

Estado del conocimiento sobre la inteligencia artificial aplicada en la movilidad inteligente

Neider Alexis Arango Lemos

Asesora

Angela María Vargas Arcila

Co-Asesor

Carlos Felipe Estrada Solano

Universidad Nacional Abierta y a Distancia - UNAD

Escuela de Ciencias Básicas, Tecnología e Ingenierías ECBTI

Ingeniería Electrónica

2025

Quisiera expresar mi más sincero y profundo agradecimiento a las personas que han sido fundamentales en este arduo pero gratificante camino académico, cuyo apoyo incondicional ha hecho posible la culminación exitosa de este trabajo de investigación, a Dios que es el pilar en mi vida, a mi esposa Victoria Tobón, que fue fundamental durante todo este proceso. Su amor inquebrantable, paciencia infinita y comprensión ante mis ausencias han sido la fuerza que me permitió perseverar. Sus palabras de aliento en momentos críticos y su capacidad para creer en mí cuando dudaba fueron invaluable, este trabajo lleva impreso el sacrificio compartido de nuestros tiempos juntos y su generosidad sin límites. A la Dra. Angela María Vargas Arcila, directora de esta investigación, por su valiosa guía, rigurosidad académica y acertadas observaciones. Su amplio conocimiento y disposición permanente para atender mis consultas fueron fundamentales para dar profundidad a este trabajo. Agradezco la confianza depositada y su estímulo constante hacia la excelencia. Mi gratitud también a la Universidad Nacional Abierta y a Distancia por los recursos proporcionados a través de sus bases de datos que sirvió para la investigación de los artículos en cuestión.

A todos, mi más profunda gratitud.

Actualmente, los registros de la Secretaría de Tránsito y Transporte de Popayán indican un aumento desmesurado de vehículos en la ciudad, lo cual ha generado congestión vial y contaminación acústica y del aire. En 2016, la Ley 1811 estableció que las empresas debían otorgar medio día libre remunerado por 30 viajes al trabajo en bicicleta. Sin embargo, la ciudad carece de un mecanismo efectivo para verificar el cumplimiento de esta norma. Para ello, surgió la investigación “Sistema de Certificación del Uso Efectivo de Medios de Transporte Eco-Amigables” de la UNAD con identificador PSIIN3102ECBTI2023, cuyo objetivo es desarrollar un prototipo de un sistema de monitorización y caracterización de recorridos, que permita certificar el uso efectivo de la bicicleta para desplazarse a un lugar específico. Esta monografía se suscribe como parte de dicha investigación para aportar a la contextualización del tema de la investigación, fundamentar teóricamente el estudio y validar los resultados obtenidos con relación a los hallazgos previos. Por lo anterior en esta monografía se llevó a cabo un estudio bibliométrico con el objetivo de analizar la evolución y las principales tendencias académicas en un área específica de investigación, mediante el uso de la herramienta SciMat, se identificaron clústeres temáticos relevantes en distintos periodos de tiempo, evaluando su impacto, centralidad y densidad dentro de la producción científica. Además, este análisis permitió reconocer qué temas han ganado relevancia, cómo se relacionan entre sí y cuáles han sido claves para el desarrollo conceptual del área estudiada.

Palabras clave: SciMat, clúster, análisis, periodos, documentos.

Currently, records from Popayán's Secretariat of Traffic and Transportation indicate a disproportionate increase of vehicles in the city, which has generated road congestion and noise and air pollution. In 2016, Law 1811 established that companies must grant half a paid day off for 30 trips to work by bicycle. However, the city lacks an effective mechanism to verify compliance with this rule. To this end, the research “Sistema de Certificación del Uso Efectivo de Medios de Transporte Eco-Amigables” of UNAD with identifier PSIIN3102ECBTI2023 emerged, whose objective is to develop a prototype of a monitoring system and characterization of routes, which allows certifying the effective use of bicycles to travel to a specific place. This monograph is subscribed as part of this research to contribute to the contextualization of the research topic, to provide a theoretical basis for the study and to validate the results obtained in relation to previous findings. Therefore, in this monograph a bibliometric study was carried out with the objective of analyzing the evolution and the main academic trends in a specific area of research, by using the SciMat tool, relevant thematic clusters were identified in different periods of time, evaluating their impact, centrality and density within the scientific production. In addition, this analysis made it possible to recognize which topics have gained relevance, how they are related to each other and which have been key to the conceptual development of the area studied.

Keywords: SciMat, cluster, analysis, periods, documents

Tabla de Contenido

5

Introducción	8
Planteamiento del Problema	10
Justificación	12
Objetivos	14
Inteligencia Artificial en Movilidad Inteligente: Tendencias y Evolución Temática con Scopus y SciMat	15
Protocolo de Búsqueda y Clasificación Documental.....	15
SciMat para la Exploración y Análisis de Redes Temáticas y Evolutivas	19
Análisis Bibliométrico sobre Inteligencia Artificial Aplicada en la Movilidad Inteligente	30
Análisis Primer Periodo 2019-2020.....	35
Análisis Segundo Periodo 2021-2022.....	43
Análisis Tercer Periodo 2023-2024	50
Conclusiones	63
Referencias Bibliográficas	66
Apéndices.....	75

Lista de Tablas

6

Tabla 1	<i>Lista de los Documentos más Relevantes Clúster Artificial Systems</i>	38
Tabla 2	<i>Lista de los Documentos más Relevantes Clúster Learning</i>	42
Tabla 3	<i>Lista de los Documentos más Relevantes Clúster Vehicular-Network</i>	46
Tabla 4	<i>Lista de los Documentos más Relevantes Clúster Machine-Learning</i>	49
Tabla 5	<i>Lista de los Documentos más Relevantes Clúster Artificial-Systems</i>	53
Tabla 6	<i>Lista de los Documentos más Relevantes Clúster Traffic-Conditions</i>	57
Tabla 7	<i>Lista de los Documentos más Relevantes Clúster Security</i>	61

Figura 1 <i>Resultado Scopus</i>	17
Figura 2 <i>Herramienta SciMat para Estudio Bibliométrico</i>	20
Figura 3 <i>Creación de Grupos Palabras Clave</i>	21
Figura 4 <i>Pasos para Generar Análisis</i>	24
Figura 5 <i>Vista Longitudinal</i>	25
Figura 6 <i>Red de Clúster Formada a Partir de Documentos Asociados al Clúster</i>	26
Figura 7 <i>Diagramas de Visualización: Estratégico y Red de Clúster</i>	27
Figura 8 <i>Gráficos de Evolución e Ítems Superpuestos</i>	28
Figura 9 <i>Red del Clúster Artificial-Systems</i>	36
Figura 10 <i>Red de Clúster Learning</i>	40
Figura 11 <i>Red del Clúster Vehicular-Network</i>	45
Figura 12 <i>Diagrama Red de Clúster Machine-Learning</i>	47
Figura 13 <i>Diagrama Red de Clúster Artificial-Systems</i>	52
Figura 14 <i>Diagrama Red de Clúster Traffic-Conditions</i>	55
Figura 15 <i>Diagrama Red de Clúster Security</i>	58

La inteligencia artificial (IA) representa uno de los avances tecnológicos más significativos del siglo XXI. La IA se define como la capacidad de las máquinas para emular procesos cognitivos humanos mediante algoritmos computacionales. Esta disciplina ha experimentado un crecimiento exponencial en las últimas décadas, transformando diversos sectores como la medicina, la ingeniería, la economía y las ciencias sociales, generando un volumen significativo de investigación científica multidisciplinaria.

De otra parte, la movilidad inteligente constituye un paradigma emergente que integra tecnologías digitales, datos masivos e infraestructuras conectadas para optimizar los sistemas de transporte urbano. Este enfoque busca mejorar la eficiencia energética, reducir la congestión y emisiones contaminantes, e incrementar la seguridad y accesibilidad mediante soluciones tecnológicas como vehículos autónomos, sistemas de gestión de tráfico y aplicaciones de movilidad compartida.

Este documento presenta una monografía que desarrolla un estudio bibliométrico enfocado en analizar la evolución temática de la aplicación de la inteligencia artificial en soluciones de movilidad inteligente, a través del tiempo. La investigación utiliza la herramienta SciMat como metodología principal para identificar y analizar clústeres temáticos que emergen, evolucionan y se consolidan en diferentes períodos.

El estudio se estructura en etapas temporales que permiten observar la dinámica de relevancia de los temas, examinando factores clave como la densidad, centralidad y volumen de publicaciones de cada clúster. Este enfoque permite evaluar tanto la cohesión interna como la importancia de cada tema en el panorama general de la investigación.

Además de identificar clústeres relevantes, el análisis destaca documentos investigativos⁹ clave que sirven como referentes conceptuales para futuras investigaciones, estableciendo vínculos entre redes temáticas y estudios específicos.

El propósito final de la monografía es proporcionar una visión estructurada sobre la evolución de la producción científica en el área seleccionada, ofreciendo un panorama detallado de las líneas de investigación más relevantes, sus interconexiones y posibles tendencias futuras, con el objetivo de orientar investigaciones posteriores y fortalecer el conocimiento académico en dicho ámbito.

La estructura de esta monografía empieza con el planteamiento del problema, en segundo lugar, se encuentra la importancia de este estudio bibliométrico, en el marco del proyecto de investigación “Sistema de Certificación del uso Efectivo de Medios de Transporte Eco-amigables”; en tercer lugar, se plantean los objetivos de esta monografía; en cuarto lugar, se encuentra un capítulo en el que se describen los pasos que se realizaron para recopilar artículos de investigación en tres periodos de tiempo, mediante el uso de la herramienta SciMat; en quinto lugar, se presenta el análisis sobre el estado y las tendencias de investigación en torno al uso de transportes eco-amigables; finalmente, se encuentran las conclusiones sobre la evolución temática de la aplicación de la inteligencia artificial en soluciones de movilidad inteligente.

En la actualidad, Popayán enfrenta un crecimiento desmesurado de vehículos automotores a pesar de su tamaño y población aproximada de 270,000 habitantes en el área urbana. Los registros de la Secretaría de Tránsito y Transporte indican un aumento significativo de vehículos en solo dos años: de 59,297 en 2020 a 74,652 en 2022, representando un incremento del 25%. Esta expansión ha generado congestión vial, tiempos prolongados de traslado y contaminación del aire y acústica.

La administración municipal ha implementado medidas como el pico y placa y modificaciones en rutas, mientras que los habitantes promueven el uso compartido de vehículos y alternativas eco-amigables como la bicicleta, respaldados por iniciativas como "Diálogos de ciudad en Bici". A pesar del interés de la Secretaría de Tránsito y Transporte y de los payaneses por una movilidad amigable con el medio ambiente, la motivación para adoptar transportes alternativos sigue siendo baja.

En 2016, se estableció la Ley 1811, que otorga incentivos para promover el uso de la bicicleta, como medio día libre remunerado por cada 30 viajes al trabajo en bicicleta. Sin embargo, carece de un mecanismo efectivo para verificar el cumplimiento de esta norma por parte de las empresas e instituciones. Para abordar este problema, surgió el proyecto denominado "Sistema de Certificación del Uso Efectivo de Medios de Transporte Eco-Amigables" de la UNAD con identificador PSIIN3102ECBTI2023, cuyo objetivo es desarrollar un prototipo de un sistema de monitorización y caracterización de recorridos que permita certificar el uso efectivo de la bicicleta para desplazarse a un lugar específico.

Ahora bien, para aportar a la solución del problema de investigación del proyecto PSIIN3102ECBTI2023 es necesario revisar el estado del conocimiento acumulado sobre

movilidad inteligente, con el propósito de contextualizar el tema de la investigación, fundamentar teóricamente el estudio y validar los resultados obtenidos con relación a los hallazgos previos. Así pues, esta propuesta se enfoca en la pregunta ¿cuál es el estado del conocimiento acumulado alrededor de soluciones tecnológicas para la movilidad inteligente en las grandes urbes?

Este trabajo de grado se articula al proyecto “Sistema de Certificación del uso Efectivo de Medios de Transporte Eco-amigables” (código PSIIN3102ECBTI2023), cuyo propósito es “desarrollar un prototipo de sistema de monitorización y caracterización de recorridos que permita certificar el uso efectivo de la bicicleta para desplazarse a un lugar específico”. La pertinencia de dicha investigación radica en su aporte a la movilidad eco-amigable y su impacto positivo en el medio ambiente, la salud humana y el desarrollo de Popayán como ciudad inteligente, además de su contribución al cumplimiento de la Ley 1811.

En el campo de la ingeniería, el proyecto en mención coadyuva a ampliar el aspecto de la investigación sobre el uso de las tecnologías para identificar los recorridos, en este caso, realizados en bicicleta. Adicionalmente, aporta al desarrollo del software que permitirá la monitorización y certificación de los recorridos.

Ahora bien, esta monografía radica en su pertinencia para el desarrollo del proyecto PSIIN3102ECBTI2023, pues el estudio bibliométrico contribuirá a la toma de decisiones sobre las metodologías y las tecnologías más adecuadas para el desarrollo del prototipo de un sistema de monitorización y caracterización de recorridos que permita certificar el uso efectivo de la bicicleta para desplazarse a un lugar específico.

Este estudio bibliométrico también tiene un valor teórico y metodológico importante, dado que analizará las relaciones que existen entre las teorías y metodologías abordadas en diferentes publicaciones relacionadas con el problema de investigación del proyecto. Este análisis, a la producción científica, derivará en la identificación de focos de trabajo emergentes del área que se va a estudiar y contribuirá a la fundamentación teórica y metodológica de la investigación, lo cual es absolutamente necesario y pertinente para los investigadores del

proyecto al que se articula este trabajo de grado y para otros investigadores interesados en el 13
área.

Finalmente, este estudio bibliométrico aporta en general al tema de la movilidad inteligente, pues será un insumo para que investigadores interesados en el área identifiquen y evalúen brechas de investigación que resulten en desarrollos y aportes a la movilidad desde las tecnologías.

Objetivo General

Investigar documentalmente sobre el estado del conocimiento acumulado alrededor de la inteligencia artificial aplicada en la movilidad inteligente.

Objetivos Específicos

Establecer un protocolo de búsqueda documental.

Clasificar las fuentes bibliográficas relevantes de acuerdo con el problema de investigación y al periodo que abarca la investigación.

Analizar los resultados de la revisión bibliométrica para la identificación de áreas de estudio, emergentes y en declive, relacionadas con soluciones tecnológicas para la movilidad inteligente.

Scopus y SciMat

En esta sección se describirá el paso a paso sobre el estudio bibliométrico que se realizó, inicialmente con una metodología sistemática que comenzó con la recopilación de documentos de investigación en la base de datos Scopus, elegida por su amplia cobertura y rigor académico, la cual ofrece una cobertura exhaustiva de literatura científica revisada por pares, abarcando más de 25.000 revistas de distintas disciplinas académicas. Esta amplitud garantiza que los análisis bibliométricos realizados con datos de Scopus sean representativos y comprendan múltiples campos del conocimiento.

Adicionalmente, Scopus proporciona metadatos estructurados y normalizados que incluyen afiliaciones institucionales, referencias bibliográficas, citas y palabras clave. Los datos obtenidos fueron procesados y analizados mediante SciMat, (Cobo et al., 2012) una herramienta especializada en la identificación de tendencias y redes temáticas en la investigación científica, que complementa los datos obtenidos de Scopus, aportando capacidades analíticas avanzadas. Su principal ventaja radica en la capacidad para procesar, visualizar y analizar la evolución de redes temáticas a través del tiempo, permitiendo identificar patrones que serían difícilmente detectables mediante análisis manuales (Cobo et al., 2012). Finalmente, se realizó un análisis exhaustivo de los resultados proporcionados por SciMat, lo cual permitió identificar patrones de desarrollo, áreas emergentes y relaciones entre temas clave, aportando una visión integral sobre el estado y las tendencias de la investigación en el campo estudiado.

Protocolo de Búsqueda y Clasificación Documental

Esta monografía se realizó en el marco de la investigación “Sistema de Certificación del Uso Efectivo de Medios de Transporte Eco-Amigables” de la UNAD con identificador

monitorización y caracterización del recorrido de la bicicleta, cuando es utilizada como medio de transporte. En este sentido, este trabajo aporta una investigación documental sobre el estado del conocimiento acumulado alrededor de la inteligencia artificial (IA) aplicada en la movilidad inteligente.

Dado lo anterior, la realización de esta monografía implicó la lectura del documento de la investigación referenciada, en el cual se identificaron dos términos claves: “Intelligent mobility” y “artificial intelligence”; por esta razón, la búsqueda documental se centró en ellos. No obstante, se tuvieron en cuenta términos sinónimos o relacionados con “Intelligent mobility” como “intelligent transportation”, “smart transport”, “advance mobility” y “smart mobility”; y términos sinónimos o relacionados con “artificial intelligence” como “machine learning”, “intelligent systems”, “cognitive computing” y “computational intelligent”. En consecuencia, el query utilizado para la búsqueda documental fue: (“intelligent mobility” OR “intelligent transportation” OR “smart transport” OR “advance mobility” OR “smart mobility”) AND (“artificial intelligence” OR “machine learning” OR “intelligent systems” OR “cognitive computing” OR “computational intelligent”).

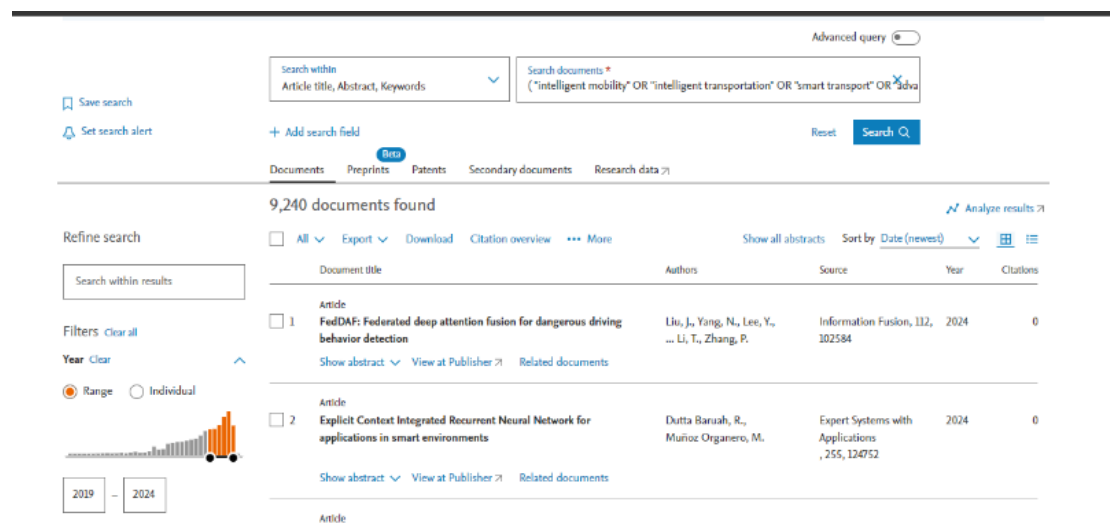
El query es un conjunto de palabras organizadas de manera estratégica para insertar en los cuadros de búsqueda de las bases de datos como Scopus y WoS; las cuales se utilizan para investigaciones y estudios bibliométricos, porque son bases de datos confiables y reconocidas internacionalmente que ofrecen acceso a publicaciones científicas de alta calidad, permitiendo un análisis de impacto, tendencias de investigación y citas de diversas disciplinas (Chaparro-Martínez et al., 2016).

Cabe resaltar que para esta investigación documental solo se utilizó Scopus, debido a 17 que ofrece una cobertura más amplia en áreas multidisciplinarias como la tecnología, la ingeniería y las ciencias aplicadas, que son clave para este tema. Además, incluye una mayor cantidad de conferencias y actas, fundamentales en campos de rápida evolución como la IA, donde las innovaciones suelen publicarse primero en eventos técnicos antes que en revistas (Martínez Musiño, 2021).

Una vez realizado el query, se insertó el resultado en el espacio "search documents" que ofrece Scopus. En la opción para refinar la búsqueda, se limitó el rango de años entre 2019 y 2024 como se muestra en la figura 1. Así entonces, evita información obsoleta y permite centrarse en los estudios más recientes y relevantes, garantizando que el análisis bibliométrico refleje el estado más actualizado del conocimiento, en un campo de rápida evolución como la inteligencia artificial o la movilidad inteligente.

Figura 1

Resultado Scopus



Nota. Página de búsqueda Scopus.

considerable de publicaciones sobre el tema. Este resultado refleja el auge del tema a investigar en los últimos años. Se puede inferir que el campo de la IA y la movilidad inteligente están en pleno desarrollo, con una gran cantidad de investigaciones y avances. Además, este volumen de información es una excelente base para un estudio bibliométrico sólido y posibilita un análisis más detallado de las tendencias actuales; pero también subraya la necesidad de refinar aún más los criterios de búsqueda para manejar eficientemente la cantidad de datos, posiblemente a través de la identificación de palabras clave más específicas o la priorización de las publicaciones más citadas. Por esta razón, en este estudio bibliométrico se utilizó una herramienta adicional para filtrar aún más los resultados y centrarse en los estudios más influyentes o específicos dentro del área de interés.

Para lo anterior, se realizó una extracción de todos los documentos encontrados en Scopus en formato RIS (*Research Information Systems*). RIS es un estándar para el intercambio de datos bibliográficos utilizado en herramientas de gestión de referencias. Éste se emplea para exportar y compartir información sobre publicaciones académicas, como autores, títulos, fechas de publicación, resúmenes y otros metadatos de documentos, entre diferentes bases de datos y programas como EndNote, Zotero o Mendeley.

En el caso de Scopus, el formato RIS sirve para extraer referencias de documentos seleccionados, facilitando su importación a un software de gestión bibliográfica, donde los investigadores pueden organizar, analizar y citar las fuentes en sus propios estudios o proyectos de manera eficiente. Una vez extraído los documentos de Scopus en el formato RIS y guardados como archivo se cargaron en la herramienta SciMat.

Para el desarrollo de este trabajo investigativo se eligió SciMat como herramienta para el estudio bibliométrico, porque permite un análisis integral de la evolución de la ciencia y de las estructuras temáticas en diversas áreas del conocimiento. SciMat está diseñada para identificar, analizar y visualizar las dinámicas científicas a lo largo del tiempo, facilitando el seguimiento de tendencias, la evolución de temas emergentes y el mapeo de redes de colaboración en investigaciones (Cobo et al., 2012).

El uso de esta herramienta en estudios bibliométricos dentro del ámbito de la ingeniería y la IA tiene un impacto significativo, debido a la naturaleza compleja, multidisciplinaria y en constante evolución de estos campos. Ambas áreas están impulsadas por el desarrollo tecnológico y la necesidad de soluciones innovadoras, lo que hace crucial el análisis de las tendencias de investigación, los temas emergentes y las colaboraciones entre científicos e instituciones.

Además, SciMat destaca por su capacidad para generar mapas estratégicos y analizar la evolución de temas en períodos específicos, proporcionando una perspectiva a lo largo del tiempo durante el desarrollo de la investigación. En disciplinas como la IA, donde la innovación avanza rápidamente, este enfoque temporal ayuda a entender cómo las tecnologías emergen, maduran y declinan. También es útil para identificar áreas de investigación interdisciplinaria, especialmente en la IA aplicada a la ingeniería, donde las sinergias entre disciplinas son cada vez más importantes.

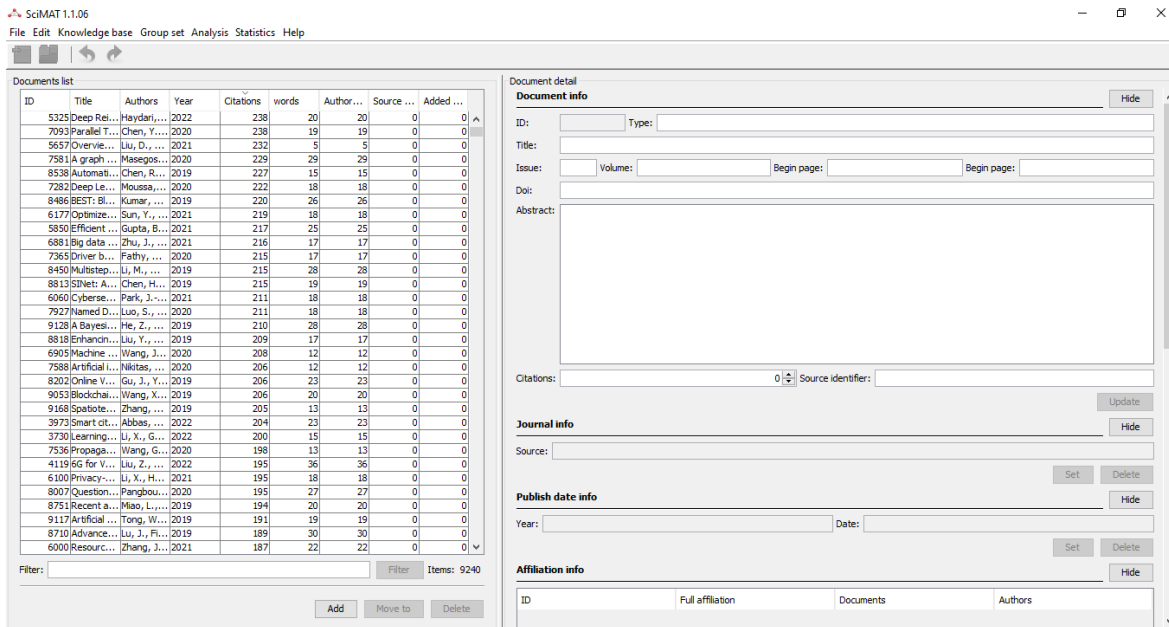
La herramienta permite a los investigadores y a las instituciones científicas tomar decisiones estratégicas, ya que proporciona información valiosa sobre patrones de citación, redes

de colaboración y áreas de crecimiento potencial (Cobo et al., 2012). SciMat ayuda a priorizar 20 recursos y esfuerzos en temas con mayor impacto o potencial de desarrollo futuro.

Así pues, con el uso de la herramienta SciMat una vez cargado el archivo por medio del formato RIS, se genera una lista y los documentos que podemos visualizar dentro de recuadros identificados por los siguientes ítems: ID, título, autores, año de publicación, número de citas y fuente de palabras, como se muestra en la figura 2. Con lo anterior se realiza una primera filtración de la búsqueda: de los 9.240 documentos se eliminan los documentos que no tienen citación.

Figura 2

Herramienta SciMat para Estudio Bibliométrico



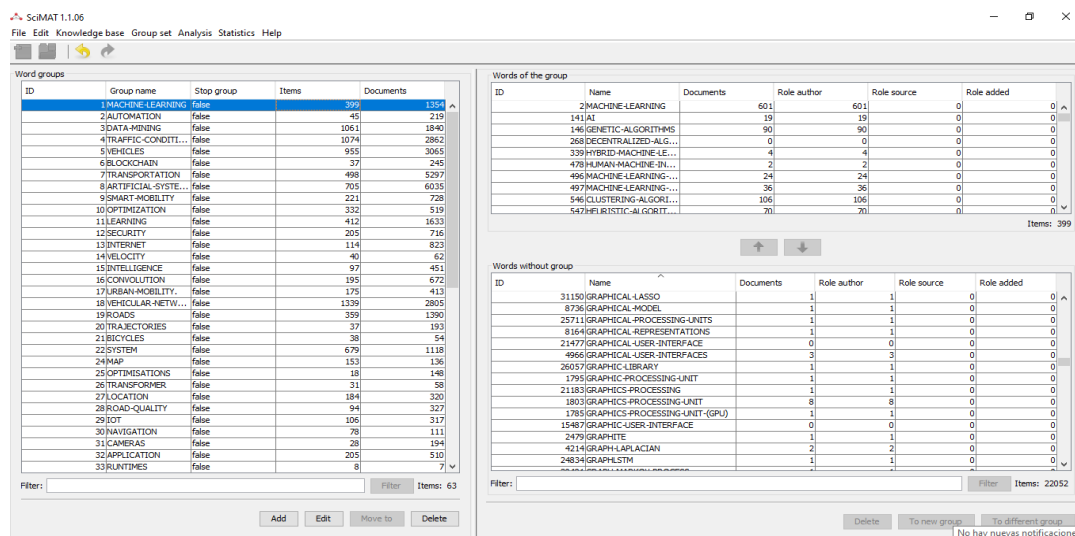
Nota. Archivo RIS cargado en SciMat.

Después de esta filtración, se obtuvo un total de 6.525 documentos respecto a los 21

9.240, que se habían cargado en la herramienta SciMat; así se avanzó hacia el siguiente proceso de filtración de documentos, el cual consiste en agrupar palabras de forma manual. Este proceso está conformado por medio de tres recuadros en la herramienta, como se muestra en la Figura 3: en el recuadro inferior derecho se encuentra una cantidad de palabras claves dentro de los 6.525 documentos; algunas de estas palabras claves se localizan en un número mayor de documentos que otras.

En el espacio de filtración de las palabras, se escribe alguna de las que se están visualizando en el recuadro izquierdo de la figura 3, para que la herramienta busque de forma automática una lista de palabras sinónimas, en común o relacionadas. Luego se agrupan todas estas palabras, y se nombran cabezas de grupo. Este proceso se repite para generar una base de grupos bastante amplia, que permita hacer análisis por periodos de tiempo, que son segmentados en el siguiente paso.

Figura 3
Creación de Grupos Palabras Clave



Nota. Set de grupos herramienta SciMat.

El siguiente paso consiste en definir unos intervalos de tiempo con los años en los que 22 fueron publicados los documentos de investigación. Cabe resaltar que la búsqueda de documentos en la base de datos contempló solo aquellos publicados entre 2019 y 2024. Se agruparon en intervalos de dos años, de modo que quedaron divididos en tres periodos: 2019-2020, 2021-2022, 2023-2024. La decisión de hacer tres periodos se basa en que, al tener un mayor número de periodos y una buena base de grupos de palabras, se puede generar un análisis más amplio en las gráficas, las cuales se representan en planos geométricos; como se detallará más adelante.

Seguidamente, se construyó el análisis por medio de un proceso de once pasos que ofrece la herramienta (ver figura 4), a saber:

1. Select periods: se seleccionaron los tres periodos creados anteriormente y se cargaron al recuadro derecho.

2. Select unit of analysis: se señalaron las unidades de análisis, para lo cual se eligieron tres criterios: las palabras enlazadas con los autores, las palabras fuentes y las palabras adicionadas.

3. Data reduction: se habilitó la reducción de datos con el parámetro frecuencia de reducción, el cual consiste en establecer un mínimo de frecuencia en la que un término debe aparecer en los documentos, para que este sea incluido en el siguiente análisis. En este caso, se le pidió a SciMat que la frecuencia de reducción fuera de 3 en cada periodo y para cada documento, dado que el análisis incluía demasiados artículos.

4. Select kind of matrix: se eligió el tipo de matriz de co-ocurrencia, la cual cuantifica la frecuencia en la que aparecen los términos dentro de una misma unidad de análisis. Esta matriz permite construir redes temáticas e identificar clústeres conceptuales.

5. Network reduction: la reducción de la red en cada periodo consiste en establecer un valor que corresponde a la cantidad mínima de documentos en los clústeres temporales de investigación; este paso elimina conexiones débiles o poco relevantes entre los clústeres. En este caso, se le pidió a la herramienta SciMat que eligiera mínimo 3 documentos por periodo.

6. Normalization: En este paso, se eligió la opción de equivalencia para depurar los documentos en los que la ocurrencia de los términos no tenga una relación temática significativa.

7. Clustering algorithm: se eligió el algoritmo de selección de cluster de centros simples. En este caso, se eligió mínimo 3 y máximo 6, dada la cantidad de documentos que se analizaron. Este paso permitió delimitar los temas de investigación para la formación de redes interconectadas en grupos coherentes, los cuales representan núcleos temáticos en el área de investigación.

8. Document mapper: Se realizaron los mapeos necesarios para el análisis. Se seleccionaron “*Core mapper*” y “*Secondary mapper*” para definir la unidad de análisis en la que se va a identificar los temas y para definir la información adicional que se va a utilizar para filtrar los documentos.

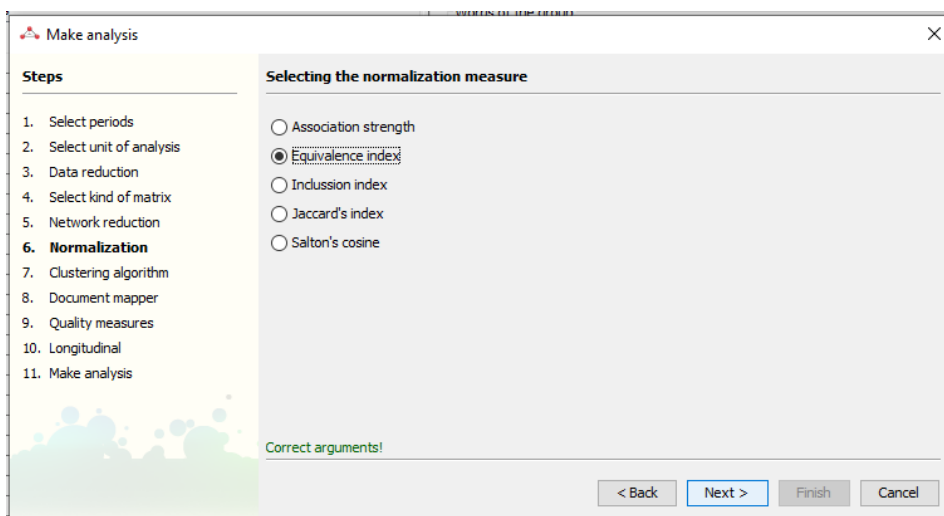
9. Quality measures: se escogieron las medidas de calidad e impacto de los temas en cada documento. Se seleccionó “*h-index*” para medir la productividad y el impacto de los documentos; y “promedio de citas” para medir la influencia de cada artículo.

10. Longitudinal: En este paso, se eligió la opción “*Equivalence index*”, que corresponde a la cuantificación de similitud de palabras clave a lo largo del tiempo. Este parámetro permite construir y analizar redes evolutivas para evaluar la evolución del tema científico en cuestión.

11. Make analysis: Este último paso le da la orden a la herramienta para realizar el análisis con todos los parámetros que se establecieron en los pasos anteriores.

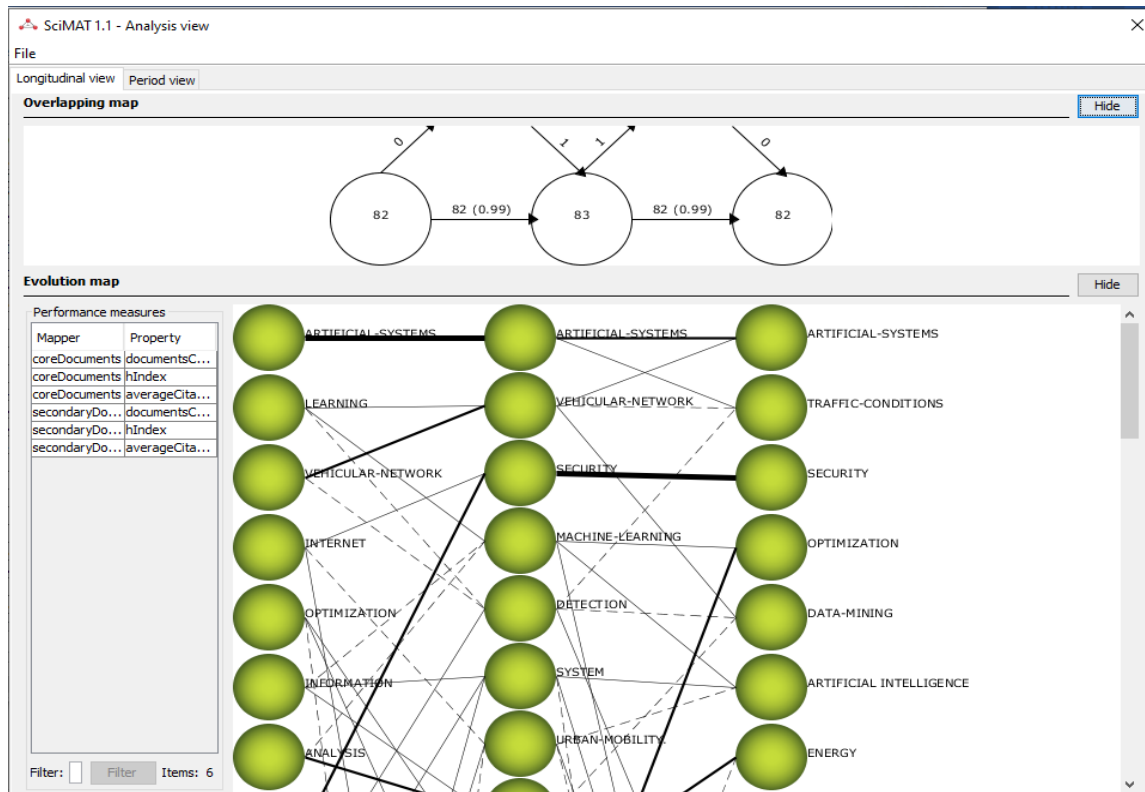
Figura 4

Pasos para Generar Análisis



Nota. Make análisis herramienta SciMat.

Una vez realizados los pasos anteriores, SciMat carga el análisis mostrando dos opciones de vista por medio de pestañas de elección, como se observa en la figura 5: la primera está denominada Overlapping map, que muestra una gráfica horizontal con tres círculos que corresponden a cada periodo y los movimientos de documentos de un periodo a otro. La segunda se denomina Evolution map; muestra una gráfica vertical, con tres columnas que representan los tres periodos; además, agrupa todos los documentos representados en círculos verdes, y que coinciden con las palabras sinónimas y relacionadas; adicionalmente, se observan líneas que evidencian conexiones entre ellos.

Vista Longitudinal

Nota. Análisis herramienta SciMat.

En la figura anterior, se presentan las relaciones de co-ocurrencia de términos claves y la co-citación. En estudios bibliométricos, las técnicas de co-ocurrencia de palabras clave y co-citación permiten identificar y mapear relaciones entre conceptos y publicaciones en un área de investigación. La co-ocurrencia de palabras clave examina aquellas que aparecen juntas en diferentes artículos, revelando así vínculos temáticos y ayudando a formar clústeres de investigación sobre temas relacionados. Esta técnica permite observar tendencias y agrupar conceptos emergentes en el campo.


conjuntamente en publicaciones posteriores, lo cual destaca aquellos trabajos que son recurrentemente referenciados de forma conjunta y que, por lo tanto, comparten un vínculo conceptual significativo. Ambas técnicas brindan una visión integral sobre la estructura temática e intelectual de un área de estudio.

En el análisis de mapas científicos, cada *clúster* es representado por una esfera que agrupa sus documentos asociados, lo cual permite la asignación de documentos a subredes mediante funciones de mapeo, como se muestra en la figura 6. Aunque los pasos de visualización y mapeo son distintos, están interrelacionados, ya que la técnica de visualización depende del método seleccionado para crear el mapa.

Los clústeres detectados se categorizan con diagramas estratégicos y su evolución en el tiempo se muestra mediante técnicas como clúster string, rolling clustering y diagramas aluviales (Cobo et al., 2012). La visualización mejora integrando datos de rendimiento, añadiendo una tercera dimensión y haciendo que el tamaño de cada esfera sea proporcional a sus citas, lo que permite una interpretación más rica y precisa.

Figura 6

Red de Clúster Formada a Partir de Documentos Asociados al Clúster



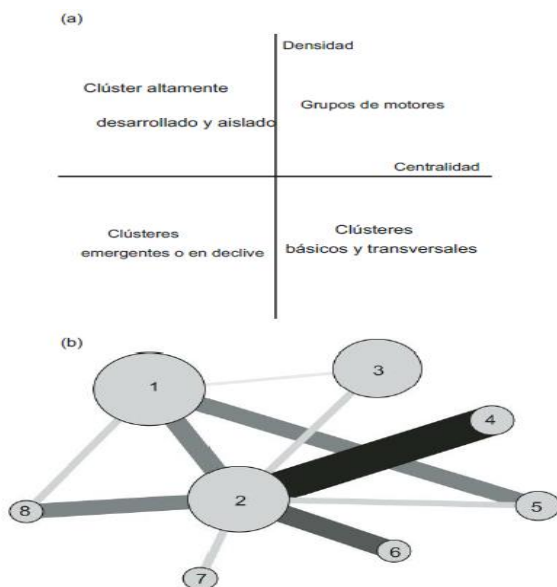
Nota. SciMat (Cobo et al., 2012).

estratégico, la red de clústeres, el mapa de evolución y el mapa de superposición, con el fin de realizar una mejor interpretación de las tendencias a través de periodos de tiempo sobre el tema que se está investigando. El diagrama estratégico (figura 7) organiza los clústeres de cada período en un espacio bidimensional según las medidas de densidad y centralidad, permitiendo clasificar los temas en función de su relevancia y conectividad en la red de investigación. Cada clúster se enriquece con métricas bibliométricas seleccionadas, y su red asociada (figura 7b) representa visualmente las relaciones entre elementos.

Para el análisis temporal o longitudinal, se emplean el **mapa de evolución** y un gráfico de **ítems superpuestos** (figura 8). En la Figura 8a, se observan áreas de evolución diferenciadas por color: una compuesta por los Clústeres A1 y A2, y otra por B1, B2 y C2. El Clúster D1 se interrumpe y D2 aparece como un nuevo conjunto de investigación.

Figura 7

Diagramas de Visualización: Estratégico y Red de Clúster


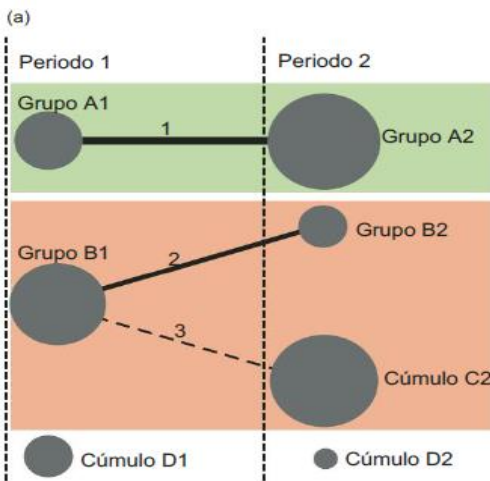


Nota. SciMat (Cobo et al., 2012).

cuando comparten el ítem principal y discontinuas (Línea 3 de la figura 8a) cuando comparten otros elementos. El grosor es proporcional al Índice de Inclusión, y el volumen de las esferas depende del número de documentos. En el gráfico de ítems superpuestos (Figura 8b), los círculos representan períodos y sus ítems; mientras las flechas indican estabilidad, cambios o nuevos elementos entre los períodos, facilitando la interpretación de la evolución en los temas de investigación.

Figura 8

Gráficos de Evolución e Ítems Superpuestos



Nota. SciMat (Cobo et al., 2012).

Interpretar correctamente los diagramas generados por SciMat es fundamental para comprender la estructura y evolución de un campo de investigación. Los gráficos, como el

diagrama estratégico, el mapa de evolución y el de ítems superpuestos, no solo muestran relaciones entre temas, sino que también permiten visualizar la relevancia y centralidad de los clústeres, así como su estabilidad o transformación a lo largo del tiempo. La capacidad de leer estos elementos proporciona información valiosa sobre las tendencias, áreas emergentes y consolidación de temas. Esto ayuda a los investigadores a tomar decisiones informadas sobre futuras líneas de estudio. De esta manera, el análisis de SciMat se convierte en una herramienta poderosa para profundizar en el conocimiento y fortalecer el desarrollo científico estratégico. El análisis de todos los elementos se presenta en el siguiente apartado.

Análisis Bibliométrico sobre Inteligencia Artificial Aplicada en la Movilidad Inteligente 30

En este análisis bibliométrico se explora el estado y las tendencias de investigación sobre la IA aplicada en la movilidad inteligente, a través de los resultados arrojados por la herramienta SciMat. La evaluación se centra en identificar clústeres temáticos y redes de colaboración que han surgido en torno a tecnologías y prácticas sostenibles de transporte, a través de gráficos como el diagrama estratégico y el mapa de evolución. El análisis revela las dinámicas y progresos en determinados clústeres, facilitando así la identificación de áreas clave y futuras líneas de desarrollo científico y tecnológico en sostenibilidad.

Ahora bien, después de compilar el análisis al cual se hizo referencia anteriormente, la herramienta SciMat arrojó una serie de imágenes que se encuentran como apéndices y otras como figuras a partir de esta página del documento. Por ejemplo, en el “*Overlapping map*” de la figura 5, se observan tres círculos grandes con números dentro de cada uno de ellos; estos números dentro de los círculos corresponden al número de clústeres de palabras clave que se encuentran en cada periodo. El “*Overlapping map*” permite visualizar la evolución de las temáticas estudiadas en un campo de investigación a lo largo de distintos periodos de tiempo. Los círculos representan periodos de tiempo, mientras que las flechas entre ellos indican las conexiones o relaciones de continuidad entre los periodos, así: 2019-2020, 2021-2022 y 2023-2024, de izquierda a derecha. El alto valor de superposición (**0.99**) refleja una gran similitud entre los periodos, lo que sugiere que las líneas de investigación han mantenido su estabilidad y relevancia con el paso del tiempo.

En este caso, de acuerdo con la poca variabilidad en el número de clústeres de cada periodo (numerados como 82, 83 y 82), se puede afirmar que las áreas de investigación, a lo largo de los tres periodos son persistentes porque se conservan casi completamente en los diferentes

periodos. En el periodo intermedio parece surgir un clúster más que en los otros periodos, lo 31 que podría interpretarse como un tema emergente, mientras que los clústeres 82 muestran una continuidad a lo largo del tiempo, evidenciando su importancia en el campo. Además, los números dentro de los círculos indican el número de clústeres, o sea las áreas de investigación que componen cada periodo.

En el mapa de evolución o “*Evolution map*” de la figura 5, se evidencian tres columnas que representan los tres periodos. Cada periodo tiene clústeres, algunos más relevantes que otros. A medida que estos clústeres pasan a otro periodo, su tamaño puede aumentar o disminuir, de acuerdo con la cantidad de citas. El aumento de un clúster de un periodo a otro está representado por una línea gruesa; y la disminución está representada por una línea delgada. Tal es el caso del clúster “*Artificial Systems*”, que está representado en cada uno de los periodos, y vinculado con líneas más gruesas que otras. La línea gruesa que conecta “*Artificial Systems*” del primer al segundo periodo, muestra que durante el segundo periodo este tema más recurrente que en el primero. Por su parte, entre el segundo y el tercer periodo (2023-2024) la línea de este clúster es más delgada. En este caso, esta línea no significa que la relevancia del clúster disminuyó sino que, debido a que este estudio bibliométrico empezó durante el año 2024, las investigaciones en torno a los temas no han terminado. Ahora bien, la permanencia de este clúster en los tres periodos evidencia que “*Artificial Systems*” es un tema de alta relevancia en los tres periodos y de mucho interés respecto de otros temas. Asimismo, muestra una tendencia en los temas de investigación que representan en el mapa, los cuales siguen enfocándose en “*Artificial Systems*”, a pesar de que el estudio bibliométrico se empezó a realizar en el último trimestre del año 2024.

Por otra parte, se analizó otros clústeres de menor tamaño pero que también muestran algo de evolución dentro del mapa. Por ejemplo, en el primer periodo, "*Vehicular network*" es el segundo clúster más grande, y tuvo un crecimiento significativo para el segundo periodo. Estos clústeres del mismo nombre están conectados por una línea gruesa, porque refleja una mayor intensidad de conexión o importancia de esta relación, en comparación con el segundo periodo. El grosor de la línea sugiere que "*Vehicular-Network*" tuvo un papel más significativo o relevante en el primer período, especialmente en su relación con otros conceptos clave como "*Artificial-Systems*" y "*Security*".

En el segundo período, aunque "*Vehicular-Network*" aún se conecta con "*Traffic-Conditions*", la línea es más delgada y está punteada, lo que indica que la relación ha perdido intensidad o relevancia. Esto puede interpretarse como un cambio en el enfoque, pues "*Traffic-Conditions*" está relacionado de manera secundaria o menos directa con "*Vehicular-Network*", posiblemente debido a una reducción en la importancia del concepto o a la aparición de nuevas conexiones más fuertes con otros clústeres.

Por otra parte, en el Apéndice A, se observa otro mapa de evolución de forma completa, que proporciona una explicación detallada sobre la relevancia de los clústeres en el área académica, por medio del h-index que indica el impacto de los documentos que hacen parte del clúster, de acuerdo con sus citas e influencia dentro de la comunidad científica. Ahora bien, en dicha figura (Apéndice A) se observa un cambio significativo del clúster "*blockchain*" entre el primer periodo y el tercero, el cual tiene una línea de conexión densa con el clúster "*Security*" en el segundo periodo; y luego este clúster tiene una línea de conexión más densa con el clúster también denominado "*Security*" en el tercer periodo. Dado que el clúster "*Blockchain*" hace parte del área de la seguridad, parece que fue muy utilizado y estudiado en el primer periodo. No

obstante, se presume que en el segundo y tercer periodo, los temas de seguridad informática en³³ relación con la movilidad inteligente expandieron el espectro temático; por ello, se empezaron a incluir otras tecnologías (no solo el “*blockchain*”), que permitieron hablar de “Security” en general y que este clúster se ha vuelto más importante en la red conceptual.

Esta evolución dinámica de las conexiones es característica de los sistemas de análisis de redes, donde las interrelaciones entre conceptos no son estáticas, sino que se transforman constantemente. Las variaciones en el grosor y el estilo de las líneas sugieren una metamorfosis conceptual, que señala que algunos clústeres pueden ganar o perder importancia relativa con el tiempo. Lo anterior refleja la complejidad y adaptabilidad de estos modelos de interconexión.

De manera complementaria a lo anterior, en el mapa de evolución que se presenta en el Apéndice C, se proporciona una visión detallada sobre los documentos más citados mediante el análisis que nos arroja la herramienta SciMat. Este es el caso del clúster “*Blockchain*”, uno de los más grandes en el primer periodo en comparación con los otros, lo que sugiere una alta frecuencia de citación. Esto implica que los documentos relacionados con el “*Blockchain*” han sido recurrentes y fundamentales en la literatura científica analizada, convirtiéndose en un tema altamente citado y que seguramente proyectó la investigación hacia otros tipos de seguridad, razón por la cual evolucionó a “*Security*”. La prominencia de este clúster refleja su relevancia actual como un campo emergente, especialmente en áreas como seguridad, análisis de datos y sistemas descentralizados, lo que ha captado la atención de la comunidad científica.

Además, la investigación en el área de “*Security*” no se limita a un campo específico, sino que se integra con otras áreas clave, como lo evidencian sus conexiones con términos como “*Internet*”, “*Analysis*” y “*Detection*”. Esta interdisciplinariedad aumenta su impacto y lo posiciona como un tema central en los estudios incluidos en el análisis bibliográfico. La

prominencia del término “*Security*” también sugiere un crecimiento reciente en su producción ³⁴ y citación, reflejando su desarrollo como una tendencia emergente en la investigación científica.

Por otro lado, la presencia de “*Security*” en los documentos más citados podría estar relacionada con su publicación en revistas de alto impacto o por autores influyentes, lo cual incrementa su visibilidad y frecuencia de citación. Así, su tamaño considerable en el gráfico revela su importancia como un eje temático de alto impacto y relevancia interdisciplinaria dentro del análisis bibliográfico.

Además del anterior clúster analizado, en el Apéndice C se puede observar que en el segundo periodo se encuentra el clúster más grande de la gráfica, llamado “*Empirical Knowledge*”. Su tamaño se puede explicar a partir de su papel como base metodológica en investigaciones de diversas disciplinas. Este término está estrechamente relacionado con el análisis de datos, observaciones y resultados basados en la experiencia, lo que refuerza su valor como eje fundamental en estudios de alto impacto. Además, sus múltiples conexiones con otros conceptos, como “*Cognitive Factors*”, “*Rider Safety*” y “*Velocity*” evidencian que este clúster actúa como un nexo interdisciplinario en investigaciones complejas, integrando aspectos técnicos, metodológicos y aplicados.

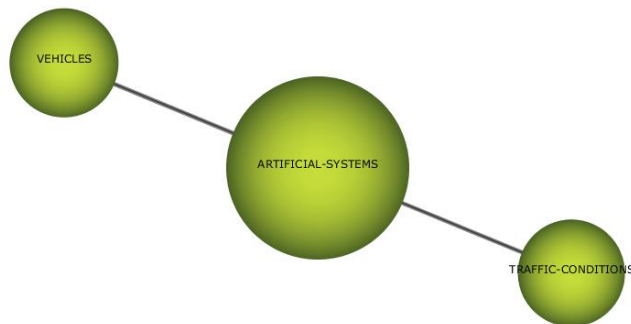
Por otra parte, el hecho de que “*Empirical Knowledge*” sea central en los documentos más citados sugiere que los estudios que incorporan este concepto ofrecen resultados robustos y verificables, lo cual aumenta su impacto en la comunidad científica. Los enfoques empíricos tienden a atraer más atención debido a su aplicabilidad práctica y su capacidad de validar hipótesis a partir de evidencias concretas; características que suelen ser altamente valoradas en investigaciones citadas con frecuencia.

Luego de describir y analizar las figuras de los Apéndices A, B y C; este apartado se enfoca en el análisis del primer periodo, presentado a través del diagrama estratégico del Apéndice D, arrojado por la herramienta SciMat. Este diagrama muestra la cantidad de documentos por área de investigación. Además, el diagrama estratégico del Apéndice E, muestra la gráfica de coreDocumentshIndex sobre el primer periodo, el cual sirve para evaluar los documentos centrados de mayor impacto y relevancia. Por último, está el Apéndice F que muestra un diagrama estratégico con los clústeres con mayores documentos citados dentro del primer periodo, encontrados entre el año 2019-2020.

En el caso del clúster “*artificial systems*”, en el Apéndice D podemos observar que dentro del círculo que representa al clúster se encuentra un número 36; sin embargo, este número no corresponde al tamaño del clúster, ya que es el más grande de la gráfica y el número correcto es 1536. Para este caso es necesario revisar el reporte en PDF extraído de la herramienta SciMat o en su defecto una carpeta en formato de lectura HTML fraccionado por periodos y por clúster obtenidos de acuerdo al análisis.

En el Apéndice D, dentro de los diagramas estratégicos, en cada periodo se encuentran tablas de información numérica sobre cada clúster de la gráfica, dado que no se pueden observar bien los números de algunos clústeres debido a su tamaño.

Por lo anterior y teniendo en cuenta el Apéndice D, se realizó un análisis del clúster más grande, que es “*Artificial- Systems*”. Para ello, se tomó como fuente de información el análisis gráfico que nos da la herramienta como se muestra en la figura 9.

Red del Clúster Artificial-Systems

Nota. Archivo html SciMat

Con la anterior grafica del clúster "*Artificial Systems*" y de acuerdo a la información suministrada del análisis SciMat, se observa que este tiene una densidad de 35.94 y una centralidad de 87.64, se posiciona como el núcleo principal del análisis y un eje estratégico dentro del mapa temático. Su alta densidad refleja una fuerte cohesión interna, lo que indica un desarrollo sólido y consistente en los documentos asociados. Además, su centralidad elevada resalta su papel como un puente clave entre otros clústeres, estableciendo conexiones significativas con "*Vehicles*" y "*Traffic Conditions*". Estas características lo convierten en un punto focal de investigación interdisciplinaria que conecta tecnologías avanzadas con el análisis de condiciones de tráfico y movilidad.

El análisis singular de este clúster es crucial, ya que permite profundizar en las dinámicas y aplicaciones de los sistemas artificiales dentro de la movilidad inteligente. Estos sistemas actúan como catalizadores en la evolución de tecnologías eco-amigables y en la optimización del transporte, aportando soluciones innovadoras que abordan tanto la sostenibilidad como la

eficiencia en el tráfico urbano. La interpretación detallada de este clúster, en términos de sus documentos asociados, relaciones y métricas, permitirá identificar tendencias emergentes, patrones de evolución y áreas de oportunidad en el campo. Este enfoque estratégico facilita comprender cómo los sistemas artificiales moldean el futuro de la movilidad inteligente y su impacto en el desarrollo tecnológico global. 37

Además, el clúster "*Artificial Systems*" se encuentra ubicado en la esquina superior derecha del diagrama estratégico, lo que lo posiciona como un tema motor dentro del análisis bibliométrico. Esta ubicación indica que posee altos valores tanto de densidad como de centralidad, lo que refleja una fuerte cohesión interna y una influencia significativa en la red general de investigación. Su posición destaca su relevancia estratégica como un tema consolidado y altamente conectado, capaz de actuar como un eje central en el desarrollo de tecnologías y en la interconexión con otros clústeres. Además, su prominencia en esta área del diagrama señala que "*Artificial Systems*" es clave para impulsar la innovación en movilidad inteligente y tecnologías eco-amigables, al mismo tiempo que conecta múltiples disciplinas y temas complementarios.

Esta posición estratégica de este clúster resalta no solo su influencia temática, sino también la relevancia de los documentos de investigación asociados que la herramienta SciMat ha identificado. Estos documentos constituyen la base para analizar en profundidad las aplicaciones y avances tecnológicos vinculados a los sistemas artificiales. La recopilación de estas publicaciones, se muestra en la **tabla 1**, donde se observa los documentos de más alta relevancia. Lo que permite comprender las líneas de investigación predominantes, las colaboraciones entre autores e instituciones, y los resultados más destacados en este ámbito.

Obtener y examinar estos documentos es fundamental para el estudio bibliométrico, ya 38 que ofrecen información valiosa sobre la evolución histórica del tema, la distribución geográfica de las investigaciones y las citas recibidas por cada trabajo. Esto, a su vez, facilita identificar patrones de desarrollo, temas emergentes y áreas de oportunidad que pueden orientar futuras investigaciones. La selección e interpretación adecuada de estos documentos garantiza un análisis robusto que respalda la relevancia del clúster en la movilidad inteligente y su impacto en las tecnologías sostenibles.

Tabla 1


Lista de los Documentos más Relevantes Clúster Artificial Systems

Título del trabajo	Cita	Numero de citas
Big Data Analytics In Intelligent Transportation Systems: A Survey	(Zhu et al., 2019)	731
Evolutionary V2x Technologies Toward The Internet Of Vehicles: Challenges And Opportunities.	(H. Zhou et al., 2020)	436
Applications Of Artificial Intelligence And Machine Learning In Smart Cities.	(Ullah et al., 2020)	413
Urban Traffic Prediction From Spatio-temporal Data Using Deep Meta Learning.	(Pan et al., 2019)	383
Dynamic Event-triggered Distributed Coordination Control And Its Applications: A Survey Of Trends And Techniques	(Ge et al., 2020)	372
Energy Management Strategies Of Connected Hevs And Phevs: Recent Progress And Outlook	(F. Zhang et al., 2019)	343
Deep Spatialoral 3d Convolutional Neural Networks For Traffic Data Forecasting	(S. Guo et al., 2019)	288

Nota. Documento html de la herramienta SciMat.

Como resumen de la tabla anterior, se puede decir que los sistemas artificiales han sido ³⁹ el motor principal de investigación durante este primer periodo, concentrándose especialmente en la predicción de tráfico mediante redes neuronales complejas, la prevalencia de artículos de revisión evidencia el creciente interés investigativo en aplicaciones de "*Artificial Systems*" dentro del ámbito de la movilidad inteligente, particularmente en la implementación de big data para sistemas de transporte y "*Machine-Learning*" en ciudades inteligentes. Paralelamente, se observa un interés significativo en la gestión energética para vehículos eléctricos híbridos conectados, desarrollando un marco de clasificación que categoriza estos sistemas según diferentes escenarios de interacción vehicular, con particular énfasis en la comunicación vehículo-infraestructura para la conducción ecológica, demostrando la convergencia tecnológica orientada al desarrollo de sistemas de transporte más eficientes y sostenibles.

Dentro de este orden de ideas, se continua con el análisis del primer periodo donde se encuentra otras relaciones de clúster entrelazados que nos arroja la herramienta y que pueden ser de alta relevancia para una investigación que se centra en estos temas, como se muestra en la siguiente figura 10, mostrando una semejanza con la figura 9 pero ahora con otros protagonistas. Al igual que el análisis previo, en esta ocasión también se traerá información de la herramienta, sobre los documentos de investigación influyentes de este análisis.

Red de Clúster Learning

Nota. Archivo html SciMat

El clúster central denominado *“Learning”* en el diagrama presentado destaca por su posición estratégica, ubicándose en un punto de conexión entre los temas circundantes como *“Machine-Learning”* y *“Convolution”*. Esta ubicación sugiere que actúa como un eje fundamental en la interrelación de conceptos dentro del análisis bibliométrico, uniendo áreas clave relacionadas con el aprendizaje y sus aplicaciones en contextos tecnológicos. Su centralidad en la red lo convierte en un tema prioritario para el análisis, ya que refleja una alta relevancia y conectividad con otros términos de interés.

Examinar *“Learning”* permite identificar las tendencias y enfoques predominantes en investigaciones relacionadas con los procesos de aprendizaje en sistemas inteligentes, proporcionando una visión integral de su papel en el desarrollo de tecnologías avanzadas. Además, debido a su posición, es probable que este clúster represente un campo dinámico y en evolución constante, siendo un indicador clave de innovación y avance conceptual. Su análisis detallado permite comprender cómo el aprendizaje está siendo conceptualizado y aplicado, así

como identificar las conexiones más relevantes entre las áreas relacionadas. Esto resulta esencial para extraer conclusiones que guíen investigaciones futuras y profundicen en su impacto dentro del marco de la inteligencia artificial y la movilidad inteligente. Ahora bien, El análisis del calibre de conexión entre los clústeres “*Machine-Learning*”, “*Learning*” y “*Convolution*” revela diferencias significativas en la fuerza de las relaciones. La conexión más fuerte se presenta entre “*Learning*” y “*Convolution*” con un valor de 0.13, lo que indica una interacción relevante y directa entre estas áreas, probablemente debido a la adaptación continua y los avances conceptuales asociados al aprendizaje y su evolución. Por otro lado, la relación entre “*Machine-Learning*” y “*Learning*”, con un valor de 0.12, refleja una conexión sólida pero ligeramente menor, sugiriendo que “*Learning*” actúa como un puente central entre los enfoques más generales del aprendizaje y su implementación específica en sistemas de aprendizaje automático.

Finalmente, la conexión entre “*Machine-Learning*” y “*Convolution*” es más débil, con un valor de 0.02, lo que podría indicar una interacción menos directa entre estos clústeres, posiblemente mediada a través del clúster central “*Learning*”. Esto refuerza su importancia como nexo en esta red temática. Estas conexiones permiten vincular conceptos con los documentos más relevantes del análisis bibliométrico. Los textos destacados en la **tabla 2** reflejan fundamentos clave y avances en aprendizaje, aprendizaje automático y evolución conceptual, los cuales son los más relevantes y citados según el análisis realizado por la herramienta SciMat, lo que permite identificar tendencias prioritarias y enfoques emergentes en la investigación. Además, los documentos actúan como un puente entre la red temática y los estudios concretos, enriqueciendo la interpretación del análisis y destacando áreas clave en el panorama académico.

Lista de los Documentos más Relevantes Clúster Learning

Título del trabajo	Cita	Numero de citaciones
A Graph Cnn-lstm Neural Network For Short And Long-term Traffic Forecasting Based On Trajectory Data	(Bogaerts et al., 2020)	229
Enhancing Transportation Systems Via Deep Learning: A Survey	(Wang et al., 2019)	209
Online Vehicle Routing With Neural Combinatorial Optimization And Deep Reinforcement Learning	(Yu et al., 2019)	206
Advanced Planning For Autonomous Vehicles Using Reinforcement Learning And Deep Inverse Reinforcement Learning	(You et al., 2019)	189
Day-ahead Traffic Flow Forecasting Based On A Deep Belief Network Optimized By The Multi-objective Particle Swarm Algorithm	(L. Li et al., 2019)	180
Contextualized Spatialoral Network For Taxi Origin-destination Demand Prediction	(L. Liu et al., 2019)	176
Real-time Sensor Anomaly Detection And Identification In Automated Vehicles	(van Wyk et al., 2020)	175

Nota. Documento html de la herramienta SciMat.

Los siete artículos analizados aplican técnicas avanzadas de “*Deep learning*” y aprendizaje por refuerzo para abordar distintos retos en movilidad urbana y sistemas de transporte inteligente, comparten el uso de modelos híbridos (como CNN, LSTM, DBN, Graph CNN) que integran datos espaciales y temporales, mejorando la precisión y eficiencia en tareas como la predicción de tráfico, el control de vehículos autónomos, la logística y la detección de anomalías. Tres trabajos se enfocan en la predicción del tráfico, cada uno con enfoques distintos pero superiores a métodos tradicionales, otros abordan temas como la imitación de

comportamientos humanos (IRL), la optimización de rutas sostenibles mediante RL, y la detección en tiempo real de fallos en sensores de vehículos conectados. Uno de los estudios ofrece una visión panorámica de estas aplicaciones, resaltando tanto avances como desafíos, como la complejidad de los modelos y su implementación en entornos reales.


Aunque los enfoques varían, todos apuntan a mejorar la eficiencia, seguridad y sostenibilidad del transporte. Sin embargo, la falta de pruebas en escenarios reales y la heterogeneidad en métricas limita la comparación directa. En conjunto, reflejan un ecosistema tecnológico prometedor y en evolución, con potencial de integración entre sus distintas aportaciones.

Análisis Segundo Periodo 2021-2022

En el inicio del segundo periodo del análisis realizado por SciMat, los clústeres reflejan una distribución estratégica que permite identificar las áreas temáticas más relevantes y su impacto dentro del campo de estudio por área de investigación como se muestra en el gráfico del Apéndice G. La ubicación de los clústeres dentro del plano, determinada por su densidad y centralidad, ofrece una perspectiva clara de su evolución y relevancia en el tiempo. Los clústeres situados en la parte superior derecha del gráfico indican temáticas maduras y bien desarrolladas con alta influencia en la red académica, tales como "*Artificial Systems*" "*Vehicular-Network*" "*Security*" y "*Machine-Learning*" mientras que los de otras regiones pueden señalar temas emergentes o especializados como lo son "*Energy*" "*Clouds*" "*Urban Mobility*". Además, también se puede observar, como se hizo referencia en el primer periodo, en el Apéndice H donde los clústeres coreDocuments-hIndex hacen referencia al número de documentos de mayor impacto en los que se suman "*Security*" "*Detection*" "*Optimization*" situados en la esquina

superior derecha y que toman relevancia dentro de este periodo. Por último, dentro de este 44 segmento principal del segundo periodo de gráficos informativos, se encuentra el Apéndice I que hace referencia al número de documentos más citados en cada uno de los clústeres de la imagen, donde se observa que el clúster "*Empirical-Knowledge*" es el de mayor tamaño por su gran cantidad de documentos citados a pesar de que no tiene una ubicación estratégica de forma positiva en la densidad y centralidad de la información subministrada por la herramienta de investigación. De manera similar al primer periodo, se realiza un análisis de los clústeres más relevantes en el segundo periodo, ya sea por su tamaño, cantidad de documentos citados o centralidad. En esta ocasión se trae a colación el clúster "*Vehicular-Network*" como se muestra en la figura 11 con una conexión directa con los clústeres "*Learning*" "*Data-Mining*" en esta imagen se muestra un análisis estratégico de clústeres con características específicas, destacando un equilibrio entre densidad y centralidad. El clúster analizado posee una densidad de 12.42 y un rango de densidad de 0.96, lo que refleja una estructura interna cohesionada que facilita la colaboración y el desarrollo de conocimiento dentro de sus temáticas. Asimismo, su centralidad de 57.14 y un rango de centralidad de 0.96 evidencian una alta conectividad con otros clústeres, posicionándolo como un clúster crítico en la red investigativa.

Desde una perspectiva bibliográfica, este clúster es particularmente relevante debido a su capacidad para vincular temas emergentes con áreas consolidadas del conocimiento. Su posición estratégica permite que actúe como un puente entre disciplinas, promoviendo la transferencia de información y la innovación. Además, su destacada centralidad indica que las investigaciones asociadas a este clúster tienen un alto impacto y visibilidad dentro del campo de estudio.

Red del Clúster Vehicular-Network

Nota. Archivo Html SciMat

Para el análisis bibliométrico, este clúster representa una oportunidad para identificar tendencias clave, priorizar áreas de investigación y comprender cómo los temas interrelacionados influyen en el desarrollo científico. Su relevancia radica no solo en su contribución temática, sino también en su capacidad para fomentar sinergias entre diferentes campos, lo cual es esencial para la construcción de un panorama integral del conocimiento. Ahora bien, el análisis de este clúster también tiene documentos investigativos como se observa en la **tabla 3** que son clave sobre aprendizaje y evolución conceptual, identificados como los más relevantes según el análisis por SciMat. Estos textos revelan tendencias prioritarias, conectan redes temáticas con estudios concretos y enriquecen la interpretación del panorama académico, dentro de este periodo.

Lista de los Documentos más Relevantes Clúster Vehicular-Network

Título del trabajo	Cita	Numero de citaciones
Digital Twin Networks	(Wu et al., 2021)	371
Graph Neural Network For Traffic Forecasting: A Survey	(Jiang & Luo, 2022)	370
A Survey Of Deep Learning Applications To Autonomous Vehicle Control.	(Kuutti et al., 2021)	356
A Hybrid Deep Learning Model With Attention-based Conv-lstm Networks For Short-term Traffic Flow Prediction.	(Zheng et al., 2021)	270
Blockchain For The Internet Of Vehicles Towards Intelligent Transportation Systems: A Survey.	(Mollah et al., 2021)	264
Deep Reinforcement Learning For Intelligent Transportation Systems: A Survey.	(Haydari & Yilmaz, 2022)	238

Nota. Archivo html SciMat


Los anteriores artículos exploran distintas aplicaciones de tecnologías avanzadas como “*Blockchain*”, “*Deep learning*” y “*Deep reinforcement learning*” en el contexto del transporte inteligente, abordando problemáticas como la seguridad, eficiencia, predicción de tráfico y control vehicular, todos coinciden en la necesidad de soluciones escalables, precisas y seguras para entornos urbanos dinámicos. El uso de “*Blockchain*”, se destaca por su potencial para garantizar seguridad, privacidad y confianza mediante arquitecturas híbridas y algoritmos de consenso, en paralelo, los *Gemelos Digitales en Red* (DTN) abren nuevas posibilidades de personalización y eficiencia en ciudades inteligentes, aunque aún enfrentan desafíos de estandarización y recursos. Por su parte, uno de los artículos propone un modelo híbrido de predicción de tráfico con mecanismos de atención, superando enfoques previos gracias a su

capacidad para captar patrones complejos, entre tanto, otros profundizan en el control inteligente: uno en vehículos autónomos usando aprendizaje profundo y otro en la optimización de semáforos mediante *deep RL*, ambos con énfasis en eficiencia y toma de decisiones en tiempo real. 47

De igual forma, se prosigue con el análisis correspondiente al segundo periodo, identificando nuevas interacciones entre clústeres vinculados que la herramienta destaca y que podrían tener gran importancia para una investigación enfocada en estos temas, como es el clúster "*Machine-Learning*" que se aprecia en la figura 12 Esta figura guarda similitudes con la figura 11 y sus antecesoras, aunque presenta nuevos elementos principales. Asimismo, se incluirá información de la herramienta sobre documentos clave para este análisis.

Figura 12

Diagrama Red de Clúster Machine-Learning



Nota. Archivo html SciMat

El análisis del clúster presentado en la figura destaca la interacción entre conceptos como "*Machine Learning*", "*Artificial Intelligence*" y "*Time-Series*", cada uno con una relevancia

particular dentro del contexto bibliométrico. Con una densidad de 4.1 y un rango de 0.85, este 48 clúster refleja una cohesión temática moderada, indicando que los estudios relacionados comparten conceptos significativos, aunque no totalmente interconectados. La centralidad de 33.81 y su rango de 0.93 subrayan la influencia de este grupo en la red temática general, posicionándolo como un clúster clave para entender las tendencias investigativas del área.

La inclusión de "*Machine Learning*" como núcleo evidencia su papel fundamental en conectar subtemas relacionados, mientras que "*Artificial Intelligence*" y "*Time-Series*" aportan perspectivas complementarias en aplicaciones específicas. Esta interacción resulta relevante para un estudio bibliográfico, ya que permite identificar documentos clave que profundicen en estos vínculos y ofrezcan una visión integral de su desarrollo.

Este análisis no solo facilita la comprensión de cómo evolucionan estas áreas, sino que también ayuda a priorizar recursos para explorar documentos que pueden actuar como pilares teóricos y prácticos dentro del campo.

Por otro lado, el estudio de este clúster incluye documentos investigativos destacados, los cuales se muestran en la tabla 4, como se realizó en las anteriores tablas, que son fundamentales en el ámbito del aprendizaje y la evolución conceptual. Según el análisis de SciMat, estos textos son los más relevantes, ya que evidencian tendencias clave, vinculan redes temáticas con investigaciones específicas y contribuyen a una interpretación más enriquecida del panorama académico durante este periodo.

Lista de los Documentos más Relevantes Clúster Machine-Learning

Título del trabajo	Cita	Numero de citaciones
Deep Learning For Safe Autonomous Driving: Current Challenges And Future Directions.	(Muhammad et al., 2021)	240
Overview And Methods Of Correlation Filter Algorithms In Object Tracking	(S. Liu et al., 2021)	232
A Multi-head Attention-based Transformer Model For Traffic Flow Forecasting With A Comparative Analysis To Recurrent Neural Networks	(Reza et al., 2022)	94
A Literature Review Of Artificial Intelligence Applications In Railway Systems	(Tang et al., 2022)	80
Moving Vehicle Detection And Classification Using Gaussian Mixture Model And Ensemble Deep Learning Technique	(Jagannathan et al., 2021)	69
Transferability Improvement In Short-term Traffic Prediction Using Stacked Lstm Network	(J. Li et al., 2021)	67
Pragmatic Real-time Logistics Management With Traffic Iot Infrastructure: Big Data Predictive Analytics Of Freight Travel Time For Logistics 4.0	(Y.-T. Chen et al., 2021)	60

Nota. Archivo Html SciMat

Los siete estudios que se muestran en la anterior tabla, revisan aplicaciones de inteligencia artificial en transporte inteligente, abordando temas como predicción de tráfico, clasificación de vehículos, conducción autónoma, seguimiento de objetos y gestión ferroviaria, coinciden en buscar mayor precisión, eficiencia y escalabilidad, aunque con distintos niveles de madurez y desafíos.

Los enfoques de predicción de tráfico destacan por su diversidad: el aprendizaje por transferencia es útil en escenarios con pocos datos; GBPRT “*Gradient Boosting Partitioned Regression Treeofrece*” ofrece robustez en condiciones normales; y los transformadores sobresalen en capturar dependencias temporales, aunque con alto costo computacional, la clasificación de vehículos y el seguimiento de objetos emplean redes profundas y técnicas de extracción de características para lograr alta precisión en tiempo real. En conjunto, los trabajos reflejan avances significativos, pero evidencian la necesidad de mejorar la robustez, eficiencia y aplicabilidad en contextos reales.

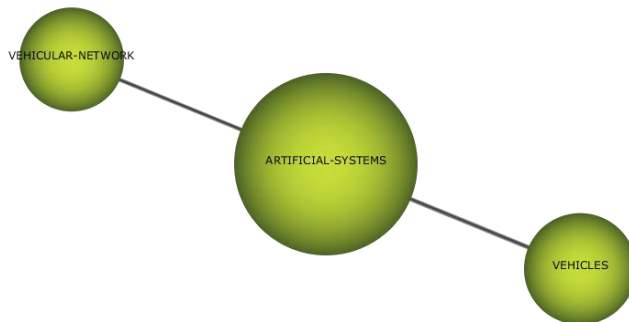
Análisis Tercer Periodo 2023-2024

El tercer periodo del análisis realizado por SciMat refleja una etapa de madurez temática y consolidación de líneas de investigación clave dentro del panorama académico. Durante este periodo, emergen algunas áreas de estudio con alta relevancia e impacto, como “*Artificial Systems*” y “*Traffic Conditions*”, como se muestran en la imagen del Apéndice J, que actúan como ejes centrales en las redes de conocimiento; otras mantienen su relevancia. Este diagrama estratégico permite identificar tanto las tendencias predominantes como las conexiones interdisciplinarias que dan forma a la evolución del campo investigativo. También se observa en la misma imagen cómo los clústeres “*Security*” y “*Detection*” van tomando menos importancia en este último periodo 2023-2024 y se van alejando de “*Artificial Systems*” y “*Traffic Conditions*”, respecto al anterior periodo que fue 2021-2022, donde estos eran más cercanos y de mayor relevancia, así mismo aparece como emergente y potencializándose “*Artificial Intelligence*” el cual son estudios predominantes en la actualidad.

Continuando en este orden de ideas se encuentra el Apéndice K mostrando la imagen 51 de los documentos coreDocuments-hIndex, que hacen referencia a los temas de mayor impacto. En este sentido, en la gráfica se observa que los clústeres están posicionados en el mismo lugar que están en la gráfica del Apéndice J. Además, el crecimiento y tamaño de los clústeres en ambas gráficas es proporcional. De manera similar se hace el análisis de la gráfica que se encuentra en el Apéndice L el cual representa los documentos más citados de este último periodo, encontrándose como el clúster con mayor número de citas “*Virtualization*” con 14.89 citas, luego esta “*3D-Mobility*” con 14.25 citas y “*Emission*” con 12 citas. Los tres ejemplos tomados del análisis del Apéndice L, son temas que al igual que los dos anteriores apéndices, se encuentran en la misma posición de la gráfica, sin embargo, no están situados de forma estratégica como los temas más relevantes entre densidad y centralidad, aunque son clústeres donde se encuentran temas que traen a colación en términos investigativos.

De igual forma, como se realizó en el primer y segundo periodo, se lleva a cabo un estudio más detallado sobre los clústeres de mayor importancia en el tercer periodo, considerando aspectos como magnitud, número de documentos citados o nivel de centralidad como por ejemplo en la **figura 13**, la cual corresponde a una etapa avanzada del análisis bibliográfico en la que los clústeres reflejan una notable densidad y centralidad.

El clúster principal, identificado como “*Artificial-Systems*,” destaca significativamente debido a su tamaño y posición central en el plano, lo que sugiere que este tema es el eje de numerosas conexiones y un pilar fundamental dentro del periodo estudiado. Este nivel de centralidad y densidad refuerza su importancia como núcleo temático y fuente de influencia para otras áreas investigativas.

Diagrama Red de Clúster Artificial-Systems

Nota. Archivo Html SciMat

Por otro lado, "*Vehicular-Network*" y "*Vehicles*", aunque más pequeños en comparación, conservan un papel crucial al establecer conexiones relevantes con el clúster principal. Estas relaciones reflejan la integración de conceptos como sistemas artificiales y redes vehiculares, áreas que emergen como tendencias prioritarias en el campo.

El análisis bibliográfico basado en estas características indica que los documentos asociados a "*Artificial-Systems*" no solo actúan como referencia clave, sino que también son fundamentales para comprender la evolución conceptual y técnica en el panorama general. Asimismo, los clústeres secundarios refuerzan el valor de los estudios interdisciplinarios, sugiriendo que temas como redes vehiculares y aplicaciones en vehículos tienen un impacto significativo en el desarrollo de sistemas más avanzados. Por lo tanto, estos hallazgos ofrecen una guía valiosa para futuras investigaciones al identificar áreas estratégicas y de alto impacto académico, los cuales están basados en distintos documentos de alta relevancia dentro de este periodo y que se pueden observar en la **tabla 5**, donde de manera similar se insertan los títulos de

estos documentos publicados en torno al clúster “*Artificial-Systems*”, los autores y los números de citas arrojados por la herramienta SciMat.

Tabla 5

Lista de los Documentos más Relevantes Clúster Artificial-Systems

Título del trabajo	Cita	Numero de citaciones
Dynamic Graph Convolutional Recurrent Network For Traffic Prediction	(F. Li et al., 2021)	121
Chat With Chatgpt On Intelligent Vehicles: An Ieee Tiv Perspective	(Du et al., 2023)	88
Resilient And Safe Platooning Control Of Connected Automated Vehicles Against Intermittent Denial-of-service Attacks	(Ge et al., 2023)	85
Deep Network-enabled Haze Visibility Enhancement For Visual Iot-driven Intelligent Transportation Systems	(R. W. Liu et al., 2023)	71
Sampled-data Control Systems With Non-uniform Sampling: A Survey Of Methods And Trends	(X.-M. Zhang et al., 2023)	70
Intelligent Transportation System For Internet Of Vehicles Based Vehicular Networks For Smart Cities	(Rani & Sharma, 2023)	58
Short-term Traffic Flow Prediction Based On Optimized Deep Learning Neural Network: Pso-bi-lstm	(Bharti et al., 2023)	53


Nota. Archivo Html SciMat.

Respecto a la anterior tabla podemos decir que los artículos analizan soluciones avanzadas para sistemas de transporte inteligente, enfocándose en eficiencia, seguridad y adaptabilidad, en predicción de tráfico, modelos como DGCRN (Red Recurrente de Convolución en Grafos Dinámicos) y PSO-BiLSTM (Optimización por Enjambre de Partículas – Memoria Bidireccional a Largo Plazo) que se destacan por combinar redes neuronales con técnicas

adaptativas, mejorando la precisión en entornos dinámicos, aunque requieren alto poder computacional. En seguridad, el uso de ensamblajes de modelos basados en árboles logra una detección de intrusiones superior, mientras que el control de pelotones vehiculares incorpora estrategias robustas contra fallos y ciberataques. Otros estudios abordan el control distribuido en redes eléctricas y vehículos autónomos, destacando el uso de muestreo inteligente y técnicas como LMIs (Desigualdades Matriciales Lineales) para garantizar estabilidad. En conjunto, los artículos comparten el uso de IA y control avanzado para enfrentar desafíos urbanos complejos, promoviendo soluciones integradas, escalables y seguras para el transporte del futuro.

En el análisis del tercer periodo, se identifican interacciones cruciales entre clústeres, con especial énfasis en "*Traffic-Conditions*". La **figura 14** revela conexiones significativas que evidencian el potencial interdisciplinario de este clúster conceptual. El clúster emerge como un punto focal que integra múltiples dimensiones de investigación, facilitando la comprensión de tendencias emergentes y perspectivas innovadoras en el estudio de condiciones de tráfico. Su capacidad para articular diferentes líneas de conocimiento lo convierte en un elemento estratégico para futuras investigaciones.

Diagrama Red de Clúster Traffic-Conditions



Nota. Archivo Html SciMat

El análisis bibliométrico revela una configuración de clústeres sumamente inteligente, donde los conceptos *"Roads"*, *"Traffic-Conditions"* y *"Learning"* emergen como núcleos fundamentales de investigación. La densidad estructural de estos clústeres sugiere una profunda interconexión conceptual, donde cada clúster no solo representa un campo de estudio específico, sino que también actúa como un punto de articulación dentro de una red de conocimiento más amplia.

"Traffic-Conditions" se destaca particularmente por su posición central y su capacidad de conectar múltiples dimensiones de análisis. Su prominencia indica que las condiciones de tráfico no son un tema aislado, sino un ecosistema complejo que integra tecnología, infraestructura y metodologías de aprendizaje. Este clúster no solo representa un área de investigación, sino un potencial catalizador de innovaciones interdisciplinarias.

La conexión entre *"Learning"* y *"Traffic-Conditions"* revela una tendencia emergente: la incorporación de técnicas de aprendizaje automático para comprender y optimizar sistemas de

movilidad urbana. Esta sinergia sugiere que los métodos tradicionales de análisis de tráfico 56
están siendo transformados por algoritmos inteligentes capaces de procesar y predecir patrones
complejos.

El clúster "*Roads*" complementa este panorama, representando la dimensión física e
infraestructural sobre la cual estas tecnologías y análisis se implementan. Su presencia indica que
la innovación no se limita al procesamiento de datos, sino que busca una transformación integral
de los sistemas de transporte.

Esta estructura refleja una visión sistémica donde tecnología, infraestructura y
conocimiento se entrelazan para generar soluciones más eficientes y adaptativas en el campo de
la movilidad urbana.

De manera similar a los anteriores análisis de periodos pasados en este estudio
bibliográfico, el análisis de este clúster incluye documentos clave presentados en **la tabla 6**. Este
análisis del clúster desenvuelve una narrativa académica rica, donde los documentos
seleccionados actúan como verdaderos hitos conceptuales. Según la herramienta SciMat, estas
investigaciones trascienden la simple recopilación de datos, constituyéndose como verdaderos
conectores de redes temáticas. Su valor radica en su capacidad para cristalizar tendencias
emergentes, mapear trayectorias intelectuales y ofrecer una perspectiva panorámica de la
evolución del conocimiento. Estos trabajos no solo documentan un estado del arte, sino que
además trazan rutas de comprensión e interpretación fundamentales para el desarrollo del campo
de estudio.

Lista de los Documentos más Relevantes Clúster Traffic-Conditions

Título del trabajo	Cita	Numero de citaciones
Short-term Traffic Flow Prediction Based On Optimized Deep Learning Neural Network: Pso-bi-lstm	(Bharti et al., 2023)	53
Deep Collaborative Intelligence-driven Traffic Forecasting In Green Internet Of Vehicles	(Z. Guo et al., 2023)	51
Temporal-spatial Quantum Graph Convolutional Neural Network Based On Schrodinger Approach For Traffic Congestion Prediction	(Qu et al., 2023)	40
Spatio-temporal Self-supervised Learning For Traffic Flow Prediction	(Ji et al., 2023)	38
Bidirectional Spatial-temporal Adaptive Transformer For Urban Traffic Flow Forecasting	(C. Chen et al., 2023)	35
A Vision Transformer Approach For Traffic Congestion Prediction In Urban Areas	(Ramana et al., 2023)	33
A Novel Stfsa-cnn-gru Hybrid Model For Short-term Traffic Speed Prediction	(Ma et al., 2023)	32

Nota. Archivo html SciMat


Sobre la anterior tabla, los seis estudios sobre predicción de tráfico urbano muestran una clara evolución desde modelos neuronales básicos hacia arquitecturas especializadas más sofisticadas. El modelo DGE-TF representa una fase intermedia, combinando incrustación profunda con redes gráficas para capturar simultáneamente patrones espaciales y temporales. Un enfoque común en todas las investigaciones es la necesidad de modelar ambas dimensiones de los datos de tráfico, como se evidencia en la integración de CNN, Transformadores de Visión y LSTM, que permite no solo predecir flujos sino también clasificar niveles de congestión. Los avances más recientes incluyen un enfoque basado en computación cuántica (QGCNN), el

modelo Bi-STAT con su Módulo de Detención Dinámica para optimizar cálculos, y el ST-SSL⁵⁸ que incorpora aprendizaje auto-supervisado para abordar la heterogeneidad espacial y temporal. Se observa también una progresión en las métricas de evaluación y una tendencia hacia modelos que equilibran precisión con eficiencia computacional.

Asimismo, como se realizó en el anterior clúster, ahora la información suministrada se centra en “*Security*” en la **figura 15** donde el clúster representado en la imagen revela una estructura con densidad de 7.27 y un rango de densidad de 0.85, la centralidad de 21.25 y su rango de 0.77 indican que su influencia dentro del conjunto global de investigaciones es significativa, aunque no dominante.

Figura 15

Diagrama Red de Clúster Security



Nota. Archivo Html SciMat

El análisis del clúster de *"Security"* revela una estructura de investigación altamente sofisticada que trasciende la simple agregación de datos, presentando una arquitectura conceptual compleja con implicaciones profundas para la comprensión de la seguridad digital contemporánea. 59

La densidad del clúster, con un valor de 7.27 y un rango de 0.85, sugiere una cohesión interna moderada pero significativa. Esta característica indica que, si bien existe una interconexión sustancial entre los conceptos, no se trata de un sistema completamente homogéneo, sino de un ecosistema dinámico con cierta flexibilidad estructural.

La centralidad de 21.25, con un rango de 0.77, posiciona este clúster como un nodo importante pero no dominante en el panorama investigativo. Esta condición refleja su relevancia estratégica dentro del campo de la ciberseguridad, donde conceptos como *"Internet"*, *"Security"* y *"Blockchain"* se entrelazan de manera compleja.

La presencia de Blockchain como elemento central es particularmente reveladora. Representa la convergencia entre seguridad tradicional y soluciones tecnológicas descentralizadas, simbolizando una evolución en las estrategias de protección digital. Este enfoque no solo aborda vulnerabilidades existentes, sino que anticipa desafíos emergentes en ecosistemas de información cada vez más interconectados.

La interrelación de estos conceptos dibuja un mapa conceptual donde la seguridad digital ya no se concibe como un elemento periférico, sino como un componente integral de la infraestructura tecnológica moderna, capaz de adaptarse y responder a amenazas en constante transformación.

En este contexto, la investigación avanza hacia modelos de seguridad más holísticos e integrados. La convergencia entre *"Security"*, *"Internet"* y Blockchain representa un paradigma

emergente donde la protección no se limita a barreras defensivas tradicionales, sino que se transforma en un sistema adaptativo y proactivo. Las tecnologías descentralizadas ofrecen nuevas perspectivas para la gestión de riesgos, permitiendo sistemas más transparentes.

Esta evolución implica una transformación radical en nuestra comprensión de la seguridad digital. Ya no se trata únicamente de prevenir amenazas, sino de crear ecosistemas tecnológicos que puedan anticipar, interpretar y neutralizar riesgos de manera inteligente y dinámica, aprovechando la potencia de la inteligencia distribuida y los mecanismos de consenso proporcionados por tecnologías como Blockchain.

El análisis bibliométrico revela un conjunto de documentos que funcionan como verdaderos núcleos de conocimiento, trascendiendo la mera recopilación de datos para convertirse en pilares fundamentales de la comprensión conceptual. La herramienta SciMat destaca estos trabajos como se muestran en la **tabla 7** no solo como investigaciones aisladas, sino como nodos críticos que tejen complejas redes de interconexión temática.

Su valor científico radica en una capacidad multidimensional: evidenciar tendencias emergentes, mapear trayectorias intelectuales y construir una visión panorámica del desarrollo académico. Cada documento se comporta como un punto de inflexión en la evolución del conocimiento, ofreciendo perspectivas que van más allá de la simple descripción, para transformarse en verdaderos catalizadores de comprensión.

Estos trabajos representan más que simples registros académicos; son verdaderos instrumentos de traducción conceptual. Permiten comprender no solo lo que se ha investigado, sino cómo el conocimiento se transforma, se conecta y se expande. Su relevancia trasciende los límites disciplinares, revelando la dinámica compleja de crecimiento y metamorfosis del saber científico.

entre diferentes corrientes de pensamiento, permitiendo una comprensión integral y sistémica de los fenómenos estudiados. Son, en esencia, los hilos conductores que dan sentido y coherencia al tejido del conocimiento académico.

En su conjunto, estos trabajos no solo documentan un estado del arte, sino que trazan rutas de interpretación, generan nuevas preguntas de investigación y abren horizontes para la exploración científica futura. Su valor es tanto retrospectivo como prospectivo, constituyéndose como verdaderos faros que iluminan la trayectoria del conocimiento en un campo específico.

Tabla 7

Lista de los Documentos más Relevantes Clúster Security

Título del trabajo	Cita	Numero de citaciones
Autonomous Vehicles Enabled By The Integration Of Iot, Edge Intelligence, 5g, And Blockchain	(Biswas & Wang, 2023)	41
Secure Internet Of Vehicles (iov) With Decentralized Consensus Blockchain Mechanism	(Tu et al., 2023)	20
Cooperative Multi-camera Vehicle Tracking And Traffic Surveillance With Edge Artificial Intelligence And Representation Learning	(Yang et al., 2023)	19
An Efficient Blockchain-based Conditional Privacy-preserving Authentication Protocol For Vanets	(X. Zhou et al., 2023)	19
Secure And Efficient Authenticated Key Management Scheme For Uav-assisted Infrastructure-less Iovs	(Tan et al., 2023)	18

Título del trabajo	Cita	Numero de citaciones
Drone Transportation System: Systematic Review Of Security Dynamics For Smart Mobility	(Ajakwe et al., 2023)	17
Blockchain For Intelligent Transportation Systems: Applications, Challenges, And Opportunities	(Das et al., 2023)	14

Nota. Archivo Html SciMat

En la anterior tabla 7, los siete estudios sobre tecnologías emergentes para sistemas de transporte inteligentes revelan una clara transición hacia arquitecturas descentralizadas basadas en blockchain, aunque con diversas implementaciones según sus objetivos específicos. Mientras algunos utilizan contratos inteligentes y pruebas de cero conocimientos para VANET (Vehicular Ad-Hoc Network), otros aplican blockchain para comunicaciones V2X (Vehicle to Everything) o autenticación IoT, evidenciando su versatilidad pero también la falta de estándares unificados. El edge computing emerge como elemento crucial tanto en sistemas de monitoreo como ECoMS (Enhanced Cooperative Mobility Services) como en vehículos autónomos, priorizando la reducción de latencia para aplicaciones en tiempo real. Las aproximaciones a la seguridad divergen entre primitivas criptográficas tradicionales y paradigmas innovadores como arquitecturas de confianza cero. Un aporte valioso es la adaptación de algoritmos de consenso específicos para entornos vehiculares (VBSBC), superando limitaciones de protocolos estándar. Los desafíos comunes incluyen escalabilidad en soluciones blockchain y aspectos regulatorios para drones y vehículos autónomos, reflejando obstáculos tanto técnicos como normativos en este campo en rápida evolución.

El estudio bibliométrico realizado con la herramienta SciMat ha permitido comprender en profundidad la evolución temática del campo de la inteligencia artificial aplicada a la movilidad inteligente, revelando la naturaleza dinámica de este conocimiento científico que evoluciona constantemente para responder a nuevas necesidades urbanas, tecnologías emergentes y enfoques innovadores en el transporte.

El análisis temporal muestra una clara progresión desde enfoques algorítmicos aislados hacia ecosistemas tecnológicos integrados. Este patrón evolutivo se observa en la distribución de publicaciones, que presenta un crecimiento exponencial en los últimos cinco años, con un notable incremento de investigaciones enfocadas en aprendizaje profundo aplicado a predicción del tráfico y sistemas autónomos de navegación. Este auge coincide con avances paralelos en capacidad computacional y disponibilidad de datos urbanos masivos, factores que han sido catalizadores fundamentales para el desarrollo del campo.

Mediante la metodología de SciMat, se identificaron cuatro clústeres temáticos principales caracterizados por su alta densidad y centralidad: 1) predicción y gestión del tráfico, 2) vehículos autónomos y sistemas de asistencia, 3) optimización energética y sostenibilidad, y 4) ciberseguridad en sistemas de transporte. Estos clústeres constituyen puntos fundamentales en la red de conocimiento del campo analizado. La interconexión detectada entre estos núcleos temáticos evidencia la naturaleza interdisciplinaria de la movilidad inteligente, en la cual los avances en un área frecuentemente impulsan desarrollos en otras.

El estudio también permitió reconocer publicaciones esenciales que no solo contribuyeron al desarrollo conceptual de los clústeres, sino que funcionaron como puentes conceptuales entre la investigación teórica en inteligencia artificial y su implementación práctica

en sistemas de movilidad. Estos trabajos seminales, identificados mediante análisis de co-citación, revelan núcleos de conocimiento esenciales asociados a arquitecturas de *deep learning* y su aplicación en entornos urbanos dinámicos.

Las métricas bibliométricas aplicadas permitieron identificar una brecha persistente entre desarrollos algorítmicos avanzados y su implementación en entornos reales, constituyendo un área de oportunidad para futuras investigaciones. Los trabajos con mayor impacto, según índices de citación, tienden a ser aquellos que demuestran validaciones en contextos urbanos reales, lo que sugiere la importancia creciente de los estudios de caso y pruebas piloto.

Un hallazgo significativo del análisis es la emergencia reciente de investigaciones centradas en *frameworks* regulatorios y consideraciones éticas para la implementación de IA en movilidad urbana, indicando una maduración del campo más allá de los aspectos puramente técnicos hacia consideraciones sociales y políticas. Esta tendencia se identificó gracias a la capacidad de SciMat para visualizar la evolución temática desde una perspectiva integral.

La metodología bibliométrica empleada ha facilitado la identificación de tendencias emergentes como la hibridación de técnicas (CNN, LSTM, redes neuronales de grafos), el interés por lograr mayor escalabilidad y adaptabilidad en entornos urbanos dinámicos, y el desarrollo de soluciones descentralizadas mediante blockchain. Estos hallazgos resultan invaluable para orientar futuras investigaciones, proporcionando claridad sobre los temas con mayor proyección y las oportunidades para desarrollar nuevas líneas de investigación.

En conclusión, este estudio demuestra cómo las herramientas bibliométricas como SciMat permiten un análisis riguroso y estructurado del conocimiento científico, facilitando la comprensión de cómo las comunidades académicas configuran y transforman un campo de estudio tan dinámico como la IA aplicada a la movilidad inteligente. El campo ha evolucionado

desde soluciones algorítmicas aisladas hacia ecosistemas tecnológicos integrados, con un 65
énfasis creciente en la validación práctica, la consideración de factores humanos y el desarrollo
de marcos regulatorios apropiados. Las tendencias identificadas sugieren que la próxima fase de
evolución probablemente se caracterizará por una mayor integración entre múltiples sistemas
urbanos inteligentes, consolidando el papel de la IA como tecnología vertebradora de las
ciudades inteligentes del futuro.

- Ajakwe, S. O., Kim, D.-S., & Lee, J.-M. (2023). Drone Transportation System: Systematic Review of Security Dynamics for Smart Mobility. *IEEE Internet of Things Journal*, *10*(16), 14462-14482. IEEE Internet of Things Journal. <https://doi.org/10.1109/JIOT.2023.3266843>
- Bharti, Redhu, P., & Kumar, K. (2023). Short-term traffic flow prediction based on optimized deep learning neural network: PSO-Bi-LSTM. *Physica A: Statistical Mechanics and its Applications*, *625*, 129001. <https://doi.org/10.1016/j.physa.2023.129001>
- Biswas, A., & Wang, H.-C. (2023). Autonomous Vehicles Enabled by the Integration of IoT, Edge Intelligence, 5G, and Blockchain. *Sensors*, *23*(4), Article 4. <https://doi.org/10.3390/s23041963>
- Bogaerts, T., Masegosa, A. D., Angarita-Zapata, J. S., Onieva, E., & Hellinckx, P. (2020). A graph CNN-LSTM neural network for short and long-term traffic forecasting based on trajectory data. *Transportation Research Part C: Emerging Technologies*, *112*, 62-77. <https://doi.org/10.1016/j.trc.2020.01.010>
- Chaparro-Martínez, E. I., Álvarez-Muñoz, P., & D'Armas-Regnault, M. (2016). Gestión de la información: Uso de las bases de datos scopus y web of science con fines académicos. *Universidad, Ciencia y Tecnología*, *20*(81), 166-175.
- Chen, C., Liu, Y., Chen, L., & Zhang, C. (2023). Bidirectional Spatial-Temporal Adaptive Transformer for Urban Traffic Flow Forecasting. *IEEE Transactions on Neural Networks and Learning Systems*, *34*(10), 6913-6925. IEEE Transactions on Neural Networks and Learning Systems. <https://doi.org/10.1109/TNNLS.2022.3183903>

Chen, Y.-T., Sun, E. W., Chang, M.-F., & Lin, Y.-B. (2021). Pragmatic real-time logistics 67

management with traffic IoT infrastructure: Big data predictive analytics of freight travel time for Logistics 4.0. *International Journal of Production Economics*, 238, 108157.

<https://doi.org/10.1016/j.ijpe.2021.108157>

Cobo, M. j., López-Herrera, A. g., Herrera-Viedma, E., & Herrera, F. (2012). SciMAT: A new science mapping analysis software tool. *Journal of the American Society for Information Science and Technology*, 63(8), 1609-1630. <https://doi.org/10.1002/asi.22688>

Das, D., Banerjee, S., Chatterjee, P., Ghosh, U., & Biswas, U. (2023). Blockchain for Intelligent Transportation Systems: Applications, Challenges, and Opportunities. *IEEE Internet of Things Journal*, 10(21), 18961-18970. *IEEE Internet of Things Journal*.

<https://doi.org/10.1109/JIOT.2023.3277923>

Du, H., Teng, S., Chen, H., Ma, J., Wang, X., Gou, C., Li, B., Ma, S., Miao, Q., Na, X., Ye, P., Zhang, H., Luo, G., & Wang, F.-Y. (2023). Chat With ChatGPT on Intelligent Vehicles: An IEEE TIV Perspective. *IEEE Transactions on Intelligent Vehicles*, 8(3), 2020-2026.

IEEE Transactions on Intelligent Vehicles. <https://doi.org/10.1109/TIV.2023.3253281>

Ge, X., Han, Q.-L., Ding, L., Wang, Y.-L., & Zhang, X.-M. (2020). Dynamic Event-Triggered Distributed Coordination Control and its Applications: A Survey of Trends and Techniques. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 50(9),

3112-3125. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*.

<https://doi.org/10.1109/TSMC.2020.3010825>

Ge, X., Han, Q.-L., Wu, Q., & Zhang, X.-M. (2023). Resilient and Safe Platooning Control of Connected Automated Vehicles Against Intermittent Denial-of-Service Attacks.

IEEE/CAA Journal of Automatica Sinica, 10(5), 1234-1251. IEEE/CAA Journal of Automatica Sinica. <https://doi.org/10.1109/JAS.2022.105845> 68

Guo, S., Lin, Y., Li, S., Chen, Z., & Wan, H. (2019). Deep Spatial–Temporal 3D Convolutional Neural Networks for Traffic Data Forecasting. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3913-3926. IEEE Transactions on Intelligent Transportation Systems. <https://doi.org/10.1109/TITS.2019.2906365>

Guo, Z., Yu, K., Konstantin, K., Mumtaz, S., Wei, W., Shi, P., & Rodrigues, J. J. P. C. (2023). Deep Collaborative Intelligence-Driven Traffic Forecasting in Green Internet of Vehicles. *IEEE Transactions on Green Communications and Networking*, 7(2), 1023-1035. IEEE Transactions on Green Communications and Networking. <https://doi.org/10.1109/TGCN.2022.3193849>

Haydari, A., & Yilmaz, Y. (2022). Deep Reinforcement Learning for Intelligent Transportation Systems: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 23(1), 11-32. IEEE Transactions on Intelligent Transportation Systems. <https://doi.org/10.1109/TITS.2020.3008612>

Jagannathan, P., Rajkumar, S., Frnda, J., Divakarachari, P. B., & Subramani, P. (2021). Moving Vehicle Detection and Classification Using Gaussian Mixture Model and Ensemble Deep Learning Technique. *Wireless Communications and Mobile Computing*, 2021(1), 5590894. <https://doi.org/10.1155/2021/5590894>

Ji, J., Wang, J., Huang, C., Wu, J., Xu, B., Wu, Z., Zhang, J., & Zheng, Y. (2023). Spatio-Temporal Self-Supervised Learning for Traffic Flow Prediction. *Proceedings of the AAAI Conference on Artificial Intelligence*, 37(4), Article 4. <https://doi.org/10.1609/aaai.v37i4.25555>

- Jiang, W., & Luo, J. (2022). Graph Neural Network for Traffic Forecasting: A Survey. *Expert Systems with Applications*, 207, 117921. <https://doi.org/10.1016/j.eswa.2022.117921>
- Kuutti, S., Bowden, R., Jin, Y., Barber, P., & Fallah, S. (2021). A Survey of Deep Learning Applications to Autonomous Vehicle Control. *IEEE Transactions on Intelligent Transportation Systems*, 22(2), 712-733. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2019.2962338>
- Li, F., Feng, J., Yan, H., Jin, G., Jin, D., & Li, Y. (2021). *Dynamic Graph Convolutional Recurrent Network for Traffic Prediction: Benchmark and Solution* (arXiv:2104.14917). arXiv. <https://doi.org/10.48550/arXiv.2104.14917>
- Li, J., Guo, F., Sivakumar, A., Dong, Y., & Krishnan, R. (2021). Transferability improvement in short-term traffic prediction using stacked LSTM network. *Transportation Research Part C: Emerging Technologies*, 124, 102977. <https://doi.org/10.1016/j.trc.2021.102977>
- Li, L., Qin, L., Qu, X., Zhang, J., Wang, Y., & Ran, B. (2019). Day-ahead traffic flow forecasting based on a deep belief network optimized by the multi-objective particle swarm algorithm. *Knowledge-Based Systems*, 172, 1-14. <https://doi.org/10.1016/j.knosys.2019.01.015>
- Liu, L., Qiu, Z., Li, G., Wang, Q., Ouyang, W., & Lin, L. (2019). Contextualized Spatial–Temporal Network for Taxi Origin-Destination Demand Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3875-3887. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2019.2915525>
- Liu, R. W., Guo, Y., Lu, Y., Chui, K. T., & Gupta, B. B. (2023). Deep Network-Enabled Haze Visibility Enhancement for Visual IoT-Driven Intelligent Transportation Systems. *IEEE*

Liu, S., Liu, D., Srivastava, G., Połap, D., & Woźniak, M. (2021). Overview and methods of correlation filter algorithms in object tracking. *Complex & Intelligent Systems*, 7(4), 1895-1917. <https://doi.org/10.1007/s40747-020-00161-4>

Ma, C., Zhao, Y., Dai, G., Xu, X., & Wong, S.-C. (2023). A Novel STFSA-CNN-GRU Hybrid Model for Short-Term Traffic Speed Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 24(4), 3728-3737. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2021.3117835>

Martínez Musiño, C. (2021). La producción documental de la Inteligencia Artificial y la Ciencia de la Información en Scopus—Análisis informétrico. *E-Ciencias de la Información*, 11(1), 143-160. <https://doi.org/10.15517/eci.v11i1.42252>

Mollah, M. B., Zhao, J., Niyato, D., Guan, Y. L., Yuen, C., Sun, S., Lam, K.-Y., & Koh, L. H. (2021). Blockchain for the Internet of Vehicles Towards Intelligent Transportation Systems: A Survey. *IEEE Internet of Things Journal*, 8(6), 4157-4185. *IEEE Internet of Things Journal*. <https://doi.org/10.1109/JIOT.2020.3028368>

Muhammad, K., Ullah, A., Lloret, J., Ser, J. D., & de Albuquerque, V. H. C. (2021). Deep Learning for Safe Autonomous Driving: Current Challenges and Future Directions. *IEEE Transactions on Intelligent Transportation Systems*, 22(7), 4316-4336. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2020.3032227>

Pan, Z., Liang, Y., Wang, W., Yu, Y., Zheng, Y., & Zhang, J. (2019). Urban Traffic Prediction from Spatio-Temporal Data Using Deep Meta Learning. *Proceedings of the 25th ACM*

1730. <https://doi.org/10.1145/3292500.3330884>

Qu, Z., Liu, X., & Zheng, M. (2023). Temporal-Spatial Quantum Graph Convolutional Neural Network Based on Schrödinger Approach for Traffic Congestion Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 24(8), 8677-8686. IEEE Transactions on Intelligent Transportation Systems.

<https://doi.org/10.1109/TITS.2022.3203791>

Ramana, K., Srivastava, G., Kumar, M. R., Gadekallu, T. R., Lin, J. C.-W., Alazab, M., & Iwendi, C. (2023). A Vision Transformer Approach for Traffic Congestion Prediction in Urban Areas. *IEEE Transactions on Intelligent Transportation Systems*, 24(4), 3922-3934. IEEE Transactions on Intelligent Transportation Systems.

<https://doi.org/10.1109/TITS.2022.3233801>

Rani, P., & Sharma, R. (2023). Intelligent transportation system for internet of vehicles based vehicular networks for smart cities. *Computers and Electrical Engineering*, 105, 108543.

<https://doi.org/10.1016/j.compeleceng.2022.108543>

Reza, S., Ferreira, M. C., Machado, J. J. M., & Tavares, J. M. R. S. (2022). A multi-head attention-based transformer model for traffic flow forecasting with a comparative analysis to recurrent neural networks. *Expert Systems with Applications*, 202, 117275.

<https://doi.org/10.1016/j.eswa.2022.117275>

Tan, H., Zheng, W., & Vijayakumar, P. (2023). Secure and Efficient Authenticated Key Management Scheme for UAV-Assisted Infrastructure-Less IoVs. *IEEE Transactions on Intelligent Transportation Systems*, 24(6), 6389-6400. IEEE Transactions on Intelligent Transportation Systems. <https://doi.org/10.1109/TITS.2023.3252082>

- Tang, T., Vittorini, V., & Wang, Z. (2022). A literature review of Artificial Intelligence applications in railway systems. *Transportation Research Part C: Emerging Technologies*, *140*, 103679. <https://doi.org/10.1016/j.trc.2022.103679>
- Tu, S., Yu, H., Badshah, A., Waqas, M., Halim, Z., & Ahmad, I. (2023). Secure Internet of Vehicles (IoV) With Decentralized Consensus Blockchain Mechanism. *IEEE Transactions on Vehicular Technology*, *72*(9), 11227-11236. *IEEE Transactions on Vehicular Technology*. <https://doi.org/10.1109/TVT.2023.3268135>
- Ullah, Z., Al-Turjman, F., Mostarda, L., & Gagliardi, R. (2020). Applications of Artificial Intelligence and Machine learning in smart cities. *Computer Communications*, *154*, 313-323. <https://doi.org/10.1016/j.comcom.2020.02.069>
- van Wyk, F., Wang, Y., Khojandi, A., & Masoud, N. (2020). Real-Time Sensor Anomaly Detection and Identification in Automated Vehicles. *IEEE Transactions on Intelligent Transportation Systems*, *21*(3), 1264-1276. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2019.2906038>
- Wang, Y., Zhang, D., Liu, Y., Dai, B., & Lee, L. H. (2019). Enhancing transportation systems via deep learning: A survey. *Transportation Research Part C: Emerging Technologies*, *99*, 144-163. <https://doi.org/10.1016/j.trc.2018.12.004>
- Wu, Y., Zhang, K., & Zhang, Y. (2021). Digital Twin Networks: A Survey. *IEEE Internet of Things Journal*, *8*(18), 13789-13804. *IEEE Internet of Things Journal*. <https://doi.org/10.1109/JIOT.2021.3079510>
- Yang, H. (Frank), Cai, J., Liu, C., Ke, R., & Wang, Y. (2023). Cooperative multi-camera vehicle tracking and traffic surveillance with edge artificial intelligence and representation

<https://doi.org/10.1016/j.trc.2022.103982>

You, C., Lu, J., Filev, D., & Tsiotras, P. (2019). Advanced planning for autonomous vehicles using reinforcement learning and deep inverse reinforcement learning. *Robotics and Autonomous Systems*, 114, 1-18. <https://doi.org/10.1016/j.robot.2019.01.003>

Yu, J. J. Q., Yu, W., & Gu, J. (2019). Online Vehicle Routing With Neural Combinatorial Optimization and Deep Reinforcement Learning. *IEEE Transactions on Intelligent Transportation Systems*, 20(10), 3806-3817. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2019.2909109>

Zhang, F., Hu, X., Langari, R., & Cao, D. (2019). Energy management strategies of connected HEVs and PHEVs: Recent progress and outlook. *Progress in Energy and Combustion Science*, 73, 235-256. <https://doi.org/10.1016/j.pecs.2019.04.002>

Zhang, X.-M., Han, Q.-L., Ge, X., Ning, B., & Zhang, B.-L. (2023). Sampled-data control systems with non-uniform sampling: A survey of methods and trends. *Annual Reviews in Control*, 55, 70-91. <https://doi.org/10.1016/j.arcontrol.2023.03.004>

Zheng, H., Lin, F., Feng, X., & Chen, Y. (2021). A Hybrid Deep Learning Model With Attention-Based Conv-LSTM Networks for Short-Term Traffic Flow Prediction. *IEEE Transactions on Intelligent Transportation Systems*, 22(11), 6910-6920. *IEEE Transactions on Intelligent Transportation Systems*. <https://doi.org/10.1109/TITS.2020.2997352>

Zhou, H., Xu, W., Chen, J., & Wang, W. (2020). Evolutionary V2X Technologies Toward the Internet of Vehicles: Challenges and Opportunities. *Proceedings of the IEEE*, 108(2), 308-323. *Proceedings of the IEEE*. <https://doi.org/10.1109/JPROC.2019.2961937>


Zhou, X., He, D., Khan, M. K., Wu, W., & Choo, K.-K. R. (2023). An Efficient Blockchain- 74

Based Conditional Privacy-Preserving Authentication Protocol for VANETs. *IEEE Transactions on Vehicular Technology*, 72(1), 81-92. IEEE Transactions on Vehicular Technology. <https://doi.org/10.1109/TVT.2022.3204582>

Zhu, L., Yu, F. R., Wang, Y., Ning, B., & Tang, T. (2019). Big Data Analytics in Intelligent Transportation Systems: A Survey. *IEEE Transactions on Intelligent Transportation Systems*, 20(1), 383-398. IEEE Transactions on Intelligent Transportation Systems. <https://doi.org/10.1109/TITS.2018.2815678>


Apéndice A

Evolution map. CoreDocuments-documentsCount



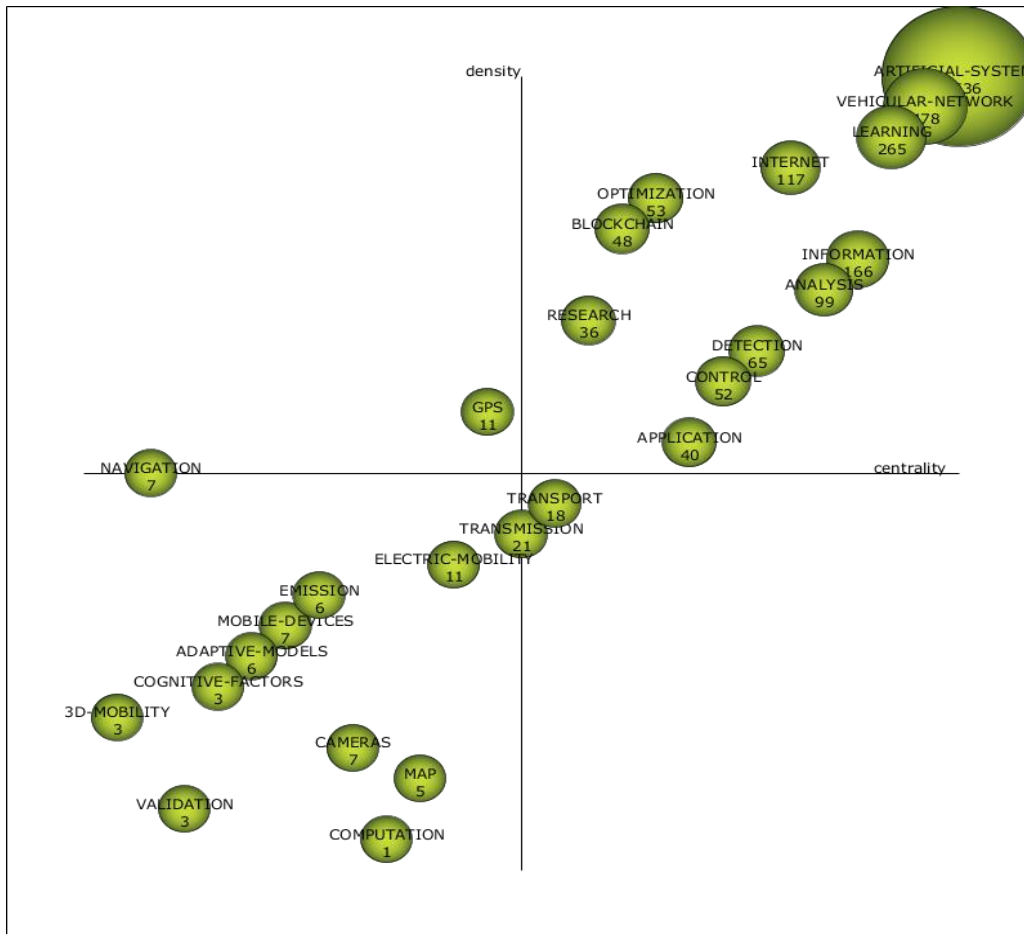
Fuente: Análisis Scimat.

Evolution map. CoreDocuments-hIndex



Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-documentsCount Periodo 1



Name	coreDocumentsdocumentsCount
ARTIFICIAL-SYSTEMS	1,536
LEARNING	265
VEHICULAR-NETWORK	478
INTERNET	117
OPTIMIZATION	53
INFORMATION	166
ANALYSIS	99
BLOCKCHAIN	48
DETECTION	65
CONTROL	52
GPS	11
TRANSMISSION	21
APPLICATION	40
NAVIGATION	7
TRANSPORT	18
RESEARCH	36
ELECTRIC-MOBILITY	11
MOBILE-DEVICES	7
ADAPTIVE-MODELS	6
3D-MOBILITY	3
CAMERAS	7
VALIDATION	3
MAP	5
COGNITIVE-FACTORS	3
EMISSION	6
COMPUTATION	1

Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-hIndex Periodo 1



Name	coreDocuments-hIndex
ARTIFICIAL-SYSTEMS	91
LEARNING	56
VEHICULAR-NETWORK	66
INTERNET	32
OPTIMIZATION	21
INFORMATION	32
ANALYSIS	28
BLOCKCHAIN	24
DETECTION	17
CONTROL	20
GPS	6
TRANSMISSION	8
APPLICATION	17
NAVIGATION	6
TRANSPORT	7
RESEARCH	15
ELECTRIC-MOBILITY	6
MOBILE-DEVICES	6
ADAPTIVE-MODELS	5
3D-MOBILITY	2
CAMERAS	5
VALIDATION	3
MAP	3
COGNITIVE-FACTORS	2
EMISSION	4
COMPUTATION	1

Fuente: Análisis Scimat.

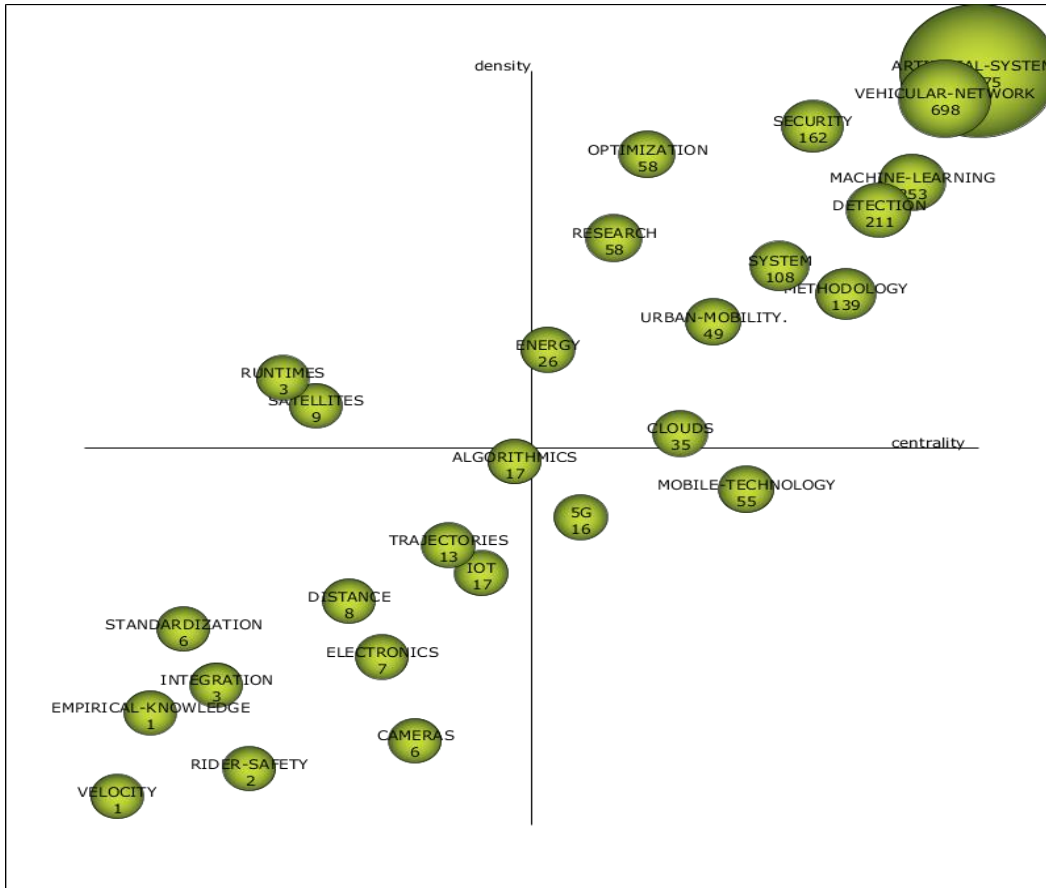
Diagrama Estratégico CoreDocuments-averageCitations Periodo 1



Name	coreDocumentsaverageCitations
ARTIFICIAL-SYSTEMS	24.96
LEARNING	36.24
VEHICULAR-NETWORK	30.25
INTERNET	38.92
OPTIMIZATION	37.43
INFORMATION	28.23
ANALYSIS	24.94
BLOCKCHAIN	62.75
DETECTION	16.37
CONTROL	30.65
GPS	11.27
TRANSMISSION	13.33
APPLICATION	43.6
NAVIGATION	24
TRANSPORT	21.67
RESEARCH	31.56
ELECTRIC-MOBILITY	27.82
MOBILE-DEVICES	36
ADAPTIVE-MODELS	12.83
3D-MOBILITY	11.33
CAMERAS	16.57
VALIDATION	17
MAP	20.8
COMPUTATION	4
COGNITIVE-FACTORS	6.67
EMISSION	19.83
COMPUTATION	4

Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-documentsCount Periodo 2



Name	coreDocumentsdocumentsCount
ARTIFICIAL-SYSTEMS	1,875
VEHICULAR-NETWORK	698
SECURITY	162
MACHINE-LEARNING	253
DETECTION	211
SYSTEM	108
URBAN-MOBILITY.	49
METHODOLOGY	139
ENERGY	26
RESEARCH	58
OPTIMIZATION	58
MOBILE-TECHNOLOGY	55
ALGORITHMICS	17
CLOUDS	35
5G	16
RUNTIMES	3
SATELLITES	9
STANDARDIZATION	6
IOT	17
DISTANCE	8
TRAJECTORIES	13
ELECTRONICS	7
INTEGRATION	3
CAMERAS	6
EMPIRICAL-KNOWLEDGE	1
RIDER-SAFETY	2
VELOCITY	1

Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-hIndex Periodo 2



Name	coreDocuments-hIndex
ARTIFICIAL-SYSTEMS	77
VEHICULAR-NETWORK	54
SECURITY	35
MACHINE-LEARNING	36
DETECTION	30
SYSTEM	18
URBAN-MOBILITY.	16
METHODOLOGY	22
ENERGY	11
RESEARCH	17
OPTIMIZATION	18
MOBILE-TECHNOLOGY	15
ALGORITHMICS	6
CLOUDS	17
5G	10
RUNTIMES	3
SATELLITES	5
STANDARDIZATION	6
IOT	9
DISTANCE	5
TRAJECTORIES	6
ELECTRONICS	4
INTEGRATION	3
CAMERAS	4
EMPIRICAL-KNOWLEDGE	1
RIDER-SAFETY	1
VELOCITY	1

Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-averageCitations Periodo 2



Name	coreDocumentsaverageCitations
ARTIFICIAL-SYSTEMS	15.85
VEHICULAR-NETWORK	19.5
SECURITY	23.76
MACHINE-LEARNING	17.87
DETECTION	16.45
SYSTEM	14.58
URBAN-MOBILITY.	23.49
METHODODOLOGY	14.14
ENERGY	12.46
RESEARCH	15.41
OPTIMIZATION	17.81
MOBILE-TECHNOLOGY	15.15
ALGORITHMICS	5.41
CLOUDS	25.77
5G	46.62
RUNTIMES	9
SATELLITES	20.33
STANDARDIZATION	14.83
IOT	11.29
DISTANCE	12.5
TRAJECTORIES	8.69
ELECTRONICS	21.86
INTEGRATION	5
CAMERAS	8.83
EMPIRICAL-KNOWLEDGE	115
RIDER-SAFETY	9
VELOCITY	4

Fuente: Análisis Scimat.


Diagrama Estratégico CoreDocuments-documentsCount Periodo 3



Name	coreDocumentsdocumentsCount
ARTIFICIAL-SYSTEMS	1,133
TRAFFIC-CONDITIONS	424
SECURITY	88
OPTIMIZATION	109
DATA-MINING	145
ARTIFICIAL INTELLIGENCE	106
ENERGY	44
MOBILE-TECHNOLOGY	36
3D-MOBILITY	8
ALGORITHMIC	9
DETECTION	74
NAVIGATION	9
LOCATION	21
CONTROL	41
TIMES-SERIES	42
RUNTIMES	1
EMISSION	3
BEHAVIORAL-BIOMETRICS	44
VIRTUALIZATION	9
AUTOMATION	19
WIRELESS-COMMUNICATION	6
ADAPTIVE-MODELS	4
GPS	3
MAP	6
BICYCLES	1
DENSITY	1

Fuente: Análisis Scimat.

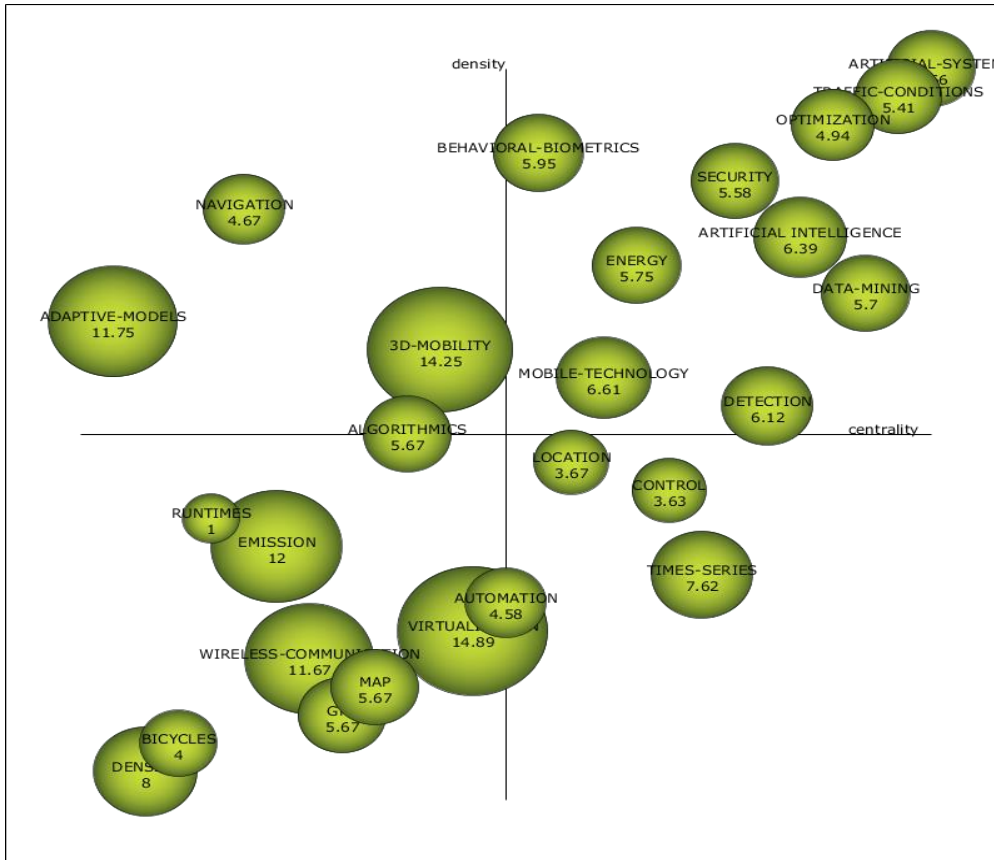
Diagrama Estratégico CoreDocuments-hIndex Periodo 3



Name	coreDocumentshIndex
ARTIFICIAL-SYSTEMS	28
TRAFFIC-CONDITIONS	20
SECURITY	12
OPTIMIZATION	13
DATA-MINING	14
ARTIFICIAL INTELLIGENCE	13
ENERGY	8
MOBILE-TECHNOLOGY	9
3D-MOBILITY	4
ALGORITHMICS	4
DETECTION	10
NAVIGATION	5
LOCATION	5
CONTROL	6
TIMES-SERIES	8
RUNTIMES	1
EMISSION	2
BEHAVIORAL-BIOMETRICS	10
VIRTUALIZATION	3
AUTOMATION	5
WIRELESS-COMMUNICATION	4
ADAPTIVE-MODELS	3
GPS	2
MAP	3
BICYCLES	1
DENSITY	1

Fuente: Análisis Scimat.

Diagrama Estratégico CoreDocuments-averageCitations Periodo 3



Name	coreDocumentsaverageCitations
ARTIFICIAL-SYSTEMS	5.66
TRAFFIC-CONDITIONS	5.41
SECURITY	5.58
OPTIMIZATION	4.94
DATA-MINING	5.7
ARTIFICIAL INTELLIGENCE	6.39
ENERGY	5.75
MOBILE-TECHNOLOGY	6.61
3D-MOBILITY	14.25
ALGORITHMICS	5.67
DETECTION	6.12
NAVIGATION	4.67
LOCATION	3.67
CONTROL	3.63
TIMES-SERIES	7.62
RUNTIMES	1
EMISSION	12
BEHAVIORAL-BIOMETRICS	5.95
VIRTUALIZATION	14.89
AUTOMATION	4.58
WIRELESS-COMMUNICATION	11.67
ADAPTIVE-MODELS	11.75
GPS	5.67
MAP	5.67
BICYCLES	4
DENSITY	8

Fuente: Análisis Scimat.