

Introducción a las redes complejas DE LA TEORÍA A LA PRÁCTICA


Carlos Luis Redroban-Ortiz
Luis Arturo Rivas-Tovar

Información de los autores



Carlos Luis Redroban-Ortiz

Nació en Milagro, Ecuador el 25 de agosto de 1978, Oficial de Marina (sp); Ingeniero en Ciencias Empresariales; Abogado; MBA, Mención Negocios Internacionales; Máster en Supply Chain Management; Magíster en Tecnología e Innovación Educativa, Magíster en Derecho de Control y Prevención de la Corrupción, Candidato a PhD, por la Pontificia Universidad Católica Argentina. Se ha desempeñado en varios cargos del sector público como Armada del Ecuador; Petroecuador-Ep; Flopec-Ep, Contraloría General del Estado, Universidad de Guayaquil, CFN B.P., BANEQUADOR B.P. Docente de pregrado y posgrado en varias universidades ecuatorianas como: Universidad Católica Santiago de Guayaquil (UCSG), Universidad Tecnológica Empresarial de Guayaquil (UTEG), Universidad Tecnológica ECOTEC. Su trayectoria profesional, ha evolucionado tanto en el ámbito profesional, laboral, docente e investigativo cuyos logros se sintetizan a continuación:



www.carlosredroban.com



Luis Arturo Rivas-Tovar

Es Doctor en Ciencias Administrativas por el Instituto Politécnico de México. Dr. (c) en Estudios Europeos en el Instituto Universitario Ortega y Gasset de España. Postdoctorado en Organización de dos años en la Universidad Politécnica de Madrid (Grupo Ingeniería de la Organización). Trabajó 13 años en Petroleos Mexicanos donde fue Gerente Corporativo de Organización. Ha sido Consultor internacional de diversos proyectos dentro de los que destaca su trabajo en el Instituto Tecnológico de Massachusetts seleccionado para colaborar en el equipo del Premio Nobel de Química 1995 Mario Molina. Ha formado a un total de 32 doctores, 15 de los cuales son miembros del Sistema Nacional de Investigadores SNI y a 71 Maestros en Ciencias. En el mundo académico ha sido: Director del Centro de investigación en Ciencias Administrativas de la ESCA-IPN. Director del European Institute of Management. Coordinador de Proyectos Estratégicos en el Centro Mario Molina de Energía y Medio Ambiente que presidió el Premio Nobel de Química (1995) con el cual trabajó durante 10 años. Es editor en jefe de la Revista Investigación Administrativa indexada en: CONACYT (Q1 Competencia internacional). Actualmente es catedrático del Instituto Politécnico Nacional. Ha recibido diversas distinciones dentro de la que destaca Investigador Nacional nivel III, el máximo del Sistema Nacional de Investigadores CONACYT (México). Es el investigador más citado del mundo en Google Scholar en Teoría de la Organización y Formación de Investigadores, el segundo investigador en Dirección Estratégica y el tercero en Complexity Management. En Research Gate que es el repositorio más importante del mundo, su obra científica ha sido leída por casi un millón de lectores de manera gratuita. En esta plataforma de conocimiento abierto, siete veces ha recibido la distinción por ser el científico más leído de México en todos los campos del saber.



© Carlos Luis Redroban-Ortiz
Luis Arturo Rivas-Tovar

© Editorial Grupo Compás, 2025
Guayaqui, Ecuador
www.grupocompas.com
<http://repositorio.grupocompas.com>

Primera edición, 2025

ISBN:978-9942-33-916-4

Distribución online

 Acceso abierto

Cita

Redroban-Ortiz, C., Rivas-Tovar, L. (2025) Introducción a las redes complejas. De la teoría a la práctica. Editorial Grupo Compás

Este libro ha sido debidamente examinado y valorado en la modalidad doble par ciego con fin de garantizar la calidad de la publicación. El copyright estimula la creatividad, defiende la diversidad en el ámbito de las ideas y el conocimiento, promueve la libre expresión y favorece una cultura viva. Quedan rigurosamente prohibidas, bajo las sanciones en las leyes, la producción o almacenamiento total o parcial de la presente publicación, incluyendo el diseño de la portada, así como la transmisión de la misma por cualquiera de sus medios, tanto si es electrónico, como químico, mecánico, óptico, de grabación o bien de fotocopia, sin la autorización de los titulares del copyright.

ÍNDICE

INTRODUCCIÓN	6
CAPÍTULO I	9
LA CIENCIA DE REDES	9
1.1.- ORÍGEN Y EVOLUCIÓN DE LA CIENCIA DE REDES	9
1.1.1.- EL PROBLEMA DE LOS PUENTES DE KÖNIGSBERG	20
1.1.2.- SOCIOGRAMAS: EL INICIO DEL ANÁLISIS DE REDES SOCIALES	23
1.1.3.- TEORÍA DE GRAFOS ALEATORIOS	29
1.1.4.- "SEIS GRADOS DE SEPARACIÓN". EL EXPERIMENTO DE MILGRAM	32
1.1.5.- EL MODELO DE REDES DE MUNDO PEQUEÑO	35
1.1.6.- EL MODELO DE REDES LIBRES DE ESCALA	40
1.1.7.- IMPORTANCIA DE LAS REDES COMPLEJAS Y SU IMPACTO EN LA INVESTIGACIÓN	42
1.2.- ESTUDIOS RELEVANTES DE REDES COMPLEJAS	44
1.2.1.- "HOMOFILIA" ESTUDIO DE LAZARSFELD Y MERTON	44
1.2.2.- ESTUDIO DE MARK GRANOVETTER: "LA FUERZA DE LOS VÍNCULOS DÉBILES"	46
1.2.3.- MODELO DE FLUJO DE INFORMACIÓN PARA CONFLICTOS Y FISIONES EN GRUPOS PEQUEÑOS DE WAYNE ZACHARY "LA RED ZACHARY KARATE CLUB"	49
1.2.4.- ESTUDIO DE JOHN PADGETT SOBRE: "MATRIMONIO Y LA ESTRUCTURA DE LA ÉLITE EN LA FLORENCIA RENACENTISTA"	52
1.2.5.- APLICACIÓN DE REDES PARA "ANÁLISIS DE COAUTORÍAS"	54
1.2.6.- APLICACIÓN DE REDES PARA LA LUCHA CONTRA EL TERRORISMO: "CAPTURA DE SADDAM HUSSEIN"	59
1.3.- RESEÑA HISTÓRICA DE LOS PIONEROS DE LAS REDES COMPLEJAS	62
1.3.1.- LEONHARD EULER (1707-1783): FUNDADOR DE LA TEORÍA DE GRAFOS	62
1.3.2.- PÁL ERDŐS (1913-1996) Y ALFRÉD RÉNYI (1921-1970): REDES ALEATORIAS	63
1.3.3.- STANLEY MILGRAM (1933-1984): REDES SOCIALES Y EL MUNDO PEQUEÑO	64
1.3.4.- LINTON FREEMAN (1927-2018): MEDIDAS DE CENTRALIDAD EN REDES	65
1.3.5.- MARK NEWMAN (1963): ANÁLISIS DE COMUNIDADES EN REDES	65
1.3.6.- LÁSZLÓ BARABÁSI (1967): REDES LIBRES DE ESCALA	66

1.3.7.- DUNCAN J. WATTS (1971) Y STEVEN STROGATZ (1959): REDES DE MUNDO PEQUEÑO -----	66
CAPÍTULO II -----	68
CONCEPTOS IMPORTANTES EN TEORÍA DE REDES -----	68
2.1.- FUNDAMENTOS CONCEPTUALES DE LA CIENCIA DE REDES -----	68
2.1.1.- ELEMENTOS BÁSICOS DE UNA RED COMPLEJA -----	68
2.1.1.1 Nodos (Vértices) -----	69
2.1.1.2 Enlaces (Aristas)-----	71
2.1.1.3 Atributos -----	73
2.2.- PROPIEDADES, ESTRUCTURA Y TOPOLOGÍA DE UNA RED -----	76
2.2.1.- COMPONENTES DE UNA RED-----	76
2.2.1.1.- Componente Conexo -----	77
2.2.1.2.- Componente Principal o Gigante -----	78
2.2.1.3.- Componentes Aislados o Pequeños Componentes-----	80
2.2.1.4.- Componentes Fuertemente Conexos-----	82
2.2.1.5.- Componentes Débilmente Conexos -----	82
2.2.1.6.- Componentes Biconexos-----	82
2.2.2.- LONGITUD DE LA RED -----	83
2.2.2.1.- Caminos-----	83
2.2.2.2.- Rutas -----	84
2.2.2.3.- Ciclo-----	85
2.2.2.4.- Camarilla (Clique)-----	86
2.2.2.5.- Distancia Geodésica -----	86
2.2.3.- DIÁMETRO Y RADIO DE UNA RED -----	87
2.2.3.1.- Diámetro de la Red -----	87
2.2.3.2.- Radio de la Red -----	88
2.2.4.- DENSIDAD DE UNA RED-----	89
2.2.4.1.- Interpretación y Rango de Valores-----	91
2.2.4.2.- Importancia de la Densidad en Redes Reales-----	91
2.2.4.3.- Factores que Afectan la Densidad -----	91
2.2.5.- COEFICIENTE DE AGRUPAMIENTO-----	92
2.2.5.1.- Coeficiente de Agrupamiento Local (para un nodo individual i)-----	92
2.2.5.2.- Coeficiente de Agrupamiento Global (para toda la red)-----	93
2.2.6.- DISTRIBUCIÓN DE GRADO -----	94
2.2.6.1.- Distribución de Grado en Redes Aleatorias (Erdős-Rényi)-----	95
2.2.6.2.- Distribución de Grado en Redes de Mundo Pequeño (W-S)-----	95
2.2.6.3.- Distribución de Grado en Redes Libres de Escala (Barabási-Albert) --	95

2.2.6.4.- Importancia de la Distribución de Grado -----	96
CAPÍTULO III-----	99
MÉTRICAS DE REDES COMPLEJAS -----	99
3.1.- MEDIDAS Y MÉTRICAS DE ANÁLISIS DE REDES COMPLEJAS-----	99
3.1.1.- MEDIDAS GLOBALES DE LAS REDES COMPLEJAS -----	99
3.1.1.1.- Tamaño de la Red y Densidad -----	99
3.1.1.2.- Distancia Media y Diámetro -----	99
3.1.1.3.- Modularidad y Detección de Comunidades-----	100
3.1.2.- MEDIDAS LOCALES DE LAS REDES COMPLEJAS -----	100
3.1.2.1.- Coeficiente de Agrupamiento-----	100
3.1.2.2.- Transitividad -----	100
3.1.3.- MEDIDAS NODALES O PARTICULARES -----	100
3.1.3.1.- Centralidad de Grado -----	100
3.1.3.2.- Centralidad de Intermediación -----	101
3.1.3.3.- Centralidad de Cercanía-----	101
CAPÍTULO IV -----	102
PREPARACIÓN PARA EL ANÁLISIS -----	102
4.1.- PREPARACIÓN DE DATOS -----	102
4.1.1.- MATRIZ DE ADYACENCIA-----	103
4.1.2.- LISTA DE ADYACENCIA-----	103
4.1.3.- APLICACIÓN EN DIFERENTES TIPOS DE REDES -----	104
4.1.3.1.- Redes No Dirigidas -----	104
4.1.3.2.- Redes Dirigidas -----	105
4.1.3.2.- Redes Ponderadas -----	106
4.1.4.- OTROS FORMATOS-----	108
4.1.4.1.- Archivos Tabulares: CSV y Excel-----	108
4.1.4.2.- Archivos Excel (.xlsx)-----	109
4.1.4.3.- Edge List (.txt, .csv)-----	109
4.1.4.4.- GraphML (.graphml)-----	109
4.1.4.5.- GML (Graph Modelling Language) -----	110
4.1.4.6.- Pajek (.net)-----	110
4.1.4.7.- JSON (JavaScript Object Notation)-----	110
4.2.- SOFTWARE PARA ANÁLISIS DE DATOS Y VISUALIZACIÓN DE REDES	111
4.2.1.- CYTOSCAPE-----	111
4.2.2.- GEPHI -----	111
4.2.3.- PAJEK -----	112
4.2.4.- UCINET -----	112

4.2.5.- R (PAQUETE IGRAPH)-----	112
4.2.6.- PYTHON (BIBLIOTECA NETWORKX) -----	112
4.2.7.- INFLOW -----	113
4.2.8.- NODEXL-----	113
4.2.9.- TULIP -----	113
4.2.10.- NEO4J-----	113
CAPÍTULO V -----	117
REDES COMPLEJAS EN LA PRÁCTICA -----	117
5.1.- CYTOSCAPE -----	117
5.1.1.- CREACIÓN DE REDES -----	119
5.1.2.- CARGA O IMPORTACIÓN DE REDES Y/O TABLAS-----	124
5.1.3.- ANALISIS DE REDES-----	134
5.1.4.- EXPORTAR REDES Y/O TABLAS -----	142
5.2.- GEPHI-----	145
5.2.1.- CREACIÓN DE REDES -----	149
5.2.2.- CARGA O IMPORTACIÓN DE REDES Y/O TABLAS-----	152
5.2.3.- ANALISIS DE REDES-----	163
5.2.4.- EXPORTAR REDES Y/O TABLAS -----	166
REFERENCIAS Y CITAS -----	168

INTRODUCCIÓN

Las redes están en todas partes, desde la intrincada malla de relaciones sociales que conforman nuestras interacciones cotidianas hasta las conexiones neuronales que permiten el pensamiento humano, la teoría de redes complejas se ha convertido en una herramienta indispensable para comprender los sistemas complejos que nos rodean.

Este libro, "Introducción a las redes complejas: De la teoría a la práctica", nos invita a sumergirnos en un universo de nodos y enlaces, donde la ciencia de las interconexiones revela los patrones subyacentes que estructuran desde pequeñas comunidades hasta sistemas globales.

El libro se divide en cinco capítulos que ofrecen un recorrido integral por la teoría, los estudios clásicos, conceptos básicos hasta las aplicaciones prácticas de las redes complejas; y, que invita a lectores interesados en introducirse en el amplio pero maravillosos e intrigante mundo de las redes a atreverse a probar la metodología de redes complejas en sus investigaciones con un lenguaje sencillo pero técnico.

El capítulo I introduce al lector a la evolución histórica de la ciencia de redes, iniciando con el problema de los puentes de Königsberg de Leonhard Euler, que sentó las bases de la teoría de grafos. Posteriormente, se explora el desarrollo de los sociogramas de Jacob Moreno, el nacimiento de los modelos aleatorios con Paul Erdős y Alfréd Rényi, y el impacto del experimento de Stanley Milgram sobre los seis grados de separación.

La sección también aborda los dos modelos fundamentales en la ciencia de redes: las redes de mundo pequeño (Watts y Strogatz, 1998) y las redes libres de escala (Barabási y Albert, 1999). Estas teorías han revolucionado la comprensión de sistemas complejos, mostrando que muchas redes reales presentan características emergentes que favorecen la eficiencia y la robustez.

Se continúa con los estudios clásicos y contribuciones fundamentales, donde se adentra en algunos de los estudios más influyentes en la ciencia de redes. Entre ellos, se destaca:

La fuerza de los vínculos débiles de Mark Granovetter (1973), que revolucionó la comprensión de la difusión de información en redes sociales.

El caso de la familia Médici en el Renacimiento, que demuestra cómo una estructura de redes bien posicionada puede conferir poder político y económico.

El estudio de la red de karate de Wayne Zachary (1977), un caso clásico en el análisis de dinámicas de separación en grupos.

El modelo de coautoría en la investigación científica (Newman, 2001), que revela cómo la ciencia avanza gracias a la colaboración en redes de investigadores.

El uso de redes complejas en la lucha contra el terrorismo, incluyendo el análisis de la captura de Saddam Hussein mediante la exploración de sus conexiones sociales.

Finaliza este capítulo con una breve reseña de los principales autores e investigadores de la ciencia de redes complejas quienes con sus trabajos dieron luz a una nueva ciencia derivada de las ciencias de la complejidad.

El capítulo II presenta los conceptos fundamentales de los componentes estructurales y topológicos de las redes complejas para que el lector pueda interpretar los resultados al aplicar las diversas métricas en función de sus objetivos de estudio.

Desde los conceptos básicos de una red como: nodos, aristas y atributos hasta aquellos que definen la topología de una red, permiten al lector analizar e identificar las propiedades de un ecosistema estudiado mediante la metodología de redes complejas.

El capítulo III se constituye en una guía para aplicar las principales métricas que se usan con la metodología de redes complejas y cómo interpretar sus resultados desde las medidas globales, locales o nodales.

El capítulo IV se enfoca en la aplicación práctica de la teoría de redes complejas, con un énfasis en herramientas y software para el análisis de datos y visualización de redes. Se presentan diez programas clave, incluyendo Cytoscape, Gephi, Pajek, UCINET, Python (NetworkX) y Neo4j, entre otros.

Finalmente, en el capítulo V, el lector aprenderá a construir y analizar redes complejas desde un enfoque computacional, aplicando diversas medidas de centralidad, coeficiente de agrupamiento, distribución de grado, modularidad, comunidad y otras métricas relevantes mediante el uso del software Cytoscape y Gephi. Además, se exploran casos prácticos en diversas disciplinas, con disponibilidad de datos para que los lectores puedan desarrollar sus habilidades en el manejo de la metodología de redes complejas.

El estudio de las redes complejas ha permeado múltiples disciplinas, permitiendo abordar problemas de enorme complejidad con herramientas matemáticas y computacionales.

En biomedicina, por ejemplo, el análisis de redes de interacciones proteicas ha sido clave para entender enfermedades como el cáncer o el Alzheimer; en la economía y administración pública, las redes de transacciones financieras y de contratación pública ayudan a identificar patrones de corrupción y lavado de dinero; en sociología y ciencias políticas, las redes de influencia permiten estudiar dinámicas de poder y movilización social.

El futuro de la investigación en redes complejas está marcado por la integración de inteligencia artificial y el análisis de grandes volúmenes de datos, en este contexto, herramientas como el aprendizaje profundo en grafos prometen avances significativos en el descubrimiento de patrones ocultos en estructuras complejas.

Este libro no solo proporciona un marco teórico introductorio a las redes complejas, sino que también invita al lector a sumergirse en un viaje de exploración y descubrimiento de cada uno de sus componentes y enseña cómo pasar de la teoría a la práctica para poder aplicar la metodología de redes complejas en casos reales de cualquier contexto.

Desde los primeros modelos matemáticos hasta las aplicaciones en la era del Big Data, "Introducción a las redes complejas: De la teoría a la práctica" es una guía indispensable para quienes deseen comenzar a comprender cómo las conexiones dan forma al mundo complejo en que vivimos.

Con un estilo que combina rigor científico con una narrativa cautivadora, esta obra promete ser una referencia clave para el inicio del estudio de redes complejas, así que, estimado lector, prepárese para adentrarse en un mundo donde todo está interconectado, y cada enlace nos lleva un paso más allá en la comprensión de la complejidad del todo.

CAPÍTULO I

LA CIENCIA DE REDES

1.1.- ORIGEN Y EVOLUCIÓN DE LA CIENCIA DE REDES

La ciencia de redes es una disciplina que analiza sistemas compuestos por nodos interconectados mediante enlaces, permitiendo comprender estructuras y dinámicas en diversos ámbitos, su complejidad deviene de la multiplicidad de actores (nodos y enlaces) que interactúan en el sistema (Barabási y Albert, 2015; Newman, 2018; Watts, 2006).

Su origen se remonta al siglo XVIII, cuando el matemático Leonhard Euler intentó resolver el problema de los puentes de Königsberg, sentando las bases de la teoría de grafos. A lo largo del siglo XX, la teoría de grafos se expandió a múltiples disciplinas; en las ciencias sociales por ejemplo, Jacob Moreno introdujo el sociograma en la década de 1930, una herramienta que representaba gráficamente las relaciones interpersonales dentro de un grupo, facilitando el análisis de estructuras sociales (Moreno, 1934).

Simultáneamente, en matemáticas, Paul Erdős y Alfréd Rényi desarrollaron la teoría de grafos aleatorios en los años 1950 y 1960, explorando las propiedades de las redes formadas por conexiones establecidas al azar (Erdős y Rényi, 1959).

En la década de 1960, el concepto de "Mundo Pequeño" fue popularizado por el psicólogo Stanley Milgram, quien demostró que cualquier par de individuos en la sociedad estadounidense estaba conectado por una cadena de aproximadamente seis intermediarios, fenómeno conocido como "Seis Grados de Separación". Este hallazgo resaltó la alta conectividad de las redes sociales humanas (Milgram, 1967).

A finales de la década de 1990, con el auge de Internet y las redes de comunicación, la ciencia de redes experimentó un resurgimiento; investigadores como Duncan Watts y Steven Strogatz introdujeron el modelo de redes de mundo pequeño, que combinaba alta agrupación local con cortas distancias globales, características observadas en muchas redes reales (Watts y Strogatz, 1998).

Posteriormente, Albert-László Barabási y Réka Albert propusieron el modelo de redes libres de escala, donde algunos nodos altamente conectados dentro de un sistema, denominados "Hubs", desempeñan un papel crucial en la estructura de la red (Barabási y Albert, 2015).

La ciencia de redes a lo largo de los años ha demostrado ser una ciencia práctica y muy ligada al comportamiento social e interacción natural de los actores que intervienen en un sistema complejo, ha encontrado aplicaciones en diversas disciplinas; por ejemplo:


En biología, ha permitido mapear y analizar redes de interacciones entre proteínas y genes, facilitando la comprensión de procesos celulares complejos, en esta área se encuentran trabajos como:

- **Redes de interacción de proteínas:** Este trabajo destaca la importancia de las interacciones proteína-proteína en la comprensión de la función proteica y su papel en procesos celulares como el control del ciclo celular y la diferenciación; el estudio de estas redes es fundamental para desentrañar la complejidad de los sistemas biológicos (Juan, 2008).
- **Nuevo método para mapear redes de proteínas:** Científicos del Instituto Salk han desarrollado un método mejorado para mapear rápidamente las interacciones entre proteínas, lo que facilita la comprensión de las "Redes Sociales" de las proteínas y su papel en diversos procesos biológicos (Salk, 2017).
- **Aplicaciones de las redes neuronales y el aprendizaje profundo en la predicción de interacciones proteína-ARN:** Este estudio explora cómo las interacciones entre proteínas y ARN desempeñan un papel crucial en procesos celulares como la transcripción y la replicación, y cómo las técnicas de aprendizaje profundo pueden predecir estas interacciones, proporcionando una comprensión más profunda de los procesos celulares y su interpretación con enfoque y aplicación de otras disciplinas desde la ingeniería hasta la administración de la salud pública (Sarmiento-Ramos, 2020).
- **Análisis topológico de las redes de interacción proteína-proteína humanas:** Este estudio compara cuatro redes de interacción proteína-proteína en humanos, analizando sus características globales, topología de subredes y centralidad de nodos; los resultados indican que, aunque las redes comparten muchos genes codificadores de proteínas y algunas medidas globales, difieren significativamente en las interacciones y vecindades; este análisis es crucial para comprender las relaciones complejas que gobiernan los procesos celulares (Ramos et al., 2023).
- **Mutagénesis de saturación de sitio de 500 dominios proteicos humanos:** El estudio presenta un análisis a gran escala de variantes de aminoácidos en 500 dominios proteicos humanos utilizando técnicas de mutagénesis de saturación por sitios, aquí se combina herramientas experimentales y modelos computacionales para medir los efectos de más de 500,000 variantes sobre la estabilidad de las proteínas y su impacto en la función y patogenicidad. Este trabajo establece un recurso experimental sin

precedentes para interpretar variantes genéticas humanas, avanzando en la comprensión de enfermedades genéticas y el diseño de terapias dirigidas. Además, ilustra el poder de las redes complejas para integrar datos experimentales y modelos computacionales en el análisis de sistemas biológicos (Beltran et al., 2025).

En la revista "Nature", <https://www.nature.com/nmeth/articles> se puede encontrar varias investigaciones y metodologías utilizando redes complejas en estudios de biología.

Figura 1 Mutación del dominio humano



Fuente: Tomado de (Beltran et al., 2025).

En epidemiología, el estudio de las redes de contacto social es esencial para modelar la propagación de enfermedades y diseñar estrategias de control, la aplicación de la teoría de redes complejas en epidemiología ha sido profundamente influenciada por los trabajos de Romualdo Pastor-Satorras y Alessandro Vespignani, entre los que destacan los siguientes:

- **La propagación de epidemias en redes sin escala:** En este artículo seminal, los autores analizan cómo las redes libres de escala afectan la propagación de epidemias, descubrieron que, debido a la alta heterogeneidad en la conectividad de estas redes, no existe un umbral epidémico definido, lo que implica que las enfermedades pueden propagarse incluso con tasas de transmisión muy bajas; este hallazgo tiene implicaciones significativas para el control de enfermedades en redes sociales y tecnológicas (Pastor-Satorras y Vespignani, 2001).
- **Patrones dinámicos de brotes epidémicos en redes heterogéneas complejas:** En este estudio, se investigan los patrones dinámicos de brotes epidémicos en redes heterogéneas complejas, los autores encuentran que la propagación de una epidemia sigue una dinámica jerárquica, afectando primero a los nodos más conectados y luego extendiéndose a nodos con menor conectividad; este comportamiento resalta la importancia de los "Super Propagadores" en la difusión de enfermedades (Barthélemy et al., 2005).
- **Procesos epidémicos en redes complejas:** Este artículo proporciona una revisión exhaustiva de los procesos epidémicos en redes complejas, abarcando tanto modelos teóricos como aplicaciones prácticas; los autores discuten cómo la estructura de la red influye en la dinámica de propagación de enfermedades y exploran estrategias de inmunización y control basadas en la topología de la red (Pastor-Satorras et al., 2015).

Dentro de la misma rama de epidemiología, las últimas décadas, enfermedades como la gripe H1N1 y el Covid-19 (dos fenómenos epidemiológicos uno de los cuales llegó a catalogarse como pandemia), fueron motivo de estudios con diferentes metodologías y ciencias, las redes complejas no quedaron al margen y su enfoque dio paso a muchas investigaciones en las que se demostró la eficacia de los modelos basados en redes complejas para analizar y predecir la propagación de estas enfermedades proporcionando herramientas valiosas para el diseño de estrategias de control y mitigación, entre los estudios más relevantes están:

- **Modelo SIR basado en movilidad para redes complejas: estudio de caso de COVID-19:** Este trabajo presenta un modelo SIR que incorpora patrones de movilidad en redes complejas para analizar la propagación del COVID-19; el estudio destaca la importancia de considerar la movilidad humana y la estructura de la red en la modelización de la propagación de enfermedades (Goel et al., 2021).
- **Identificación de la dinámica de propagación epidémica de COVID-19 mediante redes complejas:** Este artículo investiga cómo la estructura de las redes complejas influye en la dinámica de propagación del COVID-19;

los autores utilizan modelos basados en redes para identificar patrones de propagación y evaluar estrategias de control (Zhan et al., 2021).

- **Modelo de simulación epidémica basado en redes complejas para H1N1:** Este estudio propone un modelo relacionado con la posición y distancia basado en redes complejas para simular la epidemia de H1N1; el objetivo es mejorar la precisión en la simulación de la propagación de la enfermedad considerando factores espaciales y de conectividad (Zongchang, 2024).
- **Inferencia de propiedades de la red a partir de datos epidémicos:** Este artículo centra su análisis durante brotes del mundo real de tres conjuntos de datos diferentes: el brote de fiebre aftosa de 2001 en el Reino Unido; El brote de A(H1N1) en el campus de la Universidad Estatal de Washington (WSU) en Pullman, Washington, en 2009 y la tercera ola de COVID-19 en la India en 2021; el análisis de estos datos permitió inferir propiedades de la red de contactos y comprender mejor la dinámica de propagación de la enfermedad (Kiss et al., 2024).

Figura 2 Predicción de la epidemia de H1N1



Fuente: Tomado de (Barabási y Albert, 2015).

En este contexto de análisis y prevención epidemiológica, la metodología de redes complejas ha proporcionado la base para la formulación de políticas y métodos de alerta y reacción para controlar brotes y enfermedades; por ejemplo, dentro del proyecto GLEAM, se desarrolló un simulador diseñado para investigadores y estudiantes en el campo de la epidemiología, que estén interesados en realizar simulaciones realistas de la propagación de enfermedades infecciosas a escala global, que está disponible en: <https://www.gleamviz.org/>.

Por otra parte, el análisis de redes complejas ha proporcionado herramientas valiosas en sociología para comprender la difusión de información y la formación de comunidades, los siguientes estudios muestran la relevancia de la metodología de redes complejas en la sociología:

- **Aportes de los sistemas y redes complejas para la transformación social:** Este estudio explora cómo las redes complejas orientadas a la transformación social pueden brindar herramientas para comprender la relación de un sistema consigo mismo y con otros; se enfatiza la importancia de analizar las interacciones entre individuos y organizaciones para promover cambios sociales efectivos, destacando la utilidad de las redes complejas en la planificación y ejecución de estrategias de intervención social (Aya-Velandia, 2020).

El análisis de redes complejas ha sido fundamental para comprender cómo las plataformas de redes sociales, como Facebook, Twitter, Instagram o TikTok, facilitan la difusión de información y la formación de comunidades, entre los estudios que abordan estos temas están:

- **Comparación de comportamientos en redes sociales: Comparación entre Twitter e Instagram:** Este artículo examina cómo los usuarios de Twitter e Instagram participan en comportamientos de comparación social, se analiza cómo estas plataformas influyen en la formación de comunidades y en la difusión de información, considerando las diferencias en la interacción y el contenido compartido (Dündar y Tufan, 2022).


- **Análisis de prácticas de autopresentación digital y perfiles de adolescentes españoles en Instagram y TikTok:** Este artículo analiza cómo los adolescentes españoles se presentan en Instagram y TikTok; estudia la formación de comunidades en línea y cómo la difusión de información personal influye en las dinámicas sociales dentro de estas plataformas (Hernández-Serrano et al., 2022).

- **Cobertura de noticias en la red social Facebook: Una revisión sistémica en Scopus de 2018 a 2023:** Este estudio ofrece una revisión sistemática de cómo se ha cubierto la difusión de noticias en Facebook durante el período 2018-2023; en la investigación se analiza la propagación de información y desinformación, destacando los patrones de interacción entre usuarios y la formación de comunidades en torno a contenidos noticiosos (Díaz-Vicente et al., 2024).

- **Redes complejas como metodología para estudios sociales: El caso Son de Amores":** contribuye significativamente al análisis de redes complejas en el ámbito social, específicamente en el estudio de la difusión de contenido viral en medios digitales y su impacto sociocultural; este caso, originado a partir de un video creado por una YouTuber en Perú, sirve como ejemplo

paradigmático de cómo una pieza de contenido puede activar redes sociales y digitales complejas, generando fenómenos de viralización y construcción de comunidades en torno a una narrativa específica (Redroban-Ortiz, et al., 2024).

Figura 3 Visualización de la topología de Internet IPv4 e IPv6 a escala macroscópica en 2020



Fuente: Tomado del proyecto CAIDA en <https://www.caida.org/projects/as-core/2020/>

No cabe duda que, el desarrollo y evolución de las redes sociales ha sido gracias a la existencia y evolución del internet, proyectos como <https://www.opte.org/>, o <https://www.caida.org/>, permiten monitorear el comportamiento del internet con la integración de varios actores que aportan desde sus perspectivas y disciplinas; más resultados de los estudios del proyecto "CAIDA" se pueden acceder en: <https://catalog.caida.org/search?query=types=paper%20links=tag:caida%20>.

En economía, la metodología de redes complejas ha permitido estudiar y caracterizar la economía financiera de algunos países o regiones, facilitando la comprensión de fenómenos que han permitido el desarrollo de muchos países o el desarrollo de catástrofes financieras, en esta área se encuentran trabajos como:

- **El juego de las pirámides:** El estudio destaca que las decisiones económicas no siempre obedecen a una racionalidad perfecta, sino a procesos de formación de expectativas locales influenciadas por la

estructura global de la red social. Este enfoque es relevante para comprender fenómenos financieros como burbujas económicas, crisis de confianza y la propagación de choques económicos; los autores analizan el auge y colapso de esquemas piramidales en el suroccidente de Colombia, empleando la teoría de redes complejas y de juegos; se centra en cómo estas estructuras, incrustadas en redes sociales, crecen aprovechando la confianza y los vínculos fuertes entre individuos, pero también colapsan cuando las expectativas cambian debido al flujo de información negativa. El uso de redes complejas, combinado con la teoría de juegos, ofrece herramientas poderosas para analizar fenómenos colectivos en entornos de incertidumbre, aportando una perspectiva innovadora en la intersección entre economía y sociología (Trujillo y Escobar, 2009).

- **Las relaciones comerciales en América Latina en 1995 y 2015: Un análisis de redes complejas:** El estudio muestra que el análisis de redes complejas es una herramienta poderosa para comprender la interdependencia económica y las dinámicas comerciales globales. En el artículo se utiliza la metodología de redes complejas para estudiar la evolución de las relaciones comerciales entre 17 países de América Latina en los años 1995 y 2015. Los datos se basan en los principales socios comerciales de exportaciones e importaciones, analizando las características topológicas de las redes y los cambios en la composición de las canastas comerciales. Este enfoque proporciona una visión integral de cómo las políticas comerciales y las condiciones económicas globales moldean las relaciones comerciales, ofreciendo perspectivas útiles para diseñar estrategias de integración y desarrollo económico en América Latina (Gómez-Hernández et al., 2017).
- **Análisis de redes complejas del transporte marítimo en el Océano Atlántico:** El análisis aplicado al transporte marítimo proporciona una comprensión más profunda de cómo las crisis económicas impactan las redes logísticas globales; el artículo utiliza la metodología de análisis de redes complejas para estudiar los cambios en la conectividad del transporte marítimo en el Océano Atlántico entre 2006 y 2011, un período marcado por la Gran Recesión. Los autores analizan cómo los flujos comerciales se desplazaron hacia regiones del Atlántico Sur, como las costas de Brasil, Uruguay, Argentina y el Golfo de Guinea, en contraste con las economías del norte del Atlántico que fueron más vulnerables a la crisis; además, destacan la utilidad de las redes complejas para modelar y optimizar sistemas económicos interconectados, reforzando la importancia de integrar estas herramientas en el análisis de políticas comerciales y logísticas (González Laxe et al., 2019).
- **Análisis de redes complejas: Un estudio de la inflación en Uruguay:** El artículo establece un enfoque innovador para analizar la inflación como un

fenómeno emergente de un sistema complejo; los autores exploran la relación entre la incertidumbre macroeconómica y la dinámica del sistema de precios en Uruguay utilizando la metodología de análisis de redes complejas. El estudio abarca el período 1997-2020, construyendo redes basadas en datos del Índice de Precios al Consumo (IPC), donde los nodos representan clases de bienes y servicios, y las aristas corresponden a correlaciones en sus precios. Este trabajo no sólo amplía la comprensión de la inflación en Uruguay, sino que también demuestra el potencial de las redes complejas para informar políticas económicas y monetarias. Al proporcionar herramientas para anticipar disrupciones en los sistemas de precios, este enfoque tiene implicaciones prácticas para bancos centrales y formuladores de políticas económicas (Álvarez et al., 2022).


En administración, el análisis con la metodología de redes complejas ha proporcionado herramientas innovadoras para la gestión de las organizaciones y toma de decisiones; a continuación, se presentan algunos estudios referenciales:

- **Análisis de la estructura de una red de conocimiento en México:** El artículo analiza la estructura de la Red de Medio Ambiente (REMA) del Instituto Politécnico Nacional (IPN) de México, compuesta por 231 investigadores de 14 centros. Se utiliza la teoría de redes complejas para evaluar la colaboración científica en términos de grado, intermediación y coeficiente de agrupamiento. El estudio abarca publicaciones científicas, libros, capítulos de libros y tesis dirigidas entre 2009 y 2011. El estudio proporciona un modelo replicable para analizar redes de colaboración en organizaciones, mostrando cómo las interacciones y la distribución de recursos afectan la productividad. Su enfoque permite diseñar estrategias para fomentar la integración entre actores clave, maximizando la generación de conocimiento y el impacto organizacional (Cárdenas Tapia et al., 2015).
- **Redes empresariales y patrones de cooperación en MIPYMES textiles en México:** El artículo analiza los patrones de cooperación en redes empresariales del sector textil en Acolman - México, utilizando la teoría de redes complejas. Los autores evalúan cómo las micro, pequeñas y medianas empresas (Mipymes) forman y mantienen relaciones en torno a la cadena de valor, identificando las dinámicas de interacción y los desafíos en un sector crucial para la economía local. Este estudio ofrece una aplicación innovadora de las redes complejas en la gestión empresarial, destacando cómo los patrones de cooperación influyen en la sostenibilidad de las empresas textiles en contextos desafiantes; además, proporciona un marco analítico para identificar barreras estructurales y diseñar estrategias que fortalezcan las cadenas de valor mediante alianzas estratégicas, fomentando la integración de actores clave como universidades y gobiernos (Ayala et al., 2023).

- **Análisis bibliométrico de la investigación en big data y cadena de suministro:** Este estudio examina la relación entre big data y la gestión de la cadena de suministro, áreas que se benefician del análisis de redes complejas; se destaca cómo la analítica de big data puede mejorar la competitividad, el rendimiento y la productividad de las cadenas de suministro sostenibles (Duque et al., 2023).

La ciencia de redes ha trascendido de la teoría a la práctica en el contexto organizacional, soluciones integrales como <http://www.orgnet.com> o <https://orgmapper.com/>, basan su estrategia de diagnóstico empresarial en la metodología de redes complejas, brindando a las empresas mecanismos técnicos y ágiles para detectar deficiencias y perfeccionar sus fortalezas.

Figura 4 Análisis organizacional basado en redes complejas



Fuente: Tomado de <https://orgmapper.com/organizational-network-analysis/>

La aplicación de la metodología de redes complejas en la administración pública ha demostrado ser efectiva en el control de la cosa pública; algunos estudios proporcionan una visión amplia de cómo la metodología de redes complejas se aplica en la administración pública para identificar y analizar patrones de corrupción, ofreciendo herramientas valiosas para mejorar la transparencia, eficiencia y el control de los recursos públicos, tales como:

- **Corrupción en el sector público: Un análisis bibliométrico e identificación de tendencias:** El artículo presenta un análisis bibliométrico de investigaciones sobre corrupción en el sector público, utilizando la base de datos Scopus y herramientas como el software R y Gephi para mapear redes de conocimiento. Se abordan los avances en el tema entre los años 2000 y 2021, destacando patrones y tendencias en la literatura académica; el estudio organiza

las contribuciones científicas en tres categorías metafóricas: raíces (documentos fundacionales), tronco (trabajos estructurales) y hojas (investigaciones actuales y futuras). El artículo destaca cómo la metodología de redes complejas puede mejorar la comprensión de la corrupción en el sector público y guiar políticas para combatirla; la transparencia en los procesos gubernamentales y la implementación de herramientas tecnológicas son esenciales para fortalecer la confianza ciudadana y la eficiencia en la gestión pública; este enfoque interdisciplinario tiene el potencial de transformar las estrategias anticorrupción, optimizando recursos y mejorando la rendición de cuentas (Alzate-Cárdenas et al., 2022).

▪ **Redes complejas como metodología para el control gubernamental en procesos de contratación pública en Ecuador:** El artículo analiza el uso de redes complejas como herramienta para identificar patrones de corrupción y mejorar el control gubernamental en los procesos de contratación pública en Ecuador, basándose en un análisis de 19,797 procesos de contratación realizados en 2023, los autores utilizan métricas de centralidad para identificar nodos recurrentes (proveedores y entidades contratantes) y sus relaciones contractuales (enlaces); en este trabajo se destaca el potencial de las redes complejas como herramienta analítica para gestionar grandes volúmenes de datos y mejorar la transparencia en la administración pública. La metodología propuesta no solo contribuye al control de recursos, sino que también proporciona una base técnica y científica para fortalecer las políticas anticorrupción, reforzando la confianza pública en los procesos gubernamentales (Redroban-Ortiz, et al., 2024).

Prácticamente la ciencia de redes se abre campo en todas las disciplinas como una metodología que ayuda a comprender fenómenos relacionales entre actores de un ecosistema social, económico, político, organizacional, etc. En el enlace: www.orgnet.com/stories.html, se pueden encontrar varios ejemplos de cómo las redes complejas han cambiado la forma de diagnosticar a las organizaciones e implementar estrategias de cambio en las diferentes disciplinas.

Con el avance de la tecnología y la disponibilidad de grandes volúmenes de datos, la ciencia de redes ha evolucionado hacia el análisis de redes dinámicas y multicapa, donde se consideran múltiples tipos de relaciones y su evolución en el tiempo.

Además, la integración de técnicas de aprendizaje automático ha permitido abordar problemas complejos, como la predicción de enlaces y la detección de comunidades en redes a gran escala.


En la actualidad, la ciencia de redes continúa expandiéndose, incorporando enfoques interdisciplinarios y adaptándose a los desafíos de un mundo cada vez más interconectado. Su capacidad para modelar y analizar sistemas complejos la convierte en una herramienta esencial para comprender fenómenos en campos tan diversos como la biología, la sociología, la informática, la economía, la política, la administración, etc.

La ciencia de redes ha recorrido un largo camino desde los trabajos pioneros de Euler hasta convertirse en una disciplina fundamental para el análisis de sistemas complejos en la era moderna. Su evolución refleja la creciente necesidad de comprender las interconexiones que subyacen a los fenómenos naturales y sociales, proporcionando herramientas analíticas y conceptuales para abordar los desafíos de un mundo interdependiente, para ello es imprescindible conocer sus orígenes y su evolución a detalle a fin de comprender el marco teórico que en la actualidad está ayudando a revolucionar la forma de analizar las interconexiones de los sistemas complejos.

1.1.1.- EL PROBLEMA DE LOS PUENTES DE KÖNIGSBERG

La ciudad de Königsberg, situada en la actual región de Kaliningrado, Rusia, fue en el siglo XVIII un importante centro cultural y comercial de Prusia; dividida por el río Pregel, la ciudad estaba conformada por dos grandes islas y varias zonas conectadas mediante siete puentes. Este sistema de puentes se convirtió en el tema de un enigma matemático que intrigó a los habitantes de Königsberg: ¿Es posible recorrer la ciudad cruzando cada puente una única vez y regresando al punto de partida? (Biggs et al., 1986).


Figura 5 Antigua ciudad de Königsberg



Fuente: Tomado del Libro "Graph Theory" de N. Biggs, E. Lloyd, y R. Wilson, 1986.

El problema de los siete puentes de Königsberg encontró su solución en 1736 gracias al matemático suizo Leonhard Euler, quien no solo resolvió el enigma, sino que también dio origen a una nueva rama de las matemáticas conocida como teoría de grafos. Su análisis fue revolucionario porque introdujo un enfoque completamente nuevo para abordar problemas relacionados con estructuras y conexiones (Jankvist, 2015).

Figura 6 Desarrollo del problema de Königsberg



Fuente: Secuencia de imágenes de video tomado de (A. Barabási, 2022)

En su estudio, Euler representó las distintas áreas de Königsberg (Fig. 6 a)) como puntos o nodos (Fig. 6 b)) y los puentes como líneas que conectaban estos puntos o aristas (Fig. 6 c)). Este esquema abstracto permitió transformar un problema aparentemente geográfico en una cuestión puramente matemática (Fig. 6 d)). Euler observó que para recorrer cada puente una única vez y regresar al punto de partida, cada nodo debería tener un número par de conexiones (aristas). Sin embargo, al analizar el grafo correspondiente a Königsberg, descubrió que todos los nodos tenían un número impar de conexiones; esto demostró que era imposible cumplir con las condiciones del enigma (Biggs et al., 1986).

El trabajo de Euler marcó un punto de inflexión en la historia de las matemáticas, pues introdujo un concepto que trascendía los cálculos aritméticos o geométricos tradicionales, su enfoque estableció las bases de la teoría de grafos, una disciplina que estudia las relaciones entre objetos mediante nodos y aristas; aunque el problema de los puentes de Königsberg pueda parecer simple desde una perspectiva moderna, su resolución representa el nacimiento del análisis estructural en matemáticas (Rahman, 2017).

Con el tiempo, las ideas de Euler evolucionaron y encontraron aplicación en diversos campos; por ejemplo, la teoría de grafos se utiliza para modelar redes de transporte, interacciones sociales, circuitos eléctricos, y conexiones moleculares, entre otros sistemas. Esto ha dado lugar al desarrollo de la ciencia de redes complejas, una disciplina interdisciplinaria que busca entender cómo

las conexiones y estructuras influyen en el comportamiento de sistemas complejos (Barabási, 2022; Newman, 2018; Sayama, 2015; Watts, 2006).

El análisis de Euler también introdujo el concepto de camino euleriano, que se refiere a un recorrido que atraviesa cada arista de un grafo exactamente una vez. Este concepto ha sido fundamental en problemas de optimización y logística, como el diseño de rutas de distribución o el trazo de circuitos en electrónica. Asimismo, la teoría de grafos se ha integrado en el análisis de redes sociales, permitiendo estudiar las interacciones entre individuos y grupos (Newman, 2018).


La transición del problema de los puentes de Königsberg hacia la teoría de redes complejas ilustra cómo una cuestión específica puede transformarse en una herramienta universal para abordar sistemas interconectados. En redes complejas, los conceptos de nodos y aristas se extienden para representar no solo conexiones físicas, como los puentes, sino también relaciones abstractas, como las conexiones en una red de computadoras o las interacciones en un ecosistema (Barabási, 2022).

El legado de Euler se refleja en la forma en que los científicos y académicos abordan problemas en campos tan diversos como la biología, la informática y las ciencias sociales; su resolución del problema de los puentes de Königsberg no solo dio origen a la teoría de grafos, sino que también inspiró un nuevo paradigma de pensamiento, donde las conexiones y estructuras ocupan un lugar central en el análisis de sistemas complejos. En última instancia, este trabajo pionero demuestra cómo una cuestión local puede generar un impacto global al influir en la forma en que entendemos y modelamos el mundo interconectado que nos rodea.

1.1.2.- SOCIOGRAMAS: EL INICIO DEL ANÁLISIS DE REDES SOCIALES

Jacob Moreno, psiquiatra y sociólogo de origen rumano, es reconocido por introducir en la década de 1930 el sociograma como una herramienta innovadora para representar gráficamente las relaciones interpersonales dentro de un grupo; esta metodología no solo facilitó el análisis de estructuras sociales, sino que también sentó las bases para el desarrollo de la teoría de redes sociales.


Figura 7 Sociograma



Fuente: Sociograma tomado de Adobe Stock

Moreno, desarrolló la sociometría, una técnica destinada a medir las relaciones sociales y las preferencias afectivas entre individuos en un grupo; el sociograma emergió como una representación visual de estos datos, donde los individuos se representan como nodos y las relaciones entre ellos como líneas o arcos (Fig. 7), esta representación gráfica permite identificar patrones de interacción, como líderes, aislados y subgrupos dentro de una comunidad.

Figura 8 Claves para los sociogramas de Jacob Moreno (Key to charts)



Fuente: Tomado (J. Moreno, 1934, p. 30.)

La obra de Moreno, resalta la importancia que pocas obras dan a la correcta identificación que deben tener los componentes de una red como son las características o particularidades de sus nodos y de sus relaciones, las cuales en el contexto de las redes complejas se las conoce como "Atributos" (Fig. 8); estos atributos permiten por una parte, diseñar la estructura de la red y por otra parte, presentar una visualización de fácil entendimiento guiada por la leyenda de los atributos, de ahí la importancia de realizar un correcto diseño del "Key to Chart".

Precisamente Jacob Moreno realiza el "Key to Chart" en su obra: "Who Shall Survive?", para proporcionar una guía detallada que permita interpretar los elementos del sociograma que desarrolla. Este apartado es esencial porque clarifica cómo las elecciones y relaciones entre los miembros del grupo estudiado se representan gráficamente en el sociograma, asegurando que los

lectores puedan comprender correctamente la estructura de las interacciones sociales que está ilustrando.

Empero, ¿cuál es el propósito de la "*Key to Chart*"?

Clarificación Visual:

- La clave sirve como un índice visual que detalla lo que representa cada símbolo y las conexiones en el sociograma.
- Moreno utiliza formas, colores y líneas específicas para diferenciar entre tipos de relaciones, como elecciones recíprocas, unilaterales o rechazos.

Estandarización de la Representación:

- La sociometría introduce un enfoque sistemático para medir relaciones sociales, y el "*Key to Chart*" garantiza consistencia en cómo se visualizan estos datos.
- Permite que otros investigadores y lectores interpreten los gráficos de manera uniforme, facilitando la replicación y comparación de estudios sociométricos.

Facilitación del Análisis:

- Al incluir una clave, Moreno asegura que el lector pueda identificar rápidamente patrones sociales clave, como líderes, individuos aislados o subgrupos.
- Esto es fundamental para evaluar las dinámicas grupales y planificar intervenciones sociales.

Educación y Difusión de la Metodología:

- Como pionero de la sociometría, Moreno buscaba educar a otros sobre esta metodología innovadora.
- La clave es una herramienta pedagógica que simplifica la interpretación de los datos y fomenta el uso del sociograma en diferentes campos, como la educación, la psicología y la sociología.

El "*Key to Chart*" de Moreno que en las redes complejas es necesario diseñarlo y presentarlo para identificar los tributos de los nodos y las relaciones, es una guía interpretativa diseñada para hacer que los resultados sociométricos sean accesibles, comprensibles y útiles tanto para investigadores como para profesionales interesados en las dinámicas de relaciones grupales.

Procedimiento para la Elaboración del Sociograma:

- **Definición del Grupo de Estudio:** Moreno seleccionaba un grupo natural cuyos miembros se conocían entre sí, como una clase escolar, un equipo de trabajo o una comunidad. La familiaridad entre los integrantes era esencial para obtener datos precisos sobre las relaciones interpersonales.
- **Aplicación del Test Sociométrico:** Se utilizaba un cuestionario en el que se pedía a cada miembro del grupo que eligiera, según criterios específicos, a otros compañeros con los que preferiría o no realizar ciertas actividades. Por ejemplo, se podría preguntar: "¿Con quién te gustaría trabajar en un proyecto?" o "¿A quién elegirías para acompañarte en una tarea?". Estas preguntas permitían identificar las preferencias y rechazos dentro del grupo.
- **Recopilación y Análisis de Datos:** Las respuestas se recopilaban y se analizaban para determinar las elecciones recíprocas, unilaterales y los rechazos. Este análisis proporcionaba una visión cuantitativa de las relaciones afectivas y sociales dentro del grupo.
- **Construcción del Sociograma:** Utilizando los datos obtenidos, se elaboraba un diagrama en el que cada individuo se representaba como un punto (nodo) y las relaciones entre ellos como líneas (arcos). Las líneas podían ser unidireccionales o bidireccionales, dependiendo de si la elección era mutua o unilateral. Este gráfico visualizaba la estructura de la red social del grupo, destacando aspectos como líderes, individuos aislados, subgrupos y la cohesión general del grupo.

Aplicación de las Redes en el Sociograma:

- El sociograma permitía a Moreno y a otros investigadores identificar patrones y estructuras dentro de las relaciones grupales. Al representar gráficamente las conexiones entre individuos, se podían observar fenómenos como:
- **Liderazgo y Popularidad:** Individuos con múltiples conexiones entrantes eran identificados como líderes o personas populares dentro del grupo.
- **Aislamiento Social:** Personas con pocas o ninguna conexión podían ser vistas como aisladas, lo que facilitaba intervenciones para mejorar su integración.
- **Subgrupos y Cliques:** La formación de subgrupos dentro del grupo principal se hacía evidente, permitiendo el estudio de dinámicas internas más complejas.
- **Cohesión y Fragmentación:** Se podía evaluar el grado de cohesión o fragmentación del grupo, lo cual es crucial para entender su funcionamiento y eficacia.

Este enfoque innovador de Moreno proporcionó una metodología sistemática para el análisis de las estructuras sociales, sentando las bases para el desarrollo de la teoría de redes sociales y ofreciendo herramientas valiosas para la intervención en dinámicas grupales y complejas.

Aplicaciones Prácticas del Sociograma

El sociograma ha demostrado ser una herramienta valiosa en diversos contextos:

Educación: Los docentes pueden utilizar sociogramas para comprender las dinámicas de sus aulas, identificar estudiantes aislados o detectar posibles conflictos, facilitando intervenciones más efectivas (Martínez Romera, 2018).

Psicología: Los terapeutas emplean sociogramas para analizar las relaciones de sus pacientes, comprendiendo mejor su entorno social y las influencias que este ejerce sobre su comportamiento (López, 2023).

Sociología: Los investigadores utilizan sociogramas para estudiar la estructura de comunidades, organizaciones y otros grupos sociales, proporcionando una visión clara de las interacciones y relaciones de poder existentes (Ávila, 2012).

Impacto en la Teoría de Redes

La introducción del sociograma por Moreno fue un hito que impulsó el desarrollo de la teoría de redes sociales; al proporcionar una representación visual de las relaciones interpersonales, el sociograma facilitó la comprensión de cómo los individuos se conectan y cómo estas conexiones afectan el comportamiento colectivo. Este enfoque ha sido fundamental para el análisis de redes sociales, permitiendo:

- **Identificación de Estructuras:** Los sociogramas permiten visualizar estructuras como cliques, puentes y nodos aislados, proporcionando información valiosa sobre la cohesión y fragmentación de un grupo.
- **Análisis de Influencia:** Al identificar nodos centrales o periféricos, es posible determinar quiénes son los individuos más influyentes dentro de una red social y cómo fluye la información o las normas a través de la misma.
- **Estudio de la Dinámica Social:** Los sociogramas facilitan el análisis de cómo las relaciones cambian con el tiempo, permitiendo comprender procesos como la formación de alianzas, la exclusión social y la evolución de las normas grupales.

Evolución y Relevancia Actual

Desde la introducción del sociograma, el análisis de redes sociales ha evolucionado significativamente, incorporando métodos computacionales y


estadísticas avanzadas; sin embargo, la representación gráfica de las relaciones sigue siendo una herramienta esencial para comprender la complejidad de las interacciones humanas. En la era digital, donde las redes sociales en línea juegan un papel predominante, el legado de Moreno es más relevante que nunca, proporcionando fundamentos para el análisis de plataformas como Facebook, Instagram, X, TikTok, etc.

1.1.3.- TEORÍA DE GRAFOS ALEATORIOS

La teoría de grafos aleatorios, desarrollada por Paul Erdős y Alfréd Rényi a finales de la década de 1950, ha sido fundamental en el estudio de las redes complejas; su modelo, conocido como Erdős–Rényi (ER), proporciona una base para comprender cómo se forman y evolucionan las redes cuando las conexiones entre nodos se establecen de manera aleatoria (Erdős y Rényi, 1959).

Una red aleatoria consiste en un grafo cuyos nodos están conectados aleatoriamente con una determinada probabilidad p . En la práctica son muy útiles para experimentar escenarios de una red desconectada a una red totalmente conectada, siendo importantes las fases intermedias que pueden llegar a formar las redes de mundo pequeño o redes complejas también llamadas redes libres de escala (Barabási y Albert, 2015; Watts y Strogatz, 1998).

Figura 9 Modelo de redes aleatorias



Fuente: Generado a través de NetLogo, en base del modelo creado por la UNAM, (2020)

El Modelo Erdős–Rényi (ER)

El modelo ER es uno de los enfoques más simples y estudiados para generar grafos aleatorios. Existen dos variantes principales del modelo:

Modelo $G(n,M)$: Se fija un número n de nodos y un número M de aristas. Se seleccionan aleatoriamente M aristas de entre todas las posibles combinaciones de pares de nodos.

Modelo $G(n,p)$: Cada par de nodos tiene una probabilidad p de estar conectado por una arista, independientemente de los demás pares.

Ambos modelos son equivalentes en ciertos límites, pero el modelo $G(n,p)$ es más común debido a su simplicidad analítica; el centro de la complejidad de la Universidad Nacional Autónoma de México – UNAM, durante los años 2020 y 2021, realizó talleres en línea para capacitar y modelar redes complejas, mediante el uso de varios programas libres; por ejemplo la figura 9, muestra la generación de una red aleatoria utilizando NetLogo de fácil manejo y disponible en <https://complejidad-iiec.web.app/cursotaller2020/redes/redes-netlogo/index.html>

Propiedades del Modelo ER

El modelo ER exhibe varias propiedades interesantes que han sido objeto de estudio:

- **Distribución de Grados:** En un grafo ER, el número de conexiones (grado) de un nodo sigue una distribución binomial. Para grandes n y pequeños p , esta distribución se aproxima a una distribución de Poisson con media $\langle k \rangle = p(n-1)$.
- **Conectividad:** Existe un umbral crítico para la probabilidad p . Si $p > \frac{\ln n}{n}$, el grafo es casi seguramente conexo; es decir, hay un camino entre cualquier par de nodos.
- **Componentes Gigantes:** Cuando p supera un valor crítico, emerge un "componente gigante" que contiene una fracción significativa de los nodos del grafo.
- **Longitud de Camino Promedio:** La distancia promedio entre dos nodos cualesquiera en un grafo ER es proporcional a $\ln n / \ln \langle k \rangle$, lo que indica que incluso en grafos grandes, las distancias promedio son pequeñas.

Aplicaciones en Redes Complejas

Aunque el modelo ER es idealizado, ha sentado las bases para el análisis de redes reales; sin embargo, muchas redes complejas del mundo real, como las

redes sociales, biológicas o tecnológicas, exhiben características que difieren de las predicciones del modelo ER. Por ejemplo, en las redes sociales, es común observar una alta transitividad o coeficiente de agrupamiento, donde si el nodo **A** está conectado al nodo **B**, y **B** está conectado al nodo **C**, existe una alta probabilidad de que **A** también esté conectado a **C**.

Además, muchas redes reales presentan una distribución de grados que sigue una ley de potencia, con unos pocos nodos altamente conectados (*hubs*) y muchos nodos con pocas conexiones. Este comportamiento difiere de la distribución de Poisson predicha por el modelo ER y ha llevado al desarrollo de modelos más complejos, como las redes de mundo pequeño y las redes libres de escala (Barabási y Albert, 2015; Watts y Strogatz, 1998).

Limitaciones del Modelo ER

Aunque el modelo ER ha sido influyente, presenta limitaciones al intentar describir redes reales:

- **Distribución de Grados:** No captura la distribución de grados con cola pesada observada en muchas redes reales.
- **Coeficiente de Agrupamiento:** Subestima el nivel de agrupamiento presente en redes sociales y biológicas.
- **Correlaciones de Grado:** No considera las correlaciones entre los grados de nodos conectados, que son comunes en redes reales.

Estas limitaciones han motivado el desarrollo de modelos más avanzados que incorporan características observadas en redes reales, como el modelo de Barabási–Albert para redes libres de escala y el modelo de Watts–Strogatz para redes de mundo pequeño.

Importancia y Uso en Casos Reales

A pesar de sus limitaciones, el modelo ER ha sido fundamental para comprender los principios básicos de la formación de redes y ha proporcionado una línea base para comparar modelos más complejos. Ha sido utilizado en diversas aplicaciones tales como:

- **Epidemiología:** Para modelar la propagación de enfermedades en poblaciones donde las interacciones entre individuos pueden considerarse aleatorias.
- **Redes de Comunicación:** Para analizar la robustez y vulnerabilidad de redes donde las conexiones pueden fallar de manera aleatoria.

- **Biología de Sistemas:** Para estudiar redes genéticas y metabólicas, proporcionando una comprensión inicial de cómo las interacciones aleatorias pueden influir en la funcionalidad biológica.

La teoría de grafos aleatorios de Erdős y Rényi ha sido una piedra angular en el estudio de las redes complejas. Aunque el modelo ER es una simplificación, ha proporcionado una base sólida para el desarrollo de modelos más realistas que capturan las complejidades de las redes del mundo real. Su estudio ha permitido avances significativos en campos tan diversos como la epidemiología, ya que proporciona una base para comprender cómo se difunden las infecciones cuando las conexiones entre individuos se establecen de manera aleatoria.

Un ejemplo destacado es el estudio de Clancy (2022), "Una nueva relación entre los gráficos de Erdős-Rényi, los modelos epidémicos y el movimiento browniano con deriva parabólica"; este trabajo examina el modelo Reed-Frost, un ejemplo de modelo SIR (Susceptible-Infectado-Recuperado), y su relación con los grafos ER. El autor encuentra que, dentro de una ventana crítica, la sumativa de un estadístico específico converge débilmente a la integral de un movimiento browniano con deriva parabólica, estableciendo una conexión entre los gráficos ER, los modelos epidémicos y ciertos procesos estocásticos.

Además, en el trabajo "La epidemia SIR en un gráfico aleatorio dinámico de Erdős-Rényi", Huang y Röllin (2024), investigan el modelo SIR en un grafo ER dinámico y no homogéneo. Establecen una ley de grandes números funcional para las curvas de susceptibles, infectados y recuperados, demostrando que, bajo diversas escalas de los parámetros del modelo, las curvas epidémicas son soluciones a un sistema de ecuaciones diferenciales ordinarias.

Aunque el modelo ER es una simplificación y no captura todas las características de las redes de contacto reales, estos estudios demuestran su utilidad para comprender aspectos fundamentales de la propagación de enfermedades y para desarrollar estrategias de control en epidemiología.

1.1.4.- "SEIS GRADOS DE SEPARACIÓN". EL EXPERIMENTO DE MILGRAM

El origen del concepto de los "seis grados de separación" se remonta a 1929, cuando el escritor húngaro Frigyes Karinthy propuso la idea en su relato "Cadenas" (Ardissom de Souza, 2018). Sin embargo, fue en la década de 1960 cuando el psicólogo estadounidense Stanley Milgram llevó a cabo un experimento que buscaba validar esta hipótesis (Watts, 2006).

En 1967, Milgram diseñó un estudio para investigar la estructura de las redes sociales y la distancia social entre individuos en Estados Unidos. Su objetivo era

determinar cuántas conexiones eran necesarias para que una carta enviada por una persona llegara a un destinatario específico a través de conocidos mutuos, bajo la hipótesis denominada "El Problema del Mundo Pequeño" (Milgram, 1967).

El Experimento de Milgram

Milgram inició su experimento seleccionando aleatoriamente a individuos en Nebraska y Kansas, a quienes se les pidió que enviaran una carta a una persona objetivo en Boston, Massachusetts. Los participantes debían remitir la carta a alguien que conocieran personalmente y que, según su criterio, estuviera más cerca socialmente del destinatario final. Este proceso continuaba hasta que la carta llegaba al objetivo o se perdía en el camino.

De los cientos de cadenas iniciadas, solo pocas llegaron a su destino. Milgram descubrió que, en promedio, se requerían entre cinco y seis intermediarios para que la carta alcanzara al destinatario final, lo que dio origen al término "seis grados de separación", frase que aprovechó John Guare para su obra de teatro estrenada en 1990 (Watts, 2006).

Planteamiento del Problema

Milgram quería probar la hipótesis de que las personas en una sociedad están conectadas a través de una pequeña cantidad de intermediarios (Fig. 10). Para ello, diseñó el experimento en el que las personas debían enviar un mensaje a un destinatario desconocido utilizando únicamente su red de conocidos.

Selección de Participantes

Se seleccionaron aleatoriamente participantes de dos estados de EE.UU.:

- Nebraska
- Kansas

Objetivo del Experimento

El objetivo final era contactar a una persona específica en Boston, Massachusetts.

Instrucciones del Experimento

Cada participante recibió un paquete con:

- Una carta con instrucciones
- Una ficha con información sobre el destinatario final (nombre, ciudad y ocupación).

- Un formulario de seguimiento para registrar cada transferencia

Las reglas eran simples:

- No podían enviar la carta directamente al destinatario.
- Debían enviarla a alguien que conocieran personalmente y que, en su opinión, estuviera más cerca del destinatario en términos sociales.

Desarrollo del Experimento

Cada remitente enviaba la carta a un amigo o conocido, quien a su vez la reenviaba a otro contacto más cercano al destinatario. Este proceso se repetía hasta que la carta llegaba al objetivo final en Boston.


Milgram y su equipo registraron cuántas cartas llegaban a su destino y cuántos intermediarios fueron necesarios en cada caso.

Resultados

- Se enviaron 296 cartas.
- Solo 64 llegaron al destino final.
- El número promedio de intermediarios fue 5.2 personas, lo que llevó a la popularización del concepto de "seis grados de separación".
- Aunque el experimento ayudó a demostrar que las redes sociales son pequeñas y altamente conectadas, tuvo algunas limitaciones:
- Tasa de éxito baja: Solo el 21.62% de las cartas llegaron a su destino.
- Sesgo geográfico: Se realizó solo en EE.UU.
- Participación desigual: Algunas personas tienen muchas más conexiones que otras, afectando los resultados

A pesar de sus limitaciones, este experimento sentó las bases para la teoría moderna de redes sociales y tuvo aplicaciones en áreas como la epidemiología, el análisis de redes informáticas y las plataformas digitales.

Figura 10 Representación de la idea de los seis grados de separación



Fuente: Generado con asistente de AI Dall-E, para ejemplificar el experimento de Milgram

1.1.5.- EL MODELO DE REDES DE MUNDO PEQUEÑO

El concepto de "Redes de Mundo Pequeño" ha revolucionado nuestra comprensión de las estructuras complejas en diversos sistemas naturales y sociales, porque para dos nodos cualesquiera hay un camino relativamente pequeño que los conecta aún, cuando la red sea muy grande.

El término "Mundo Pequeño" se popularizó a partir del experimento de Stanley Milgram en la década de 1960, donde se demostró que cualquier par de individuos en la sociedad estadounidense estaba conectado por una corta cadena de conocidos, típicamente de seis intermediarios (Milgram, 1967).

Sin embargo, fue en 1998 cuando Duncan J. Watts y Steven H. Strogatz formalizaron el concepto en su influyente artículo "*Collective dynamics of 'small-world' networks*" publicado en *Nature* (Watts y Strogatz, 1998). Ellos introdujeron un modelo que interpolaba entre redes completamente ordenadas y redes completamente aleatorias, demostrando que muchas redes reales

exhiben propiedades de mundo pequeño, caracterizadas por una alta agrupación y cortas distancias promedio entre nodos.


El Modelo de Watts-Strogatz

Watts y Strogatz propusieron un modelo que genera redes con propiedades de mundo pequeño mediante un proceso de "Reconexión" de una red regular. El procedimiento fue el siguiente:

- **Construcción de una red regular:** Se inicia con una red en forma de anillo donde cada nodo está conectado a sus k vecinos más cercanos.
- **Reconexión aleatoria:** Con una probabilidad p , cada enlace se reconecta a otro nodo seleccionado al azar en la red.

Este proceso introduce aleatoriedad en la red, reduciendo la longitud promedio de los caminos entre nodos mientras se mantiene un alto coeficiente de agrupamiento.

Figura 11 Modelo Watts-Strogatz



Fuente: Tomado de (Barabási, 2022)

Las redes de mundo pequeño tienen dos propiedades importantes, una es que el coeficiente de agrupamiento es alto, es decir, existen conexiones entre sus nodos vecinos, y la otra es que tienen longitud de camino o trayectos cortos entre pares de nodos (Watts y Strogatz, 1998).

- **Coeficiente de Agrupamiento (C):** Mide la probabilidad de que dos vecinos de un nodo estén conectados entre sí.
- **Longitud de Camino Promedio (L):** Es la distancia promedio más corta entre todos los pares de nodos en la red.

El modelo de Watts-Strogatz (Fig. 11) muestra que, al aumentar la probabilidad de reconexión p desde 0 (red regular) hasta 1 (red aleatoria), la longitud de camino promedio L disminuye rápidamente, mientras que el coeficiente de agrupamiento C se mantiene alto para valores intermedios de p , lo que caracteriza a las redes de mundo pequeño (Barabási y Albert, 2015; Newman, 2018; Watts y Strogatz, 1998).


Las redes de mundo pequeño se encuentran en una variedad de sistemas reales, por ejemplo:

- **Redes Sociales:** Las conexiones entre individuos en plataformas como Facebook o LinkedIn exhiben propiedades de mundo pequeño, facilitando la rápida difusión de información y comportamientos sociales.
- **Redes Biológicas:** Las interacciones entre proteínas en las células forman redes con alta agrupación y cortas distancias de camino, lo que es crucial para la eficiencia de los procesos biológicos.
- **Redes Tecnológicas:** La estructura de Internet y las redes eléctricas muestran características de mundo pequeño, lo que tiene implicaciones para su robustez y vulnerabilidad.
- **Redes Científicas:** El estudio sobre la red de colaboración entre científicos reveló que la comunidad científica forma una red de mundo pequeño, lo que facilita la difusión de conocimientos y la colaboración interdisciplinaria.

El Modelo de Redes de Mundo Pequeño y el Juego de Kevin Bacon

El concepto de redes de mundo pequeño, ha sido fundamental para comprender la conectividad en diversos sistemas complejos reales. Una de sus manifestaciones más conocidas en la cultura popular es el juego de "Seis grados de Kevin Bacon", el cual se basa en la idea de que cualquier actor en Hollywood puede estar conectado con Kevin Bacon a través de un número reducido de colaboraciones cinematográficas.

Figura 12 Red de actuación de Kevin Bacon



Fuente: Tomado de <https://oracleofbacon.org/help.php>

Cómo las Redes de Mundo Pequeño Motivan el Juego de Kevin Bacon

El juego se fundamenta en el principio del mundo pequeño, que sostiene que la mayoría de los nodos en una red están interconectados a través de un corto número de enlaces. En el caso de la industria cinematográfica, los actores representan los nodos y las películas en las que han trabajado en conjunto representan los enlaces entre ellos.

La aplicación de este modelo en Hollywood es particularmente interesante debido a la naturaleza de la industria cinematográfica, donde los actores suelen trabajar con múltiples colegas en distintos proyectos, generando una red densamente interconectada con un alto coeficiente de agrupamiento y caminos cortos entre los nodos.

Funcionamiento del Juego de Kevin Bacon

El juego de "Seis grados de Kevin Bacon" se basa en determinar el número mínimo de conexiones (conocido como el número de Bacon) entre un actor y Kevin Bacon. Las reglas son las siguientes:

- **Identificar un actor:** Se elige cualquier actor o actriz en la industria del cine.
- **Rastrear sus conexiones:** Se busca una película en la que haya trabajado dicho actor junto con otro actor.
- **Seguir las conexiones hasta llegar a Kevin Bacon:** Se continúa este proceso hasta encontrar una película en la que haya participado Kevin Bacon.
- **Calcular el número de Bacon:** Este número se calcula contando el mínimo número de pasos o conexiones necesarias para llegar a Kevin Bacon.

Ejemplo de Aplicación

Supongamos que queremos determinar el número de Bacon de la actriz Emma Watson, actriz conocida principalmente por haber interpretado el personaje de Hermione en la famosa saga de películas de Harry Potter.

Emma Watson trabajó en *Little Women* (2019) con **Meryl Streep**.

Meryl Streep trabajó en *The River Wild* (1994) con **Kevin Bacon**.

Como hay dos conexiones entre Emma Watson y Kevin Bacon, el número de Bacon de Emma Watson es **2**.

Si se desea conocer el número Bacon de Emma Watson o de cualquier actor o actriz en el entorno cinematográfico se puede realizar la consulta en el link: <https://oracleofbacon.org/help.php> , para el caso de Watson la respuesta es la siguiente:

NÚMERO DE EMMA WATSON	# DE PERSONAS
0	1
1	1.014
2	150.350
3	837.979
4	404.803
5	56.198
6	9.772
7	2.361
8	772
9	271
10	79
11	19
12	8
13	3

- Número total de actores vinculables con Emma Watson: 1'463.630
- Número promedio de Emma Watson: 3,280

También se puede realizar la consulta en <https://www.sixdegreesofbacon.org/>

Aplicaciones Matemáticas y Computacionales

El juego ha inspirado el desarrollo de herramientas matemáticas para medir la conectividad dentro de redes de colaboración. En la base de datos de películas

IMDb, se han desarrollado algoritmos de búsqueda para calcular el número de Bacon de cualquier actor usando métodos como:

- **Búsqueda en Anchura (BFS - *Breadth-First Search*):** Explora conexiones en capas sucesivas hasta encontrar la ruta más corta hacia Kevin Bacon.
- **Análisis de Redes Complejas:** Utiliza modelos como Watts-Strogatz y Erdős-Rényi para estudiar la distribución de enlaces y caminos cortos dentro de la industria cinematográfica.
- **El oráculo de Bacon y Seis Grados de Bacon** son sitios web que calculan automáticamente el número de Bacon de cualquier actor utilizando una gran base de datos de películas y algoritmos de búsqueda en grafos.

El juego de Kevin Bacon no solo es un entretenimiento popular, sino que también ha servido como una ilustración accesible del concepto de redes de mundo pequeño. Este principio tiene aplicaciones en múltiples áreas, desde la propagación de información en redes sociales hasta el estudio de redes neuronales y sistemas biológicos. Gracias a estudios matemáticos y algoritmos computacionales, podemos entender mejor cómo funciona la conectividad en diversos sistemas, incluyendo la propia industria del cine.

1.1.6.- EL MODELO DE REDES LIBRES DE ESCALA

Las redes complejas han revolucionado la comprensión de estructuras interconectadas en diversos campos como la biología, la sociología y la tecnología. Uno de los modelos fundamentales en este campo es el modelo de redes libres de escala, propuesto por Albert-László Barabási y Réka Albert en 1999. Este modelo describe redes que siguen una distribución de grado en forma de ley de potencias, lo que implica la existencia de unos pocos nodos altamente conectados (*hubs*) y una gran cantidad de nodos con pocas conexiones (Barabási y Albert, 1999).

La importancia de este modelo radica en su aplicabilidad a diversas disciplinas, permitiendo la descripción y el análisis de sistemas complejos desde una nueva perspectiva. La teoría de redes libres de escala ha sido clave en la predicción de fenómenos como la propagación de epidemias, la robustez de infraestructuras tecnológicas y la influencia en redes sociales (M. Newman, 2018).

Origen y Evolución del Modelo

El concepto de redes libres de escala surge como una extensión de los modelos aleatorios propuestos por Erdős y Rényi en la década de 1960. Aunque estos modelos explicaban ciertas propiedades de redes reales, no reflejaban la distribución de grado observada en muchas redes del mundo real. Barabási y Albert, analizando redes como la World Wide Web y redes biológicas,

identificaron que la probabilidad de que un nodo tenga k conexiones sigue una distribución en ley de potencias:

$$P(k) \sim k^{-\gamma}$$

Donde, γ suele estar en el rango de 2 a 3 en redes reales. Esto significa que la mayoría de los nodos tienen pocas conexiones, mientras que unos pocos nodos cuentan con un número desproporcionadamente alto de enlaces (Barabási, 2022).

A lo largo de los años, el modelo ha sido refinado y aplicado a diversas disciplinas. Investigaciones posteriores han explorado cómo las redes libres de escala emergen en sistemas naturales y artificiales, incluyendo redes metabólicas, el cerebro humano y la infraestructura de transporte.

El modelo de Barabási-Albert se basa en dos principios clave:

- **Crecimiento:** La red se expande continuamente con la adición de nuevos nodos.
- **Preferencia de adjunción:** Un nuevo nodo se conecta preferentemente a nodos que ya tienen muchas conexiones.

El modelo también introduce el concepto de robustez y vulnerabilidad. Aunque las redes libres de escala son resilientes ante fallas aleatorias, son altamente vulnerables a ataques dirigidos contra los nodos más conectados. Este descubrimiento ha tenido implicaciones en la seguridad de redes informáticas y la planificación de infraestructuras.

Aplicaciones en la Vida Real

El modelo de redes libres de escala tiene aplicaciones en diversos ámbitos:

- **Redes Tecnológicas**
 - La estructura de Internet sigue un patrón de red libre de escala, donde ciertos servidores tienen una gran cantidad de conexiones mientras que la mayoría de los nodos tienen pocas.
 - La arquitectura de redes eléctricas y de telecomunicaciones también sigue este patrón. La optimización de estas redes para prevenir fallos catastróficos es un área activa de investigación.
- **Redes Sociales**
 - Las plataformas como Facebook, Twitter e Instagram muestran distribuciones de grado similares, con influenciadores altamente conectados y millones de usuarios con pocas conexiones.
 - El estudio de la propagación de la información y la dinámica de noticias falsas también se ha beneficiado del análisis basado en redes libres de escala.

- **Redes Biológicas**

- Los sistemas metabólicos y las redes de interacción proteica en los organismos también siguen estructuras de red libre de escala.
- La identificación de *hubs* en estas redes ha sido clave para el desarrollo de nuevos fármacos.

- **Epidemiología y Redes de Contacto**

- Las redes de interacción humana, fundamentales en la propagación de enfermedades, presentan características de redes libres de escala.
- Modelos basados en este principio han sido utilizados para predecir la propagación de epidemias y diseñar estrategias de vacunación focalizadas en los *hubs* de la red.

El modelo de redes libres de escala ha transformado nuestra comprensión de los sistemas complejos, su capacidad para explicar la estructura de redes reales y su impacto en diversas disciplinas lo han convertido en un marco teórico esencial en la ciencia de redes. A medida que se desarrollan nuevos enfoques y algoritmos, la aplicabilidad de este modelo sigue expandiéndose, influyendo en la ciencia de datos, la inteligencia artificial y la seguridad informática.

1.1.7.- IMPORTANCIA DE LAS REDES COMPLEJAS Y SU IMPACTO EN LA INVESTIGACIÓN

La teoría de redes complejas ha revolucionado la manera en que los científicos estudian fenómenos en diversas disciplinas, desde su origen con los modelos de redes aleatorias de Erdős y Rényi, pasando por las redes de mundo pequeño de Watts y Strogatz, hasta las redes libres de escala de Barabási y Albert, esta evolución ha permitido entender mejor los sistemas complejos en la física, la biología, la inteligencia artificial y muchas otras áreas.

Esta metodología ha sido clave en los trabajos de destacados científicos que han recibido el Premio Nobel, como Giorgio Parisi (Premio Nobel de Física 2021), John J. Hopfield y Geoffrey E. Hinton (Premio Nobel de Física 2024), y David Baker, Demis Hassabis y John Jumper (Premio Nobel de Química 2024).

Giorgio Parisi y la Física de Sistemas Complejos

Giorgio Parisi, galardonado con el Premio Nobel de Física en 2021, realizó importantes contribuciones en el estudio de sistemas desordenados y la teoría de redes complejas. Sus investigaciones relacionadas con la conexión entre el desorden y las fluctuaciones en los sistemas físicos, así como en vidrios de espín han permitido entender mejor la evolución y dinámica de redes con interacciones no lineales, lo cual tiene aplicaciones en neurociencia y biología (Mulet, 2021).

John J. Hopfield y Geoffrey E. Hinton: Redes Neuronales y Física de la Computación

El Premio Nobel de Física 2024 fue otorgado a John J. Hopfield y Geoffrey E. Hinton, pioneros en redes neuronales y aprendizaje profundo; la teoría de redes complejas ha sido crucial en la creación de modelos como las redes de Hopfield y las redes profundas de Hinton. La conexión entre redes neuronales y redes complejas ha permitido avances significativos en inteligencia artificial, optimización y reconocimiento de patrones (Vacas, 2024).

David Baker, Demis Hassabis y John Jumper: Redes Complejas en Biología y Química

El Premio Nobel de Química 2024 reconoció a David Baker, Demis Hassabis y John Jumper por sus contribuciones en la predicción de estructuras de proteínas mediante inteligencia artificial. La metodología de redes complejas ha sido utilizada para modelar interacciones entre aminoácidos y predecir estructuras mediante aprendizaje profundo. El uso de redes libres de escala ha sido clave para entender la conectividad de proteínas y la funcionalidad biológica (De Jorge, 2024).

La Importancia de la Metodología de Redes Complejas

El estudio de redes complejas ha permitido abrir nuevos campos de investigación en múltiples disciplinas, desde la modelización de sistemas neuronales hasta la predicción de estructuras biológicas, el enfoque de redes ha sido una herramienta esencial en la ciencia moderna. La combinación de técnicas de redes con inteligencia artificial y computación ha permitido descubrimientos innovadores con impacto en la salud, la tecnología y la economía.

La evolución de la teoría de redes complejas ha sido fundamental para la comprensión de fenómenos en diversos campos científicos, la conexión entre redes aleatorias, redes de mundo pequeño y redes libres de escala ha permitido avances en física, química, biología e inteligencia artificial.

Los trabajos de científicos galardonados con el Premio Nobel demuestran la relevancia de esta metodología y su potencial para continuar impulsando el conocimiento en el futuro. Con el desarrollo de nuevas herramientas computacionales y la creciente interconectividad global, el estudio de redes complejas seguirá siendo un pilar fundamental en la ciencia del siglo XXI.


1.2.- ESTUDIOS RELEVANTES DE REDES COMPLEJAS

Si bien los trabajos citados anteriormente, constituyen hitos importantes dentro de la teoría de redes complejas, existen más investigaciones relevantes que permitieron el desarrollo y aplicación de la metodología de redes complejas en diferentes disciplinas; a continuación, se presentan algunos estudios más citados dentro de las investigaciones relacionadas con redes complejas:

1.2.1.- "HOMOFILIA" ESTUDIO DE LAZARSFELD Y MERTON

El concepto de "*homophily*" (homofilia), introducido formalmente por Lazarsfeld y Merton en 1954, se refiere a la tendencia de las personas a asociarse con individuos que comparten características similares; este principio ha tenido un impacto significativo en el estudio de redes complejas, ya que afecta la formación de comunidades, la difusión de la información y la estructura general de las redes sociales (Kandel, 1978).

Figura 13 Red de homofilia en social media



Fuente: <https://medium.com/@ssimmons93/homophily-on-social-media-b6e479650c05>

Metodología del Estudio Original

Lazarsfeld y Merton llevaron a cabo su investigación a través de estudios sociológicos y encuestas en diversas comunidades. Se centraron en dos tipos de homofilia:

- **Homofilia de estatus:** Asociaciones basadas en factores estructurales como clase social, etnia, género y religión.

- **Homofilia de valores:** Asociaciones determinadas por creencias, ideología política y otras actitudes subjetivas.

Mediante el análisis de redes de amistad y afiliaciones grupales, los autores demostraron que la homofilia influye fuertemente en la cohesión social y la formación de clústers dentro de las redes sociales.

Impacto en las Redes Complejas

El concepto de homofilia ha sido ampliamente estudiado dentro de la teoría de redes complejas, particularmente en la modelización de grafos sociales. Se ha observado que las redes homofílicas presentan:

- **Alta modularidad:** Las comunidades tienden a estar fuertemente conectadas internamente pero débilmente conectadas con otros grupos.
- **Efecto de refuerzo:** La homofilia promueve la redundancia en la información y la propagación de opiniones similares dentro de subgrupos.
- **Polarización:** Puede llevar a la fragmentación de la red en subgrupos con visiones homogéneas y limitar la exposición a perspectivas diversas.

Aplicaciones en Estudios Actuales

El concepto de homofilia ha sido aplicado en diversos campos:

- **Redes sociales digitales:** Estudios en plataformas como Facebook y Twitter muestran que los usuarios tienden a interactuar con personas de opiniones similares, creando cámaras de eco y burbujas informativas.
- **Epidemiología:** La homofilia en el comportamiento social afecta la propagación de enfermedades y el impacto de intervenciones de salud pública.
- **Mercados laborales:** La homofilia en redes profesionales influye en la movilidad laboral y en la desigualdad de oportunidades.
- **Política y radicalización:** Se ha estudiado cómo la homofilia contribuye a la polarización política y a la difusión de información sesgada.

El trabajo de Lazarsfeld y Merton sobre homofilia ha sido fundamental para la comprensión de la estructura y dinámica de las redes sociales, su aplicación en redes complejas ha permitido avanzar en la modelización de interacciones humanas y en el diseño de estrategias para mejorar la conectividad y la diversidad de información en las redes sociales actuales.

1.2.2.- ESTUDIO DE MARK GRANOVETTER: "LA FUERZA DE LOS VÍNCULOS DÉBILES"

La teoría de los "vínculos débiles" de Mark Granovetter (1973) representa un hito en la sociología y en el estudio de redes complejas, su trabajo desafió la noción tradicional de que las conexiones más fuertes dentro de una red social eran las más importantes y, en su lugar, argumentó que los vínculos débiles desempeñan un papel crucial en la difusión de información y en la formación de oportunidades sociales y económicas. Esta idea ha influido en múltiples disciplinas, incluyendo la economía, la epidemiología y la inteligencia artificial.

Contexto y Desarrollo de la Teoría

Mark Granovetter desarrolló su teoría en un contexto en el que la sociología de redes aún no había formalizado herramientas matemáticas avanzadas. En su artículo "*The Strength of Weak Ties*" (1973), argumentó que los vínculos sociales pueden clasificarse en fuertes, débiles y ausentes, dependiendo de la frecuencia de interacción, la reciprocidad y la intensidad emocional entre los actores de una red.


Granovetter descubrió que los vínculos débiles actúan como "puentes" entre comunidades o subgrupos desconectados dentro de una red, facilitando la transmisión de información novedosa.

Un ejemplo paradigmático de esta teoría es su aplicación en la búsqueda de empleo, Granovetter encontró que las personas tienen más probabilidades de conseguir un nuevo trabajo a través de conocidos distantes que de amigos cercanos o familiares. Esto ocurre porque los vínculos fuertes tienden a compartir información redundante dentro de grupos cerrados, mientras que los vínculos débiles conectan con otras comunidades y proporcionan acceso a recursos y oportunidades que de otro modo serían inaccesibles.

Metodología Utilizada

El estudio de Granovetter se basó en una combinación de encuestas y análisis de redes sociales; para su investigación empírica, entrevistó a trabajadores en busca de empleo en los Estados Unidos y analizó cómo habían conseguido su trabajo. Se encontró que un alto porcentaje de las personas había conseguido empleo a través de contactos que veían "ocasionalmente" o "raramente".

Figura 14: Representación del modelo de Granovetter



Fuente: Adaptado de <https://sermiuc2015.wordpress.com/wp-content/uploads/2016/05/lazos.jpg?w=542>

Además, utilizó representaciones gráficas de redes en las que los nodos representaban individuos y las aristas representaban relaciones entre ellos. Esta representación permitió identificar los "puentes estructurales" formados por vínculos débiles, los cuales son cruciales para la conectividad de la red en su conjunto.

Impacto en la Ciencia de Redes Complejas

El concepto de vínculos débiles se convirtió en una piedra angular para el desarrollo de la ciencia de redes complejas. Con la llegada de herramientas matemáticas más avanzadas, investigadores han aplicado esta teoría en múltiples contextos:

- **Difusión de información en redes sociales:** Investigaciones han demostrado que la propagación de noticias, innovaciones tecnológicas y opiniones políticas en plataformas como Twitter y Facebook depende en gran medida de los vínculos débiles. Estudios recientes han utilizado modelos de redes de mundo pequeño (Watts y Strogatz, 1998) y redes libres de escala

(Barabási y Albert, 1999) para explicar cómo los vínculos débiles facilitan la difusión de contenido viral.

- **Epidemiología y propagación de enfermedades:** La teoría de los vínculos débiles también se ha aplicado en modelos epidemiológicos. Estudios, han demostrado que la propagación de enfermedades infecciosas, como el COVID-19, se ve afectada por la existencia de conexiones débiles entre comunidades que, de otro modo, estarían aisladas. Las estrategias de control de pandemias han adoptado esta perspectiva para diseñar medidas de confinamiento y cuarentenas dirigidas (Pastor-Satorras y Vespignani, 2024).
- **Inteligencia artificial y análisis de redes:** En el ámbito del aprendizaje automático, los vínculos débiles han sido utilizados para mejorar la detección de comunidades y la propagación de señales en grafos. Algoritmos de PageRank y propagación de etiquetas han aprovechado este principio para optimizar motores de búsqueda y recomendaciones en plataformas como Google y Netflix.

Aplicaciones Contemporáneas

En la actualidad, la teoría de los vínculos débiles sigue siendo relevante en diversas áreas:

- **Mercados laborales digitales:** Plataformas como LinkedIn han demostrado que los vínculos débiles son clave para la búsqueda de empleo en la era digital. Estudios han encontrado que los algoritmos de recomendación basados en redes sociales utilizan principios derivados del trabajo de Granovetter para mejorar la conexión entre empleadores y trabajadores.
- **Emprendimiento e innovación:** En ecosistemas de startups, los vínculos débiles facilitan la conexión entre inversores, mentores y emprendedores, permitiendo una rápida diseminación de ideas y capital.
- **Redes de cooperación científica:** Se ha observado que las colaboraciones interdisciplinarias en la academia son más exitosas cuando incluyen vínculos débiles entre investigadores de distintas áreas del conocimiento.

El trabajo de Mark Granovetter ha sido fundamental para la sociología de redes y ha influenciado múltiples campos científicos, su idea de que los vínculos débiles son cruciales para la difusión de información ha permitido la creación de modelos más sofisticados en redes complejas y ha generado aplicaciones en ámbitos como la epidemiología, la inteligencia artificial y la economía del conocimiento.

A medida que las redes digitales siguen expandiéndose, la importancia de los vínculos débiles en la estructuración de la sociedad moderna se vuelve cada vez

más evidente. La teoría de Granovetter continúa siendo un punto de referencia esencial para entender la conectividad y la difusión en sistemas complejos.

1.2.3.- MODELO DE FLUJO DE INFORMACIÓN PARA CONFLICTOS Y FISIONES EN GRUPOS PEQUEÑOS DE WAYNE ZACHARY "LA RED ZACHARY KARATE CLUB"

El estudio de la Red de Karate de Wayne Zachary (1977), es uno de los casos más emblemáticos en la teoría de redes complejas; a través del análisis de interacciones sociales en un club de karate, Zachary demostró cómo la estructura de una red social puede predecir la fragmentación de un grupo debido a conflictos internos.

Contexto del Estudio

En la década de 1970, Wayne Zachary, un matemático y científico, estudió durante más de dos años las interacciones entre los miembros de un club de karate universitario en los Estados Unidos; su objetivo era comprender cómo los vínculos sociales influían en la dinámica del grupo y cómo las redes podrían predecir la fragmentación de una comunidad.

El club de karate se componía de 34 miembros, incluyendo a un instructor y a los alumnos, durante su estudio, Zachary recopiló datos sobre las interacciones sociales entre los miembros, registrando tanto las relaciones de amistad como las de instrucción dentro del grupo.

Metodología del Estudio

Zachary utilizó herramientas del análisis de redes sociales (SNA) para modelar y representar gráficamente las relaciones entre los miembros del club.

Construcción de la Red

- Los nodos representaban a los 34 miembros del club.
- Las aristas (o enlaces) representaban interacciones regulares entre los miembros, basadas en observaciones y cuestionarios sobre amistad y colaboración.


Técnicas de Análisis

Zachary aplicó métricas de teoría de grafos, como:

- **Centralidad de grado:** Identificó a los miembros más influyentes dentro de la red.

- **Coeficiente de clustering:** Analizó la tendencia de los miembros a formar subgrupos.
- **Detección de comunidades:** Utilizó algoritmos para identificar subgrupos naturales dentro del club.

Figura 15 Red Zachary Karate Club de la paquetería de Python



Hallazgos Clave: La Fragmentación de la Red

Durante su investigación, el club experimentó un conflicto entre el instructor principal y un miembro influyente del grupo, lo que llevó a una escisión o división. Zachary demostró que la red social del club predijo con precisión cómo se dividiría el grupo.

División en Dos Facciones

La red reveló dos comunidades emergentes:

Grupo liderado por el instructor principal (Nodo 0 en la red).

Grupo liderado por un estudiante influyente (Nodo 33).

Cuando el conflicto escaló, los miembros se alinearon con uno de estos dos líderes, resultando en una división efectiva del club.

Validación del Modelo

Zachary utilizó el algoritmo de máxima similitud para predecir la división del club y logró una precisión del 94%, demostrando que los modelos de redes pueden anticipar la fragmentación de grupos sociales.

Impacto en la Teoría de Redes Complejas

El estudio de Zachary fue pionero en demostrar cómo la estructura de una red social puede predecir divisiones dentro de una comunidad, desde entonces, sus hallazgos han sido aplicados en disciplinas como:

- **Sociología:** Modelado de conflictos en organizaciones y comunidades.
- **Política:** Análisis de facciones en partidos políticos y movimientos sociales.
- **Epidemiología:** Estudio de la propagación de enfermedades dentro de redes sociales.

Influencia en Modelos de Detección de Comunidades

El conjunto de datos de la red de karate de Zachary se ha convertido en un *benchmark* estándar para evaluar algoritmos de detección de comunidades, como:

- Algoritmo de Newman-Girvan (2004).
- Algoritmos de propagación de etiquetas (*Label Propagation*).
- Modelos de percolación en redes.

Aplicaciones Modernas del Estudio de Zachary

- **Redes Corporativas y Gestión de Conflictos.-** Las empresas utilizan análisis de redes para entender las estructuras informales dentro de una organización y prever conflictos internos.
- **Redes Terroristas y Seguridad Nacional.-** Los principios de Zachary han sido aplicados en la detección de células terroristas, analizando cómo las redes se fragmentan cuando ciertos nodos son eliminados.
- **Redes de Inteligencia Artificial y Aprendizaje Automático.-** El dataset de Zachary se ha integrado en experimentos de aprendizaje de redes neuronales para estudiar estructuras complejas de conectividad.

El estudio de la Red de Karate de Zachary es un referente clave en la teoría de redes complejas, su impacto se extiende más allá de la sociología, influyendo en disciplinas como la seguridad, la política y la ciencia de datos. A casi medio centenario de su publicación, sigue siendo un modelo esencial para comprender la dinámica de las comunidades y las divisiones sociales.

1.2.4.- ESTUDIO DE JOHN PADGETT SOBRE: "MATRIMONIO Y LA ESTRUCTURA DE LA ÉLITE EN LA FLORENCIA RENACENTISTA"

El trabajo de John F. Padgett, *"Marriage and Elite Structure in Renaissance Florence, 1282-1500"*, es un estudio clave en la intersección de la teoría de redes complejas y la historia social, este analiza cómo las estrategias matrimoniales de las familias florentinas influyeron en la consolidación del poder político y económico durante el Renacimiento.


Metodología del Estudio

Padgett (2011), utilizó una metodología de análisis de redes sociales (SNA, por sus siglas en inglés) para estudiar las conexiones matrimoniales entre familias de élite en Florencia entre 1282 y 1500. Su investigación se basó en:

- **Datos históricos detallados** sobre matrimonios y estructuras de poder recopilados de archivos florentinos.
- **Modelado de redes sociales**, identificando a las familias más influyentes a través de medidas de centralidad y grado de intermediación en la red matrimonial.
- **Análisis de evolución temporal**, observando cómo las estrategias de matrimonio moldearon la estructura política a lo largo de los siglos.

Uno de los puntos clave de su investigación es que las redes familiares no solo consolidaban poder dentro de la élite, sino que también facilitaban la movilidad social y la estabilidad política a través de alianzas estratégicas.

Figura 16 Redes matrimoniales en Florencia



Fuente: (Jackson, 2014)

Principales Hallazgos

1. Redes Matrimoniales y Poder Político

Padgett demostró que las alianzas matrimoniales en Florencia no eran casuales, sino una herramienta clave para consolidar y expandir el poder. Familias como los Médici usaron matrimonios estratégicos para integrarse en círculos de poder y eventualmente dominar la ciudad.

2. Estructura de la Red

El estudio reveló que la red matrimonial tenía una estructura de mundo pequeño, con ciertos "*hubs*" o familias clave que actuaban como nodos de alta conectividad, permitiendo una integración eficiente de nuevos actores en la élite.

3. Innovación Organizativa y Flexibilidad

Padgett argumenta que los Médici fueron innovadores en la forma en que usaron estas redes. A diferencia de otras familias con redes más cerradas, los Médici se insertaron en múltiples facciones, lo que les permitió maniobrar políticamente y adaptarse a cambios en la estructura del poder.

Impacto en el Estudio de Redes Complejas

El trabajo de Padgett ha sido fundamental en la aplicación del análisis de redes en la historia y las ciencias sociales, su contribución incluye:

- **Uso temprano del análisis de redes en estudios históricos**, demostrando que estas herramientas pueden revelar patrones ocultos en datos históricos.
- **Concepto de "emergencia organizacional"**, mostrando cómo la estructura de red puede determinar la evolución institucional y política.
- **Relación entre redes políticas y económicas**, influenciando estudios posteriores sobre la interacción entre estructuras de poder y mercados financieros en sociedades históricas y modernas.

Aplicaciones en Investigaciones Actuales

El estudio de Padgett sigue siendo influyente en diversas áreas:

- **Ciencias Políticas:** Se ha aplicado para entender cómo las conexiones informales afectan la política moderna, desde redes de lobby hasta grupos de presión.
- **Sociología Económica:** Inspiró estudios sobre cómo las redes familiares influyen en la distribución de riqueza y acceso a recursos.
- **Análisis de Redes en Historia:** Modelos similares se han utilizado para estudiar otras ciudades renacentistas y la organización de elites en contextos distintos.

El análisis de Padgett sobre las redes matrimoniales en Florencia ofrece una visión profunda sobre cómo las relaciones sociales pueden estructurar el poder y la influencia a lo largo del tiempo. Su trabajo demuestra que la teoría de redes complejas no solo es aplicable en contextos contemporáneos, sino que también es una herramienta valiosa para entender la historia política y económica.

1.2.5.- APLICACIÓN DE REDES PARA "ANÁLISIS DE COAUTORÍAS"

El análisis de coautoría con la metodología de redes complejas ha sido fundamental para comprender la estructura de la colaboración académica en diversas disciplinas. Investigaciones pioneras y actualizadas en este ámbito han permitido identificar patrones de colaboración, centralidad de actores clave y estructuras jerárquicas en comunidades científicas. A continuación, se analizan algunos estudios representativos en matemáticas, física, economía y ciencias.

1. Grossman y Erdős (1997): Coautoría en Matemáticas

Contexto y Objetivo

Grossman estudió la red de colaboración en matemáticas basándose en el concepto del Número de Erdős, una medida de distancia de coautoría con el matemático Paul Erdős. Su objetivo principal era analizar cómo se estructuraban las colaboraciones en matemáticas y determinar qué tan conectado estaba el campo a partir de las relaciones de coautoría (De Castro y Grossman, 1999; Safari, 2020).

Metodología

- Se utilizó la base de datos de publicaciones matemáticas para construir una red de coautoría.
- Cada nodo representa a un autor, y una arista representa una publicación conjunta.
- Se calcularon distancias en la red tomando a Erdős como nodo central (Número de Erdős).

Resultados Claves

- La mayoría de los matemáticos activos tenían un Número de Erdős finito, lo que demuestra una alta conectividad en la comunidad matemática.
- La distribución del número de coautores por matemático seguía una ley de potencias, indicando que algunos académicos actúan como "hubs" dentro de la red.
- La estructura de la red es altamente centralizada alrededor de ciertos autores influyentes.

Impacto.- Este estudio resaltó la importancia de los nodos centrales en la difusión de conocimiento dentro de las matemáticas y sentó las bases para futuros análisis en otras disciplinas.

2. Newman (2001): Redes de Coautoría en Física

Contexto y Objetivo

Mark Newman amplió el estudio de redes de coautoría a la física, analizando las publicaciones en diferentes subdisciplinas; su objetivo era explorar la estructura de la red de colaboración científica, midiendo su conectividad, el *clustering* y la distancia promedio entre los científicos (Newman, 2001).

Metodología

- Se recopiló información de bases de datos científicas con publicaciones en física.
- Se construyeron redes en las que los nodos representaban a físicos y las aristas indicaban coautoría en publicaciones científicas.
- Se calcularon métricas como el coeficiente de *clustering*, el grado promedio de los nodos y la distancia promedio entre autores.

Resultados Claves

- La red de coautoría en física presentó una estructura de mundo pequeño, donde la distancia promedio entre cualquier par de físicos es baja.
- Se observó una fuerte presencia de *hubs*, es decir, autores con una gran cantidad de conexiones, lo que sugiere que unos pocos individuos actúan como centros de colaboración.
- Las redes de coautoría en física tienen alta modularidad, lo que significa que existen comunidades bien definidas que colaboran con más frecuencia dentro de sus grupos.

Impacto.- Este estudio demostró cómo la física se organiza como una red compleja altamente interconectada, lo que facilita la rápida propagación del conocimiento. Además, introdujo técnicas de análisis de redes a otras disciplinas.

3. Goyal et al. (2004): Redes de Coautoría en Economía

Contexto y Objetivo

El profesor S. Goyal y sus colegas realizaron un análisis de redes de coautoría en economía, comparando su estructura con otras disciplinas como la física y las matemáticas. Se centraron en la dinámica de formación de redes y en cómo influyen factores como la reputación y la productividad de los economistas en sus colaboraciones (Goyal et al., 2006).

Metodología

- Se usaron datos de publicaciones en revistas económicas de alto impacto.
- Se construyó la red de coautoría considerando nodos (autores) y enlaces (colaboraciones en papers).
- Se midieron indicadores clave como grado medio de los nodos, coeficiente de clustering y centralidad de intermediación.

Resultados Claves

- La red de economistas tiene una estructura menos conectada que la de los físicos y matemáticos, lo que indica una menor tendencia a la colaboración en economía.
- Existen barreras estructurales entre diferentes subcampos económicos, lo que reduce la conectividad general de la red.
- Los autores más productivos tienden a colaborar con otros investigadores de alto impacto, lo que refuerza la conexión preferencial, característica de redes libres de escala.

Impacto.- Este estudio destacó diferencias estructurales en las redes de colaboración entre disciplinas y explicó por qué algunas áreas del conocimiento son más interconectadas que otras.

4. Cárdenas (2021): Redes de Coautoría en el IPN

Contexto y Objetivo

La Dra. Magali Cárdenas Tapia ha centrado su investigación en analizar las redes de colaboración científica en el IPN, aplicando la teoría de sistemas complejos y utilizando indicadores de centralidad para evaluar las interacciones entre investigadores (Cárdenas, 2021).

Metodología

- En este estudio, se analizaron las colaboraciones de coautoría de los investigadores miembros de las 11 Redes de Investigación y Posgrado del IPN durante el periodo 2018-2020.
- Se utilizaron bases de datos de Google Académico para recopilar información sobre publicaciones conjuntas.
- La estructura de la red se evaluó mediante indicadores de centralidad, como grado, cercanía e intermediación, utilizando herramientas de análisis de redes sociales.

Resultados Clave

- **Centralidad de Grado:** Se identificaron investigadores con un alto número de colaboraciones, actuando como nodos centrales en la red y facilitando la difusión del conocimiento.
- **Centralidad de Cercanía:** Los investigadores con alta cercanía tienen acceso más directo a otros miembros de la red, lo que puede acelerar la comunicación y colaboración.

- **Centralidad de Intermediación:** Algunos investigadores actúan como intermediarios clave, conectando diferentes subgrupos dentro de la red y permitiendo el flujo de información entre ellos.

Impacto

El estudio de la Dra. Cárdenas Tapia revela que las redes de colaboración en el IPN presentan una estructura compleja con nodos centrales que desempeñan roles cruciales en la cohesión y eficiencia de la red. Estos hallazgos pueden orientar estrategias institucionales para fortalecer la colaboración científica y optimizar la difusión del conocimiento dentro del IPN.

Los estudios realizados por estos autores brindan una guía de la metodología y estructura para investigaciones futuras en base a sus hallazgos en función de los siguientes patrones identificados:

Estudio	Disciplina	Conectividad	Mundo Pequeño	Presencia de Hubs	Modularidad
Grossman (1997)	Matemáticas	Alta conectividad en torno a Paul Erdős, con caminos cortos entre autores.	Sí, los matemáticos están conectados con un bajo número de grados de separación.	Sí, algunos matemáticos tienen un gran número de colaboraciones (hubs).	Baja, debido a la interconexión entre subgrupos en la comunidad matemática.
Newman (2001)	Física	Alta conectividad, con grupos bien definidos en subdisciplinas.	Sí, estructura de mundo pequeño con caminos cortos entre investigadores.	Sí, algunos físicos tienen cientos de colaboraciones.	Moderada, con comunidades dentro de las subdisciplinas de la física.
Goyal et al. (2004)	Economía	Conectividad más baja que en matemáticas y física, con clusters	No tan marcado como en otras ciencias, pero sigue un patrón de red pequeña.	Moderada, algunos economistas tienen muchas colaboraciones, pero en menor grado.	Alta, con grupos bien definidos en torno a centros de investigación y

Estudio	Disciplina	Conectividad	Mundo Pequeño	Presencia de Hubs	Modularidad
		menos densos.			escuelas de pensamiento.
Cárdenas (2021)	Ciencias en el IPN (México)	Conectividad variable según área de investigación; en algunas es alta, en otras más dispersa.	Sí, aunque algunas áreas muestran mayor fragmentación.	Sí, algunos investigadores concentran la mayoría de colaboraciones.	Alta, con fuerte división entre facultades y especialidades.

La conectividad varía según la disciplina: Matemáticas y física presentan mayor interconectividad, mientras que en economía y en ciencias multidisciplinarias hay mayor fragmentación.

Estructura de mundo pequeño: Se observa en todas las disciplinas, aunque en economía es menos marcada.

Presencia de *hubs*: En todas las redes existen investigadores con un alto número de conexiones, pero en economía su influencia es menor en comparación con matemáticas y física.

Modularidad: Economía y ciencias multidisciplinarias presentan una mayor modularidad debido a la segmentación en grupos especializados o institucionales.

Este análisis refleja cómo la estructura de las redes de coautoría cambia según la disciplina, influenciada por las dinámicas de colaboración y las barreras institucionales o temáticas.


1.2.6.- APLICACIÓN DE REDES PARA LA LUCHA CONTRA EL TERRORISMO: "CAPTURA DE SADDAM HUSSEIN"

El análisis de redes complejas se ha convertido en una herramienta esencial en la lucha contra el terrorismo, permitiendo a las fuerzas de seguridad identificar y dismantelar estructuras terroristas al comprender las conexiones y dinámicas entre individuos y células.

Un ejemplo destacado de esta aplicación es la captura de Saddam Hussein en 2003, donde el uso de técnicas de análisis de redes sociales fue crucial para localizar al dictador iraquí.

Tras la invasión de Irak en 2003, las fuerzas estadounidenses se enfrentaron al desafío de localizar a Saddam Hussein, quien se encontró prófugo. A pesar de la captura de varios altos funcionarios del régimen, la ubicación de Saddam seguía siendo desconocida. Fue entonces cuando un equipo de soldados estadounidenses innovadores aplicó teorías de redes sociales para rastrear y capturar al dictador.

Figura 17 Red de contactos de Saddam Hussein



Fuente: (Wilson, 2010)

Este enfoque se centró en analizar las conexiones personales y familiares de individuos cercanos a Saddam, identificando nodos clave dentro de la red que podrían conducir a su paradero. Al mapear estas relaciones, las fuerzas de seguridad pudieron centrarse en personas que, aunque no eran figuras prominentes del régimen, desempeñaban roles cruciales en la red de apoyo a Saddam. Esta estrategia culminó con la captura de Saddam Hussein en diciembre de 2003, demostrando la eficacia del análisis de redes en operaciones antiterroristas.

Aplicación del Análisis de Redes Complejas en la Captura de Saddam Hussein

Tras la invasión de Irak en 2003, Saddam Hussein se ocultó, eludiendo la captura durante meses, las fuerzas estadounidenses, enfrentadas a la dificultad de localizarlo, recurrieron al análisis de redes sociales bajo la estructura que usa Facebook para la detección de ciertos patrones relacionales; sin embargo dicha red social fue creada meses más tarde.

Metodología Implementada:

- **Recopilación de Datos:** Se recopiló información detallada sobre individuos asociados a Hussein, incluyendo familiares, antiguos colaboradores y contactos tribales.
- **Construcción de la Red:** Utilizando software especializado, se creó un mapa de relaciones que destacaba las conexiones directas e indirectas entre estos individuos.
- **Identificación de Nodos Clave:** El análisis de la red permitió identificar a personas centrales en la estructura de apoyo de Hussein, cuya localización podría conducir al dictador.
- **Operaciones Dirigidas:** Basándose en esta información, las fuerzas realizaron operaciones focalizadas, interrogando a individuos clave y estrechando el cerco alrededor de Hussein.

Resultados:

La operación culminó el 13 de diciembre de 2003, cuando Saddam Hussein fue capturado cerca de Tikrit, ciudad iraquí, localizada a 140 km al noroeste de Bagdad sobre el río Tigris, escondido en un bunker subterráneo. La aplicación del análisis de redes sociales fue crucial para dismantelar su red de apoyo y localizar su paradero.

Aplicaciones contemporáneas del análisis de redes en la lucha contra el terrorismo

La eficacia del análisis de redes complejas no se limita al caso de Saddam Hussein. En la actualidad, diversas operaciones antiterroristas han implementado estas técnicas para identificar y dismantelar células terroristas.

Por ejemplo, en marzo de 2025, una operación conjunta entre la Policía Nacional de España, los *Mossos d'Esquadra* y la *Polizia di Stato* italiana resultó en la detención de 11 miembros de un grupo paquistaní que promovía la decapitación de "infieles" a través de canales cifrados. Los detenidos estaban acusados de enaltecimiento, apología, financiación y adoctrinamiento del terrorismo. La operación se llevó a cabo en Barcelona e Italia, y es la tercera fase de una serie de investigaciones que han resultado en 30 detenciones en tres años (Zarco, 2025).

Además, España ha establecido una unidad militar de élite conocida como los "boinas grises" del Mando Conjunto del Ciberespacio (MCCE), compuesta por 400 militares especializados en ciberseguridad, inteligencia artificial y defensa digital. Esta unidad opera para proteger el ciberespacio, vigilando y contrarrestando ciberataques que amenazan las infraestructuras críticas del país.

Desde su creación en 2020, el MCCE ha aumentado en importancia y recursos, con planes de llegar a 1.300 efectivos para 2031.

El análisis de redes complejas ha demostrado ser una herramienta invaluable en la lucha contra el terrorismo. Desde la captura de líderes como Saddam Hussein hasta la desarticulación de células terroristas contemporáneas, estas técnicas permiten a las fuerzas de seguridad comprender y atacar las estructuras subyacentes que sostienen las actividades terroristas. A medida que las redes terroristas se adaptan y evolucionan, la aplicación continua y avanzada del análisis de redes será crucial para anticipar y contrarrestar las amenazas.


1.3.- RESEÑA HISTÓRICA DE LOS PIONEROS DE LAS REDES COMPLEJAS

La ciencia de redes complejas ha sido moldeada por matemáticos, físicos y científicos de diversas disciplinas, cuyas contribuciones han transformado la forma en que entendemos la conectividad en sistemas reales. Desde la teoría de grafos hasta la modelización de redes en la naturaleza y la sociedad, estos investigadores han sido fundamentales para el desarrollo del campo.

1.3.1.- LEONHARD EULER (1707-1783): FUNDADOR DE LA TEORÍA DE GRAFOS

Euler nació en Basilea, Suiza, y desde joven mostró una habilidad excepcional para las matemáticas. Estudió en la Universidad de Basilea bajo la tutela de Johann Bernoulli y, más tarde, trabajó en la Academia de San Petersburgo y la Academia de Berlín.

Su conexión con la teoría de redes surgió en 1736 cuando resolvió el problema de los puentes de Königsberg, que consistía en determinar si era posible recorrer los siete puentes de la ciudad sin repetirlos. Euler demostró que no existía tal recorrido y, en el proceso, sentó las bases de la teoría de grafos, el pilar matemático de la ciencia de redes.




Aporte a las redes complejas:

- Introdujo la noción de nodos y enlaces en grafos.
- Sentó las bases para el estudio de la conectividad y los caminos en redes.
- Su trabajo influyó en el desarrollo de la teoría de redes en áreas como la biología y la informática.

1.3.2.- PÁL ERDŐS (1913-1996) Y ALFRÉD RÉNYI (1921-1970): REDES ALEATORIAS

Erdős, nacido en Budapest, Hungría, fue un matemático prolífico que publicó más de 1,500 artículos y trabajó con más de 500 colaboradores. Era un investigador errante, que viajaba de universidad en universidad colaborando en proyectos matemáticos. Su principal interés era la combinatoria, la teoría de números y la teoría de grafos.

Alfréd Rényi, también húngaro, colaboró con Erdős en el desarrollo del modelo de redes aleatorias, proponiendo que las conexiones en una red pueden formarse de manera probabilística.



Pál Erdős



Alfréd Rényi

Aporte a las redes complejas:

- Introdujeron el modelo Erdős-Rényi (ER), que describe redes aleatorias.
- Mostraron que, dependiendo de la probabilidad de conexión entre nodos, una red puede pasar de un estado fragmentado a un estado altamente conectado.
- Su modelo es utilizado en áreas como epidemiología y telecomunicaciones.

1.3.3.- STANLEY MILGRAM (1933-1984): REDES SOCIALES Y EL MUNDO PEQUEÑO

Nacido en Nueva York, Milgram estudió en la Universidad de Harvard y se convirtió en un psicólogo social influyente. Su interés por las conexiones humanas lo llevó a diseñar el experimento del mundo pequeño en 1967.



Milgram envió cartas a personas seleccionadas al azar en EE.UU., y les pidió que las hicieran llegar a un destinatario específico a través de conocidos. Descubrió que la mayoría de las cartas llegaban en seis pasos, lo que originó la noción de seis grados de separación.

Aporte a las redes complejas:

- Demostró que las redes sociales tienen caminos cortos entre individuos.
- Inspiró modelos de difusión de información, epidemiología y análisis de redes sociales.
- Su trabajo influyó en el modelo de Watts-Strogatz.

1.3.4.- LINTON FREEMAN (1927-2018): MEDIDAS DE CENTRALIDAD EN REDES

Freeman nació en EE.UU., en 1927, se especializó en sociología y matemáticas aplicadas. Su trabajo en análisis de redes sociales lo llevó a desarrollar métricas fundamentales para evaluar la importancia de los nodos en una red.

En 1979, publicó un artículo clave donde propuso medidas de centralidad, que permiten identificar nodos clave en redes sociales, biológicas y tecnológicas.



Aporte a las redes complejas:

- Desarrolló las métricas de centralidad de grado, cercanía e intermediación.
- Su trabajo es utilizado en redes complejas, inteligencia artificial, criminología y sociología.

1.3.5.- MARK NEWMAN (1963): ANÁLISIS DE COMUNIDADES EN REDES

Newman, nacido en el Reino Unido en 1963, es físico y matemático. Trabajó en el Laboratorio Nacional de Los Álamos y en la Universidad de Michigan, donde se especializó en redes complejas.

Junto con Michelle Girvan, Newman desarrolló métodos para detectar comunidades en redes, aplicando la métrica de modularidad.



Aporte a las redes complejas:

- Introdujeron técnicas para detectar estructuras comunitarias en redes sociales y biológicas.
- Su trabajo ha sido aplicado en la minería de datos, inteligencia artificial y epidemiología.

1.3.6.- LÁSZLÓ BARABÁSI (1967): REDES LIBRES DE ESCALA

Barabási nació en Rumania en 1967, estudió en la Universidad de Bucarest antes de trasladarse a EE.UU., para especializarse en física estadística. Su investigación sobre sistemas complejos lo llevó a descubrir que muchas redes reales, como Internet y redes biológicas, no siguen una distribución aleatoria, sino que presentan hubs altamente conectados.

Trabajando junto con Réka Albert, y otros investigadores donde propuso el modelo de redes libres de escala, basado en un proceso de crecimiento preferencial, donde los nodos con más conexiones tienen mayor probabilidad de recibir nuevos enlaces.



Aporte a las redes complejas:

- Descubrieron que muchas redes siguen una distribución en ley de potencia.
- Introdujeron el concepto de crecimiento preferencial, explicando la formación de *hubs* en redes.
- Sus estudios han impactado la biología, economía y ciberseguridad.

1.3.7.- DUNCAN J. WATTS (1971) Y STEVEN STROGATZ (1959): REDES DE MUNDO PEQUEÑO

Duncan Watts, nacido en Australia en 1971, estudió en la Universidad de Cornell bajo la supervisión de Strogatz. Durante su doctorado, trató de explicar cómo un grupo de grillos sincroniza su canto, lo que lo llevó a analizar redes con estructura de mundo pequeño.



Duncan Watts



Steven Strogatz

Steven Strogatz, por su parte, es un matemático y físico estadounidense que nació en 1959, ha trabajado en teoría de sistemas complejos y dinámica no lineal.

Ambos investigadores en 1998, publicaron su artículo explicando el modelo de redes de mundo pequeño, que combina la cohesión de redes regulares con la eficiencia de redes aleatorias.

Aporte a las redes complejas:

- Demostraron que muchas redes sociales, neuronales y tecnológicas presentan alta conectividad local y cortos caminos globales.
- Explicaron la rápida difusión de información en redes sociales.
- Su modelo ha sido aplicado en biología, informática y urbanismo.

Los investigadores mencionados han definido la forma en que comprendemos las redes en diversos campos, desde la sociología y la biología hasta la inteligencia artificial y la ciberseguridad. Gracias a sus aportes, hoy en día podemos modelar y analizar sistemas complejos con precisión, abriendo nuevas fronteras en la investigación y la innovación.

CAPÍTULO II

CONCEPTOS IMPORTANTES EN TEORÍA DE REDES

2.1.- FUNDAMENTOS CONCEPTUALES DE LA CIENCIA DE REDES

Las redes complejas han surgido como una herramienta fundamental para analizar sistemas interconectados en diversas disciplinas (Shlesinger, 2007) . Estas redes, compuestas por nodos y enlaces, presentan patrones estructurales que permiten comprender fenómenos como la propagación de información, la formación de comunidades y la resiliencia de infraestructuras críticas (Barabási y Albert, 2015; Newman, 2018).

Desde el punto de vista matemático, las redes complejas han sido formalizadas mediante modelos como los grafos aleatorios y las redes libres de escala (Shlesinger, 2007). Estos modelos han sido clave en el desarrollo de aplicaciones computacionales, como la inteligencia artificial y la realidad aumentada, donde la interconexión de datos desempeña un papel crucial en la optimización de algoritmos y la representación de información (Geroimenko, 2023).

En términos prácticos, el análisis de redes complejas ha sido aplicado en la optimización de infraestructuras, como redes eléctricas y sistemas de transporte (Watts, 2006). La capacidad de identificar nodos críticos y analizar la robustez de estas redes ha llevado a mejoras significativas en la planificación urbana y la gestión de crisis (Geroimenko, 2023).


El enfoque interdisciplinario de las redes complejas continúa evolucionando y proporcionando nuevas herramientas para el estudio de sistemas dinámicos (Newman, 2018). A medida que la tecnología avanza, la integración de modelos de redes con inteligencia artificial y big data ofrece perspectivas innovadoras para resolver problemas complejos en diversas áreas del conocimiento, sin embargo, es importante para quienes inician en el mundo de las redes complejas conocer sus fundamentos teóricos básicos sobre los cuales se aplica esta metodología para la solución de problemáticas de la vida real.

2.1.1.- ELEMENTOS BÁSICOS DE UNA RED COMPLEJA

Matemáticamente, una red se representa como un grafo $G = (V, E)$, donde V es el conjunto de nodos y E el conjunto de enlaces entre ellos, en algunos libros su notación particular está dada por N = Número de nodos y L = Número de

enlaces, siendo i el identificador del nodo específico. La complejidad de la red está relacionada con la gran cantidad de estos componentes y sus atributos (Barabási y Albert, 2015; Newman, 2018; Sayama, 2015; Watts, 2006).


Figura 18 Representación gráfica y matemática de una red



2.1.1.1 Nodos (Vértices)

En la teoría de redes complejas, los nodos (también llamados vértices) representan las entidades o elementos fundamentales que conforman una red. La naturaleza de estos nodos varía según el tipo de sistema que se modela.

Figura 19 Ejemplo de una red social



Fuente: Tomado de <https://bit.ly/41i8lnu>

Un nodo es un punto dentro de una red que puede estar conectado con otros nodos a través de enlaces o aristas. En términos matemáticos, un conjunto de nodos se denota como:

$$V = \{v_1, v_2, v_3, \dots, v_n\}$$

Donde, cada v_i representa un nodo en la red.


Ejemplo:

- En una red social, cada nodo representa una persona.
- En una red neuronal, cada nodo es una neurona.
- En una red de transporte, cada nodo es un aeropuerto o una estación.

Dependiendo del rol que cumplen dentro de la red, los nodos pueden clasificarse en:

- **Nodos periféricos:** Aquellos con pocas conexiones dentro de la red.
- **Nodos intermedios:** Conectan varios nodos y ayudan en la transmisión de información.
- **Nodos centrales (hubs):** Tienen muchas conexiones y juegan un papel clave en la estructura de la red.

Figura 20 Clasificación de nodos por su rol en la red



Fuente: Adaptado de Redroban, et al., 2025.


Grado de un Nodo (k)

El grado de un nodo k es el número de conexiones o enlaces que tiene con otros nodos.

Ejemplo:

La siguiente red, no dirigida está conformada por $N = 13$ nodos, y $L = 13$ enlaces; el nodo más conectado es el 6 con $k = 7$, luego el nodo 4 con $k = 6$, los nodos 2 y 3 tienen un $k = 2$ y los demás 9 nodos tienen un $k = 1$.

Figura 21 Ejemplificación de nodos y enlaces en una red



2.1.1.2 Enlaces (Aristas)

En la teoría de redes complejas, los enlaces o aristas representan las conexiones entre los nodos o vértices de una red; estas conexiones pueden reflejar relaciones de distintos tipos, dependiendo del contexto en el que se estudie la red.

En una red no dirigida, el número total de enlaces viene dado por L , que se expresa también como la suma de los grados de los nodos:

$$L = \frac{1}{2} \sum_{i=1}^N k_i$$

El factor $\frac{1}{2}$ corrige que, en la sumatoria de la fórmula, cada enlace en una red no dirigida se cuenta dos veces.

Al aplicar la fórmula, en la Figura 21, tenemos:


$$L = \frac{1}{2} (7+6+2+2+1+1+1+1+1+1+1+1+1)$$

$$L = \frac{1}{2} (26)$$

$$L = 13$$

En otro contexto, los enlaces en una matriz de adyacencia (explicada más adelante); un enlace e_{ij} es una conexión entre dos nodos i y j .

Figura 22 Ejemplos de redes según los tipos de enlaces



Los enlaces pueden ser de distintos tipos:

Dirigidos ($e_{ij} \neq e_{ji}$): Cuando la conexión tiene una dirección específica, como en las redes de Twitter (seguidores y seguidos) (Fig. 22 a).

No dirigidos ($e_{ij} = e_{ji}$): Cuando la conexión es bidireccional, como en las redes de amistad de Facebook (Fig. 22 b-c).

Ponderados: Cuando los enlaces tienen un valor asociado que representa la intensidad o frecuencia de la relación (Fig. 22 c).

No ponderados: Cuando solo importa la existencia o ausencia de la conexión, sin considerar su peso (Fig. 22 a-b).

2.1.1.3 Atributos

En el contexto de las redes complejas, los nodos y las aristas no solo representan actores y conexiones, sino que pueden llevar información adicional conocida como atributos; estos atributos permiten enriquecer el análisis estructural de la red y entender mejor la dinámica del sistema analizado.

El trabajo de Moreno (1934), influyó significativamente en la teoría de redes complejas al demostrar que los atributos de los nodos y las aristas no solo eran importantes, sino que podían determinar la dinámica y estructura de una red social.

Respecto de los nodos se pueden determinar algunos tipos de atributos tales como:

Identificadores: Nombre, ID único o categoría del nodo.

Propiedades físicas o cualitativas: Tamaño, tipo de entidad (por ejemplo, en redes sociales: persona, empresa, organización).

Atributos cuantitativos: Número de conexiones, peso asociado a la entidad, nivel de influencia o centralidad.

Estados dinámicos: Estado de salud en modelos epidemiológicos, nivel de actividad en redes sociales, etc.

Por ejemplo: En una red de colaboración científica, los nodos representan investigadores y pueden tener atributos como el número de publicaciones, afiliación institucional y área de especialización.

De igual manera, respecto de las aristas o conexiones, se pueden determinar varios tipos de atributos, tales como:

Dirección: Si la conexión es unidireccional o bidireccional.

Peso: Representa la fuerza o frecuencia de la conexión (ejemplo: cantidad de correos entre dos personas en una red de comunicación).

Tipo de relación: Amistad, transacción económica, colaboración, etc.

Dinámica temporal: Momento en que se estableció la conexión o su duración.

Por ejemplo: En una red de transporte, las aristas representan carreteras entre ciudades, y sus atributos pueden incluir la distancia, el tiempo de viaje promedio y el volumen de tráfico.

Los atributos de los nodos y las aristas enriquecen el análisis de redes complejas, permitiendo un estudio más detallado y realista de los sistemas; al incorporar estos atributos, los investigadores pueden generar modelos más precisos y útiles en diversas disciplinas, como sociología, biología, economía y transporte.

Previo a realizar el análisis de un sistema mediante la metodología de redes complejas, se debe definir todos los atributos tanto de sus nodos como de sus aristas, por ejemplo, en un entorno empresarial donde trabajan cinco empleados de diferentes áreas con diferentes cargos, de varios grupos generacionales tanto hombres como mujeres, se deben identificar todas las características que se desean resaltar o evaluar durante el análisis, para el efecto la matriz de nodos debe contener por lo menos la siguiente información:

Tabla 1 Ejemplo de atributos de nodos

Ord.	Nombre	Cargo	Género	Grupo_generacional	Área
1	Carlos	Técnico	Masculino	Millennials	Operativa
2	Luis	Técnico	Masculino	Generación X	Logística
3	Lisette	Técnico	Femenino	Generación X	Operativa
4	Charlotte	Analista	Femenino	Generación Y	Administrativa
5	Brandon	Gerente	Masculino	Generación Z	Finanzas

De igual manera, las aristas o enlaces que se presentan entre los nodos de la red, tienen ciertas particularidades que se deben definir previo a cargar los datos en un determinado software de análisis de redes con la finalidad de que todas las características que se desean resaltar o evaluar sean fácilmente identificables, para el ejemplo la matriz de aristas debe contener por lo menos la siguiente información:

Tabla 2 Ejemplo de atributos de aristas


Relación	Actividad	Cantidad	Tipo_solicitud
Carlos (interacts with) Charlotte	Envía a	5	Orden_Compra
Luis (interacts with) Lissete	Envía a	5	Permiso
Lissete (interacts with) Luis	Devuelve	2	Viáticos
Lissete (interacts with) Charlotte	Envía a	2	Orden_Compra
Luis (interacts with) Charlotte	Envía a	3	Viáticos
Charlotte (interacts with) Brandon	Aprueba	8	Orden_Compra
Brandon (interacts with) Charlotte	Envía a	6	Orden_Compra

La correcta caracterización de nodos y aristas permite entender la estructura de una red y facilita la identificación de los principales atributos tanto de los actores como de sus enlaces; así por ejemplo la figura 23, muestra las características de los nodos establecidos en la tabla 1 así como las características de los enlaces definidos en la tabla 2.

En el ejemplo señalado, se evidencia una red dirigida conformada por cinco individuos, dos de sexo femenino (fondo color rosa) y tres de sexo masculino (fondo color azul), que son de cuatro diversos grupos generacionales: Millennials (letras color blanco), generación X (letras color fucsia), generación Y (letras color negro) y generación Z (letras color amarillo). Los individuos pertenecen a cuatro áreas de la empresa: Operativa (entorno color verde), logística (entorno color amarillo), Finanzas (entorno color rojo) y administrativa (entorno color azul). Finalmente, los individuos analizados pertenecen a tres cargos laborales: Técnico (figura octogonal), analista (figura de triángulo) y gerente (figura circular).

De igual manera, según las características de las aristas o enlaces, la red muestra la interacción que existe entre los actores con el manejo de documentos, la afluencia y dirección, así como el peso o cantidad de documentos que fluyen en el sistema analizado, por lo que personalizar cada atributo, facilita la comprensión de la red.

Figura 23 Ejemplo de red con atributos



2.2.- PROPIEDADES, ESTRUCTURA Y TOPOLOGÍA DE UNA RED


Las redes complejas son estructuras que modelan sistemas interconectados en diversas disciplinas como la biología, la sociología, la informática y la física, su estudio ha permitido comprender la organización, estructura y dinámica de fenómenos tan variados como la propagación de enfermedades, la formación de comunidades en redes sociales y el comportamiento de sistemas neuronales.

En este sentido, para analizar cualquier sistema bajo la metodología de redes complejas es importante conocer ciertas características topológicas fundamentales de las redes complejas y cómo estas influyen en su funcionalidad y comportamiento.

2.2.1.- COMPONENTES DE UNA RED

Como ya se ha señalado, una red está compuesta por nodos (entidades) y aristas (conexiones entre ellas), su estructura global se define por la disposición y relación entre estos elementos; dentro de una red pueden identificarse componentes conectados, es decir, subconjuntos de nodos en los cuales existe al menos un camino que conecta cualquier par de nodos (Newman, 2003). La identificación de estos componentes es esencial para entender la cohesión y funcionalidad de la red.

Figura 24 Identificación de componentes en dos ejemplos de redes



Tipos de Componentes:

Los componentes pueden clasificarse de acuerdo a varios autores según su conectividad y estructura interna. A continuación, se presentan varios tipos con ejemplos específicos:


2.2.1.1.- Componente Conexo

Un componente conexo es un conjunto de nodos en el que existe al menos un camino entre cada par de nodos dentro de ese conjunto, pero ningún nodo del conjunto está conectado con nodos fuera de él (Albert y Barabási, 2002).

El análisis de los componentes conexos en una red es crucial para comprender su cohesión estructural y la manera en que la información, recursos o enfermedades pueden propagarse. Por ejemplo:

- En redes sociales, un componente conexo representa un grupo de individuos que pueden comunicarse entre sí directa o indirectamente.
- En redes biológicas, un componente conexo puede representar una vía metabólica funcional dentro de un organismo.
- En un grafo de colaboración científica, si dos autores han trabajado juntos o a través de una cadena de colaboradores, pertenecen al mismo componente conexo.

Figura 25 Ejemplificación de una red con componente conexo



2.2.1.2.- Componente Principal o Gigante

En redes grandes, suele existir un componente gigante, que es el mayor subconjunto conexo de nodos en la red y que contiene una fracción significativa del total de nodos.

El componente gigante es una propiedad emergente en muchas redes complejas, en términos matemáticos, se define como el componente conexo más grande de una red, es decir, aquel conjunto de nodos donde es posible encontrar un camino entre cualquier par de ellos.

Cuando una red es lo suficientemente grande y la densidad de enlaces supera un umbral crítico, aparece un componente gigante que contiene una fracción significativa de todos los nodos. Este fenómeno se estudia en profundidad en el modelo de grafos aleatorios de Erdős-Rényi y en modelos de redes reales.

Importancia del Componente Gigante

El componente gigante juega un papel fundamental en la estructura y funcionalidad de una red, su aparición marca la transición de una red fragmentada a una red altamente conectada, lo que permite una mayor eficiencia en el flujo de información, propagación de epidemias, difusión de innovaciones y resiliencia de la red.

Ejemplos del Componente Gigante en Redes Complejas

a) Redes de Transporte

El componente gigante en una red de transporte indica qué tan interconectadas están las rutas; en sistemas como el metro de una ciudad o redes aéreas, el

componente gigante permite determinar qué tan robusta es la conectividad entre ciudades.

b) Redes Biológicas

En redes metabólicas o de interacción de proteínas, el componente gigante representa los elementos que participan en los procesos biológicos esenciales; la fragmentación de este componente podría indicar enfermedades o disfunciones celulares.

c) Redes de Información y Comunicaciones

En redes de Internet, el componente gigante es crucial para garantizar la conectividad global; una falla en nodos críticos dentro de este componente podría causar la caída de grandes sectores de la red.

d) Redes Sociales


Las redes sociales como Facebook o Twitter tienen un componente gigante que agrupa a la mayoría de los usuarios; a través de este componente, la información se propaga de manera eficiente, y su estructura es clave para analizar dinámicas de influencia.

d) Redes de Contratación Pública

En redes de contratación pública, se presentan componentes gigantes cuando los mismos proveedores participan de forma recurrente en varios procesos de contratación generados por diferentes entidades estatales.

El componente gigante es un indicador clave de la conectividad en una red compleja, su estudio ha permitido comprender fenómenos como la propagación de epidemias, los patrones de corrupción, la robustez de las redes de transporte y la resiliencia de infraestructuras críticas. Su análisis es fundamental para diseñar redes más eficientes y seguras en distintos ámbitos del conocimiento.

Figura 26 Ejemplo de una red con un componente gigante y componentes aislados



Fuente: (Redroban-Ortiz, Rivas-Tovar, Torres, et al., 2024)

2.2.1.3.- Componentes Aislados o Pequeños Componentes

En una red compleja, los componentes aislados o pequeños componentes son subconjuntos de nodos que están interconectados entre sí, pero que no tienen conexión con el componente gigante ni con otras partes de la red (Easley y Kleinberg, 2010).

Estos componentes pueden representar nodos desconectados por diversas razones, como la falta de enlaces directos con el resto del sistema, fallos en la conectividad o la existencia de comunidades aisladas dentro de la red. En algunas redes, estos pueden ser irrelevantes, pero en otras, como en estudios de difusión de enfermedades, pueden representar subpoblaciones desconectadas que mitigan el riesgo de contagio.

Características de los Componentes Aislados

- **Tamaño Reducido:** En comparación con el componente gigante, estos grupos contienen pocos nodos y enlaces.

- **Baja Influencia en la Dinámica Global:** Debido a su aislamiento, estos nodos no participan en la transmisión de información o propagación dentro de la red.
- **Mayor Probabilidad de Fragmentación:** En redes donde la conectividad es baja, la fragmentación aumenta y los pequeños componentes son más comunes.
- **Dependencia de la Densidad de la Red:** En redes muy densas, los componentes aislados son escasos, pero en redes dispersas o en fase de crecimiento pueden ser frecuentes.

Ejemplos de Componentes Aislados en Redes Complejas

a) Redes Sociales

En plataformas como Twitter o Facebook, los usuarios que no interactúan con otros (sin seguidores o amigos) forman pequeños componentes aislados dentro del ecosistema de la red.

b) Infraestructura de Transporte

En sistemas de carreteras o redes de transporte, algunas comunidades rurales o regiones remotas pueden estar desconectadas de las principales autopistas, formando pequeños componentes aislados en la red de movilidad.

c) Biología y Ecología

En redes ecológicas, ciertas especies pueden interactuar en pequeños ecosistemas sin conexión con el resto de la red trófica global. Un ejemplo es una población de animales en una isla sin interacción con otras especies del continente.

d) Sistemas de Información

En redes de computadoras, servidores o dispositivos sin conexión a la red principal forman pequeños componentes que no participan en la transmisión global de datos.

d) Contratación Pública

En redes de contratación pública, se forman componentes pequeños o aislados cuando participan en los procesos de contratación generados por entidades estatales diferentes proveedores de los que están inmersos en los componentes gigantes y no lo hacen de forma recurrente.

Importancia del Estudio de los Componentes Aislados

Aunque en la práctica parecen patrones insignificantes frente a los componentes gigantes o conexos, los componentes aislados y pequeños pueden ser muy útiles al momento de realizar un análisis de cualquier sistema, ya que son muy útiles para -entre otras cosas- lo siguiente:

- **Detección de comunidades vulnerables:** En redes sociales, pueden indicar exclusión o aislamiento de grupos específicos.
- **Evaluación de robustez en sistemas:** En redes de infraestructura, la identificación de componentes desconectados ayuda a mejorar la redundancia del sistema.
- **Análisis de propagación de enfermedades:** En epidemiología, los componentes aislados pueden representar poblaciones protegidas de epidemias debido a su falta de conexión con el resto de la población.
- **Redistribución de riqueza:** En economía los componentes aislados pueden representar grupos económicos rezagados a los cuales se puede aplicar políticas de redistribución de bienes y/o servicios.

2.2.1.4.- Componentes Fuertemente Conexos

En una red dirigida, un componente fuertemente conexo es un subconjunto de nodos en el que cada nodo tiene un camino dirigido a todos los demás nodos dentro del componente (Easley y Kleinberg, 2010).

Ejemplo: En redes de comunicación, como el correo electrónico, los componentes fuertemente conexos pueden representar grupos de usuarios que intercambian mensajes regularmente entre sí.

2.2.1.5.- Componentes Débilmente Conexos

Un componente débilmente conexo es aquel en el que los nodos están conectados entre sí, pero sin importar la dirección de los enlaces (Radicchi et al., 2004).

Ejemplo: En redes de citas académicas, un artículo puede citar a otro, pero el citado no necesariamente devuelve la referencia, formando una red débilmente conexas.

2.2.1.6.- Componentes Biconexos

Un componente biconexo es un subconjunto en el que al eliminar cualquier nodo, la conectividad dentro del componente no se rompe (Cohen et al., 2000).

Ejemplo: En redes de transporte, si un sistema ferroviario tiene rutas alternativas, sigue siendo funcional incluso si una estación deja de operar.

Los componentes de una red son una herramienta esencial en el análisis de sistemas complejos. Su estudio permite comprender la estructura, la resiliencia y la dinámica de las interacciones en distintos dominios. Al aplicar estas métricas en campos como la epidemiología, las redes sociales y las infraestructuras, se pueden tomar decisiones estratégicas informadas para mejorar su funcionamiento y seguridad.

2.2.2.- LONGITUD DE LA RED

En el estudio de redes complejas, ciertos conceptos fundamentales permiten describir la conectividad y estructura de los grafos; a continuación, se presentan los más importantes: Camino, Ruta, Ciclo, Distancia Geodésica, Clique y Camarillas.

2.2.2.1.- Caminos

Un camino en una red es una secuencia de nodos conectados por aristas en la que no se repiten nodos ni enlaces. Es la trayectoria más general entre dos nodos.


Un camino está compuesto por:

- Un nodo inicial y un nodo final.
- Una serie de nodos intermedios conectados mediante aristas.
- No hay repeticiones de nodos.

Ejemplo:

En una red social, si un usuario **A** conoce a **B**, **B** conoce a **C**, **C** conoce a **D**, **E** y **F**; y, **D** conoce a **E** y **G**, entonces existen dos caminos de longitud diferente entre los nodos **A** y **G**. = uno de longitud 4 (enlaces color azul) y otro de longitud 5 (enlaces color rojo).

Figura 27. Ejemplo de caminos en una red



2.2.2.2.- Rutas

Una ruta es cualquier secuencia de nodos conectados por enlaces, permitiendo la repetición de nodos o enlaces (Diestel, 2025).


Estructura:

- Puede contener ciclos o pasar varias veces por el mismo nodo.
- Permite redundancia en los enlaces.

Ejemplo:

Si consideramos la misma red graficada para ejemplificar el concepto de camino; podemos identificar la ruta entre **A** y **F** considerando los pasos por los nodos **A→B→C→F**, de longitud 3 (enlaces color azul); pero también la ruta: **A→B→C→D→E→C→F**, de longitud 6 (enlaces color rojo), como también la ruta: **A→B→C→E→D→C→F**, de longitud 6, (enlaces color verde) donde el paso por el nodo **C** se repite.

Figura 28 Ejemplo de rutas en una red



2.2.2.3.- Ciclo

Un ciclo es un camino cerrado en el que el nodo inicial y el nodo final son el mismo, sin repetir aristas ni nodos intermedios.


Estructura:

- Empieza y termina en el mismo nodo.
- No repite nodos intermedios.
- Es una subestructura fundamental en redes biológicas y de comunicación.

Ejemplo:

En una red social, si cuatro personas A, B, C y D están conectadas entre sí, forman un ciclo: $A \rightarrow B \rightarrow C \rightarrow D \rightarrow A$.

Figura 29 Ejemplo de un ciclo en una red




2.2.2.4.- Camarilla (Clique)

Un clique, o camarilla, es un subconjunto de nodos en el que cada nodo está conectado con todos los demás nodos del subconjunto.

Ejemplo:

En redes sociales, un clique o camarilla puede representar un grupo cerrado de amigos donde todos se conocen entre sí. En la siguiente figura, se puede observar una camarilla formada por los nodos **A**, **E** y **B**, y otra formada por los nodos **B**, **C** y **D**.

Figura 30 Ejemplo de camarillas en una red




2.2.2.5.- Distancia Geodésica

Es la longitud del camino más corto entre dos nodos en la red; dicho de otro modo, la distancia geodésica es la menor cantidad de aristas necesarias para conectar dos nodos en la red. Este concepto es crucial para el análisis de redes de comunicación o redes de transporte.

Ejemplo:

Si en una red de transporte el nodo **A** está a 4 estaciones del nodo **G** mediante **B**, **C** y **D**, la distancia geodésica entre **A** y **G** es 4 (representado con enlaces de color azul). Nótese en la gráfica que también se puede llegar al nodo **G** por un camino más largo.

Figura 31 Ejemplo de distancia geodésica en una red



Los caminos y rutas son secuencias de aristas que conectan nodos en una red. Los ciclos y los cliques son caminos cerrados que inician y terminan en el mismo nodo; y la distancia geodésica es la distancia mas corta entre nodos.

La importancia de estos conceptos radica en que permiten analizar la eficiencia de la comunicación o conexión de la red, por lo que son fundamentales en el estudio de la resiliencia de infraestructuras críticas.

2.2.3.- DIÁMETRO Y RADIO DE UNA RED

En el estudio de las redes complejas, el diámetro y el radio son métricas fundamentales para comprender la estructura global de la red y su eficiencia en la transmisión de información. Estas medidas permiten analizar la conectividad y accesibilidad entre los nodos, lo que resulta crucial en aplicaciones como redes sociales, redes biológicas y sistemas de transporte.


2.2.3.1.- Diámetro de la Red

El diámetro de una red se define como la mayor distancia geodésica entre cualquier par de nodos dentro de la red. En otras palabras, representa el camino más largo (en términos de número de enlaces) entre dos nodos más alejados en la red.

Ejemplo

En una red social, si el usuario más alejado de otro ($A \rightarrow G$), necesita 4 conexiones intermedias para alcanzarlo, el diámetro de la red es 4.

Figura 32 Ejemplo de diámetro en una red



Importancia del Diámetro

- **Indica la dispersión de la red:** Cuanto mayor sea el diámetro, más pasos se requieren para conectar los nodos más lejanos.
- **Aplicación en redes de comunicación:** Un diámetro bajo implica alta eficiencia en la transmisión de información.
- **Redes de transporte:** En aerolíneas, un diámetro pequeño asegura conexiones rápidas entre aeropuertos.


2.2.3.2.- Radio de la Red

El radio de una red se define como la menor de las distancias máximas desde cualquier nodo hasta todos los demás nodos. Se calcula encontrando el mínimo valor del excentricidad de los nodos.

Ejemplo

Si en una red de transporte público el punto central desde el cual se pueden alcanzar todos los destinos en menos de 2 conexiones tiene una excentricidad de 2, entonces el radio de la red es 2.

Figura 33 Ejemplo de radio en una red



Importancia del Radio

- **Identifica el núcleo de la red:** En redes sociales, el radio puede indicar usuarios con más influencia.
- **Optimización en telecomunicaciones:** Un radio bajo indica eficiencia en el acceso a información.
- **Detección de hubs centrales:** En redes de aeropuertos, el radio ayuda a identificar aeropuertos principales con accesibilidad rápida a otros destinos.

Relación entre Diámetro y Radio

En redes aleatorias, la diferencia entre el diámetro y el radio suele ser pequeña.

En redes de mundo pequeño, el diámetro es bajo, lo que significa que cualquier nodo puede alcanzar otro en pocos pasos.

En redes libres de escala, el radio puede ser bajo, pero el diámetro puede crecer en ciertas configuraciones.

2.2.4.- DENSIDAD DE UNA RED

La densidad **D** de una red es una medida global que indica cuán conectados están los nodos entre sí en comparación con el número máximo de conexiones posibles. En términos simples, mide qué tan lleno o vacío está el grafo.

Para una red no dirigida con **N** nodos y **L** enlaces, la densidad **D** se define como:

$$D = \frac{2L}{N(N-1)}$$

Donde:

L : es el número de aristas o enlaces presentes en la red.

N : es el número total de nodos.


$N(N - 1)/2$: representa el número máximo posible de conexiones en una red completamente conectada (grafo completo).

Para redes dirigidas, la fórmula es:

$$D = \frac{L}{N(N - 1)}$$

Ya que cada nodo puede conectarse a cualquier otro en dos direcciones de ida y vuelta.

Figura 34 Ejemplo de variación de la densidad de una red de 7 nodos



Ejemplo de Cálculo de Densidad para el Resultado $D=0,333$

Verificamos que la primera red de la Figura 34 tiene:

$N = 7$ nodos

$L = 7$ enlaces

Aplicamos la fórmula para una red no dirigida:

$$D = \frac{2(7)}{7(7 - 1)}$$

$$D = 14/42 = 0,333$$

2.2.4.1.- Interpretación y Rango de Valores

La red tiene una densidad del **33%**, lo que indica que el 33% de las conexiones posibles están presentes.

- **Densidad = 1:** La red está completamente conectada (grafo completo).
- **Densidad = 0:** No hay conexiones entre los nodos (grafo vacío).
- **Densidad baja ($D \approx 0$):** La mayoría de los nodos tienen pocos enlaces (característico de redes dispersas, como redes de colaboración científica o redes neuronales).
- **Densidad alta ($D \approx 1$):** Casi todos los nodos están conectados con la mayoría de los demás (ej., redes pequeñas de confianza o grupos cerrados en redes sociales).

2.2.4.2.- Importancia de la Densidad en Redes Reales

Redes Sociales

En redes de amistad, una alta densidad sugiere que la mayoría de las personas se conocen entre sí (ej., grupos cerrados).

En plataformas como Twitter o Facebook, la baja densidad refleja que solo una fracción de las posibles conexiones se materializan.

Redes Biológicas

En redes de proteínas, una alta densidad puede sugerir fuertes interacciones bioquímicas, mientras que una baja densidad indica interacciones específicas y esporádicas.

Redes de Transporte

Un sistema de transporte con alta densidad implica una gran cantidad de rutas interconectadas, mientras que una baja densidad indica pocas conexiones directas entre estaciones o conexiones.

2.2.4.3.- Factores que Afectan la Densidad


- **Tamaño de la Red (N):** Redes grandes tienden a tener densidad baja porque el número de conexiones posibles crece cuadráticamente con N .
- **Estructura de la Red:** Redes jerárquicas, como las libres de escala, presentan densidad baja, mientras que redes homogéneas pueden tener densidad más alta.
- **Presencia de Comunidades:** En redes con alta modularidad, la densidad local es alta dentro de comunidades, pero baja entre comunidades.

2.2.5.- COEFICIENTE DE AGRUPAMIENTO

El coeficiente de agrupamiento o *clustering coefficient*, es una medida fundamental en la teoría de redes complejas que cuantifica el grado en el que los nodos tienden a formar triángulos o grupos cerrados de conexiones. Esta propiedad es crucial para entender la estructura de las redes y sus dinámicas, ya que influye en la propagación de información, robustez y modularidad de la red (Watts y Strogatz, 1998).

Mide la probabilidad de que dos vecinos de un nodo estén conectados entre sí, en términos simples, responde a la pregunta: "Si dos de mis amigos son amigos míos, ¿qué tan probable es que también sean amigos entre sí?"

Figura 35 Ejemplificación del coeficiente de agrupamiento



Barabási y Albert (2015), señalan que el coeficiente de agrupamiento puede calcularse de dos maneras:

2.2.5.1.- Coeficiente de Agrupamiento Local (para un nodo individual i)

Se define como:

$$C_i = \frac{2L_i}{k_i(k_i - 1)}$$

Donde:

C_i es el coeficiente de agrupamiento del nodo i .

L_i es el número de enlaces existentes entre los vecinos del nodo i .

k_i es el grado del nodo i (número de conexiones directas que tiene).

$k_i(k_i - 1)/2$ es el número máximo posible de enlaces entre los vecinos del nodo.

Este valor varía entre 0 y 1:

$C_i = 0$: No hay conexiones entre los vecinos del nodo. Baja agrupación.

$C_i = 1$: Todos los vecinos están completamente conectados entre sí (y forman un clique o camarilla). Alta agrupación.

Sus resultados se pueden interpretar de la siguiente manera:

- **Alta agrupación:** Todos o casi todos los vecinos de un nodo están conectados entre sí.
- **Agrupación media:** Algunos vecinos están conectados, pero no todos.
- **Baja agrupación:** Los vecinos de un nodo no están conectados entre sí.

2.2.5.2.- Coeficiente de Agrupamiento Global (para toda la red)

El coeficiente global de agrupamiento se obtiene promediando los coeficientes locales de todos los nodos:

$$\langle C \rangle = \frac{1}{N} \sum_{i=1}^N C_i$$

Donde:

N es el número total de nodos en la red.

Mark Newman (2018), considera que otra forma de calcular el coeficiente de agrupamiento global es mediante la relación entre el número total de triángulos en la red y el número total de triadas abiertas (conexiones de tres nodos donde al menos dos están conectados).

$$C = \frac{(\text{Número de triángulos}) \times 3}{(\text{Número de triadas conectadas})}$$

Este método es más comúnmente usado en estudios empíricos de redes.

Importancia del Coeficiente de Agrupamiento

El coeficiente de agrupamiento tiene múltiples aplicaciones en diversas áreas:

Redes Sociales

- Permite identificar comunidades y estructuras de cohesión en redes de interacción humana.
- En plataformas como Facebook o Twitter, un alto coeficiente de agrupamiento indica la existencia de grupos cerrados o comunidades densamente conectadas.

Redes Biológicas

- En redes de proteínas y genes, un alto coeficiente de agrupamiento sugiere módulos funcionales que trabajan de manera coordinada.
- Ayuda a detectar estructuras modulares en redes metabólicas.

Redes Tecnológicas y de Infraestructura

- En redes de transporte y telecomunicaciones, permite analizar redundancia y eficiencia en la conectividad.
- Las redes con alto coeficiente de agrupamiento pueden ser más resilientes a fallos al mantener conexiones locales fuertes.

Redes de Propagación de Información o Epidemias

- Un alto coeficiente de agrupamiento facilita la propagación de información dentro de subgrupos, pero puede dificultar su difusión a nivel global.
- En epidemiología, una red con coeficiente de agrupamiento alto puede favorecer la propagación local de enfermedades antes de que estas se expandan globalmente.

2.2.6.- DISTRIBUCIÓN DE GRADO

En el estudio de redes complejas, la distribución de grado es una de las propiedades más fundamentales, ya que describe cómo se reparten las conexiones entre los nodos. Esta distribución permite entender la estructura de la red y predecir su comportamiento ante cambios o perturbaciones.

Como se señaló anteriormente, el grado (k) de un nodo se define como el número de conexiones (o enlaces) que posee. La distribución de grado se expresa como $P(k)$, que representa la probabilidad de que un nodo seleccionado al azar tenga exactamente k conexiones.

La forma de esta distribución es clave para clasificar las redes en diferentes categorías: redes aleatorias, redes libres de escala y redes de mundo pequeño, cada una con implicaciones significativas en la dinámica de los sistemas complejos.

2.2.6.1.- Distribución de Grado en Redes Aleatorias (Erdős-Rényi)

En una red aleatoria modelo Erdős-Rényi (Erdős y Rényi, 1959), los enlaces entre nodos se crean de manera probabilística, lo que genera una distribución de grado que sigue aproximadamente una distribución de Poisson:

Características:

- La mayoría de los nodos tienen un grado cercano al promedio.
- No existen nodos con grado extremadamente alto o bajo.
- No hay *hubs* (nodos altamente conectados).
- Es una red homogénea en cuanto a conectividad.

Ejemplo: Redes de conexiones telefónicas generadas aleatoriamente.

2.2.6.2.- Distribución de Grado en Redes de Mundo Pequeño (W-S)

Las redes de mundo pequeño (Watts y Strogatz, 1998) combinan propiedades de redes regulares y redes aleatorias. Su distribución de grado suele seguir una curva con un pico en el grado medio y una caída exponencial en los extremos.

Características:

- Alto *clustering* (agrupamiento local).
- Distancia promedio baja entre nodos.
- La distribución de grado no es tan homogénea como en redes aleatorias, pero tampoco sigue una ley de potencia.

Ejemplo: Redes neuronales y redes de colaboración científica.

2.2.6.3.- Distribución de Grado en Redes Libres de Escala (Barabási-Albert)

Las redes libres de escala (Barabási y Albert, 1999) presentan una distribución de grado que sigue una ley de potencia:

Esto significa que hay pocos nodos con muchas conexiones (*hubs*) y muchos nodos con pocas conexiones.

Características:

- La mayoría de los nodos tienen pocos enlaces.
- Unos pocos nodos tienen muchísimas conexiones (*hubs*).
- La estructura es autosimilar (se parece a sí misma a diferentes escalas).
- No tiene una escala característica de grado, de ahí el nombre "libre de escala".

- Es robusta ante fallos aleatorios, pero vulnerable a ataques dirigidos a *hubs*.

Ejemplo:

- Redes de Internet y enlaces web.
- Redes sociales (Facebook, Twitter, LinkedIn).
- Redes de interacciones biológicas (proteínas, genes).

2.2.6.4.- Importancia de la Distribución de Grado

El análisis de la distribución de grado es esencial para comprender cómo funciona una red y cómo responde ante diferentes dinámicas tales como:

Resiliencia y Robustez:

- Las redes aleatorias son sensibles a la eliminación de nodos al azar, ya que la conectividad está distribuida de manera homogénea.
- Las redes libres de escala son muy resistentes a fallos aleatorios, pero vulnerables a ataques dirigidos a los *hubs*.

Propagación de Información o Epidemias:

- En redes con distribución Poisson, la propagación es uniforme.
- En redes libres de escala, los *hubs* facilitan una propagación rápida y global.

Eficiencia en Transporte y Comunicación:

- Las redes de transporte optimizan su conectividad a través de nodos con diferentes grados para evitar congestión en *hubs*.


Dinamismo y Evolución de la Red:

- Las redes evolucionan siguiendo mecanismos de conectado preferencial o crecimiento aleatorio, impactando en su distribución de grado.

Cálculo y Representación Gráfica de la Distribución de Grado

Para visualizar la distribución de grado, se construyen histogramas donde el eje x representa el grado (k) y el eje y la probabilidad $P(k)$.


Figura 36 Distribución de grado



Fuente: (Barabási, 2015)

En redes libres de escala, es común representar estos datos en gráficos log-log, ya que la ley de potencia aparece como una línea recta en dicha escala.

Figura 37 Distribución de grado de una red real



Fuente: (Barabási, 2015)

Ejemplo de visualización de distribuciones de grado:

- Red aleatoria: Curva en forma de campana (Poisson).
- Red de mundo pequeño: Pico alto en el grado medio y caída exponencial.
- Red libre de escala: Línea recta en escala log-log.

CAPÍTULO III

MÉTRICAS DE REDES COMPLEJAS

3.1.- MEDIDAS Y MÉTRICAS DE ANÁLISIS DE REDES COMPLEJAS

Las redes complejas han revolucionado la manera en que se estudian sistemas interconectados en diversos campos, desde la biología hasta las ciencias sociales y la tecnología (Newman, 2003).

Para caracterizar y comprender estas redes, se emplean diversas métricas que pueden clasificarse en tres categorías: medidas globales, que describen propiedades generales de toda la red; medidas locales, que se centran en subestructuras específicas; y medidas nodales, que analizan la relevancia de los nodos dentro de la red (Allen, 2018; Budel et al., 2023; Burt, 1980).

A continuación, se presentan de forma breve algunas métricas que se aplican según estas tres categorías:

3.1.1.- MEDIDAS GLOBALES DE LAS REDES COMPLEJAS

Las medidas globales permiten describir la estructura general de una red y compararla con otras, estas métricas son esenciales para entender el comportamiento macroscópico de un sistema interconectado como, por ejemplo:

3.1.1.1.- Tamaño de la Red y Densidad

- El tamaño de la red se define como el número total de nodos (N) y el número de aristas (E).
- La densidad mide la proporción de conexiones existentes en comparación con el número máximo posible de conexiones.

Una red con alta densidad tiende a ser más conectada, lo que puede influir en la propagación de información o en la robustez estructural (Barabási y Albert, 1999)

3.1.1.2.- Distancia Media y Diámetro

- La distancia media es el promedio de las distancias más cortas entre todos los pares de nodos de la red.
- El diámetro de la red es la distancia más larga entre dos nodos dentro de la red.

Redes con distancias cortas favorecen la comunicación eficiente y son características de los modelos de mundo pequeño (Watts y Strogatz, 1998).

3.1.1.3.- Modularidad y Detección de Comunidades

- La comunidad se define como un conjunto de nodos que están conectados más densamente entre sí que con el resto de la red.
- La modularidad por otra parte es la medida en que una red se organiza en múltiples comunidades.

Un alto valor de modularidad indica una fuerte presencia de comunidades bien definidas en la red (Newman, 2006).

3.1.2.- MEDIDAS LOCALES DE LAS REDES COMPLEJAS

Las medidas locales analizan la conectividad de un nodo en relación con sus vecinos y estructuras cercanas, entre las métricas más utilizadas para estas medidas están:

3.1.2.1.- Coeficiente de Agrupamiento

El coeficiente de agrupamiento mide la probabilidad de que dos vecinos de un nodo estén conectados entre sí.

Redes con alto coeficiente de agrupamiento suelen tener una estructura más cohesiva (Watts Y Strogatz, 1998).

3.1.2.2.- Transitividad

La transitividad generaliza el coeficiente de agrupamiento para toda la red, este parámetro es clave para identificar patrones estructurales dentro de redes sociales y biológicas (Barrat et al., 2004).

3.1.3.- MEDIDAS NODALES O PARTICULARES

Las medidas nodales analizan la importancia y el rol de un nodo dentro de la red, entre las métricas más usadas en esta medida están:

3.1.3.1.- Centralidad de Grado

El grado de un nodo es el número de conexiones que posee. Nodos con alto grado pueden actuar como centros de información o *hubs* en redes libres de escala (Barabási y Albert, 1999).

3.1.3.2.- Centralidad de Intermediación

Mide la frecuencia con la que un nodo aparece en los caminos más cortos entre otros nodos.

Nodos con alta intermediación son cruciales para el control del flujo de información (Freeman, 1977).

3.1.3.3.- Centralidad de Cercanía

Se basa en la distancia promedio desde un nodo a todos los demás:

Un nodo con alta cercanía tiene acceso eficiente a otros nodos y puede influir rápidamente en la red (Newman, 2003).

Las medidas globales, locales y nodales son fundamentales para comprender la estructura y dinámica de las redes complejas, desde la detección de comunidades hasta la identificación de nodos clave, estas métricas han permitido avances significativos en disciplinas como la sociología, la biología y la informática.

CAPÍTULO IV

PREPARACIÓN PARA EL ANÁLISIS

4.1.- PREPARACIÓN DE DATOS

Luis Rivas-Tovar (2020), sostiene que, tres factores son los que definen el éxito o el fracaso de un proceso investigativo: los datos, el acceso a personas claves y la experiencia del investigador. En esta parte del texto nos centraremos en cómo preparar la data para realizar análisis bajo la metodología de redes complejas.

Independiente del software que se pretenda utilizar para el análisis y visualización de las redes complejas; las matemáticas y el álgebra lineal brindan el marco conceptual y estructural para la teoría de redes, en las cuales la definición y formulación de la matriz de adyacencia y/o lista de adyacencia juega un papel preponderante poder entender la estructura de una red compleja.

Barabási (2002, 2016): Recomienda la lista de adyacencia para analizar redes libres de escala, debido a la estructura dispersa.

Newman (2010): Sugiere el uso de la matriz de adyacencia para análisis espectral de redes y propagación de información.

Watts y Strogatz (1998): Modelan redes de mundo pequeño con matrices de adyacencia, útiles en simulaciones dinámicas.

Freeman (1977): Utiliza ambas representaciones en la teoría de centralidad, dependiendo de la métrica analizada.

Software como Cytoscape o Gephi, necesitan de matrices o listas de datos debidamente estructurados y depurados para poder realizar correctamente un análisis de las redes, si bien estos se pueden originar en archivos tan sencillos con formatos de *.xlsx, *.csv, *.tsv, también se pueden formular con otros más complejos como: *. Graphml, *.json, *.net, etc.

Sobre la base de la clasificación de redes promulgada por Barabási, (2022), a continuación se presenta la definición y tipos de matrices y listas de adyacencia que son importantes para la preparación de la data para un análisis de redes complejas.

4.1.1.- MATRIZ DE ADYACENCIA

La matriz de adyacencia es una representación matemática fundamental de una red compleja, se trata de una matriz cuadrada que describe las conexiones entre los nodos de una red, permitiendo un análisis estructural preciso y la aplicación de herramientas algebraicas y computacionales para estudiar sus propiedades.

Esta matriz es crucial en diversas disciplinas como la sociología, la biología, la informática y la física, ya que facilita el análisis de propiedades como conectividad, centralidad, rutas óptimas y propagación de información en una red.

Definición Formal

Dada una red con N nodos, su matriz de adyacencia A es una matriz de tamaño $N \times N$, donde cada elemento A_{ij} indica la existencia de un enlace entre los nodos i y j :

$$A_{ij} = \begin{cases} 1, & \text{si hay un enlace entre los nodos } i \text{ y } j \\ 0, & \text{si no hay un enlace entre los nodos } i \text{ y } j \end{cases}$$

Dependiendo del tipo de red, esta matriz puede ser simétrica (para redes no dirigidas) o asimétrica (para redes dirigidas), lo que afecta su interpretación y las métricas derivadas de ella.

4.1.2.- LISTA DE ADYACENCIA

La lista de adyacencia es una de las estructuras de datos más utilizadas para representar redes complejas, se emplea principalmente cuando las redes son dispersas, es decir, cuando el número de conexiones E es mucho menor que el número máximo posible de enlaces $N(N-1)/2$ en un grafo de N nodos.

Su eficiencia en almacenamiento y rapidez en operaciones como recorridos y búsqueda de vecinos la hace ideal para el modelado de redes reales en múltiples disciplinas.

Esta estructura de datos permite representar los nodos y sus conexiones de manera compacta, proporcionando una alternativa eficiente a la matriz de adyacencia, que suele ser costosa en términos de memoria para redes de gran tamaño.

Definición Formal

Una lista de adyacencia es una estructura de datos que asocia a cada nodo i una lista de los nodos con los que está conectado. Se puede representar de la siguiente manera:

$$A(i)=\{j_1,j_2,j_3,...,j_k\}$$

Donde:

i es un nodo de la red.

$\{j_1,j_2,j_3,...,j_k\}$ representa los nodos vecinos de i .

4.1.3.- APLICACIÓN EN DIFERENTES TIPOS DE REDES

A continuación, se detalla la aplicación de la matriz y lista de adyacencia en distintos tipos de redes:

4.1.3.1.- Redes No Dirigidas

En una red no dirigida, los enlaces no tienen dirección, lo que implica que la matriz de adyacencia es simétrica:

$$A_{ij} = A_{ji}$$

Por otra parte, en este tipo de red la lista de adyacencia es más eficiente debido a sus conexiones son dispersas, por ejemplo, en redes de colaboración científica.

Ejemplo: Si tenemos una red con 4 nodos conectados de la siguiente manera:

- Nodo 1 conectado con nodos 2 y 3
- Nodo 2 conectado con nodos 1 y 3
- Nodo 3 conectado con nodos 1, 2 y 4
- Nodo 4 conectado solo con el nodo 3

La matriz de adyacencia sería:

$$A_{ij} = \begin{bmatrix} 0 & 1 & 1 & 0 \\ 1 & 0 & 1 & 0 \\ 1 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

La lista de adyacencia sería:


$$A_{(1)} = \{2, 3\}$$

$$A_{(2)} = \{1, 3\}$$

$$A_{(3)} = \{1, 2, 4\}$$

$$A_{(4)} = \{3\}$$

La figura de la red sería:



4.1.3.2.- Redes Dirigidas

En una red dirigida, los enlaces tienen dirección, lo que hace que la matriz de adyacencia no sea necesariamente simétrica:

$$A_{ij} \neq A_{ji}$$

Por otra parte, la lista de adyacencia es más eficiente para redes donde cada nodo tiene miles de enlaces salientes y entrantes, por ejemplo, la web.

Ejemplo: Si tenemos la red dirigida con 4 nodos conectados de la siguiente manera:

- Nodo 1 conectado hacia el nodo 3
- Nodo 2 conectado hacia el nodo 1
- Nodo 3 conectado hacia el nodo 2
- Nodo 4 conectado hacia el nodo 3

La matriz de adyacencia sería:

$$A_{ij} = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

La lista de adyacencia sería:


$$A_{(1)} = \{3\}$$

$$A_{(2)} = \{1\}$$

$$A_{(3)} = \{2\}$$

$$A_{(4)} = \{3\}$$

La figura de la red sería:



4.1.3.2.- Redes Ponderadas

En redes donde los enlaces tienen pesos (por ejemplo, en redes de transporte o redes financieras), la matriz de adyacencia incorpora estos valores en lugar de solo 0 y 1.

$$A_{ij} = \begin{cases} w_{ij}, & \text{si hay un enlace con peso } w_{ij} \text{ entre los nodos } i \text{ y } j \\ 0, & \text{si no hay un enlace entre los nodos } i \text{ y } j \end{cases}$$

En la lista de adyacencia en cambio, se registra el peso junto con cada nodo vecino.

Ejemplo: Si tenemos la red dirigida con 4 nodos conectados de la siguiente manera:

- Nodo 1 conectado hacia el nodo 3 con peso 5
- Nodo 2 conectado hacia el nodo 1 con peso 9
- Nodo 3 conectado hacia el nodo 2 con peso 4
- Nodo 4 conectado hacia el nodo 3 con peso 2

La matriz de adyacencia sería:

$$A_{ij} = \begin{bmatrix} 0 & 9 & 0 & 0 \\ 0 & 0 & 4 & 0 \\ 5 & 0 & 0 & 2 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

La lista de adyacencia sería:


$$A_{(1)} = \{(3, 5)\}$$

$$A_{(2)} = \{(1, 9)\}$$

$$A_{(3)} = \{(2, 4)\}$$

$$A_{(4)} = \{(3, 2)\}$$

La figura de la red sería:



La elección entre matriz de adyacencia y lista de adyacencia depende del tipo de red y del análisis que se desea realizar.

- Matriz de Adyacencia:
 - Útil para redes densas, análisis algebraico y modelos de propagación.
 - Eficiente para cálculos de *clustering* y teoría espectral.
- Lista de Adyacencia:

- Ideal para redes dispersas y dinámicas.
- Más eficiente en el almacenamiento y el acceso a nodos con altos grados.

En el análisis de redes complejas, la elección de la representación afecta directamente la eficiencia y la precisión del análisis, la comprensión de estas estructuras permite modelar y optimizar sistemas en diversos campos, desde la biología hasta las redes sociales y la infraestructura tecnológica.

4.1.4.- OTROS FORMATOS

En el análisis de redes complejas, la forma en que se organiza y almacena la información es crucial para garantizar eficiencia en el procesamiento, compatibilidad con herramientas especializadas y facilidad de interpretación.

Además de la matriz de adyacencia y la lista de adyacencia, existen múltiples formatos de archivo y representaciones de datos utilizadas para modelar redes en diferentes contextos, como archivos CSV, Excel, GraphML, JSON, GML, Pajek (net), Edge List, DOT, y Bases de Datos de Grafos.

A continuación, se presentan los principales formatos utilizados en la ciencia de redes, junto con sus características, ventajas y desventajas.

4.1.4.1.- Archivos Tabulares: CSV y Excel

1.1. CSV (*Comma-Separated Values*)

Los archivos CSV son ampliamente utilizados en análisis de datos y permiten representar redes en listas de aristas (*Edge List*) o listas de nodos con atributos.

Cada fila representa un enlace o relación entre nodos, con columnas que pueden incluir pesos, direcciones y atributos adicionales.

Ventajas:

- Formato ligero y ampliamente compatible con software como Gephi, Python (NetworkX), R (igraph), Cytoscape y Excel.
- Fácil de manipular en pandas (Python) y R.
- Se puede expandir con atributos adicionales.

Desventajas:

- No es adecuado para representar redes extremadamente grandes de forma eficiente.
- Puede volverse redundante cuando se incluyen múltiples relaciones.

4.1.4.2.- Archivos Excel (.xlsx)

Se pueden estructurar redes en archivos Excel utilizando hojas separadas para nodos y enlaces, lo que facilita la organización de datos en contextos empresariales y académicos.

Ventajas:

- Compatible con herramientas como Gephi, UCINET, R y Python.
- Permite manipulación rápida de datos en interfaces gráficas.
- Acepta múltiples hojas para estructurar información de nodos, aristas y atributos.
- Software como Cytoscape, permite importar datos de una hoja con al menos 2 nodos para elaborar una red.

Desventajas:

- Puede volverse ineficiente para redes con miles de nodos y relaciones.
- No es óptimo para el análisis algorítmico en grafos muy grandes.

4.1.4.3.- Edge List (.txt, .csv)

Representa una red en una simple lista de pares de nodos conectados.

Ventajas:

- Ligero y fácil de procesar en software como Gephi, Pajek, NetworkX.
- Compatible con la mayoría de herramientas de redes.

Desventajas:

- No incluye atributos de nodos.
- Puede volverse redundante en redes ponderadas o dirigidas.

4.1.4.4.- GraphML (.graphml)

Formato basado en XML que permite almacenar no solo la estructura de la red, sino también atributos de nodos y aristas.

Ventajas:

- Soporta redes dirigidas y no dirigidas.
- Permite almacenar metadatos y atributos.
- Compatible con Gephi, Cytoscape, NetworkX.

Desventajas:

- Formato más pesado que CSV o Edge List.
- Puede ser complejo de editar manualmente.

4.1.4.5.- GML (Graph Modelling Language)

Formato de texto estructurado para representar redes con atributos en un formato legible por humanos.

Ventajas:

- Más flexible que GraphML para ediciones manuales.
- Compatible con Gephi, Pajek, y Cytoscape.

Desventajas:

- Puede ser redundante para redes grandes.
- No es óptimo para bases de datos dinámicas.

4.1.4.6.- Pajek (.net)

Formato especializado en el software Pajek, diseñado para análisis de redes grandes.

Ventajas:

- Optimizaciones para redes grandes.
- Compatible con múltiples herramientas de análisis de redes.

Desventajas:

- No es ampliamente soportado fuera de Pajek.
- Sintaxis menos intuitiva para principiantes.

4.1.4.7.- JSON (*JavaScript Object Notation*)

Se usa en bases de datos como Neo4j y ArangoDB para representar redes con relaciones y atributos en un formato estructurado.

Ventajas:

- Compatible con aplicaciones web y bases de datos de grafos.
- Soporta atributos y relaciones complejas.

Desventajas:

- No está optimizado para cálculos algebraicos en redes.
- Puede ser más pesado en comparación con Edge List.

El formato de datos ideal depende del tamaño de la red, el software utilizado y el tipo de análisis requerido.

4.2.- SOFTWARE PARA ANÁLISIS DE DATOS Y VISUALIZACIÓN DE REDES

El análisis y visualización de redes complejas es esencial en diversas disciplinas, estas herramientas permiten comprender estructuras, detectar patrones y extraer información valiosa de sistemas interconectados. A lo largo del tiempo se han identificado más de cien programas que han servido tanto para la visualización de redes como para el análisis de las mismas (Watts, 2006).

Actualmente, la evidencia de las publicaciones o investigaciones relevantes concluyen que existen ciertos programas que son más usados por los investigadores al momento de aplicar la metodología de redes complejas (Larrosa, 2016); a continuación, se presenta una revisión breve de diez softwares destacados en este ámbito, incluyendo: Cytoscape, Gephi, Pajek, UCINET, R, Python, InFlow, NodeXL, Tulip y PajekXXL.

4.2.1.- CYTOSCAPE

Cytoscape, es una plataforma de código abierto diseñada inicialmente para la visualización y análisis de redes moleculares y vías biológicas (Shannon et al., 2003). Aunque su enfoque inicial fue la bioinformática, su flexibilidad lo ha convertido en una herramienta general para el análisis de redes complejas en cualquier disciplina.

Permite integrar datos de expresión de cualquier atributo, facilitando la exploración de relaciones y estructuras en los datos. Su arquitectura basada en complementos permite ampliar sus funcionalidades según las necesidades del usuario.

4.2.2.- GEPHI

Gephi es una plataforma de código abierto para la visualización y exploración de todo tipo de gráficos y redes, es especialmente valorada por su capacidad para manejar grandes conjuntos de datos y por su interfaz ergonómica que no requiere habilidades de programación.

Gephi permite realizar análisis estructurales, detectar comunidades y aplicar diversos algoritmos de disposición para revelar patrones ocultos en los datos.

Su capacidad de renderizado en tiempo real facilita la interacción dinámica con las visualizaciones (Bastian, 2022).

4.2.3.- PAJEK

Pajek es un software especializado en el análisis y visualización de grandes redes, capaz de manejar estructuras con miles a millones de vértices, ofrece una amplia gama de herramientas para el análisis estructural, incluyendo la detección de comunidades, análisis de centralidad y exploración de subredes.

Su diseño está orientado a investigadores que requieren un análisis detallado de redes extensas, aunque su interfaz puede resultar menos intuitiva para usuarios novatos que otros programas (De Nooy et al., 2018).

4.2.4.- UCINET

UCINET es un programa integral para el análisis de redes sociales. Incluye herramientas para medir la centralidad, cohesión y otros indicadores clave en el estudio de estructuras sociales, además, ofrece funciones para la visualización de redes y la realización de análisis estadísticos avanzados. UCINET es ampliamente utilizado en sociología y antropología para examinar las relaciones y patrones dentro de grupos sociales (Borgatti et al., 1992).

4.2.5.- R (PAQUETE IGRAPH)

R es un entorno de programación estadística que, a través del paquete igraph, proporciona herramientas robustas para el análisis y visualización de redes; Igraph permite crear, manipular y visualizar grafos, además de calcular una variedad de métricas estructurales (Rodríguez, 2025).

La flexibilidad de R y su capacidad para integrarse con otros paquetes estadísticos lo convierten en una opción poderosa para analistas que requieren personalización y análisis profundos, su limitación para el uso en investigadores novatos radica en los conocimientos de programación para su uso.

4.2.6.- PYTHON (BIBLIOTECA NETWORKX)

Python, con su biblioteca NetworkX, ofrece una plataforma versátil para el análisis de redes complejas, NetworkX permite la creación, manipulación y estudio de la estructura, dinámica y funciones de grafos complejos.

Es especialmente útil para investigadores con mayor experiencia que buscan integrar el análisis de redes con otras tareas de programación y análisis de datos, aprovechando la amplia gama de bibliotecas disponibles en Python (Amat Rodrigo y Carazo, 2023).

4.2.7.- INFLOW

InFlow es una herramienta comercial diseñada para el análisis de redes sociales y organizacionales, ofrece capacidades de visualización interactivas y herramientas analíticas para identificar patrones, flujos de información y estructuras dentro de organizaciones. InFlow es utilizado frecuentemente en consultorías y estudios organizacionales para optimizar la comunicación y la eficiencia dentro de las empresas (Alber, 2002).

4.2.8.- NODEXL

NodeXL es un complemento para Microsoft Excel que facilita el análisis de redes dentro de una interfaz familiar para muchos usuarios, permite importar, analizar y visualizar datos de redes, siendo especialmente útil para principiantes en el análisis de redes debido a su integración con Excel.

NodeXL es utilizado en diversos campos, incluyendo estudios de comunicación y análisis de redes sociales en línea (Smith et al., 2009).

4.2.9.- TULIP

Tulip es una plataforma de código abierto dedicada a la visualización de datos relacionales, ofrece un entorno flexible y eficiente para la visualización de grandes conjuntos de datos, permitiendo a los usuarios desarrollar representaciones personalizadas y explorar interactivamente las estructuras de las redes.

Tulip es valorado por su capacidad de manejar datos complejos y su extensibilidad a través de *plugins* (Kurniawan, 2020).

4.2.10.- NEO4J

Neo4j es un sistema de gestión de bases de datos orientado a grafos desarrollado por Neo4j, Inc., su principal característica es que almacena y procesa datos utilizando nodos y relaciones en lugar de tablas, lo que lo hace ideal para modelar estructuras de redes complejas.

Neo4j se ha convertido en una de las herramientas más importantes para el análisis de redes complejas en el mundo empresarial, científico y tecnológico, su capacidad para gestionar grandes volúmenes de datos lo hace ideal para aplicaciones que requieren una estructura basada en grafos, superando muchas limitaciones de los modelos relacionales tradicionales (Miller, 2013).

A diferencia de herramientas como Gephi o Cytoscape, que están más enfocadas en la visualización de redes, Neo4j es un sistema de almacenamiento y gestión de datos que permite análisis avanzados y consultas de manera rápida

y eficiente. Es especialmente útil para aplicaciones en tiempo real y análisis dinámico de redes.

La selección del software adecuado para el análisis y visualización de redes complejas depende de las necesidades específicas del proyecto o de la investigación, el tamaño de la red y la experiencia del usuario.

Herramientas como Cytoscape y Gephi son ideales para visualizaciones interactivas y análisis exploratorios, mientras que R y Python ofrecen flexibilidad y capacidad de personalización para análisis más profundos.

Es esencial considerar las características de cada software y cómo se alinean con los objetivos del análisis para obtener resultados óptimos. La siguiente tabla muestra las características particulares de cada software que el investigador debe considerar para decidir qué programa utilizar para sus fines investigativos:

Tabla 3 Características de Programas de Análisis de Redes Complejas

Software	Características principales	Tipo	Lenguaje / Plataforma	Fortalezas	Limitaciones	Usos comunes
Cytoscape	Análisis y visualización de redes biológicas y moleculares	Open Source	Java, multiplataforma	Extensible mediante plugins, manejo de datos biológicos	Enfoque principal en bioinformática, curva de aprendizaje moderada	Bioinformática, análisis de interacciones genéticas
Gephi	Exploración visual de grandes redes en tiempo real	Open Source	Java, multiplataforma	Visualización interactiva, algoritmos de disposición avanzados	Limitada capacidad de análisis estadístico	Redes sociales, ciencia de datos, visualización de grafos
Pajek	Análisis de redes grandes con herramientas matemáticas avanzadas	Freeware	Windows	Manejo eficiente de redes de gran tamaño, análisis estructural	Interfaz poco intuitiva, curva de aprendizaje alta	Sociología, investigación en redes complejas
UCINET	Análisis de redes sociales con	Comercial	Windows	Completo en análisis SNA, integración con NetDraw	Interfaz desactualizada, no es de código abierto	Sociología, estudios organizacionales

Software	Características principales	Tipo	Lenguaje / Plataforma	Fortalezas	Limitaciones	Usos comunes
	herramientas estadísticas					
R (igraph)	Análisis avanzado de redes con modelado estadístico	Open Source	R	Altamente personalizable, integración con otras bibliotecas	Requiere conocimientos de programación	Ciencia de redes, bioinformática, sociología computacional
Python (NetworkX)	Biblioteca para modelado, generación y análisis de redes	Open Source	Python	Gran flexibilidad, integración con ML y Big Data	No orientado a visualización interactiva	Modelado de redes, IA, análisis de redes sociales
InFlow	Análisis de redes organizacionales y flujos de información	Comercial	Windows	Análisis enfocado en gestión empresarial	Costoso, funcionalidad limitada a redes sociales y empresariales	Consultoría organizacional, inteligencia empresarial
NodeXL	Complemento de Excel para análisis de redes	Comercial	Excel (Windows)	Fácil de usar para principiantes, integración con Office	Limitado en escalabilidad y análisis avanzado	Análisis de redes sociales, periodismo de datos
Tulip	Plataforma para visualización de datos relacionales	Open Source	C++	Soporta redes grandes, flexible y extensible	No tan popular, requiere aprendizaje técnico	Ciencia de datos, visualización de redes científicas
Neo4j	Almacena y procesa datos utilizando nodos y relaciones en lugar de tablas	Comercial	Cypher	Eficiencia en la exploración de redes complejas. Alto rendimiento en	Se requiere aprender Cypher, un lenguaje de consulta específico para	Análisis de redes sociales. Sistemas de recomendación. Detección de fraude.

Software	Características principales	Tipo	Lenguaje / Plataforma	Fortalezas	Limitaciones	Usos comunes
				consultas de relaciones Escalabilidad y almacenamiento eficiente	bases de datos de grafos. Gran uso de capacidad por su base de datos Costo elevado	Gestión de conocimiento. Ciberseguridad y monitoreo de redes.

Esta matriz ayudará a comparar y elegir la herramienta más adecuada según las necesidades de análisis de redes complejas; para el objetivo del texto, a continuación, se demostrará como el software Cytoscape y Gephi, permiten realizar análisis y visualización de redes complejas con ejemplos prácticos con el uso de datos disponibles.

CAPÍTULO V

REDES COMPLEJAS EN LA PRÁCTICA

5.1.- CYTOSCAPE

Para el uso del software Cytoscape, iniciaremos con descargarlo directamente desde el link de su página oficial en <https://cytoscape.org/>, es importante señalar que Cytoscape es un *software open source*, por lo que su descarga es gratuita y su funcionamiento ni tiene limitaciones ni demanda conocimientos de programación.


Figura 38: Sitio oficial para descarga de Cytoscape



En los casos que exista incompatibilidad con Java instalado de forma predeterminada en su computador, es recomendable eliminarlo y volver a instalarlo el cual se puede descargar también de la página oficial de Cytoscape.


Una vez instalado y al correr el software se presenta la siguiente interfaz de usuario. La interfaz está dividida en cuatro secciones principales: la zona de comandos en la parte superior, la zona de archivos y caracterización o atributos de nodos y enlaces en la parte izquierda, la zona de visualización de redes en la parte superior derecha y la zona de tablas en la zona inferior derecha.

Figura 39 Interfaz de usuario del software Cytoscape Versión 3.10.3



Una vez que se carga el software se encuentran disponibles varios ejemplos de redes por default que facilitan la familiarización del software y el desarrollo de habilidades en su manejo, en complemento la página oficial de Cytoscape cuenta con manuales y tutoriales digitales que se actualizan constantemente conforme se actualizan las versiones del software y que están disponibles para su descarga en <https://manual.cytoscape.org/en/stable/> y <https://github.com/cytoscape/cytoscape-tutorials/wiki>.

Figura 40 Visualización de interfaz con red cargada




5.1.1.- CREACIÓN DE REDES

El software Cytoscape permite la creación, importación, visualización y análisis de redes independiente de la disciplina o área que pertenezcan los datos, a continuación, comenzaremos por crear redes sencillas aplicando los conceptos básicos de redes.


En la parte conceptual, se señaló que una red es un conjunto de nodos y aristas y, que su representación matemática es: $G = (V, E)$; la figura 22, muestra varias representaciones gráficas de redes sencillas de la cual seleccionamos la figura 22 b), como ejemplo para empezar a crear una red con Cytoscape.

Pese a que una red se puede crear o importar de una base de datos previamente tratados, en este caso se iniciará de cero utilizando las bondades que tiene el software para crear una red utilizando sus comandos.

Figura 41 Pasos para diseñar redes de forma directa en Cytoscape




En la pestaña "File", accedemos a "New Network" y seleccionamos "Empty"; luego de aceptar, aparece una sección donde pide que coloquemos un nombre de la nueva red que se creará.



Una vez que registramos el nombre que tendrá la nueva red se da "OK", y se abre una ventana de trabajo completamente vacía

En la zona de visualización de redes, pulsamos el botón derecho del mouse y aparecen dos secciones en la opción "**Add**", la primera "**Edge**", permitirá crear los enlaces entre los nodos y la segunda "**Node**" permitirá crear los nodos de la red.




La figura 22 b) corresponde a una red sencilla (no dirigida - no ponderada) conformada por 9 nodos y 15 enlaces, que graficaremos a continuación:

1.- En la zona de visualización de redes, pulsamos el botón derecho del mouse y seleccionamos la opción "**Add**", luego "**Node**", esto creará un nodo que por default lo nombrará como "**Node 1**".

2.- Repetimos el paso 1 por nueve ocasiones, ya que la red que graficaremos tendrá 9 nodos.


3.- En la zona de visualización de redes, pulsamos el botón derecho del mouse sobre un nodo creado y seleccionamos la opción "**Add**", luego "**Edge**", y seleccionamos el otro nodo que debe conectarse. (Es importante colocar el mouse sobre un nodo creado caso contrario no se habilitarán las opciones para crear los enlaces entre los nodos).

4.- repetimos el paso 3 uniendo los nodos según la siguiente imagen:




En primera instancia tenemos creada nuestra primera red, sin embargo, la figura 22.b) muestra ciertos atributos que todavía no se visualizan en la red creada; nótese también que, en las pestañas inferiores del lado derecho se van generando datos en las tablas tanto de nodos como de enlaces conforme se va creando la red de forma manual.

En la zona de tablas, en la pestaña “**Node Table**” creamos una nueva columna de tipo String (tipología de acuerdo a las características de las variables)



Colocamos el nombre que le daremos a la nueva columna y le damos aceptar.




Una vez que tenemos creada la nueva columna le asignamos los atributos a cada nodo que para nuestro ejemplo le corresponde la siguiente información:


- Femenino = (3,5,7,8,9)
- Masculino = (1,2,4,6)

Node Table ▾		
$f(x)$		
shared name	name	Género
Node 1	Node 1	Masculino
Node 2	Node 2	Masculino
Node 3	Node 3	Femenino
Node 4	Node 4	Masculino
Node 5	Node 5	Femenino
Node 6	Node 6	Masculino
Node 7	Node 7	Femenino
Node 8	Node 8	Femenino
Node 9	Node 9	Femenino

En la zona de atributos de nodos seleccionamos la opción "*Image/Chart1*" para poder reemplazar los nombres de los nodos por una imagen que represente a cada género, para lo cual además se debe seleccionar en la misma opción "*Column*" = "*Género*" y también "*Mapping Type*" = "*Discrete Mapping*". Esta selección permitirá que el usuario pueda cargar una imagen a cada género.




Posteriormente, en los tres puntos del lado derecho de cada género "**Femenino**" y "**Masculino**", se abre la opción para poder cargar la imagen que se desea relacionar a cada uno de ellos.




Para el ejemplo se seleccionó dos imágenes en formato *.png que representan el uno al género masculino y el otro al género femenino

Column	Género	
Mapping Type	Discrete Mapping	
Femenino		dama.png
Masculino		varon.png

Finalmente, para evitar duplicidad entre el la identificación del nodo y la imagen seleccionada, en la opción "**Label**", seleccione en la opción "**Column**" = "**Género**" y en la opción "**Mapping Type**" = "**Discrete Mapping**"



Con esta configuración, debemos contar con la siguiente imagen similar a la presentada en la figura 22 b), cabe señalar que solo se asignó un atributo a los nodos que se registró en la columna "**Género**", asumiendo que las conexiones entre estos miembros es una relación que puede ser de amistad, laboral, etc., los atributos para los enlaces lo decide usted y lo puede configurar al igual que se realizó con los nodos.



5.1.2.- CARGA O IMPORTACIÓN DE REDES Y/O TABLAS

Normalmente, un investigador, cuenta previamente con una data depurada para iniciar un análisis de redes complejas, Cytoscape, permite importar datos para redes con los siguientes formatos:

- Files (or URLs)
- Excel, TSV, CSV
- XGMML: *Xtensible Graph Markup and Modelling Language*
- SBML: *Systems Biology Markup Language*
- BioPAX
- PSI-MI
- SIF: *Simple Interaction Format*
- GML: *Graph Markup Language*
- Otros dependiendo de los Apps cargados.

El Software, también permite importar datos de redes de repositorios públicos tales como:

- *PSICQUIC*
- *STRING (via the stringApp)*
- *IntAct (via the IntActApp)*
- *Reactome (via the ReactomeFI app)*
- *WikiPathways (via the WikiPathways app)*
- *Pathway Commons (via the CyPath2 app)*
- *NDEx*

Por otra parte, Cytoscape permite también cargar tabla de datos para crear las redes y posteriormente analizarlas, estas pueden ser:



- **Archivos (or URLs)**
 - Excel, TSV, CSV
- **Repositorios Públicos**
 - BioMart
- **Programados:**
 - Command line scripts
 - CyREST via R, Python, etc

Para la generación de la siguiente red, utilizaremos un archivo de formato Excel, elaborado con datos descargados de la página oficial de “Contratación Pública en Cifras” del Gobierno de la República del Ecuador, disponible en <https://portal.compraspublicas.gob.ec/sercop/contratacion-publica-en-cifras-2/>, del cual surgió la data para la elaboración del artículo titulado “Redes complejas como metodología para el control gubernamental en procesos de contratación pública en Ecuador” de Redroban-Ortiz, Rivas-Tovar, Torres, et al., (2024).


En esta ocasión crearemos la red por tipo de contratación pública en Ecuador durante el año 2023 que es parte del artículo citado anteriormente y consta en la figura 7.

El archivo Excel para la creación de la red está disponible para su descarga en el link: <https://github.com/carluiredro/RedContratacion>.


Iniciamos con el software Cytoscape; para importar los datos desde el archivo en formato *xlsx o similares de Excel tenemos tres opciones, digitamos Ctrl+L; en la pestaña “**File**” seleccionamos la opción “**Import**” y luego “**Network from File...**”; y la tercera opción es directamente con el ícono  de “**Import Network from File Sytem**”, ubicado debajo de la pestaña “**Layout**”.



En cualquier opción que seleccione para importar los datos debe aparecer la siguiente pantalla:



Tome en cuenta que primero debe descargar el archivo desde el link de *github* y guardar en su dispositivo; una vez que se presenta la ventana anterior, seleccione el archivo a importar y seleccione la opción “**Abrir**”.




La ventana que aparece muestra los datos que son parte del archivo a importar -independiente del formato-; el procedimiento que se aplica en esta ventana es crucial para definir la estructura de la red que se formará, esto obedece a un diseño metodológico que el investigador previamente debe establecer.

En el caso del artículo “Redes complejas como metodología para el control gubernamental en procesos de contratación pública en Ecuador”, los autores


diseñaron una red Bipartita en el que los nodos eran por una parte el nombre del proveedor ubicado en la columna **M**; y, por otra parte, el tipo de contratación ubicado en la columna **I** del archivo Excel. Para la relación o enlaces consideraron el nombre de la entidad pública contratante ubicado en la columna **B** del archivo.

Recuerde que una red se puede generar a partir de una matriz de adyacencia y también a partir de una lista de adyacencia, para lo cual es necesario reorganizar la data para que exista una relación directa entre los nodos de entrada y los nodos de salida. Para importar los datos de una lista de adyacencia en cytoscape necesitamos el archivo con datos en dos columnas, empero, se necesita otro archivo con los atributos de los nodos para su posterior caracterización.


Para el ejemplo de la red que vamos a crear, se utilizó una matriz, la cual facilita caracterizar directamente los atributos de la red. En la ventana que se abrió luego de seleccionar el archivo, dando clic sobre el título **"Tipo Contratación"**, se despliega otra ventana donde se debe indicar al software que características va a tener cada variable, en este caso indicamos a cytoscape que el tipo de contratación será el nodo de entrada **"Source Node"**.



Luego realizamos el mismo procedimiento para indicar que la variable **"Nombre de Proveedor"** será el nodo de destino **"Target Node"**.




Finalmente, realizamos el mismo procedimiento para indicar a cytoscape que la variable "**Nombre Entidad**" será el enlace entre los nodos "**Interaction Type**". Nótese que en este caso está seleccionado el ícono, por lo que en la imagen se observa que junto a la variable "**Nombre Entidad**" aparece el ícono de "**Interaction Type**" y los tipos de datos de la parte inferior se desactivan. Esta es una forma de verificar que los datos están siendo programados correctamente.



En esta ventana se debe indicar al software que atributos se van a designar a cada variable y si deseamos que se carguen o no cuando se genere la red.


- El ícono  impide que los datos con dicha selección en esa variable aparezcan en la red.
- El ícono  de color morado, indica al software que esa variable tendrá atributos de enlaces.
- El ícono  de color verde, indica que esa variable tendrá atributos de los nodos de origen.
- El ícono  de color naranja, indica que esa variable tendrá atributos de los nodos de destino.

Para nuestro ejemplo, indicamos que la variable "Código Proceso" "Descripción compra", "CPC N9" y "Descripción CPC N9", servirán para otorgar atributos a los nodos de origen , la variable "Ruc Proveedor" tendrá atributos en los nodos de destino , las variables "Ruc Entidad", "Provincia Entidad" y "Cantón Entidad" tendrán atributos de enlaces ; y, finalmente indicamos que los datos de las variables "Presupuesto", "Fecha Publicación", "Valor adjudicado" y "Fecha Adjudicación", no serán parte de este análisis , por lo que no deben aparecer en los atributos de la red que se formará. Esto no significa que estos datos no sirven, una misma matriz puede servir para elaborar varias redes y varios análisis.




Luego de realizar una correcta asignación de roles y funciones a cada variable y datos, generamos la red dando clic en "Ok". Cuando se maneja poca cantidad de datos, se muestra la imagen de la red creada, por el contrario, cuando se maneja gran cantidad de datos es común que aparezca en la ventana de red, algún nodo principal por lo que es necesario cambiar la visualización de la red.

En la pestaña “**Layout**”, seleccionamos la opción “**yfiles Organic Layout**”, para cambiar la visualización de la red, usted puede escoger la opción que más le convenga o le guste. En caso de que una nueva versión no tenga incluido estas opciones, los algoritmos de visualización se puede descargar desde la pestaña “**Apps**”.



Una vez que se corre el algoritmo de visualización seleccionado, de inmediato tenemos la red creada por cytoscape. Nótese que, en la zona de tablas, ya existe información que se importó del archivo de Excel y solo constan los atributos que se indicaron en párrafos anteriores.




Como se puede observar, cytoscape presenta la nueva red creada; empero, esta dista de la figura 7 del artículo publicado por Redroban-Ortiz, Rivas-Tovar, Torres, et al., (2024); por lo que aquí inicia el proceso de caracterización y personificación de las redes de tal manera que visualmente sea entendible incluso antes de realizar el análisis topológico.

En la zona de archivos de redes y caracterización, seleccionamos la pestaña "**Style**", luego de lo cual se habilitan las opciones de estilo tanto para los nodos como para los enlaces.

Una forma de verificar que los atributos programados al inicio están correctamente asignados es en esta sección, donde caracterizaremos tanto a los nodos como a los enlaces, si seleccionamos una opción por ejemplo "**Label**", debe desplegarse los atributos que programamos al inicio.

Cuando se realiza el análisis topológico, los resultados de las métricas como grado, cercanía, intermediación, etc., también se muestran en esta sección.




Para lograr que nuestra red, se asemeje a la figura 7 del artículo de ejemplo, debemos modificar estas opciones tanto en la pestaña **"Node"** como en la pestaña **"Edge"**.

Cuando las redes son grandes, difícilmente los nombres o identificadores de los nodos y/o enlaces se pueden ver a simple vista, por lo que se puede recurrir a anotaciones que se lo puede realizar desde la pestaña **"Annotation"**, en nuestro ejemplo, sirven para colocar el tipo de contratación que el software agrupó de forma automática.

Si se necesita girar o desplegar las distancias entre nodos para que se asemeje a la red del artículo en referencia, se puede optar por usar la pestaña **"Layout Tools"** y girar la gráfica hasta el punto deseado.

Use cada una de las opciones para caracterizar la red hasta el punto que obtenga una imagen similar a la figura 7 del artículo publicado, cuyo resultado será el siguiente:



5.1.3.- ANALISIS DE REDES

El software Cytoscape al igual que otros especializados en análisis de redes, tiene integrado algoritmos de análisis para medir ciertos parámetros o métricas como el grado, la centralidad, modularidad, comunidad, etc. Cytoscape cuenta con al menos las siguientes métricas de análisis:


Métricas	Descripción	Comentarios
Clustering Coefficient	Promedio de los coeficientes de acoplamiento de la red	Se puede interpretar como la probabilidad de que dos nodos cualesquiera de la red estén conectados
Conected components	Conjunto de nodos que están conectados entre sí por caminos directos o indirectos	Se puede ver como el total de grupos de nodos que hay en la red
Network diameter	La máxima longitud de las trayectorias entre nodos en la red	El máximo número de saltos necesarios para alcanzar el nodo más lejano. (Utiliza el cálculo de la excentricidad de los nodos)

Métricas	Descripción	Comentarios
Network Radius	La mínima excentricidad entre los nodos de la gráfica	Es el mínimo número de saltos para alcanzar el nodo más lejano en la red
Shortest Paths	Distancia L entre dos nodos	Cuando se habla de distribución SP se trata del número de pares que tienen distancia L
Average number of neighbors	Indica la conectividad promedio de un nodo en la red	
Characteristic path length	Promedio de SP	
Network centralization	A las redes tipo estrella se les asigna un valor cercano a 1 en este parámetro	Las redes descentralizadas poseen un valor cercano a cero en este parámetro
Network density	Es la normalización del número promedio de vecinos	Se mide entre 0 y 1 las redes descentralizadas tienen densidad cerca de cero, mientras que las centralizadas tienen valor cerca de uno
Network heterogeneity	Refleja la tendencia de la red a contener hubs	Valores cercanos a 0 muestran baja tendencia a tener nodos Hub
Multi-edge node pairs	Con qué frecuencia los nodos vecinos están vinculados por más de una arista	


Nota: Tomado de <https://www.complejidad.iiec.unam.mx/cursotaller2020/redes/medidas.php>

Para realizar análisis y cálculos más avanzados, así como para facilitar visualizaciones, Cytoscape cuenta con un repositorio de Apps disponibles en


<https://apps.cytoscape.org/>, donde se pueden descargar más algoritmos en base a la necesidad del investigador.




Estas actualizaciones o importaciones se las pueden realizar desde la pestaña “Apps” opción “App Store” seleccionando el archivo o desde el repositorio indicado.




Para realizar el análisis topológico de la red, seleccionamos en la pestaña “Tools”, la opción “Analyze Network”.



Cytoscape le pedirá que confirme si la red que va analizar es dirigida o no dirigida. Para nuestro ejemplo es una red no dirigida por lo que no se debe señalar dicha opción y se debe escoger directamente "OK".




Mientras dura el proceso del cálculo se desplegará la siguiente ventana:




Finalizado el tiempo de análisis, en el sector superior derecho de la zona de visualización de redes del software, se despliega la información de los resultados como el siguiente resumen estadístico:

Summary Statistics	
<i>Number of nodes:</i>	9479
<i>Number of edges:</i>	20643
<i>Avg. number of neighbors:</i>	2,197
<i>Network diameter:</i>	8
<i>Network radius:</i>	4
<i>Characteristic path length:</i>	3,746
<i>Clustering coefficient:</i>	0,000
<i>Network density:</i>	0,000
<i>Network heterogeneity:</i>	19,718
<i>Network centralization:</i>	0,337
<i>Connected components:</i>	2
<i>Analysis time (sec):</i>	6,161




Los resultados individuales por cada nodo o enlace, se agregan como datos en columnas nuevas en la zona de tablas tales como: *Degree*, *BetweennessCentrality*, *ClosenessCentrality*, etc.


Una vez realizado el análisis, tal como se mencionó anteriormente, cuando vamos a caracterizar la red luego del análisis, en la opción de estilos, ya están disponibles los nuevos parámetros para que permiten personalizar la red en función del objeto de estudios.




Para nuestro ejemplo, vamos a reorganizar la estructura de la red considerando la métrica de grado "**Degree**" como variable principal para personalizar la red. Para lograrlo primero debemos señalar en la opción "**Lock node width and height**", esto permite que podamos modificar el tamaño de los nodos de la red.




En la opción **"Size"** de la pestaña **"Style"**, seleccionamos en la opción **"Column"** la opción **"Degree"**, la cual surgió del análisis topológico de la red, luego de lo cual escogemos en la opción **"Mapping Type"**, la opción **"Continuous Mapping"**, que nos permitirá el degradado automático del tamaño de los nodos en función de los resultados individuales del grado obtenidos en el análisis de cada nodo y que constan en la zona de tablas.




Luego seleccionamos la opción **"Fill Color"**, para definir los colores que tendrán cada nodo en función de su grado; seleccionamos en la opción **"Column"** la opción **"Degree"**, luego escogemos en la opción **"Mapping Type"**, la opción **"Continuous Mapping"**, que nos permitirá el degradado automático del color de los nodos en función de los resultados individuales del grado obtenidos en el análisis de cada nodo y que constan en la zona de tablas.




Al hacer doble clic en la opción "**Current Mapping**", se despliega la siguiente imagen donde se puede personalizar los colores que se van asignar a cada nodo según el resultado de su grado (En este caso por ser la métrica seleccionada para el ejemplo).




Esto nos permite caracterizar la red de acuerdo a los atributos y particularidades que el investigador diseño en su modelo inicial.



Cuando se despliega la ventana seleccionamos el formato **PNG**, seleccionamos la ruta de destino, la forma y calidad de la imagen y damos "OK".




Finalmente, contamos con las dos redes, la primera en la que se caracterizó mediante los atributos, los tipos de contratación pública y la segunda aplicando la métrica de grado, se identifican los nodos más conectados.



5.2.- GEPHI

Para el uso del software Gephi, iniciaremos con descargarlo desde el link de su página oficial en <https://gephi.org/>, es importante señalar que al igual que Cytoscape, Gephi es un *software open source*, por lo que su descarga es gratuita y su funcionamiento ni tiene limitaciones ni demanda conocimientos de programación además cuenta con algoritmos de visualización más amigables y de fácil aplicación (Bastian et al., 2009). En el link: <https://gephi.org/users/quick-start/> se puede acceder al tutorial de uso del software.

Figura 42 Sitio oficial para descarga de Gephi




Una vez instalado y al correr el software, la primera ventana que se presenta, le permite seleccionar las opciones de: crear nuevos proyectos, abrir proyectos existentes, abrir archivos de uso reciente y ejemplos con los cuales se puede iniciar a familiarizar con el software y sus facilidades. Esta ventana si no desea que se desplaye cada vez que inicia el software se puede desactivar eliminando el visto en el ícono ☒ **Mostrar al iniciar**.

Figura 43 Ventana de bienvenida y selección de opciones iniciales



Para familiarizarse con el software, empezaremos seleccionando la opción “**Nuevo proyecto**”, de tal manera que nos permita visualizar la interfaz de usuario que tiene Gephi Versión 0.10.1.

Figura 44 Interfaz de usuario del software Gephi Versión 0.10.1



El software Gephi en la zona de pestañas de “Cambio de Ventanas” presenta tres espacios de trabajo: Vista general, “**Laboratorio de datos y Previsualización**”; para explicarlo y entenderlo de mejor manera, optaremos por abrir el archivo “**Les Miserables.gexf**”, disponible en la ventana de “Bienvenida”. Al seleccionarlo se despliega la siguiente ventana:

Figura 45 Ventana de importación de datos en Gephi

Informe de importación

Fuente: Les Misérables

Notificaciones | Informe

Nodes	Notificaciones
GEXF version 1.3	INFO

Tipo de grafo: No dirigido

Más opciones...

☒ Auto-escalar

☒ Crear nodos faltantes

☒ Bucles

Estrategia para combinar aristas: Promedio

de nodos: 77

de aristas: 254

Grafo dinámico: no

Atributos dinámicos: no

Multi grafo: no


☒ Nuevo espacio de trabajo

☐ Añadir al espacio de trabajo existente

Aceptar Cancelar

Esta ventana se presentará cada vez que usted abra un archivo, proyecto o red en la cual se deberá seleccionar el tipo de red con la que se va a trabajar, de entre las siguientes opciones: "Dirigido, no dirigido o mixto". Así como también, se deberá seleccionar el espacio de trabajo deseado. Para este ejemplo seleccionaremos "Tipo de Grafo": "No dirigido"; y, "Nuevo espacio de trabajo".


Figura 46 Vista general de Gephi



En esta vista se desplegará el conjunto de nodos y aristas representados en la gráfica, para proyectos iniciales, los nodos se presentarán como puntos negros y las aristas como líneas entre ellos, posteriormente cada usuario caracterizará la visualización de acuerdo a sus necesidades.


La segunda vista que ofrece Gephi es: **“Laboratorio de datos”**, en esta se puede realizar la configuración tanto de los nodos como de las aristas o enlaces.

Figura 47 Vista de laboratorio de datos de Gephi



La tercera vista que ofrece Gephi es: **“Previsualización”**, en esta se realiza la parametrización de la imagen de la red que posteriormente podrá ser descargada en formatos: SVG, PDF o PNG.

Figura 48 Vista de previsualización de Gephi




2.2.1.- CREACIÓN DE REDES

El software Gephi, al igual que Cytoscape, permite crear, importar, visualización y analizar redes, igual que lo hicimos con Cytoscape, empezaremos por crear una red sencilla tomando como modelo la red de amistad de la figura 22 b), formada por 9 nodos y 15 aristas.

A diferencia de Cytoscape, Gephi, no permite crear nodos y aristas directamente en la zona de visualización de redes, en este caso podemos optar por ingresar nodos y aristas en la vista **"Laboratorio de datos"**.




En esta vista, en la **"Tabla de datos"**, opción **"Nodos"** seleccionamos la pestaña **"Añadir nodo"**, luego se despliega una ventana para asignar la etiqueta del nodo, en la cual, para nuestro ejemplo, lo designaremos como **"Carlos"**.



Este proceso lo repetimos durante nueve veces designando nombres de cuatro hombres y cinco mujeres; para el ejemplo asignamos los siguientes:

- Hombres: (Carlos, José, Arturo, Elian)
- Mujeres: (Liss, Carmen, Charlotte, Mía, Karen)

A estas alturas, en la “**Vista general**”, ya se observan los nueve nodos creados; ahora nos corresponde crear la relación entre ellos.



En esta vista, en la “**Tabla de datos**”, opción “**Aristas**” seleccionamos la pestaña “**Añadir arista**”, luego se despliega una ventana para añadir la relación que existe entre los nodos, para nuestro ejemplo, configuraremos las siguientes relaciones considerando una red no dirigida en la cual la dirección de amistad es irrelevante:

1. Carlos es amigo de: Elian, José, Liss, Carmen, Charlotte, Mía y Karen.
2. Elian es amigo de: Liss, Carlos y Charlotte.
3. Liss es amiga de: Elian, Arturo y Charlotte.
4. Charlotte es amiga de: Arturo, Liss, Elian y Carlos.
5. Carmen es amiga de: José, Karen y Carlos.
6. José es amigo de: Carmen, Karen y Carlos.
7. Karen es amiga de: Carmen, Carlos y José.
8. Arturo es amigo de: Liss y Charlotte; y,
9. Mía es amiga de Carlos.

En la vista de tablas tendremos lo siguiente:

Gephi 0.10.1 - Proyecto 3

Vista general Laboratorio de datos Previsualización Espacio de trabajo 1

Tabla de datos x


Nodos Aristas Configuración Añadir nodo Añadir arista Buscar/Reemplazar Importar hoja de cálculo Exportar tabla Más acciones Filtro: Origen

Origen	Destino	Tipo	Clase	Id	Label	Interval	Weight
0	1	No dirigida	Amistad	0			1.0
6	0	No dirigida	Amistad	1			1.0
2	6	No dirigida	Amistad	8			1.0
0	3	No dirigida	Amistad	3			1.0
0	8	No dirigida	Amistad	4			1.0
0	4	No dirigida	Amistad	5			1.0
0	5	No dirigida	Amistad	6			1.0
0	7	No dirigida	Amistad	7			1.0
2	4	No dirigida	Amistad	9			1.0
3	6	No dirigida	Amistad	10			1.0
4	4	No dirigida	Amistad	11			1.0
4	6	No dirigida	Amistad	12			1.0
1	5	No dirigida	Amistad	13			1.0
5	8	No dirigida	Amistad	14			1.0
1	8	No dirigida	Amistad	15			1.0


Añadir nueva columna Mezclar columnas Borrar columna Borrar datos de columna Copiar datos a otra columna Rellenar columna con un valor Duplicar columna

Crear columna booleana a partir de expresión regular Crear columna con lista de grupos que se ajustan a una expresión regular Negar columna booleana Convertir columna a dinámica

Y en la vista general ya podemos observar que se graficaron los enlaces entre los nodos.



Es importante señalar que en “Laboratorio de datos” se puede asignar los atributos que se desean tanto para los nodos como para las aristas, sin embargo, Gephi a diferencia de Cytoscape no permite reemplazar directamente los nodos por imágenes. Para ello se debe optar por *plugins* extras que permitan realizar esta actividad.



Para mejorar la visualización de la red, caracterizamos la misma en “Distribución” y seleccionamos el algoritmo que más se adecúe a nuestras necesidades; para el ejemplo seleccionamos “Yifan Hu Proporcional” y activamos las etiquetas en el ícono

5.2.2.- CARGA O IMPORTACIÓN DE REDES Y/O TABLAS


A diferencia de Cytoscape, para crear una red en Gephi, es necesario contar con dos archivos que contenga, uno, detalle de los nodos con sus atributos y otro, con el detalle de las aristas y sus atributos, la preparación de estos archivos fue explicado en el Capítulo IV.

Gephi, permite importar datos para redes por lo menos con los siguientes formatos:


- CSV
- Excel
- GEXF
- GraphML
- Pajek NET
- GDF
- GML
- Tulip TLP

Para la generación de la siguiente red, utilizaremos los archivos de formato Excel, utilizados para la elaboración del artículo titulado “Redes complejas como metodología de investigación en procesos de formación” de Redroban-Ortiz, Rivas-Tovar y Torres, (2025). Estos archivos están disponibles para su descarga en <https://github.com/carluiredro/Networks-EFS>.

Iniciamos con “**Nuevo proyecto**”, para importar los datos tenemos dos opciones, desde la pestaña “**Archivo**”, la primera es mediante la opción “**Abrir**” y la segunda, mediante la opción “**Importar hoja de cálculo**”.




Una tercera opción para importar o cargar los datos es a través de la opción “**Importar hoja de cálculo**” en la vista de “**Laboratorio de datos**” y seleccionar el archivo que se desea utilizar. Para nuestro ejemplo, primero seleccionaremos los datos de los nodos y seleccionamos la opción “**Abrir**”.




En cualquiera de las tres opciones, se despliega la siguiente ventana en la cual se debe indicar al software ¿Cómo se desea importar estos datos?

Las opciones que se presentan son: Tabla de nodos, Tabla de aristas, Lista de Adyacencia y Matriz.



Seleccionamos “Tabla de nodos” y “Siguiente >”, luego se despliega la ventana de los parámetros de importación, donde se configura el tipo de cada variable. Normalmente estas se asignan por *default*, sin embargo, para nuestro ejemplo, debemos seleccionar en la variable “LONGITUD” y “LATITUD” la

opción **"Double"**, pues permitirán ubicar las coordenadas en las dimensiones "X" y "Y" al aplicar el algoritmo de **"Geo-layout"** y **"Map of Countries"** que deberá ser descargado en la opción **"Plugins"** en la pestaña **"Herramientas"** de Gephy.



Al seleccionar **"Terminar"**, se despliega la ventana de "Informe de importación". En ocasiones se generarán alertas de error para corregir el diseño de las variables o en otras ocasiones estas se las puede corregir luego de cargar los datos.

En esta ventana debemos seleccionar en **"Tipo de grafo"** la opción **"No dirigido"** y **"Nuevo espacio de trabajo"**.

Informe de importación

Fuente: NODOS-EFS-VALIDADO.xlsx

Notificaciones Informe

No se encontraron problemas durante la importación

Tipo de grafo: No dirigido Más opciones...

☒ Auto-escalar Estrategia para combinar aristas: Promedio

☒ Crear nodos faltantes

☒ Bucles

de nodos: 256 ☒ Nuevo espacio de trabajo

de aristas: 0 ☐ Añadir al espacio de trabajo existente

Grafo dinámico: no

Atributos dinámicos: no

Multi grafo: no


Aceptar Cancelar

El mismo procedimiento volvemos aplicar para importar los datos de las aristas, solo que, para estos datos seleccionamos **"Tabla de aristas"** y en la ventana de **"Informe de importación"** se deberá seleccionar la opción **"Añadir al espacio de trabajo existente"**, ya que estos se relacionarán con la tabla de nodos cargados inicialmente.

Tenga mucho cuidado porque la opción **"Nuevo espacio de trabajo"** viene marcado por *default*, esto generará otro espacio de trabajo distinto al que se subieron los datos de las aristas. Si esto sucede elimine el nuevo espacio y vuelva a importar la tabla de aristas correctamente.

Si los datos se cargaron correctamente podremos visualizar la siguiente imagen en **"Vista General"**, lo primero que debemos realizar antes de aplicar cualquier métrica a la red, es cambiar la visualización a una imagen que le permita visualizar o entender de mejor manera la red elaborada.


Para el ejemplo, en **"Distribución"** seleccionamos el algoritmo **"ForceAtlas2"** y parametrizamos las opciones internas hasta obtener esta imagen de la red:



Los datos utilizados para la elaboración de la red corresponden a las Entidades Fiscalizadoras Superiores (EFS) a nivel mundial, es decir que están relacionados con instituciones de control en varios países a nivel mundial, para el ejemplo se seleccionó este archivo por cuanto permitirá ubicar a cada país en un mapa mundial.


Adicional consideraremos en el ejemplo la aplicación de medidas de centralidad y medidas de modularidad y comunidad. Previo a aplicar los algoritmos que ubicará a cada nodo (EFS) en cada posición geo satelital en el mapa, es importante primero ejecutar las métricas señaladas para que estas se puedan visualizar también al momento de generar el mapa completo.

Primero empezamos con activar las etiquetas de los nodos para identificar los países a los que corresponden cada EFS. En la zona inferior activamos el ícono  y en la opción "**Configuración**", señalamos todos los atributos que deseamos que aparezca en la imagen. Para el ejemplo solo seleccionamos el "Id" que permite seleccionar los datos del nombre de cada país según constan registrados en la tabla de nodos en "**Laboratorio de datos**".



Para ejecutar las métricas de centralidad y de modularidad, en la zona derecha de la interfaz de Gephi, escogemos **“Estadísticas”** y luego ejecutamos las métricas de:


- **“Diámetro de la red”** que nos dará los resultados de la centralidad de Intermediación y Cercanía, al momento de aplicarlas debemos confirmar que se trata de una red **“No dirigido”** y que deseamos que se haga un cálculo normalizado por lo que se debe activar **Normalizar centralidades en el rango [0,1]**.
- **“Centralidad de vector propio”**, para calcular la medida de eigenvector también de red no dirigida; y, para nuestro ejemplo,
- **“Modularidad”**, en la cual se calculará también la cantidad de comunidades existentes en la red.



Cuando se ejecutan las métricas, los resultados de cada nodo se registrarán en la tabla de datos en “Laboratorio de datos”.


Gephi 0.10.1 - Proyecto 3														
Espacio de trabajo 1 x NODOS-EFS-VALIDADO x														
Tabla de datos x														
Filtro: Id														
Nodos	Aristas	Configuración	Añadir nodo	Añadir arista	Buscar/Reemplazar	Importar hoja de cálculo	Exportar tabla	Más acciones						
Id	Label	Timestamp	asociación	tipo de entidad	inglés	tipo de entidad	modelo	longitud	latitud	Modularity Class	Inferred Class	Component ID	Eccentricity	Closeness Centrality
Andorra			Miembro	Tribunal de Comptes	Tribunal de Cu...	Colegiado		<11.0, 5914.0...	<42.0, 5422...	4	0	0	4.0	0.286632
Angola			Miembro	Tribunal de Contas d...	Tribunal de Cu...	Colegiado		<17.0, 5818...	<-12.0, 360...	0	0	0	4.0	0.288114
Anguilla			Miembro	Office of the Perman...	Oficina de Au...	Unipersonal		<-63.0, 376...	<-18.0, 2241...	3	0	0	4.0	0.268029
Antigua y Ba...			Miembro	Office of the Directo...	Auditoría / Co...	Unipersonal		<-61.0, 809...	<-17.0, 785.0...	3	0	0	4.0	0.268029
Arabia Saud...			Miembro	General Court of Aud...	Tribunal de Cu...	Colegiado		<44.0, 9537...	<-24.0, 1338...	1	0	0	4.0	0.259421
Argentina			Miembro	Cour des Comptes	Tribunal de Cu...	Colegiado		<2.0, 6825.0...	<-28.0, 1467...	1	0	0	4.0	0.299731
Armenia			Miembro	Auditoría General de ...	Auditoría / Co...	Colegiado		<-63.0, 588...	<-31.0, 580...	6	0	0	4.0	0.26611
Austria			Miembro	Chamber of Audit	Cámara de Cu...	Colegiado		<44.0, 9184...	<-40.0, 3035...	2	0	0	4.0	0.320402
Australia			Miembro	Court of Audit	Tribunal de Cu...	Colegiado		<-49.0, 980...	<-12.0, 5249...	3	0	0	4.0	0.268029
Austria			Miembro	Australian National A...	Auditoría / Co...	Unipersonal		<134.0, 361...	<-25.0, 581...	7	0	0	4.0	0.298128
Azerbaijan			Miembro	Rechnungshof Österr...	Tribunal de Cu...	Colegiado		<14.0, 1373...	<-47.0, 5847...	4	0	0	4.0	0.286632
Bahamas			Miembro	Chamber of Accounts	Cámara de Cu...	Unipersonal		<47.0, 6875...	<-40.0, 3449...	2	0	0	4.0	0.320402
Bahrain			Miembro	Office of the Auditor	Auditoría / Co...	Unipersonal		<-76.0, 611...	<-24.0, 2543...	3	0	0	4.0	0.268029
Bangladesh			Miembro	National Audit Office	Auditoría / Co...	Unipersonal		<50.0, 5474...	<-26.0, 546.0...	1	0	0	4.0	0.293421
Barbados			Miembro	Office of the Compr...	Auditoría / Co...	Unipersonal		<90.0, 2518...	<-23.0, 8479...	2	0	0	4.0	0.283715
Belarus			Miembro	Auditor General's Off...	Auditoría / Co...	Unipersonal		<-39.0, 555...	<-13.0, 167.0...	3	0	0	4.0	0.268029
Belgium			Miembro	State Control Commi...	Comisión de C...	Colegiado		<28.0, 284.0...	<-53.0, 5308...	4	0	0	4.0	0.286632
Belize			Miembro	Rekenhof - Cour des ...	Tribunal de Cu...	Colegiado		<-4.0, 6593.0...	<-50.0, 6429...	4	0	0	4.0	0.286632
Belize			Miembro	Auditoría General	Auditoría / Co...	Unipersonal		<-88.0, 714...	<-17.0, 1903...	6	0	0	4.0	0.282278
Benin			Miembro	Cour des comptes	Tribunal de Cu...	Colegiado		<2.0, 3384.0...	<-19.0, 6486.0...	0	0	0	4.0	0.288114
Bermuda			Miembro	Office of The Auditor	Auditoría / Co...	Unipersonal		<-64.0, 766...	<-32.0, 2994...	3	0	0	4.0	0.268029
Bhutan			Miembro	Royal Audit Authority	Real Autorida...	Unipersonal		<90.0, 4666...	<-27.0, 383.0...	2	0	0	4.0	0.283715
Bielorrusia			Miembro	The State Control Co...	Cámara de Cu...	Colegiado		<27.0, 9533...	<-53.0, 7098...	4	0	0	4.0	0.286632
Bolivia			Miembro	Contraloría General d...	Auditoría / Co...	Unipersonal		<-64.0, 674...	<-16.0, 715...	6	0	0	4.0	0.26611
Bosnia-Herz...			Miembro	Ured za reviziju inett...	Oficina de Au...	Unipersonal		<17.0, 7895...	<-44.0, 1624...	4	0	0	4.0	0.286632
Botswana			Miembro	Office of the Auditor	Auditoría / Co...	Unipersonal		<23.0, 8028...	<-22.0, 180...	0	0	0	4.0	0.288114
Brasil			Miembro	Tribunal de Contas d...	Tribunal de Cu...	Colegiado		<-53.0, 845...	<-10.0, 767...	6	0	0	4.0	0.26611
Brunei Darus...			Miembro	Jabatan Audit	Departamento...	Unipersonal		<114.0, 602...	<-4.0, 5553.0...	2	0	0	4.0	0.283715
Bulgaria			Miembro	Smernitsa Palata	Tribunal de Cu...	Colegiado		<-25.0, 235.0...	<-42.0, 7546...	4	0	0	4.0	0.286632
Burkina Faso			Miembro	Cour des Comptes	Tribunal de Cu...	Colegiado		<-1.0, 7352...	<-12.0, 2722...	0	0	0	4.0	0.288114
Añadir nueva columna Mezclar columnas Borrar columna Borrar datos de columna Copiar datos a otra columna Rellenar columna con un valor Duplicar columna Crear columna booleana a partir de expresión regular Crear columna con lista de grupos que se ajustan a una expresión regular Negar columna booleana Convertir columna a dinámica														

De igual manera, estas métricas pasan a ser parte de los atributos que se podrán evidenciar en las redes y que permitirán caracterizar tanto nodos como enlaces. En la pestaña “Apariencia”, seleccionamos “Nodos”, escogemos “Modularity Class” para definir el color de los nodos.




Como el resultado de la métrica de Modularidad dio como resultado ocho comunidades, Gephi, al activar esta opción como atributos para los colores de los nodos, presenta ocho tipos de colores que identificarán a cada comunidad. Estos colores pueden modificarse de acuerdo a las exigencias requeridas.

Si los colores de los nombres que identifican a los nodos no cambian al aplicar esta selección, revise que, en la zona de **"Etiquetas"** este seleccionado en la opción **"Color"**, la opción **"Objeto"**.



Como el objetivo final es plasmar en un mapa la estructura de la red, en “Distribución” seleccionamos primero el algoritmo “Geo-layout” y posteriormente ejecutamos el algoritmo “Map of Countries”.



El algoritmo “Geo-layout” posicionará los nodos de la red de EFS en función de cada latitud y longitud, por lo que es importante que en la pestaña que se despliega seleccionen los atributos de latitud y longitud en cada parámetro del algoritmo.

El segundo algoritmo “Map of Countries”, diagramará un mapa que se visualizará de inmediato en la interfaz de Gephi. Para nuestro ejemplo necesitamos el mapa de todo el planeta por lo que es importante que, en los parámetros, de “Country” esté seleccionada la opción “World” y en los

parámetros de “Subregion”, “Region” y “District”, mantener las selección por default.

Distribución

Map of Countries


Ejecutar

Geo Layout

Country	World
Subregion	No subregion
Region	No region
District	No district
Scale	1000.0
Weight	1.0
Projection	Mercator
Center	☒

Si la intención es diseñar la red de una región o ciudad específica, se deberá programar los parámetros de “Subregion”, “Region” y “District”, al área de su elección.

La secuencia correcta de ejecución de algoritmos de métricas, y posicionamiento, permitirá que Gephi diseñe la siguiente imagen.




Recuerde que, los colores y tamaños de nodos y enlaces se pueden programar a conveniencia o en función de los atributos definidos por el investigador inicialmente.

5.2.3.- ANALISIS DE REDES


El análisis de las redes con Gephi, aplica la estructura conceptual y metodológica similar al de Cytoscape, y esto es lógico ya que ambos, se basan en la teoría de redes. Para ejecutar las diferentes métricas con Gephi, en la pestaña de **"Estadísticas"** (en la zona superior derecha de la interfaz) escogemos y ejecutamos las métricas deseadas de entre las siguientes:

Estadísticas		✕	📄
Configuración			
☑ Visión general de la red			
Grado medio	Ejecutar	?	
Grado medio con pesos	Ejecutar	?	
Diámetro de la red	Ejecutar	?	
Densidad de grafo	Ejecutar	?	
HITS	Ejecutar	?	
PageRank	Ejecutar	?	
Componentes conexos	Ejecutar	?	
☑ Community Detection			
Modularidad	Ejecutar	?	
Statistical Inference	Ejecutar	?	
☑ Visión general de los nodos			
Coeficiente medio de clustering	Ejecutar	?	
Centralidad de vector propio	Ejecutar	?	
☑ Visión general de las aristas			
Longitud media de camino	Ejecutar	?	
☑ Dinámicas			
# de Nodos	Ejecutar	?	
# de Aristas	Ejecutar	?	
Grado	Ejecutar	?	
Coeficiente de clustering	Ejecutar	?	


Si las opciones de “**Estadísticas**”, no se visualiza en la interfaz o pantalla principal, se debe activar la misma en la opción “**Ventana**” del menú principal.



Cuando se maneja gran cantidad de datos es necesario acotar la red para un mejor análisis y comprensión de su estructura, Gephi, permite hacerlo aplicando “filtros” que están disponibles junto a la opción de “Estadísticas”.



Si algún comando o algoritmo no está disponible dentro de las opciones de “Estadísticas”, o “Distribución” en la opción “Herramientas” del menú principal, se debe activar “**Plugins**”, e instalar aquellos necesarios para el objetivo de su estudio.



5.2.4.- EXPORTAR REDES Y/O TABLAS

El trabajo de diseño y/o análisis de redes se puede, guardar, exportar, imprimir o descargar, con las mismas funcionalidades y facilidades de Cytoscape sin embargo, Gephi guarda las sesiones por default con formato *.gephi.


También se pueden exportar las redes en varios formatos, tales como:

- Archivos CSV (*.csv*.edges),
- Archivos DL (UCINET) (*.dl),
- Archivos GDF, (GUESS) (*.gdf),
- Archivos GEXF (*.gexf),
- Archivos GML (*.gml),
- Archivos GraphML (*.graphml),
- Archivos JSON (*.json),
- Archivos NET (Pajek) (*.net),
- Archivos de hoja de cálculo (*.csv *.tsv); y,
- Archivos VNA (Netdraw) (*.vna).


Las imágenes se pueden exportar en formatos:

- Archivos PNG (*.png),
- Archivos SVG (*.svg)
- Archivos PDF (*.pdf)

La red elaborada en nuestro ejemplo en este caso la vamos a descargar en formato ***PNG**, para lo cual, seleccionamos en la pestaña “**ARCHIVO**” del menú principal, la opción “**Exportar**”, luego la opción “**Archivo SVG/PDF/PNG**”.



Cuando se despliega la ventana seleccionamos el formato **PNG**, decidimos la ruta de destino, el nombre que tendrá el archivo (imagen de la red) y damos “**Guardar**”.



Finalmente, contamos con la red caracterizada mediante los atributos, particulares asignados por el investigador inicialmente y los generados como resultados de las métricas aplicadas lo cual permite interpretar sus resultados en función de la teoría de redes complejas.

REFERENCIAS

- Alber, M. (2002). A conceptual model of estuarine freshwater inflow management. *Estuaries*, 25(6), 1246-1261. <https://doi.org/10.1007/BF02692222>
- Albert, R., & Barabási, A.-L. (2002). Statistical mechanics of complex networks. *Reviews of Modern Physics*, 74(1), 47-97. <https://doi.org/10.1103/RevModPhys.74.47>
- Allen, A. (2018). *Modelos de redes adaptativas críticamente auto-organizadas: Aplicación al estudio de modelos de población* [Phd, E.T.S. de Ingeniería Agronómica, Alimentaria y de Biosistemas (UPM)]. <https://oa.upm.es/50800/>
- Álvarez, E., Brida, J. G., Martínez, M., & Mones, P. (2022). Complex network analysis: A study of inflation in Uruguay. *Revista Finanzas y Política Económica*, 14(1), 131-166. Scopus. <https://doi.org/10.14718/revfinanzpolitecon.v14.n1.2022.6>
- Alzate-Cárdenas, M. del S., Posada-Girado, J. J., & Herrera-Mahecha, V. A. (2022). Corrupción en el Sector Público: Un Análisis Bibliométrico e Identificación de Tendencias. *Revista Lasallista de Investigación*, 19(2), Article 2. <https://doi.org/10.22507/rli.v19n2a15>
- Amat Rodrigo, J., & Carazo, F. (2023). *Análisis de redes con Python y NetworkX*. Cienciadedatos.net; Zenodo. <https://zenodo.org/doi/10.5281/zenodo.10006330>
- Ardissom de Souza, R. (2018, marzo 14). De las redes hacia el ciberespacio I. *Revista Digital Universitaria UNAM. RDU UNAM*. <https://www.revista.unam.mx/2018v19n2/de-las-redes-hacia-el-ciberespacio/>
- Ávila, J. H. (2012). *Redes sociales y Análisis de Redes: Aplicaciones en el contexto comunitario y virtual*. Corporación Universitaria Reformada. <https://dialnet.unirioja.es/servlet/libro?codigo=511130>
- Ayala, K. L., Rivas-Tovar, L. A., & Cardénas-Tapia, M. (2023). Redes empresariales y patrones de cooperación en MIPYMES textiles en México. *Revista Universidad y Empresa*, 25(44), Article 44. <https://doi.org/10.12804/revistas.urosario.edu.co/empresa/a.12379>

- Aya-Velandia, L. A. (2020). Aportes de los sistemas y redes complejas para la transformación social. *Logos Ciencia & Tecnología*, 12(1), 204-216.
- Barabási, A. (2022). *Ciencia de Redes* (Primera). ITESO. <https://books.google.com.ec/books?id=v0ulEAAAQBAJ>
- Barabási, A., & Albert, R. (2015). *Network Science by Albert-László Barabási*. Cambridge University Press. <http://networksciencebook.com/>
- Barabási, A.-L., & Albert, R. (1999). Emergence of Scaling in Random Networks. *Science*, 286(5439), 509-512. <https://doi.org/10.1126/science.286.5439.509>
- Barrat, A., Barthélemy, M., Pastor-Satorras, R., & Vespignani, A. (2004). The architecture of complex weighted networks. *Proceedings of the National Academy of Sciences*, 101(11), 3747-3752. <https://doi.org/10.1073/pnas.0400087101>
- Barthélemy, M., Barrat, A., Pastor-Satorras, R., & Vespignani, A. (2005). Dynamical patterns of epidemic outbreaks in complex heterogeneous networks. *Journal of Theoretical Biology*, 235(2), 275-288. <https://doi.org/10.1016/j.jtbi.2005.01.011>
- Bastian, M. (2022). *Releases Gephi*. GitHub. <https://github.com/gephi/gephi/wiki/Releases>
- Bastian, M., Heymann, S., & Jacomy, M. (2009). *Gephi: An Open Source Software for Exploring and Manipulating Networks*. AAAI. <https://aaai.org/papers/00361-13937-gephi-an-open-source-software-for-exploring-and-manipulating-networks/>
- Beltran, A., Jiang, X., Shen, Y., & Lehner, B. (2025). Site-saturation mutagenesis of 500 human protein domains. *Nature*, 1-10. <https://doi.org/10.1038/s41586-024-08370-4>
- Biggs, N., Lloyd, E. K., & Wilson, R. J. (1986). *Graph Theory*, 1736-1936. Clarendon Press.
- Borgatti, S., Everett, M., & Freeman, L. (1992). UCINET for Windows: Software for social network analysis. *Connections*, XV(1,2). https://www.researchgate.net/publication/216636663_UCINET_for_Windows_Software_for_social_network_analysis

- Budel, G., Jin, Y., Van Mieghem, P., & Kitsak, M. (2023). Topological properties and organizing principles of semantic networks. *Scientific Reports*, 13(1), Article 1. <https://doi.org/10.1038/s41598-023-37294-8>
- Burt, R. S. (1980). Models of Network Structure. *Annual Review of Sociology*, 6(Volume 6, 1980), 79-141. <https://doi.org/10.1146/annurev.so.06.080180.000455>
- Cárdenas, M. (2021). Redes de colaboración científica en el Instituto Politécnico Nacional de México. *Investigación Administrativa*, 50(127), 192-210.
- Cárdenas Tapia, M., Rivas Tovar, L. A., Ramírez Alatríste, F., & Simón Domínguez, N. (2015). Análisis de la estructura de una red de conocimiento en México. *Revista de ciencias sociales*, 21(4), 521-537.
- Clancy, D. (2022). *A new relationship between Erdős-Rényi graphs, epidemic models and Brownian motion with parabolic drift* (No. arXiv:2006.06838). arXiv. <https://doi.org/10.48550/arXiv.2006.06838>
- Cohen, R., Erez, K., ben-Avraham, D., & Havlin, S. (2000). Resilience of the Internet to Random Breakdowns. *Physical Review Letters*, 85(21), 4626-4628. <https://doi.org/10.1103/PhysRevLett.85.4626>
- De Castro, R., & Grossman, J. W. (1999). Famous trails to Paul Erdős. *The Mathematical Intelligencer*, 21(3), 51-53. <https://doi.org/10.1007/BF03025416>
- De Jorge, J. (2024). *Nobel de Química 2024 para la inteligencia artificial de Google que predice la estructura de las proteínas*. Diario ABC. <https://www.abc.es/ciencia/nobel-quimica-2024-20241009112344-nt.html>
- De Nooy, W., Mrvar, A., & Batagelj, V. (2018). *Exploratory Social Network Analysis with Pajek: Revised and Expanded Edition for Updated Software* (3.^a ed.). Cambridge University Press. <https://doi.org/10.1017/9781108565691>
- Díaz-Vicente, E. E., Turriate-Guzman, A. M., & Salazar-Vegas, K. V. (2024). News Coverage on the Social Network Facebook: A Systematic Review in Scopus from 2018 to 2023. En G. F. Olmedo Cifuentes, D. G. Arcos Avilés, & H. V. Lara Padilla (Eds.), *Emerging Research in Intelligent Systems* (pp. 315-326). Springer Nature Switzerland. https://doi.org/10.1007/978-3-031-52258-1_23
- Diestel, R. (2025). *Graph Theory* (Vol. 173). Springer. <https://doi.org/10.1007/978-3-662-70107-2>

- Dündar, A., & Tufan, F. (2022). *Social Comparison Behaviour on Social Network Sites: The Comparison Between Twitter and Instagram*. 12, 2022.
- Duque, P. L., Giraldo, J. D., & Osorio, I. D. (2023). Análisis bibliométrico de la investigación en big data y cadena de suministro. *Revista CEA*, 9(20), Article 20. <https://doi.org/10.22430/24223182.2448>
- Easley, D., & Kleinberg, J. (2010). *Networks, Crowds, and Markets: Reasoning about a Highly Connected World*. Cambridge University Press. <https://doi.org/10.1017/CBO9780511761942>
- Erdős, P., & Rényi, A. (1959). On random graphs. *Publications Mathematicae*, 6, 290-297.
- Freeman, L. C. (1977). A Set of Measures of Centrality Based on Betweenness. *Sociometry*, 40(1), 35-41. <https://doi.org/10.2307/3033543>
- Geroimenko, V. (Ed.). (2023). *Augmented Reality and Artificial Intelligence: The Fusion of Advanced Technologies*. Springer Nature Switzerland. <https://doi.org/10.1007/978-3-031-27166-3>
- Goel, R., Bonnetain, L., Sharma, R., & Furno, A. (2021). Mobility-based SIR model for complex networks: With case study Of COVID-19. *Social Network Analysis and Mining*, 11(1), 105. <https://doi.org/10.1007/s13278-021-00814-3>
- Gómez-Hernández, L. Y., Ramos-Ramírez, A. D., Gómez-Hernández, L. Y., & Ramos-Ramírez, A. D. (2017). Las relaciones comerciales en América Latina en 1995 y 2015: Un análisis de redes complejas. *Semestre Económico*, 20(45), 163-185. <https://doi.org/10.22395/seec.v20n45a6>
- González Laxe, F., Freire, M. J., Pais Montes, C., & López-Bermúdez, B. (2019). Análisis de redes complejas del transporte marítimo en el Océano Atlántico. *Revista de ciencias sociales*, 25(Extra 1), 42-61.
- Goyal, S., Van der Leij, M., & Moraga-Gonzalez, J. L. (2006). Economics: An Emerging Small World. *Journal of Political Economy*, 114(2), 403-412.
- Granovetter, M. S. (1973). The Strength of Weak Ties. *American Journal of Sociology*, 78(6), 1360-1380. <https://doi.org/10.1086/225469>
- Hernández-Serrano, M. J., Jones, B., Renés-Arellano, P., & Ortuño, R. A. C. (2022). Analysis of Digital Self-Presentation Practices and Profiles of Spanish Adolescents on Instagram and TikTok. *Journal of New Approaches*

in *Educational Research*, 11(1), Article 1.
<https://doi.org/10.7821/naer.2022.1.797>

Huang, Y., & Röllin, A. (2024). *The SIR epidemic on a dynamic Erdős-Rényi random graph* (No. arXiv:2404.12566). arXiv.
<https://doi.org/10.48550/arXiv.2404.12566>

Jackson, M. (2014). *Social and economic networks*.
https://www.nber.org/sites/default/files/2021-01/Jackson-NBER-slides2014_lecture1.pdf

Jankvist, U. T. (2015). History, Application, and Philosophy of Mathematics in Mathematics Education: Accessing and Assessing Students' Overview and Judgment. En S. J. Cho (Ed.), *Selected Regular Lectures from the 12th International Congress on Mathematical Education* (pp. 383-404). Springer International Publishing. https://doi.org/10.1007/978-3-319-17187-6_22

Juan, D. (2008). *Redes de Interacción de Proteínas*.
https://pdg.cnb.uam.es/pazos/cursos/bionet_UAM/DAJS_ppint_uam2008.pdf?utm_source=chatgpt.com

Kandel, D. B. (1978). Homophily, Selection, and Socialization in Adolescent Friendships. *American Journal of Sociology*, 84(2), 427-436.

Kiss, I. Z., Berthouze, L., & KhudaBukhsh, W. R. (2024). Towards Inferring Network Properties from Epidemic Data. *Bulletin of Mathematical Biology*, 86(1), 6. <https://doi.org/10.1007/s11538-023-01235-3>

Kurniawan, T. (2020). *Tulip—Data Visualization Software*.
<https://taufiqkurniawan.com/tulip-data-visualization-software/>

Larrosa, J. M. (2016, junio 21). Análisis de redes sociales: 30 paquetes de software de ARS. *Análisis de redes sociales*. <https://ars-uns.blogspot.com/2016/06/30-paquetes-de-software-de-ars.html>

López, E. (2023). ▷ *El Sociograma y la Sociometría de Jacob Levy Moreno: ¿En qué consiste?* - PsicoActiva. <https://www.psicoactiva.com/blog/el-sociograma-de-jacob-levy-moreno-en-que-consiste/>

Martínez Romera, D. (2018). *Sociometría, una metodología al servicio de la investigación en el aula de Ciencias Sociales*.

Milgram, S. (1967). The small—World problem. *Psychology Today*, 1(1), 61-67.

- Miller, J. (2013). Graph Database Applications and Concepts with Neo4j. *SAIS 2013Proceedings*. <https://aisel.aisnet.org/sais2013/24>
- Moreno, J. (1934). Who shall survive? *Nervous and Metal Disease Monograph Series*, 58, 464.
- Moreno, J. L. (1934). *Who Shall Survive: A New Approach to the Problem of Human Interrelations*.
- Mulet, R. (2021). The 2021 Physics Nobel Prize: Climate and Disorder: El Premio Nobel de Física de 2021: Clima y Desorden. *Revista Cubana de Fisica*, 38(2), 127-131.
- Newman, M. (2018). *Networks*. Oxford University Press. <https://doi.org/10.1093/oso/9780198805090.001.0001>
- Newman, M. E. J. (2001). The structure of scientific collaboration networks. *Proceedings of the National Academy of Sciences of the United States of America*, 98(2), 404-409. Scopus. <https://doi.org/10.1073/pnas.98.2.404>
- Newman, M. E. J. (2003). The Structure and Function of Complex Networks. *SIAM Review*, 45(2), 167-256. <https://doi.org/10.1137/S003614450342480>
- Newman, M. E. J. (2006). Modularity and community structure in networks. *Proceedings of the National Academy of Sciences*, 103(23), 8577-8582. <https://doi.org/10.1073/pnas.0601602103>
- Padgett, J. F. (2011). Marriage and elite structure in Reinassance Florence, 1282-1500. *Redes. Revista hispana para el análisis de redes sociales*, 21(2), Article 2. <https://doi.org/10.5565/rev/redes.418>
- Pastor-Satorras, R., Castellano, C., Van Mieghem, P., & Vespignani, A. (2015). Epidemic processes in complex networks. *Reviews of Modern Physics*, 87(3), 925-979. <https://doi.org/10.1103/RevModPhys.87.925>
- Pastor-Satorras, R., & Vespignani, A. (2024). Epidemic Spreading in Scale-Free Networks. *Physical Review Letters*, 86(14), 3200-3203. <https://doi.org/10.1103/PhysRevLett.86.3200>
- Radicchi, F., Castellano, C., Cecconi, F., Loreto, V., & Parisi, D. (2004). Defining and identifying communities in networks. *Proceedings of the National Academy of Sciences*, 101(9), 2658-2663. <https://doi.org/10.1073/pnas.0400054101>

- Rahman, Md. S. (2017). *Basic Graph Theory*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-49475-3>
- Ramos, R. H., Ferreira, C. de O. L., & Simao, A. (2023). *Human Protein Protein Interaction Networks: A Topological Comparison Review* (No. arXiv:2310.02378). arXiv. <https://doi.org/10.48550/arXiv.2310.02378>
- Redroban-Ortiz, C., Rivas-Tovar, L. A., Torres, X., Jaramillo, L., & Almeida, C. (2024). Redes complejas como metodología para el control gubernamental en procesos de contratación pública en Ecuador. *Revista Española de la Transparencia*, 20, Article 20. <https://doi.org/10.51915/ret.346>
- Redroban-Ortiz, C., Rivas-Tovar, L., Pino, A., & Reyes, L. (2024). *Complex Networks as a Methodology for Social Studies: The Case of 'Son de Amores'*. 3795, 54-64. Scopus.
- Rivas-Tovar, L. (2020). *Elaboración de tesis: Estructura y metodología*. Trillas. https://www.researchgate.net/profile/Luis-Arturo-Rivas-Tovar/publication/318969826_Elaboracion_de_Tesis_Estructura_y_Metodologia/links/5988d099aca27266ada4da3d/Elaboracion-de-Tesis-Estructura-y-Metodologia.pdf
- Rodríguez, D. (2025). *Introducción a igrph en R: Análisis de Redes desde Cero*. Analytics Lane. <https://www.analyticslane.com/2025/03/12/introduccion-a-igrph-en-r-analisis-de-redes-desde-cero/>
- Safari, H. (2020). Erdős number and co-authorship network: An application of graph theory in scientometrics. *Mathematics and Society*, 5(2), 47-57. <https://doi.org/10.22108/msci.2021.128339.1427>
- Salk. (2017). Nuevo método para mapear rápidamente las “redes sociales” de proteínas. *Salk Institute for Biological Studies*. <https://www.salk.edu/es/comunicado-de-prensa/nuevo-m%C3%A9todo-mapea-r%C3%A1pidamente-las-prote%C3%ADnas-de-las-redes-sociales/>
- Sarmiento-Ramos, J. L. (2020). Aplicaciones de las redes neuronales y el deep learning a la ingeniería biomédica. *Revista UIS Ingenierías*, 19(4), 1-18.
- Sayama, H. (2015). *Introduction to the Modeling and Analysis of Complex Systems* (Primera). SUNY. <https://knightscholar.geneseo.edu/cgi/viewcontent.cgi?article=1013&context=oer-ost>
- Shannon, P., Markiel, A., Ozier, O., Baliga, N. S., Wang, J. T., Ramage, D., Amin, N., Schwikowski, B., & Ideker, T. (2003). Cytoscape: A Software

Environment for Integrated Models of Biomolecular Interaction Networks. *Genome Research*, 13(11), 2498-2504. <https://doi.org/10.1101/gr.1239303>

Shlesinger, M. F. (2007). Complex Adaptive Systems: An Introduction to Computational Models of Social Life. *Journal of Statistical Physics*, 129(2), 409-410. <https://doi.org/10.1007/s10955-007-9384-z>

Smith, M. A., Shneiderman, B., Milic-Frayling, N., Mendes Rodrigues, E., Barash, V., Dunne, C., Capone, T., Perer, A., & Gleave, E. (2009). Analyzing (social media) networks with NodeXL. *Proceedings of the fourth international conference on Communities and technologies*, 255-264. <https://doi.org/10.1145/1556460.1556497>

Trujillo, B. S., & Escobar, A. M. F. (2009). El juego de las pirámides. *Sociedad y economía*, 16, 87-105.

UNAM. (2020). *Redes Aleatorias* [Institucional]. Sistemas complejos aplicados a la economía y fenómenos sociales. <https://complejidad.iiec.unam.mx/cursotaller2020/redes/redesAleatorias.php>

Vacas, C. (2024). *El Nobel de Física 2024 es para investigaciones sobre el aprendizaje automático, clave para la Inteligencia Artificial*. National Geographic España. https://www.nationalgeographic.com.es/ciencia/premio-nobel-fisica-2024-ganador_23401

Watts, D. (2006). *Seis grados de separación. La ciencia de las redes en la era del acceso* (Ediciones Paidós Ibérica S.A.). https://www.academia.edu/34577427/DUNCAN_WATTS_Seis_grados_de_separacion

Watts, D. J., & Strogatz, S. H. (1998). Collective dynamics of 'small-world' networks. *Nature*, 393(6684), 440-442. Scopus. <https://doi.org/10.1038/30918>

Wilson, C. (2010). Searching for Saddam. *Slate*. <https://slate.com/news-and-politics/2010/02/searching-for-saddam-a-five-part-series-on-how-social-networking-led-to-the-capture-the-iraqi-dictator.html>

Zachary, W. W. (1977). An Information Flow Model for Conflict and Fission in Small Groups. *Journal of Anthropological Research*, 33(4), 452-473.

- Zarco, H. (2025). *Ni mar ni tierra ni aire ni espacio: El grupo especial del ejército español que custodia «el quinto dominio»*. ElHuffPost. <https://www.huffingtonpost.es/tecnologia/ni-mar-tierra-aire-espacio-grupo-especial-ejercito-espanol-custodia-el-quinto-dominio.html>
- Zhan, C., Zheng, Y., Lai, Z., Hao, T., & Li, B. (2021). Identifying epidemic spreading dynamics of COVID-19 by pseudocoevolutionary simulated annealing optimizers. *Neural Computing and Applications*, 33(10), 4915-4928. <https://doi.org/10.1007/s00521-020-05285-9>
- Zong-chang, Y. (2024). A Complex Networks-Based Position-Distance-Related Epidemic Simulation Model for the H1N1: A Case Study. *Cybernetics and Systems*, 55(4), 961-980. <https://doi.org/10.1080/01969722.2022.2122017>

ISBN: 978-9942-33-916-4



Compás
capacitación e investigación