

Knowledge Management and Scientific Productivity in Engineering Doctoral Education: A Predictive and Non-Linear Analysis

María del Carmen Ancaya Martínez, Dra.¹ , Ricardo Conde Aldude, Dr.¹ , Leopoldo Choque Flores, Dr.¹ 

¹Universidad Cesar Vallejo, Perú, mancayam@ucvvirtual.edu.pe, rcondeal8@ucvvirtual.edu.pe, lchoquef@ucvvirtual.edu.pe,

Abstract– *Scientific productivity during doctoral education in engineering has become a key indicator of academic quality and institutional positioning; however, its development faces limitations associated with individual, institutional, and technological factors. In this context, the objective of this study was to evaluate knowledge management as a methodology for strengthening scientific productivity among engineering doctoral students, considering human, structural, and relational capitals, as well as technological skills. The research adopted a mixed-methods approach, with a longitudinal, descriptive, correlational, and predictive design, covering the period from 2018 to 2024. The population consisted of 188 doctoral students, complemented by 773 valid survey records. The analysis included descriptive statistics, Spearman's rho correlation, and machine learning models such as random forest, multilayer perceptron, and metaheuristic additive regression. The results reveal positive and statistically significant associations between knowledge management capitals and scientific productivity, with human capital and technological skills showing the strongest relationships. Moreover, non-linear predictive models demonstrated superior performance, suggesting that the relationship between knowledge management and scientific publication is complex and non-additive. It is concluded that knowledge management constitutes an operational and predictive methodology for strengthening doctoral scientific productivity in engineering education.*

Keywords– Knowledge Management, Scientific Productivity, Doctoral Education, Engineering Education, Machine Learning, Non-Linear Analysis.

I. INTRODUCCIÓN

La formación doctoral en ingeniería constituye un componente estratégico para la generación de conocimiento avanzado, la innovación tecnológica y el desarrollo sostenible en las sociedades basadas en el conocimiento. En este contexto de las sociedades basadas en el conocimiento y de la evaluación de la investigación, la productividad científica ha sido tradicionalmente operacionalizada mediante indicadores bibliométricos, tales como el número de publicaciones indexadas y las métricas de citación, debido a su capacidad para reflejar visibilidad, impacto y contribución al conocimiento científico. Estos indicadores han sido ampliamente utilizados en sistemas de evaluación académica y políticas científicas, a pesar de sus limitaciones, por su consistencia y comparabilidad entre contextos institucionales y disciplinares [1], el índice h se ha consolidado como un

indicador clave de la calidad académica, el prestigio institucional y el posicionamiento internacional de los programas de posgrado [2], [3], [4]. En disciplinas STEM, las agencias de aseguramiento de la calidad y los sistemas de evaluación científica enfatizan de manera creciente la necesidad de evidenciar resultados de investigación durante la etapa doctoral.

En las sociedades contemporáneas, caracterizadas por la centralidad del conocimiento como recurso estratégico, la producción científica cumple una función clave en los procesos de innovación, competitividad y desarrollo económico. Desde la perspectiva de la economía del conocimiento, la generación, difusión y apropiación del conocimiento científico constituyen elementos fundamentales de los sistemas nacionales de ciencia, tecnología e innovación, lo que ha intensificado la relevancia de la productividad científica como criterio de evaluación del desempeño académico e institucional [5].

En el campo de la ingeniería, la formación doctoral adquiere un rol particularmente relevante al constituirse en un eslabón clave entre la generación de conocimiento científico, la innovación tecnológica y el desarrollo socioeconómico. Desde el enfoque de la Triple Hélice, la universidad no solo cumple una función formativa, sino que actúa como un actor central del sistema de innovación, articulando la producción científica con las demandas del Estado y del sector productivo [6]. En este marco, la productividad científica doctoral se convierte en un indicador crítico de la capacidad institucional para generar conocimiento con potencial impacto social y tecnológico.

Desde una perspectiva sociológica de la ciencia, la publicación científica no constituye únicamente un producto académico, sino un mecanismo central de validación, reconocimiento y legitimación del conocimiento dentro de la comunidad científica. En este marco, la producción científica no puede entenderse como el resultado exclusivo del esfuerzo individual del investigador, sino como un proceso dinámico de construcción colectiva, regulado por normas institucionales y sustentado en la interacción entre redes académicas, artefactos tecnológicos, instituciones y mecanismos de evaluación que condicionan qué conocimientos logran consolidarse como ciencia reconocida, especialmente durante la formación doctoral [5], [7].

La literatura especializada coincide en que los doctorandos que publican durante su formación presentan mayores niveles de visibilidad académica, integración en redes científicas y mejores trayectorias investigadoras posteriores [2], [8]. Sin embargo, esta exigencia ha puesto en evidencia limitaciones estructurales y formativas que afectan la capacidad de los estudiantes para desarrollar publicaciones científicas de calidad, particularmente en contextos latinoamericanos y en sistemas científicos en consolidación [9], [10].

Diversos estudios han identificado que una de las principales dificultades en la formación doctoral no radica únicamente en el dominio disciplinar, sino en la gestión estratégica del proceso de publicación científica. Estas dificultades se sintetizan en la literatura como las '3W' del proceso de publicación científica (what to publish, when to publish and where to publish), las cuales se asocian con bajas tasas de publicación y limitado impacto científico [11], [12]. A ello se suman debilidades relacionadas con el acompañamiento metodológico, el desarrollo de competencias investigativas, el uso de tecnologías para la investigación y la articulación entre los recursos institucionales y las capacidades individuales del doctorando [13], [14].

Desde una perspectiva organizacional y educativa, la gestión del conocimiento se presenta como un enfoque integral para abordar estas limitaciones. Desde la literatura clásica, la gestión del conocimiento se define como el conjunto de procesos orientados a identificar, crear, organizar, compartir y aplicar el conocimiento de manera sistemática dentro de las organizaciones, incluidas las instituciones de educación superior [15], [16]. En el ámbito universitario, este enfoque se operacionaliza a través del capital intelectual, conformado por el capital humano, el capital estructural y el capital relacional, dimensiones que interactúan de manera dinámica en los procesos de generación y difusión del conocimiento científico [17].

Desde el enfoque del capital intelectual aplicado a la gestión del conocimiento en contextos universitarios, el capital humano comprende las competencias investigativas, las habilidades metodológicas, la experiencia académica, las capacidades de comunicación científica y la motivación investigadora del doctorando. El capital estructural se refiere a los procesos institucionales, las normativas, los sistemas de información para la investigación, el soporte tecnológico y la infraestructura académica que facilitan o limitan la producción científica. Por su parte, el capital relacional involucra las redes académicas, la colaboración científica y la interacción con supervisores, editores y comunidades de investigación. A estas dimensiones se suma, de manera transversal, el desarrollo de destrezas tecnológicas, entendidas como la capacidad de utilizar herramientas digitales para la búsqueda, el análisis, la gestión y la difusión del conocimiento científico [13], [17].

Asimismo, la gestión del conocimiento y el capital intelectual constituyen campos de investigación consolidados dentro de la literatura científica internacional, con una producción sostenida y revistas especializadas de alto impacto.

Estudios bibliométricos y de clasificación de revistas han evidenciado la madurez teórica y metodológica del área, así como su relevancia en contextos organizacionales y educativos, lo que respalda su utilización como marco analítico en investigaciones sobre productividad científica y formación doctoral [18].

Estudios previos han señalado que la aplicación de la gestión del conocimiento en contextos universitarios contribuye a mejorar la productividad investigativa, fortalecer la colaboración científica y optimizar los procesos de generación de conocimiento [13], [16]. No obstante, la mayoría de los estudios se ha centrado en análisis descriptivos o correlacionales, sin profundizar en la complejidad de las interacciones entre los distintos capitales ni en su capacidad para explicar diferencias en los resultados de publicación científica durante la formación doctoral, especialmente en programas de ingeniería.

En el contexto peruano, estas limitaciones adquieren especial relevancia. Investigaciones previas han señalado que la producción científica universitaria presenta niveles relativamente bajos en comparación con otros países de la región, y que los sistemas de gestión de la información de investigación muestran grados desiguales de implementación y articulación [13], [14]. A pesar de los avances normativos y de los procesos de acreditación, persiste la necesidad de modelos metodológicos integrales que fortalezcan las competencias de publicación científica en los programas doctorales, alineados con estándares internacionales de calidad.

En atención a este vacío, el presente estudio tiene como objetivo evaluar una metodología de gestión del conocimiento orientada a mejorar las habilidades de publicación científica en estudiantes de doctorado en ingeniería, considerando tanto indicadores objetivos de productividad e impacto científico como enfoques analíticos que permitan capturar la complejidad del fenómeno estudiado. Al integrar análisis descriptivos, relacionales y predictivos, la investigación busca aportar evidencia empírica y un modelo replicable que contribuya al fortalecimiento de la formación doctoral en educación en ingeniería.

En este marco, el objetivo general del estudio es evaluar la gestión del conocimiento como metodología para fortalecer la productividad científica en estudiantes de doctorado en ingeniería, considerando los capitales humano, estructural y relacional, así como las destrezas tecnológicas, mediante un enfoque analítico integrado que combina análisis descriptivos, correlacionales y predictivos. Asimismo, el estudio busca examinar la capacidad de modelos no lineales de aprendizaje automático para estimar la probabilidad de publicación científica, con el fin de capturar la complejidad de las interacciones entre las dimensiones de la gestión del conocimiento y los resultados de producción científica doctoral.

II. METODOLOGÍA

A. Enfoque y diseño de investigación

Desde un enfoque metodológico integral, la investigación se desarrolló bajo un enfoque mixto, combinando componentes cualitativos y cuantitativos, estrategia recomendada para el estudio de fenómenos complejos vinculados a la formación doctoral y la productividad científica [19], [20]. La adopción de métodos mixtos permitió articular la profundidad interpretativa del análisis cualitativo con la capacidad explicativa y predictiva del análisis cuantitativo, fortaleciendo la validez interna y externa de los resultados.

En la fase cualitativa se aplicó un diseño de investigación-acción, orientado a la mejora continua de los procesos de investigación y publicación científica de los estudiantes de doctorado. Este enfoque resulta pertinente cuando el objetivo es generar conocimiento a partir de la práctica reflexiva y de la intervención sistemática en contextos reales de formación doctoral [21]. La investigación-acción permitió analizar de manera iterativa las dificultades, estrategias y avances de los doctorandos en su proceso de publicación científica.

La fase cuantitativa tuvo un alcance descriptivo, correlacional y predictivo, orientado a analizar la relación entre las dimensiones de la gestión del conocimiento y los indicadores objetivos de productividad científica. El diseño fue longitudinal, abarcando el periodo 2018–2024, lo que permitió observar tendencias y patrones de comportamiento investigativo a lo largo del tiempo, enfoque ampliamente recomendado en estudios sobre productividad científica doctoral [22].

En coherencia con el objetivo del estudio, el diseño metodológico adoptado permitió no solo describir y analizar las relaciones entre la gestión del conocimiento y la productividad científica doctoral, sino también evaluar la capacidad predictiva de distintos enfoques analíticos. De este modo, la investigación articula métodos tradicionales de análisis estadístico con técnicas avanzadas de aprendizaje automático, con el propósito de capturar la complejidad y la naturaleza no lineal del fenómeno estudiado.

B. Población y muestra

La población del estudio estuvo conformada por 188 estudiantes matriculados en un programa de doctorado en ingeniería de una universidad peruana, quienes contaban con registros académicos y bibliométricos completos durante el periodo de análisis. Esta población fue considerada en su totalidad para el análisis de los indicadores objetivos de productividad científica, lo que permitió trabajar con un enfoque censal en la fase cuantitativa.

De manera complementaria, se analizaron 773 registros válidos de encuestas, correspondientes a la evaluación de los capitales de la gestión del conocimiento y las destrezas tecnológicas. Para la fase cualitativa de validación del modelo

se seleccionó una muestra de cinco estudiantes, mediante muestreo aleatorio simple, lo que posibilitó un seguimiento profundo del proceso de investigación y publicación científica, en coherencia con estudios previos que emplean muestras reducidas en diseños de investigación-acción [23].

C. Variables e instrumento de recolección de datos

Variables independientes: Gestión del conocimiento

Las variables independientes se estructuraron a partir del enfoque de capital intelectual y gestión del conocimiento, ampliamente validado en la literatura científica aplicada a contextos universitarios y de investigación [24]. Se consideraron las siguientes dimensiones:

- Capital humano, referido a las competencias investigativas, habilidades metodológicas, experiencia académica, capacidades de comunicación científica y motivación investigadora.
- Capital estructural, asociado a los procesos institucionales, normativas, sistemas de información para la investigación y soporte organizacional.
- Capital relacional, vinculado a las redes académicas, la colaboración científica y la interacción con supervisores, editores y comunidades de investigación.
- Destrezas tecnológicas, relacionadas con el uso de herramientas digitales para la búsqueda, el análisis, la gestión y la difusión del conocimiento científico.

Cada dimensión fue medida mediante ítems en escala Likert de cinco puntos (1 = muy bajo, 5 = muy alto). Para el análisis estadístico se calcularon promedios por dimensión y por sujeto, procedimiento aceptado en estudios de gestión del conocimiento y productividad científica.

Variable dependiente: Productividad científica

La variable dependiente fue la productividad científica, medida a través de indicadores objetivos obtenidos de registros institucionales y bases bibliométricas:

- Número de publicaciones científicas indexadas en SCOPUS.
- Índice h (SCOPUS), como indicador de impacto y citación científica [25].

La selección de estos indicadores se sustenta en la literatura clásica sobre evaluación de la investigación científica, que reconoce al número de publicaciones y a las métricas de citación como aproximaciones válidas y comparables del desempeño científico, especialmente en estudios de alcance institucional y longitudinal [1].

La validez de contenido de los instrumentos fue establecida mediante juicio de expertos, quienes evaluaron la pertinencia, claridad y coherencia de los ítems en relación con las dimensiones teóricas propuestas.

La confiabilidad se evaluó mediante el coeficiente alfa de Cronbach, calculado sobre 773 registros válidos. Los resultados evidenciaron niveles altos y muy altos de consistencia interna: capital humano ($\alpha = 0.918$), capital

estructural ($\alpha = 0.870$), capital relacional ($\alpha = 0.883$) y destrezas tecnológicas ($\alpha = 0.995$). En conjunto, los valores superan ampliamente el umbral mínimo recomendado de 0.70, garantizando la calidad y estabilidad de las mediciones empleadas [26], [27].

D. Procedimiento y análisis de datos

En correspondencia con el objetivo de evaluar la gestión del conocimiento como metodología explicativa y predictiva de la productividad científica doctoral, se recopilieron 773 encuestas aplicadas a estudiantes de doctorado entre los años 2018 y 2024, utilizando una escala tipo Likert de cinco puntos [28].

El análisis inferencial se realizó utilizando IBM SPSS Statistics versión 26 [29]. Dado que los datos correspondían a escalas ordinales y no cumplían con los supuestos de normalidad, se empleó el coeficiente de correlación Rho de Spearman para examinar la relación entre las variables, estableciendo un nivel de significancia de $p < 0.05$ [30], [31].

Asimismo, para complementar el análisis descriptivo e inferencial, se incorporó un análisis predictivo mediante algoritmos de aprendizaje automático, orientado a estimar resultados, observados sin asumir relaciones causales directas [32], [33]. En particular, se emplearon modelos de perceptrón multicapa, bosque aleatorio, subespacio aleatorio y regresión aditiva, como enfoques comparativos de modelamiento predictivo, para estimar la probabilidad de publicación científica a partir de capital humano, capital estructural, capital relacional y destrezas tecnológicas.

El uso del perceptrón multicapa se justifica por su capacidad para modelar relaciones no lineales y patrones complejos entre variables explicativas, característica ampliamente documentada en la literatura sobre aprendizaje profundo [34]. Este tipo de redes neuronales permite capturar interacciones de alta complejidad que no pueden ser adecuadamente representadas mediante modelos lineales o aditivos tradicionales.

La selección de modelos predictivos con distintos niveles de complejidad responde a la necesidad de evaluar el equilibrio entre sesgo y varianza, así como la capacidad de generalización de los algoritmos empleados. De acuerdo con la literatura clásica en aprendizaje estadístico, los métodos no lineales y de ensamblaje presentan ventajas sustantivas para modelar fenómenos complejos caracterizados por interacciones entre variables y relaciones no aditivas [35].

El objetivo metodológico de este análisis fue evaluar la capacidad predictiva de los modelos; por tanto, se priorizó la precisión de la estimación sobre la inferencia causal, conforme a la distinción entre modelamiento explicativo y predictivo [36].

Para este propósito, se compararon modelos con distintos supuestos y capacidad de modelamiento. El bosque aleatorio, como ensamblaje de árboles de decisión, permite capturar interacciones no lineales y es robusto frente a multicolinealidad [37].

Los resultados del análisis predictivo son consistentes con estudios comparativos previos que señalan que los modelos de aprendizaje automático no superan sistemáticamente a los métodos estadísticos tradicionales, sino que su desempeño depende del grado de complejidad y no linealidad del fenómeno analizado [38]. En el presente estudio, la superioridad del bosque aleatorio sugiere que la relación entre los capitales de la gestión del conocimiento y la publicación científica presenta interacciones complejas, que son capturadas con mayor eficiencia por modelos de ensamblaje.

Siguiendo las advertencias metodológicas sobre la comparación de clasificadores, se evitó interpretar las diferencias de desempeño entre modelos como evidencia de superioridad absoluta. De acuerdo con [39], las métricas predictivas deben contextualizarse en función del fenómeno analizado y del propósito del modelo. Por ello, el análisis se centró en la capacidad relativa de los modelos para capturar relaciones complejas, más que en la optimización aislada de indicadores de clasificación.

La comparación entre distintos enfoques predictivos responde a la evidencia empírica que señala que no existe un método de pronóstico universalmente superior, y que el desempeño de los modelos depende de la naturaleza del problema y de la estructura de los datos. Estudios comparativos a gran escala han mostrado que los modelos de aprendizaje automático tienden a ofrecer ventajas en contextos caracterizados por relaciones no lineales e interacciones complejas, mientras que los métodos estadísticos tradicionales mantienen un desempeño competitivo en escenarios más estables y lineales [38]. En este sentido, el presente estudio adopta un enfoque comparativo para evaluar la adecuación de distintos modelos predictivos al fenómeno de la productividad científica doctoral.

E. Consideraciones éticas

El estudio se desarrolló en concordancia con los principios éticos de la investigación científica definidos por organismos internacionales [40]. La información utilizada fue anonimizada y empleada exclusivamente con fines académicos y de investigación. Asimismo, se contó con autorización institucional para el acceso a los datos académicos y bibliométricos, garantizando la confidencialidad y el uso responsable de la información.

III. RESULTADOS

Los resultados se presentan de manera integrada, considerando el análisis descriptivo de los capitales de la gestión del conocimiento, los indicadores objetivos de productividad científica, el análisis relacional y, finalmente, el análisis predictivo, con el propósito de evaluar la capacidad explicativa de la gestión del conocimiento en la producción científica doctoral en ingeniería.

A. Capitales de la gestión del conocimiento

En primer lugar, el análisis descriptivo de los capitales de la gestión del conocimiento evidencia niveles predominantemente medios en todas las dimensiones evaluadas. El capital relacional presenta la media más alta, lo que sugiere la existencia de redes académicas y vínculos colaborativos relativamente consolidados. Le sigue el capital estructural, asociado a los procesos y soportes institucionales. Por su parte, el capital humano y las destrezas tecnológicas muestran valores ligeramente inferiores y una mayor dispersión, lo que indica heterogeneidad en las competencias investigativas individuales de los estudiantes de doctorado.

TABLA I
 ESTADÍSTICOS DESCRIPTIVOS DE LOS CAPITALES DE LA GESTIÓN DEL CONOCIMIENTO

Capital	Media	Desv. Est.
Capital humano	2.58	0.77
Capital estructural	2.75	0.66
Capital relacional	2.83	0.61
Destrezas tecnológicas	2.67	0.93

Los resultados de Tabla 1 indican que, si bien existen condiciones relacionales e institucionales favorables, persisten brechas en el fortalecimiento del capital humano y en el dominio de herramientas tecnológicas clave para la investigación científica.

B. Productividad científica doctoral

En relación con los indicadores objetivos de productividad científica, los resultados revelan una situación crítica en la formación doctoral. Solo una proporción reducida de estudiantes cuenta con al menos una publicación científica, mientras que la gran mayoría no registra producción académica visible en bases de datos indexadas. Asimismo, se observa un índice h promedio muy bajo, lo que evidencia un impacto científico limitado.

TABLA II
 INDICADORES OBJETIVOS DE PRODUCTIVIDAD CIENTÍFICA DOCTORAL

Indicador	Valor
Estudiantes con al menos un artículo publicado	13.3 %
Estudiantes sin publicaciones	86.7 %
Estudiantes con perfil Scopus	0.0 %
Índice h promedio	0.42
Índice h máximo	15

C. Relación entre los capitales de la gestión del conocimiento y la productividad científica

El análisis relacional muestra asociaciones positivas y estadísticamente significativas entre los capitales de la gestión del conocimiento y las habilidades vinculadas a la publicación científica. El capital humano presenta una relación alta con la productividad científica, seguido del capital relacional y del capital estructural. Las destrezas tecnológicas muestran la

asociación más fuerte, lo que confirma su rol determinante en el desarrollo de competencias de escritura académica, análisis de datos y comunicación científica.

TABLA III
 RELACIÓN ENTRE LOS CAPITALES DE LA GESTIÓN DEL CONOCIMIENTO Y LA PRODUCTIVIDAD CIENTÍFICA (Rho de Spearman)

Dimensión	Coefficiente ρ	Significancia
Capital humano	0.67	$p < 0.01$
Capital estructural	0.59	$p < 0.01$
Capital relacional	0.62	$p < 0.01$
Destrezas tecnológicas	0.71	$p < 0.01$

Estos resultados confirman que el fortalecimiento de las capacidades individuales y tecnológicas resulta clave para transformar los recursos institucionales y relacionales en producción científica efectiva.

D. Análisis predictivo de la publicación científica

Finalmente, se aplicaron modelos de aprendizaje automático con el objetivo de evaluar la capacidad predictiva de los capitales de la gestión del conocimiento sobre la probabilidad de publicación científica. Los resultados evidencian diferencias claras en el desempeño de los modelos evaluados. El bosque aleatorio alcanzó el mejor desempeño predictivo, seguido del perceptrón multicapa, mientras que la regresión aditiva metaheurística mostró un desempeño aceptable, aunque inferior.

TABLA IV
 COMPARACIÓN DEL DESEMPEÑO DE MODELOS PREDICTIVOS

Modelo	Accuracy	MAE
Perceptrón multicapa	0.877	0.123
Bosque aleatorio	0.895	0.105
Regresión aditiva metaheurística	0.860	0.140

Estos hallazgos evidencian que los enfoques de aprendizaje automático permiten capturar relaciones no lineales entre los capitales de la gestión del conocimiento y la productividad científica, aportando valor explicativo adicional al análisis correlacional tradicional.




Fig. 1 Framework conceptual: Gestión del conocimiento como metodología predictiva para fortalecer la productividad científica doctoral en ingeniería, basado del análisis inferencial.

En conjunto, los resultados confirman que la gestión del conocimiento incide significativamente en la productividad científica doctoral, especialmente a través del capital humano y de las destrezas tecnológicas. No obstante, los bajos niveles de publicación observados ponen de manifiesto la necesidad de implementar estrategias sistemáticas y articuladas que permitan transformar las capacidades existentes en resultados científicos concretos y sostenibles.

IV. DISCUSIÓN

Los resultados del estudio confirman que la gestión del conocimiento constituye un marco pertinente para analizar y fortalecer la productividad científica en la formación doctoral en ingeniería, tal como lo señala la literatura especializada en educación superior y gestión universitaria [3], [13], [16]. Sin embargo, los hallazgos evidencian que la relación entre los capitales de la gestión del conocimiento y la publicación científica no es directa ni lineal, sino que responde a dinámicas complejas de interacción entre factores individuales, institucionales y tecnológicos.

En primer lugar, los niveles predominantemente medios observados en los capitales humano, estructural y relacional concuerdan con estudios previos que señalan que las universidades suelen disponer de infraestructura básica, redes académicas y marcos normativos para la investigación, pero presentan debilidades en la consolidación de competencias investigativas avanzadas en los doctorandos [13], [14]. En particular, el menor desarrollo relativo del capital humano y de las destrezas tecnológicas coincide con lo reportado por investigaciones que identifican dificultades en la escritura científica, el manejo de herramientas digitales especializadas y la gestión estratégica del proceso de publicación durante el doctorado [8], [11], [12].

Desde la perspectiva de la gestión del conocimiento, estos resultados refuerzan la idea de que el capital estructural y relacional, por sí solos, no garantizan productividad científica, si no se articulan con un capital humano sólido capaz de transformar el conocimiento tácito en productos científicos explícitos [13], [17]. Esta interpretación es consistente con los modelos de capital intelectual que enfatizan la interdependencia entre sus dimensiones y advierten sobre el riesgo de enfoques fragmentados en la gestión universitaria del conocimiento.

En segundo lugar, los indicadores objetivos de productividad científica evidencian una brecha significativa entre las capacidades disponibles y los resultados alcanzados, reflejada en la baja proporción de estudiantes con publicaciones científicas y en el reducido índice promedio [9], [10]. En línea con la literatura previa, en los contextos latinoamericanos, la exigencia de publicar durante el doctorado no siempre se acompaña de metodologías sistemáticas de apoyo a la publicación científica, lo que limita el impacto y la visibilidad de la producción doctoral. Asimismo, refuerza la pertinencia de abordar la productividad

científica como un proceso que requiere gestión, acompañamiento y desarrollo progresivo de competencias, más que como un resultado espontáneo del trabajo individual.

Si bien los indicadores bibliométricos empleados permiten una aproximación objetiva a la productividad científica, estos deben interpretarse considerando sus limitaciones, tal como advierte la literatura especializada en evaluación de la investigación [1].

El análisis correlacional aporta evidencia empírica adicional al mostrar relaciones positivas y significativas entre los capitales de la gestión del conocimiento y la productividad científica, destacando el peso del capital humano y de las destrezas tecnológicas. Este resultado es coherente con la literatura que subraya que las competencias metodológicas, la capacidad de comunicación científica y el uso efectivo de tecnologías para la investigación son factores críticos para la publicación en revistas indexadas [2], [8], [13]. En este sentido, los hallazgos respaldan los planteamientos teóricos que vinculan la productividad científica doctoral con la calidad del capital humano y con la apropiación de herramientas digitales para la gestión del conocimiento.

No obstante, el principal aporte interpretativo del estudio emerge del análisis predictivo, el cual permite profundizar en la naturaleza de la relación entre las variables. El mejor desempeño del modelo de bosque aleatorio, en comparación con el perceptrón multicapa y la regresión aditiva metaheurística, sugiere que la relación entre los capitales de la gestión del conocimiento y la publicación científica es intrínsecamente no lineal y responde a dinámicas complejas de interacción entre múltiples factores. Esta evidencia es coherente con enfoques contemporáneos que conciben la producción científica como un fenómeno emergente, resultado de interacciones simultáneas más que de efectos aditivos simples [16]. Desde la perspectiva del aprendizaje estadístico, la superioridad de los métodos de ensamblaje se explica por su capacidad para reducir el error de generalización al combinar múltiples modelos base y controlar el sobreajuste, lo que resulta especialmente adecuado en contextos con alta complejidad estructural [13].

No obstante, la comparación entre modelos predictivos debe interpretarse con cautela. Tal como advierte [39], las mejoras en métricas de clasificación pueden generar una “ilusión de progreso” si no se consideran el contexto del problema, la naturaleza de los datos y el objetivo analítico del modelo. En este estudio, el uso de modelos de aprendizaje automático no persigue maximizar métricas de desempeño per se, sino evaluar su capacidad para capturar patrones complejos y no lineales asociados a la productividad científica doctoral. En este sentido, el valor del bosque aleatorio radica menos en la magnitud de su ventaja predictiva y más en su adecuación metodológica para representar la interacción entre los capitales de la gestión del conocimiento.

La superioridad de los modelos de ensamblaje respalda la idea de que la probabilidad de publicación científica depende de configuraciones específicas de capital humano, destrezas tecnológicas, soporte institucional y redes académicas, donde

la ausencia o debilidad de una dimensión puede limitar el efecto de las demás. Este hallazgo amplía los estudios previos, mayoritariamente correlacionales, al mostrar que los enfoques predictivos permiten capturar relaciones complejas y ofrecer una comprensión más realista del proceso de publicación científica durante el doctorado.

Desde una perspectiva aplicada, la discusión de los resultados sugiere que las políticas y estrategias institucionales orientadas a mejorar la productividad científica doctoral deberían diseñarse bajo un enfoque integral de gestión del conocimiento, priorizando el fortalecimiento del capital humano y tecnológico, en coherencia con el capital estructural y relacional existente. Esta recomendación se alinea con la literatura que destaca la necesidad de modelos sistemáticos y replicables para la gestión de la investigación doctoral en ingeniería y otras disciplinas STEM [2], [4], [13].

Estos resultados pueden interpretarse desde la sociología de la ciencia, que concibe la producción científica como un fenómeno socialmente regulado, en el que la publicación constituye el principal mecanismo de reconocimiento y validación del conocimiento. En este marco, las limitaciones observadas en la productividad científica doctoral no reflejan únicamente déficits individuales, sino que evidencian tensiones estructurales del sistema científico, donde la interacción entre actores, recursos, normas institucionales y tecnologías configura redes de acción que condicionan el acceso a los canales formales de difusión y la visibilidad del conocimiento. Esta naturaleza relacional y no lineal del proceso de publicación resulta coherente con el mejor desempeño de los modelos predictivos no lineales, los cuales logran capturar con mayor precisión las interacciones complejas que subyacen a la productividad científica doctoral [7].

En conjunto, la discusión evidencia que la gestión del conocimiento no solo constituye un marco conceptual válido, sino también una metodología operativa para comprender y mejorar la productividad científica doctoral. La articulación entre resultados empíricos y fundamentos teóricos refuerza el valor del enfoque adoptado y abre nuevas líneas de investigación orientadas al uso de modelos predictivos y analíticos avanzados en el estudio de la formación doctoral en educación en ingeniería.

En particular, si bien la disponibilidad de infraestructura sigue siendo un componente relevante, la evidencia sugiere que no resulta suficiente por sí sola para explicar las diferencias observadas en la producción científica. Más bien, esta parece estar fuertemente asociada a factores vinculados con el desarrollo del capital humano y el dominio de competencias tecnológicas, así como la evidencia de relaciones no lineales entre las variables analizadas sugiere la limitada efectividad de estrategias aisladas o de carácter incremental, en conjunto estos hallazgos invitan a repensar las políticas científicas para promover una mayor articulación entre redes académicas y refuerzan la necesidad de enfoques más integrales de gestión del conocimiento.

V. CONCLUSIONES

El estudio permitió evaluar la pertinencia de la gestión del conocimiento como metodología para fortalecer la productividad científica en estudiantes de doctorado en ingeniería, integrando evidencia empírica desde un enfoque descriptivo, relacional y predictivo. Los resultados obtenidos confirman que la publicación científica doctoral constituye un fenómeno complejo, condicionado por la interacción de factores individuales, institucionales y tecnológicos.

En primer lugar, se evidenció que los capitales de la gestión del conocimiento —capital humano, estructural y relacional— junto con las destrezas tecnológicas, presentan niveles predominantemente medios, lo que sugiere la existencia de condiciones básicas para la investigación doctoral. Sin embargo, estos niveles no se traducen automáticamente en resultados de publicación científica, lo que pone de manifiesto una brecha entre capacidades disponibles y producción científica efectiva.

En segundo lugar, los indicadores objetivos de productividad científica revelaron un bajo desempeño doctoral, caracterizado por una reducida proporción de estudiantes con publicaciones científicas y un índice h promedio limitado. Este hallazgo confirma que la productividad científica no puede ser asumida como un resultado espontáneo del proceso doctoral, sino que requiere estrategias sistemáticas de acompañamiento y gestión del conocimiento orientadas específicamente a la publicación.

En tercer lugar, el análisis correlacional demostró que los capitales de la gestión del conocimiento se relacionan de manera positiva y significativa con la productividad científica, destacando el capital humano y las destrezas tecnológicas como las dimensiones con mayor asociación. Este resultado confirma que el desarrollo de competencias investigativas, habilidades de escritura académica y dominio de herramientas digitales resulta determinante para transformar los recursos estructurales y relacionales en productos científicos visibles.

En cuarto lugar, el análisis predictivo evidenció que los modelos de ensamblaje, particularmente el bosque aleatorio, alcanzan un mejor desempeño para estimar la probabilidad de publicación científica. Este hallazgo sugiere que la relación entre la gestión del conocimiento y la productividad científica es intrínsecamente no lineal, con efectos combinados e interacciones entre variables, lo que justifica el uso de enfoques analíticos avanzados como complemento al análisis estadístico tradicional.

Desde una perspectiva aplicada, los resultados permiten concluir que los programas doctorales en ingeniería deberían adoptar un enfoque integral de gestión del conocimiento, priorizando el fortalecimiento del capital humano y tecnológico, articulado con soporte institucional efectivo y redes académicas orientadas a resultados de publicación. Asimismo, el uso de modelos predictivos puede constituir una herramienta valiosa para la toma de decisiones académicas, la identificación temprana de brechas formativas y el diseño de intervenciones focalizadas en la formación doctoral.

El estudio aporta evidencia empírica y metodológica relevante para el campo de la educación en ingeniería, al demostrar que la gestión del conocimiento no solo es un marco conceptual explicativo, sino también una metodología operativa para mejorar la productividad científica doctoral. Como líneas futuras de investigación, se sugiere incorporar variables adicionales y ampliar el análisis a otros contextos institucionales, con el fin de fortalecer la generalización y aplicabilidad del modelo propuesto.

Finalmente, la replicación del análisis mediante técnicas comparativas y modelos predictivos en múltiples instituciones contribuiría a consolidar la gestión del conocimiento como un enfoque generalizable para la mejora de la productividad científica doctoral, mediante futuras investigaciones en diferentes contextos académicos para identificar configuraciones específicas de capitales de la gestión del conocimiento que optimizan la productividad científica en distintos entornos institucionales.

REFERENCES

- [1] H. F. Moed, *Citation Analysis in Research Evaluation*. Dordrecht, Netherlands: Springer, 2005. doi: 10.1007/1-4020-3714-7.
- [2] S. Lee y B. Bozeman, «The impact of research collaboration on scientific productivity», *Soc. Stud. Sci.*, vol. 35, n.º 5, pp. 673-702, 2005, doi: 10.1177/0306312705052359.
- [3] I. Nonaka y H. Takeuchi, *The Knowledge-Creating Company: How Japanese Companies Create the Dynamics of Innovation*. New York, NY, USA: Oxford University Press, 1995. [En línea]. Disponible en: <https://global.oup.com/academic/product/the-knowledge-creating-company-9780195092691>
- [4] OECD, *Education at a Glance 2023: OECD Indicators*. Paris, France: OECD Publishing, 2023. doi: 10.1787/e13bef63-en.
- [5] B. Latour, *Science in Action*. Cambridge, MA, USA: Harvard University Press, 1987. [En línea]. Disponible en: <https://www.hup.harvard.edu/books/9780674812813>
- [6] H. Etzkowitz y L. Leydesdorff, «The Triple Helix as a model for innovation studies», *Sci. Public Policy*, vol. 25, n.º 3, pp. 195-203, 1998, doi: 10.1093/spp/25.3.195.
- [7] R. K. Merton, *The Sociology of Science*. Chicago, IL, USA: University of Chicago Press, 1973. [En línea]. Disponible en: <https://press.uchicago.edu/ucp/books/book/chicago/S/bo3622982.html>
- [8] S. K. Gardner, «The development of doctoral students: Phases of challenge and support», *ASHE High. Educ. Rep.*, vol. 34, n.º 6, pp. 1-127, 2009, doi: 10.1002/aehe.3406.
- [9] A. Bernasconi, «Is there a Latin American model of the university?», *Comp. Educ. Rev.*, vol. 52, n.º 1, pp. 27-52, 2008, doi: 10.1086/524305.
- [10] P. A. David y D. Foray, «An introduction to the economy of the knowledge society», *Int. Soc. Sci. J.*, vol. 54, n.º 171, pp. 9-23, 2002, doi: 10.1111/1468-2451.00355.
- [11] B. M. Belcher, K. E. Rasmussen, M. R. Kemshaw, y D. A. Zornes, «Defining and assessing research quality in a transdisciplinary context», *Res. Eval.*, vol. 25, n.º 1, pp. 1-17, nov. 2016, doi: 10.1093/RESEVAL/RVV025.
- [12] M. R. McGrail, C. M. Rickard, y R. Jones, «Publish or perish: A systematic review of interventions to increase academic publication rates», *High. Educ. Res. Dev.*, vol. 25, n.º 1, pp. 19-35, 2006, doi: 10.1080/07294360500453053.
- [13] N. Bontis, «Managing organisational knowledge by diagnosing intellectual capital», *Int. J. Technol. Manag.*, vol. 18, n.º 5-8, pp. 433-462, 1999, doi: 10.1504/IJTM.1999.002780.
- [14] UNESCO, *Reimagining Our Futures Together: A New Social Contract for Education*. Paris, France: UNESCO, 2021. doi: 10.54675/ASRB4722.
- [15] T. H. Davenport y L. Prusak, *Working Knowledge: How Organizations Manage What They Know*. Boston, MA, USA: Harvard Business School Press, 1998. [En línea]. Disponible en: <https://store.hbr.org/product/working-knowledge-how-organizations-manage-what-they-know/6166>
- [16] G. Von Krogh, K. Ichijo, y I. Nonaka, *Enabling Knowledge Creation*. New York, NY, USA: Oxford University Press, 2000. [En línea]. Disponible en: <https://global.oup.com/academic/product/enabling-knowledge-creation-9780195126167>
- [17] T. A. Stewart, *Intellectual Capital: The New Wealth of Organizations*. New York, NY, USA: Doubleday, 1997. [En línea]. Disponible en: <https://www.penguinrandomhouse.com/books/159807/intellectual-capital-by-thomas-a-stewart/>
- [18] A. Serenko y N. Bontis, «Global ranking of knowledge management and intellectual capital academic journals», *J. Knowl. Manag.*, vol. 17, n.º 2, pp. 307-326, 2013, doi: 10.1108/13673271311315231.
- [19] K. Lewin, «Action research and minority problems», *J. Soc. Issues*, vol. 2, n.º 4, pp. 34-46, 1946, doi: 10.1111/j.1540-4560.1946.tb02295.x.
- [20] A. Tashakkori y C. Teddlie, *Mixed Methodology: Combining Qualitative and Quantitative Approaches*. Thousand Oaks, CA, USA: SAGE, 1998. [En línea]. Disponible en: <https://us.sagepub.com/en-us/nam/mixed-methodology/book6075>
- [21] J. McNiff, *Action Research: Principles and Practice*, 3rd ed. London, UK: Routledge, 2013. [En línea]. Disponible en: <https://www.routledge.com/Action-Research-Principles-and-Practice/McNiff/p/book/9780415535217>
- [22] G. Abramo, C. A. D'Angelo, y F. Di Costa, «Research productivity: Are higher academic ranks more productive than lower ones?», *Scientometrics*, vol. 88,

- n.º 3, pp. 915-928, 2011, doi: 10.1007/s11192-011-0406-6.
- [23] J. W. Creswell y V. L. Plano Clark, *Designing and Conducting Mixed Methods Research*, 3rd ed. Thousand Oaks, CA, USA: SAGE, 2018. [En línea]. Disponible en: <https://us.sagepub.com/en-us/nam/designing-and-conducting-mixed-methods-research/book241842>
- [24] E. T. Stringer, *Action Research*, 4th ed. Thousand Oaks, CA, USA: SAGE, 2014. [En línea]. Disponible en: <https://us.sagepub.com/en-us/nam/action-research/book241986>
- [25] L. J. Cronbach, «Coefficient alpha and the internal structure of tests», *Psychometrika*, vol. 16, n.º 3, pp. 297-334, 1951, doi: 10.1007/BF02310555.
- [26] W. J. Conover, *Practical Nonparametric Statistics*, 3rd ed. New York, NY, USA: Wiley, 1999. doi: 10.1002/9780470523992.
- [27] J. C. Nunnally y I. H. Bernstein, *Psychometric Theory*, 3rd ed. New York, NY, USA: McGraw-Hill, 1994. [En línea]. Disponible en: <https://www.mheducation.com/highered/product/psychometric-theory-nunnally/M9780070478497.html>
- [28] J. Pallant, *SPSS Survival Manual*, 7th ed. London, UK: McGraw-Hill Education, 2020. [En línea]. Disponible en: <https://www.mheducation.co.uk/spss-survival-manual-9780335242399-emea>
- [29] A. Field, *Discovering Statistics Using IBM SPSS Statistics*, 5th ed. London, UK: SAGE, 2018. [En línea]. Disponible en: <https://uk.sagepub.com/en-gb/eur/discovering-statistics-using-ibm-spss-statistics/book252022>
- [30] IEEE, *IEEE Editorial Style Manual*. Piscataway, NJ, USA: IEEE, 2023. [En línea]. Disponible en: <https://www.ieee.org/conferences/publishing/templates.html>
- [31] C. Spearman, «The proof and measurement of association between two things», *Am. J. Psychol.*, vol. 15, n.º 1, pp. 72-101, 1904, doi: 10.2307/1412159.
- [32] M. Kuhn y K. Johnson, *Applied Predictive Modeling*. New York, NY, USA: Springer, 2013. doi: 10.1007/978-1-4614-6849-3.
- [33] World Medical Association, «Declaration of Helsinki: Ethical principles for medical research involving human subjects», *JAMA*, vol. 310, n.º 20, pp. 2191-2194, 2013, doi: 10.1001/jama.2013.281053.
- [34] I. Goodfellow, Y. Bengio, y A. Courville, *Deep Learning*. Cambridge, MA, USA: MIT Press, 2016. [En línea]. Disponible en: <https://www.deeplearningbook.org/>
- [35] T. Hastie, R. Tibshirani, y J. Friedman, *The Elements of Statistical Learning*, 2nd ed. New York, NY, USA: Springer, 2009. doi: 10.1007/978-0-387-84858-7.
- [36] G. Shmueli, «To Explain or to Predict?», *Stat. Sci.*, vol. 25, n.º 3, pp. 289-310, 2010, doi: 10.1214/10-STS330.
- [37] L. Breiman, «Random forests», *Mach. Learn.*, vol. 45, n.º 1, pp. 5-32, 2001, doi: 10.1023/A:1010933404324.
- [38] S. Makridakis, E. Spiliotis, y V. Assimakopoulos, «Statistical and machine learning forecasting methods: Concerns and ways forward», *PLOS ONE*, vol. 13, n.º 3, 2018, doi: 10.1371/journal.pone.0194889.
- [39] D. J. Hand, «Classifier technology and the illusion of progress», *Stat. Sci.*, vol. 21, n.º 1, pp. 1-14, 2006, doi: 10.1214/088342306000000060.
- [40] W. Bank, *Improving Tertiary Education in Latin America*. Washington, DC, USA: World Bank, 2017. [En línea]. Disponible en: <https://documents.worldbank.org/en/publication/documents-reports/documentdetail/224091467988708186>