	0.0129 B	0.001				
31	0.1686	0.1559	0.0127 B	0.000	0.1411	0.0842	0.0570 B	0.000	0.1276	0.1245	0.0031 B	0.000	0.1067	0.0627	0.0440 B	0.000				
35	0.1193	0.1218	-0.0025 W	0.000	0.1057	0.0465	0.0592 B	0.000	0.0695	0.0731	-0.0036 W	0.000	0.0655	0.0425	0.0230 B	0.000				
36	0.1020	0.1180	-0.0161 W	0.003	0.1090	0.0471	0.0619 B	0.022	0.0954	0.1081	-0.0126 W	0.000	0.1036	0.0443	0.0592 B	0.000				
37	0.1122	0.1430	-0.0308 W	0.254	0.0879	0.0819	0.0060 B	0.398	0.1058	0.0972	0.0086 B	0.000	0.0798	0.0672	0.0126 B	0.883				
39	0.3305	0.3384	-0.0080 W	0.000	0.3411	0.0625	0.2786 B	0.000	0.2132	0.2157	-0.0025 W	0.077	0.1797	0.0621	0.1176 B	0.000				
42	0.0754	0.0637	0.0117 B	0.001	0.0560	0.0144	0.0415 B	0.001	0.0605	0.0522	0.0083 B	0.001	0.0532	0.0189	0.0343 B	0.001				
44	0.1499	0.1486	0.0013 B	0.034	0.1525	0.0192	0.1332 B	0.000	0.1548	0.1517	0.0030 B	0.000	0.1523	0.0195	0.1328 B	0.000				
45	0.0745	0.0642	0.0103 B	0.000	0.0646	0.0528	0.0118 B	0.000	0.0697	0.0627	0.0070 B	0.000	0.0616	0.0466	0.0149 B	0.000				
47	0.1753	0.1597	0.0156 B	0.001	0.1318	0.0439	0.0879 B	0.001	0.1278	0.1323	-0.0045 W	0.001	0.1249	0.0436	0.0813 B	0.001				
48	0.0305	0.0337	-0.0032 W	0.000	0.0301	0.0236	0.0065 B	0.000	0.0304	0.0306	-0.0002 W	0.000	0.0299	0.0237	0.0062 B	0.000				
53	0.1947	0.1740	0.0207 B	0.001	0.1801	0.0402	0.1399 B	0.001	0.1899	0.1523	0.0375 B	0.001	0.1810	0.0399	0.1411 B	0.001				
55	0.1088	0.1019	0.0070 B	0.000	0.1212	0.0333	0.0879 B	0.000	0.0931	0.0844	0.0087 B	0.000	0.0692	0.0375	0.0317 B	0.000				
57	0.1206	0.1025	0.0181 B	0.034	0.0986	0.0612	0.0374 B	0.034	0.1020	0.0988	0.0031 B	0.000	0.1063	0.0605	0.0458 B	0.034				
58	0.0687	0.0587	0.0100 B	0.000	0.0555	0.0410	0.0145 B	0.000	0.0626	0.0565	0.0062 B	0.000	0.0550	0.0395	0.0155 B	0.000				
59	0.2546	0.2558	-0.0012 W	0.077	0.2451	0.0691	0.1760 B	0.599	0.2532	0.2543	-0.0011 W	0.077	0.2430	0.0627	0.1803 B	0.000				
70	0.0530	0.0657	-0.0127 W	0.000	0.0498	0.0565	-0.0067 W	0.034	0.0532	0.0530	0.0003 B	0.034	0.0491	0.0455	0.0036 B	0.034				
73	0.0849	0.0822	0.0027 B	0.065	0.0732	0.0305	0.0427 B	0.000	0.0762	0.0755	0.0007 B	0.000	0.0714	0.0328	0.0387 B	0.000				
75	0.1525	0.1528	-0.0004 W	0.001	0.1469	0.0163	0.1306 B	0.001	0.0901	0.1006	-0.0105 W	0.001	0.0919	0.0146	0.0773 B	0.001				

(Anexo – 13) Imagen del software integrado con algoritmos de aprendizaje automático para calcular el número de animales (Cristo, et.al, 2019)



(Anexo-14) Comparación de las predicciones del modelo de aprendizaje automático con las estimaciones de la dirección utilizando el error absoluto medio y el error absoluto medio raíz (Ding, Peng, Lev, Sun y Vasarhelyi 2019)

Business line	Training/Validation Sample	Obs	Managers' estimates		Machine learning without manager estimates				Machine learning with manager estimates			
			MAE	RMSE	MAE	RMSE	Accuracy edge (MAE)	Accuracy edge (RMSE)	MAE	RMSE	Accuracy edge (MAE)	Accuracy edge (RMSE)
Private Passenger Auto Liability	1996-2005	5,949	9,461	37,494	8,213	34,687	13%	7%	7,758	36,071	18%	4%
	1996-2006	6,298	9,793	38,266	7,848	34,547	20%	10%	7,220	30,305	26%	21%
	1996-2007	6,602	9,575	37,940	7,869	35,047	18%	8%	6,902	30,220	28%	20%
Commercial Auto Liability	1996-2005	5,383	4,209	18,562	3,565	14,051	15%	24%	3,446	13,555	18%	27%
	1996-2006	5,661	4,155	18,375	3,520	13,881	15%	24%	3,266	13,583	21%	26%
	1996-2007	5,957	4,338	19,175	3,575	13,671	18%	29%	3,322	13,121	23%	32%
Workers' Compensation	1996-2005	4,183	11,547	43,652	7,518	29,418	35%	33%	7,144	28,629	38%	34%
	1996-2006	4,398	12,360	44,187	7,434	29,387	40%	33%	6,988	26,888	43%	39%
	1996-2007	4,645	13,214	47,541	7,298	29,468	45%	38%	6,861	26,574	48%	44%
Commercial Multi-Peril	1996-2005	5,235	5,737	27,615	5,103	22,060	11%	20%	4,854	22,062	15%	20%
	1996-2006	5,457	5,871	27,931	5,151	23,404	12%	16%	4,968	22,308	15%	20%
	1996-2007	5,846	6,017	28,349	4,963	22,556	18%	20%	4,534	21,265	25%	25%
Homeowner/Farmowner	1996-2005	6,121	3,905	16,789	5,674	22,069	-4%	-31%	4,402	16,359	-13%	3%
	1996-2006	6,544	3,878	16,611	5,687	21,070	-4%	-27%	4,203	16,201	-8%	2%
	1996-2007	6,946	3,962	16,826	5,548	21,269	-4%	-26%	4,321	16,674	-9%	1%