HADOOP, como una plataforma de procesamiento masivo de datos

# ANALISIS DEL SITIO WEB DE LA ESPOL

# Esquema de Trabajo

**Análisis Preliminar**

- Objetivo
- Alcances
- Limitaciones
- Fundamentos Teóricos

**Desarrollo del Estudio**

- Herramientas
- Estructura del Cluster
- Resultados

**Resultados**

- Análisis
- Conclusiones
- Recomendaciones

# Objetivo

- Realizar un análisis de la estructura de la Web de la ESPOL, para determinar si tiene una forma ***Pequeño Mundo***, con miras a mejorar su navegabilidad y el valor a los usuarios de la misma

# Fundamentos Teóricos: Redes Pequeño Mundo

- Grafo en el que mayoría de los nodos no son vecinos entre sí
  - Pero, la mayoría de los nodos pueden ser alcanzados desde cualquier nodo a través de un número relativamente corto de saltos
- Posee valores altos de coeficiente de agrupamiento (clustering coefficient)
  - Aunque dos nodos en la red no estén conectados de forma directa, existe una gran probabilidad de que se conecten a través de otros nodos
- Estructura libre escala (scale free network)

# Fundamentos Teóricos: Redes Pequeño Mundo

REPRESENTACION DE ESTÁNDARES DE REDES

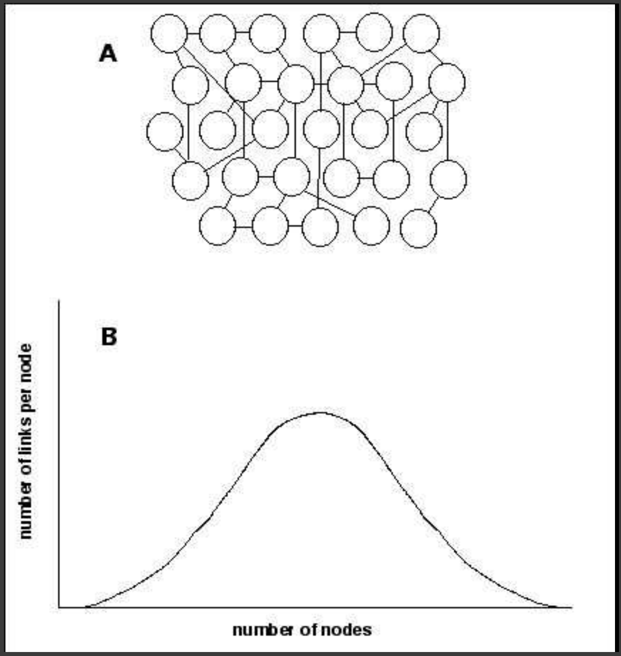


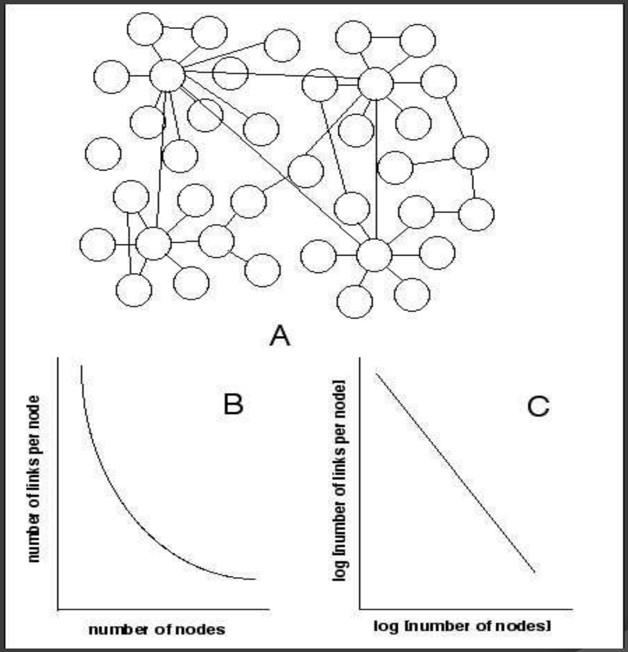


ALEATORIA

LIBRE DE ESCALA

# Redes Libre Escala

- Distribución de enlaces sigue a la de la Ley de las Potencias
  - La fracción P(x) de nodos en una red que tienen K conexiones hacia otros nodos, para grandes valores de K,

$$P(k) \approx k^{-y}$$

  - $y$: constante, generalmente está entre 2 y 3
- Algunos nodos se encuentran altamente conectados, aunque el grado de conexión de casi todos los nodos es bajo

# Redes Libre Escala

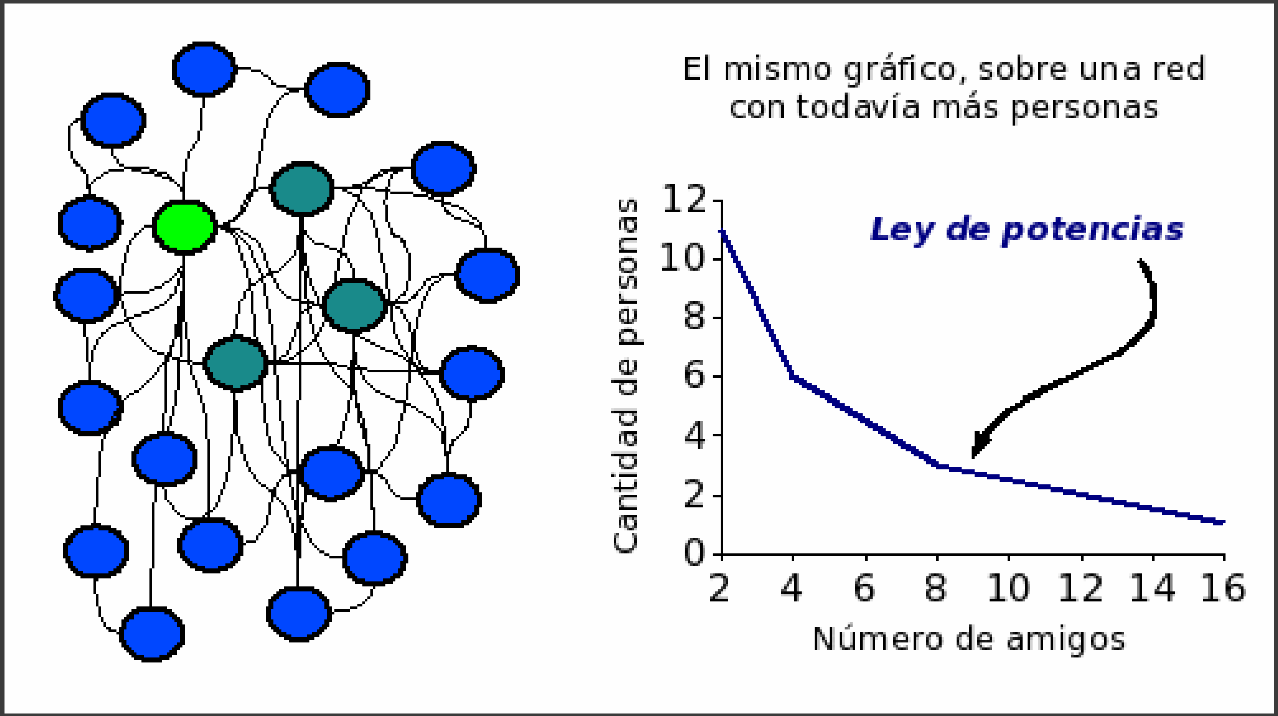


CARACTERÍSTICA DE LA RED LIBRE DE ESCALA

# Ley de Potencias

- Tipo de relación matemática entre dos cantidades
- Si una cantidad es la frecuencia y la otra el tamaño del evento en sí, entonces la relación es una distribución ***Ley de Potencia***s si el tamaño del evento incrementa de forma en que la frecuencia del evento decrece lentamente
- Una relación en forma de ***Ley de Potencias*** entre dos escalares cuantitativos X y Y es aquella que puede expresarse como sigue:

$$y = ax^k$$

  - **a**: constante de proporcionalidad
  - ***k***: exponente de la potencia (constante)

# Esquema de Trabajo

- Objetivo
- Alcances
- Limitaciones
- Fundamentos Teóricos

**Análisis Preliminar**

- Herramientas
- Estructura del Cluster
- Resultados

**Desarrollo del Estudio**

- Análisis
- Conclusiones
- Recomendaciones

**Resultados**

# Herramientas: HADOOP

- Plataforma de procesamiento de datos masivos, de código libre
  - Del Apache Software Foundation
- Basada en el paradigma de programación distribuida MapReduce
  - Similar a Dividir y Vencer pero que se aplica a grandes volúmenes de datos
- HDFS: sistema de archivos distribuido
- Altamente escalable y tolerante a fallos

# HDFS Architecture

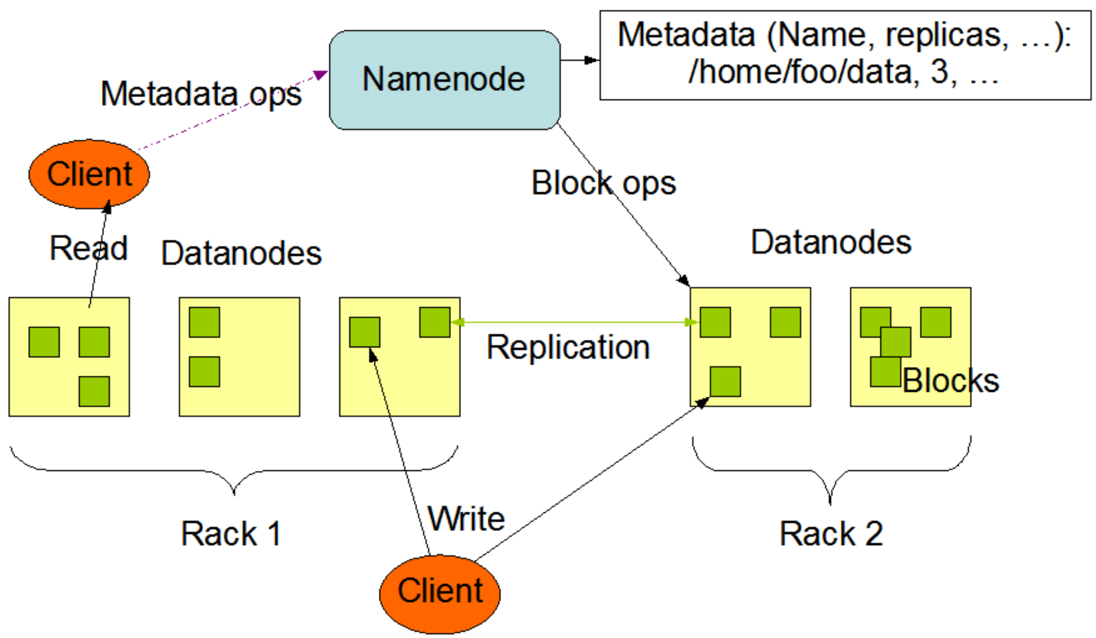


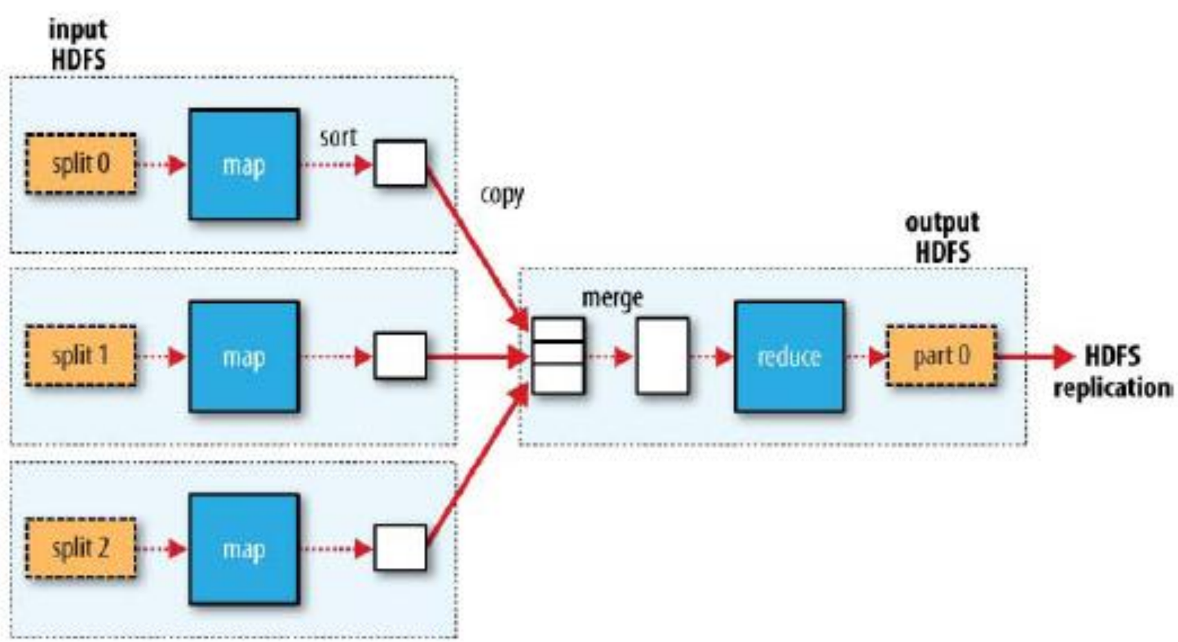

# Herramientas: Otras

- **Ubuntu Studio Works**
- **NUTCH**
- **ECLIPSE**
- **JAVA**
- **TOMCAT**
- **R-project**
- **Visualización:**
  - **Graphviz**
  - **Lanetvi**
  - **Cytoscape**

# Desarrollo del Cluster

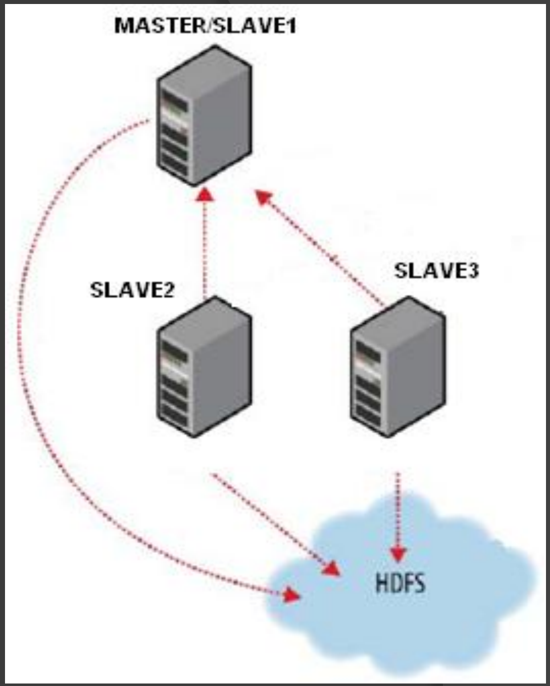


- Instalamos y configuramos un clúster Hadoop
- Descargamos Web de ESPOL
- Escribimos código Map-Reduce para procesar los Web y generar los resultados
- Resultados de procesados con el lenguaje R (R-project), para el análisis estadístico de las propiedades del grafo

# Resultados

- Obtuvimos los enlaces de toda la red de la ESPOL
- Generamos una tabulación con los enlaces de salida y de entrada, de manera que visualizamos el grado de nodos y la frecuencia
- Procesamos estos datos en la herramienta R-project para determinar si la distribución de los enlaces de salida y entrada seguía una ley de potencias

# Esquema de Trabajo

**Análisis Preliminar**

- Objetivo
- Alcances
- Limitaciones
- Fundamentos Teóricos

**Desarrollo del Estudio**

- Herramientas
- Estructura del Cluster
- Resultados

**Resultados**

- Análisis
- Conclusiones
- Recomendaciones

# Análisis: Sitio Web ESPOL

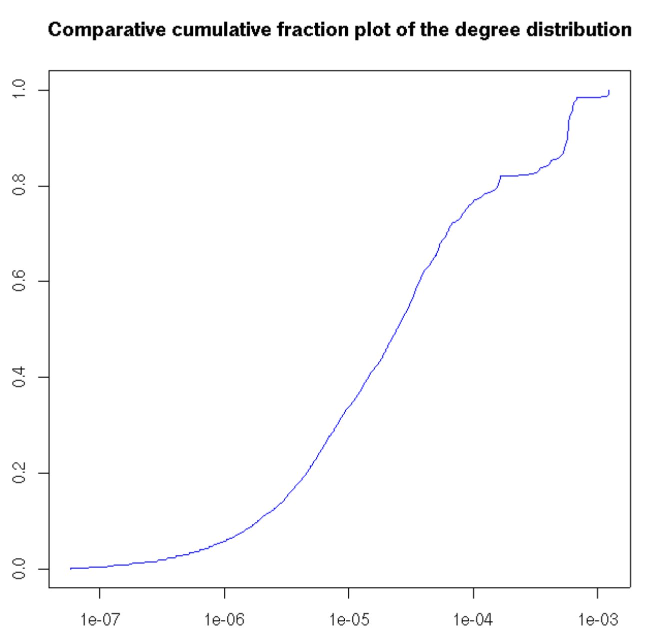


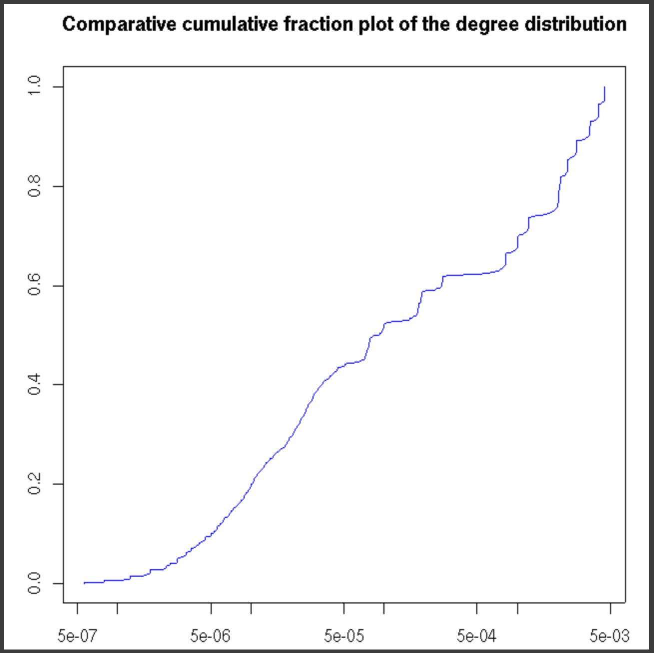


- Web de ESPOL no sigue una distribución de ley de potencias
  - Coeficiente de agrupamiento alfa < 1

➔ Web de ESPOL no es una pequeño mundo

# Análisis: Otros Sitios

- Para dar mayor realce a este estudio se creyó conveniente agregar un estudio de otros sitios, para su comparación
- Se escogió las universidades de Reino Unido (UK)
  - Estudio demuestra sus Web tienen la estructura pequeño mundo y muestra los beneficios de esta estructura en la navegabilidad de las mismas

**Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.**

# Análisis: Red de universidades del Reino Unido (UK)

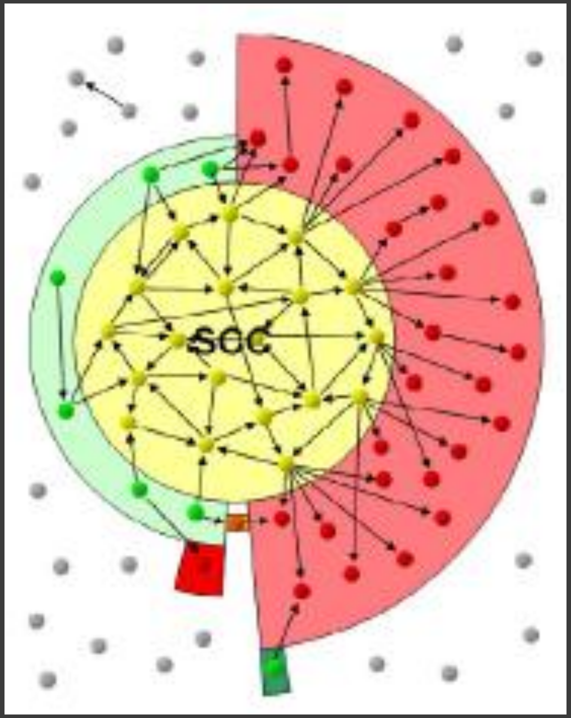


ANALISIS CENTRADO EN LA RED SCC

Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.

# Análisis: Red de universidades del Reino Unido (UK)

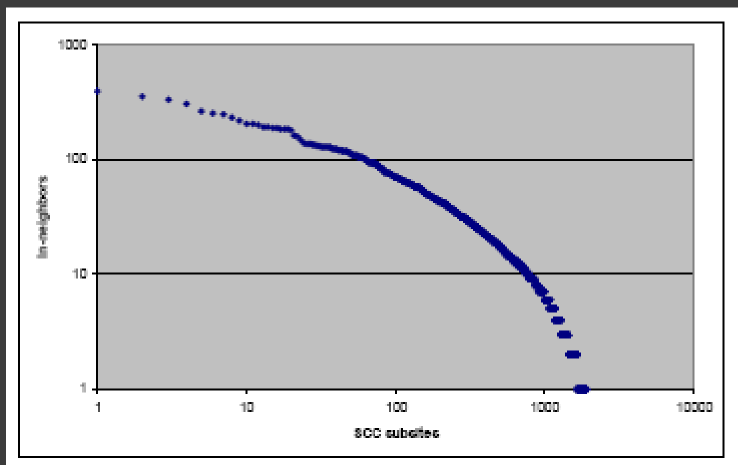


DISTRIBUCIONES DE ENLACES ENTRANTES PARA 1893 SUB-SITIOS DE LA RED SCC EN ESCALA LOG-LOG

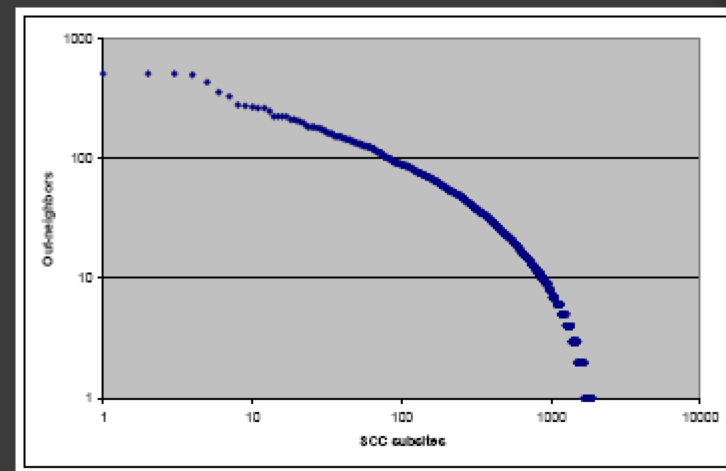


DISTRIBUCIONES DE ENLACES SALIENTES PARA 1893 SUB-SITIOS DE LA RED SCC EN ESCALA LOG-LOG


**Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.**

# Análisis: Red de universidades del Reino Unido (UK)

## LOS 15 SUB-SITIOS CON LA MAYOR CANTIDAD DE ENLACES ENTRANTES HACIA SUS VECINOS EN LA RED

| rank | id | subsite | comp. | # in-neigh -bors | # out-neigh -bors | affiliation |
|---|---|---|---|---|---|---|
| 1 | 4124 | src.doc.ic.ac.uk | OUT | 411 | 0 | 'Sun Site' mirror site (Usenet archive) at Imperial College, London |
| 2 | 1357 | cbl.leeds.ac.uk | SCC | 387 | 91 | Computer Based Learning Unit, Univ. of Leeds |
| 3 | 3017 | scit.wlv.ac.uk | SCC | 349 | 434 | School of Computing and Info.Technology, Univ. of Wolverhampton |
| 4 | 4129 | sunsite.doc.ic.ac.uk | OUT | 331 | 0 | 'Sun Site' mirror site (Usenet archive) at Imperial College, London |
| 5 | 1821 | users.ox.ac.uk | SCC | 330 | 507 | Personal web pages at Univ. of Oxford |
| 6 | 2760 | cs.ucl.ac.uk | SCC | 300 | 265 | Dept. of Computer Science, Univ. College London |
| 7 | 4928 | comlab.ox.ac.uk | OUT | 289 | 0 | Computing Laboratory (CS dept.), Univ. of Oxford |
| 8 | 1866 | info.ox.ac.uk | SCC | 259 | 120 | Former server with official web pages of Univ. of Oxford |
| 9 | 3020 | scitsc.wlv.ac.uk | SCC | 249 | 8 | School of Computing and Info. echnology, Univ. of Wolverhampton |
| 10 | 3339 | cup.cam.ac.uk | OUT | 249 | 0 | Cambridge University Press |
| 11 | 325 | cl.cam.ac.uk | SCC | 246 | 141 | Computer Laboratory (CS dept.), Univ. of Cambridge |
| 12 | 2642 | cogs.susx.ac.uk | SCC | 231 | 268 | School of Cognitive and Computing Sciences, Univ. of Sussex |
| 13 | 1466 | cs.man.ac.uk | SCC | 218 | 224 | Dept. of Computer Science, Univ. of Manchester |
| 14 | 925 | dcs.gla.ac.uk | SCC | 203 | 511 | Dept. of Computing Science, Univ. of Glasgow |
| 15 | 3010 | csv.warwick.ac.uk | SCC | 202 | 354 | Univ. of Warwick Information Service |

**Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.**

# Análisis: Red de universidades del Reino Unido (UK)

## LOS 15 SUB-SITIOS CON LA MAYOR CANTIDAD DE ENLACES SALIENTES HACIA SUS VECINOS EN LA RED

| rank | id | subsite | comp. | # in-neigh-bors | # out-neigh-bors | affiliation |
|---|---|---|---|---|---|---|
| 1 | 1088 | cee.hw.ac.uk | SCC | 148 | 518 | Dept. of Computing and Electrical Engineering, Heriot-Watt Univ. |
| 2 | 1572 | doc.mmu.ac.uk | SCC | 127 | 514 | Dept. of Computing and Mathematics, Manchester Metropolitan Univ |
| 3 | 925 | dcs.gla.ac.uk | SCC | 203 | 511 | Dept. of Computing Science, Univ. of Glasgow |
| 4 | 1821 | users.ox.ac.uk | SCC | 330 | 507 | Personal web pages at Univ. of Oxford |
| 5 | 3017 | scit.wlv.ac.uk | SCC | 349 | 434 | School of Computing and Info. Technology, Univ. of Wolverhampton |
| 6 | 3010 | csv.warwick.ac.uk | SCC | 202 | 354 | Univ. of Warwick Information Service |
| 7 | 2387 | ecs.soton.ac.uk | SCC | 117 | 327 | Dept. of Electronics and Computer Science, Univ. of Southampton |
| 8 | 791 | dai.ed.ac.uk | SCC | 137 | 280 | Department of Artificial Intelligence, Univ. of Edinburgh |
| 9 | 2291 | afm.sbu.ac.uk | SCC | 2 | 277 | 'Virtual library', Centre for Applied Formal Methods, South Bank Univ |
| 10 | 2642 | cogs.susx.ac.uk | SCC | 231 | 268 | School of Cognitive and Computing Sciences, Univ. of Sussex |
| 11 | 1268 | comp.lancs.ac.uk | SCC | 183 | 265 | Computing Dept., Univ. of Lancaster |
| 12 | 2760 | cs.ucl.ac.uk | SCC | 300 | 265 | Dept. of Computer Science, Univ. College London |
| 13 | 19 | users.aber.ac.uk | SCC | 34 | 250 | Personal web pages at Univ. of Wales, Aberystwyth |
| 14 | 3042 | www-users.york.ac.uk | SCC | 94 | 226 | Personal web pages at Univ. of York |
| 15 | 1597 | dcs.napier.ac.uk | SCC | 127 | 226 | School of Computing, Napier Univ. |

Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.

# Análisis: Red de universidades del Reino Unido (UK)

**PATH NET NH05. TODOS LOS CAMINOS CORTOS ENTRE eye.ex.ec.uk Y geog.plym.ac.uk**

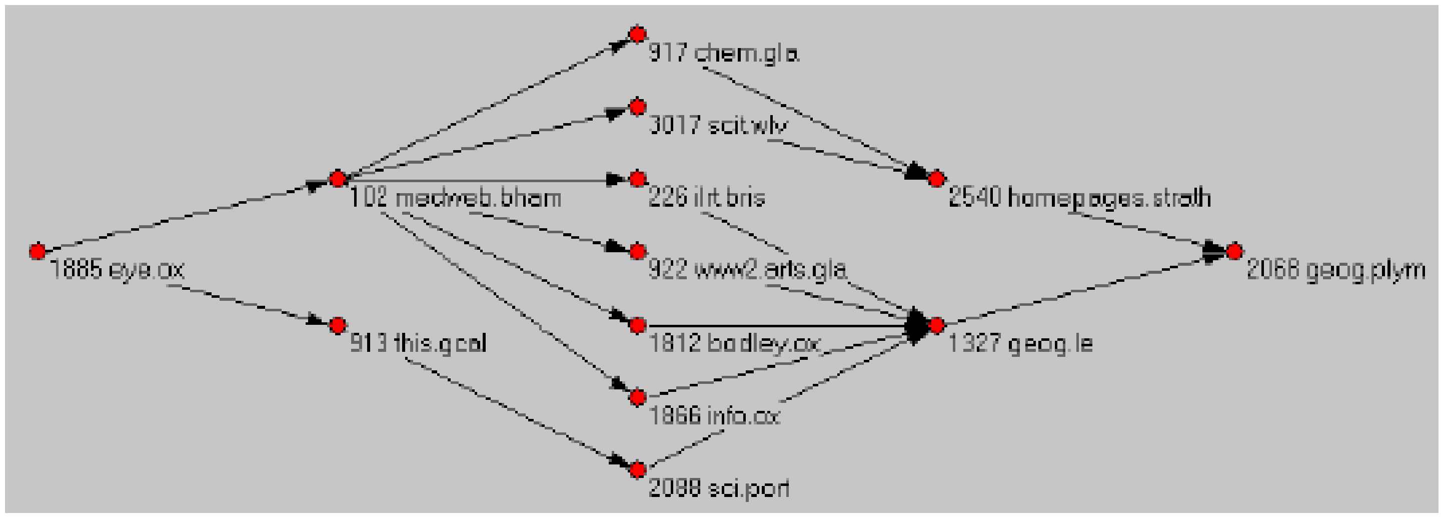


Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.

# Análisis: Red de universidades del Reino Unido (UK)

**Conclusiones:**

- Longitud del camino y coeficiente de agrupamiento cumplen los requisitos de una red pequeño mundo
- Las distribuciones de enlaces entrantes poseen propiedades pequeño mundo
- Se encontró que la red de nodos centrales (SCC) poseían una distribución pequeño mundo

**Björneborn, Lennart. "Small-World Link Structures across an Academic Web Space: A Library and Information Science Approach" Tesis Doctoral, del Departamento de Estudios de la Información, Royal School of Library and Information Science, Dinamarca.**

# Conclusiones

- La Web de la ESPOL no posee propiedades pequeño mundo en este momento
- Gracias al interés interno en el mejoramiento de su información, la estructura ha mejorado recientemente
- Hemos podido observar una reestructuración en los sitios de la ESPOL
  - Tuvo un impacto negativo en el presente estudio ya que produjo inconvenientes en el proceso de indexación
  - Ha mejorado la navegabilidad de la ESPOL, ya que ahora existe al menos un enlace de entrada y salida en cada sitio de la ESPOL
  - Aún no existe una correcta navegabilidad en muchos sitios, pues estos poseen problemas en su interacción con el usuario y no manejan un correcto enlazado de sitios

# Recomendaciones

- Dado que el ranking de universidades de Webometrics mide la usabilidad de los sitios Web y la cantidad de información investigativa que este proporcione a los usuarios, debemos coordinar una correcta estructura, de manera que se priorice la visibilidad de las investigaciones realizadas dentro de la institución y que esto sirvan para el desarrollo de actividades similares en otras instituciones
- Realizar un nuevo estudio en un periodo no mayor a un año, para observar efectos de nuevas políticas
- Siempre enlazar al sitio principal de la ESPOL y otros sub-sitios relacionados

# Recomendaciones

- Evitar en todo momento la creación de sitios Web que no estén enlazados directamente con algún sito representativo de la universidad
  - Debería estar conectada a una unidad, facultad, centro de investigación, etc. que tenga alguna característica común con el sitio que se pretende crear.
- Hacer un mantenimiento de los sitios de las unidades u otras representaciones dentro del dominio de la ESPOL de manera que no nos encontremos con sitios que no están activos o que carezcan de enlaces de entrada o salida