

Si de entender se trata: el rol de la visualización en el procesamiento de datos

Andrés A. Ilčić
Julián Reynoso

What I am really trying to do is bring birth to clarity, which is really a half-assedly thought-out pictorial semi-vision thing. I would see the jiggle-jiggle-jiggle or the wiggle of the path.

Richard Feynman

Introducción.

Desde los orígenes de la llamada *big science* y a medida que el uso de las computadoras para la producción científica (incluyendo a la propia ciencia computacional pero no reduciéndose a ésta, aunque la línea de separación sea cada vez más difusa) se hizo más extensivo, los científicos se han tenido que enfrentar a un crecimiento exponencial en la cantidad de datos que producen experimentos, observaciones y simulaciones. Y con el tiempo el problema se ha vuelto más serio, puesto que cada vez es más económico generar y guardar esos datos, mientras que nuestra capacidad cognitiva no ha evolucionado. Esto ha llevado al desarrollo de múltiples herramientas que permitan manejar el enorme caudal de datos obtenidos de múltiples fuentes de manera de poder tratarlos y analizarlos. Una de ellas ha sido la visualización científica, la producción de imágenes a partir de los datos producidos por modelos o simulaciones. Herbert Simon decía:

En un mundo lleno de información, la riqueza de información implica una pobreza de otra cosa: una escasez de lo que sea que la información consume. Aquello que la información consume es bastante obvio: consume la atención de sus destinatarios. Por ello la riqueza de información genera pobreza de atención y una necesidad de asignar esa atención eficientemente entre la sobreabundancia de fuentes de información que puedan consumirla. (Simon 1971, pp. 40-41)

Patrick Suppes, por su parte, presenta en 1962 una distinción entre tres tipos de modelos que conectan los datos con la teoría. Para Suppes los modelos teóricos y los modelos de experimentos no se comparaban directamente con los “datos crudos” sino con los llamados por él “modelos de datos”.

En el presente trabajo nos proponemos mostrar que las herramientas de visualización científica cumplen un rol primordial en el procesamiento de la abundante cantidad de datos que los científicos tienen a su disposición, en el sentido que ilustra la cita de Simon más arriba. Para ello, en primer lugar analizaremos brevemente la idea de descubrimiento a partir de bases de datos (KDD por sus siglas en inglés) y cómo se relaciona con la técnica de visualización. Luego presentaremos dos casos de visualizaciones para ilustrar nuestra posición y finalmente

evaluaremos en qué medida la noción de modelo de datos de Suppes puede dar cuenta del empleo de visualizaciones. Puntualmente, sostenemos que la visualización científica cumple en parte un rol “mediador”, entre modelos y entre nosotros.




Fig. 1 Representación de la llamada “Ley de Moore” que indica un aumento en la de la cantidad de cálculos por segundo dada la duplicación de la cantidad de transistores en un procesador cada aproximadamente 1.2 años. En ciertos ámbitos las computadoras superan ampliamente las capacidades cognitivas de los humanos, aunque estén todavía lejos en algunos aspectos que suelen parecernos “simples” como atar los cordones. (Imagen con licencia *Creative Commons* de Wikipedia¹).

Descubrimiento de Conocimiento en Bases de Datos (KDD).

La velocidad con la que se acumulan datos en diversos campos se ha incrementado exponencialmente en los últimos años, con lo que se generó la necesidad de desarrollar herramientas que ayuden a utilizarlos y darles sentido. Una de ellas es la que se ha dado a llamar Descubrimiento de Conocimiento en Bases de Datos (*Knowledge Discovery in Databases*) y suele abreviarse como KDD. El término proviene de (Piatetsky-Shapiro 1991) y en la reconstrucción del proceso seguimos a (Fayyad *et al.* 1996). KDD es el proceso no trivial consistente en encontrar patrones novedosos y en última instancia comprensibles en un conjunto de datos mediante herramientas computacionales: “en un sentido abstracto, el campo

¹ Vista en <https://upload.wikimedia.org/wikipedia/commons/b/ba/PPTSuperComputersPRINT.jpg>

del KDD se ocupa del desarrollo de métodos y técnicas para darle sentido a los datos”. (Fayyad *et. al.* 1996, p. 37).

El primer paso consiste en la creación de un subconjunto de los datos crudos, apelando a datos previos sobre el campo en el que el proceso de descubrimiento vaya a aplicarse. Luego se procede a limpiar y preprocesar los datos, como puede ser eliminación de ruido. Le sigue la reducción y proyección de datos, siempre de acuerdo al objetivo que se considera. La selección de un método particular de *data-mining* y el análisis exploratorio es el siguiente paso, para luego aplicar la minería de datos, esto es, la búsqueda de patrones interesantes. La interpretación de estos patrones es el paso siguiente.

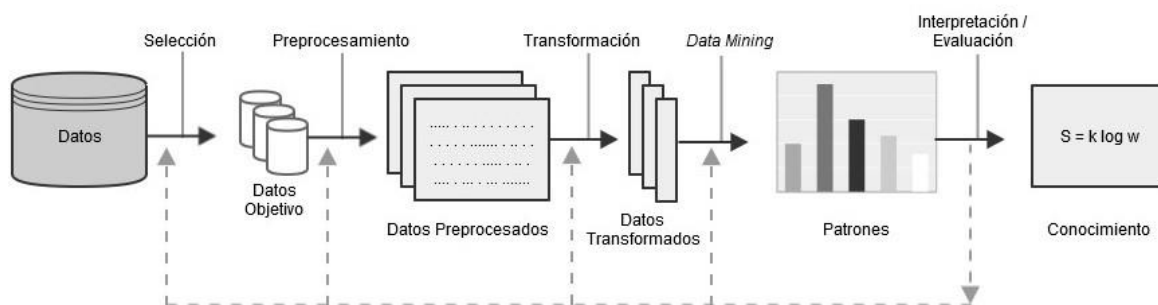


Fig. 2. El proceso de descubrimiento de conocimiento en bases de datos. Ilustración propia en base a (Fayyad *et al.* 1996)

Paul Humphreys (2004, 2009) ha señalado algunas de las novedades que esta transformación de la ciencia trae para la filosofía de la ciencia, concentrándose en el denominado “escenario híbrido”, en el cual nos encontramos. Utilizamos a las computadoras como un soporte extra para la ciencia mientras que nosotros, humanos, seguimos realizando parte del trabajo. La clara contraposición es un escenario automatizado, en el que el conocimiento y la producción científica pasa a manos de las computadoras. Si bien es cierto que es este último escenario el que presenta mayores novedades para los científicos y los filósofos, proponemos analizar cuál es el proceso actual de generación de conocimiento en los que el *tsunami de datos* es un hecho.

Dentro de este escenario, encontramos que la llamada visualización científica cumple un rol fundamental al que no suele darse crédito durante las descripciones del proceso de generación de conocimiento.

Visualización científica.

La visualización científica surge como disciplina científica en un *workshop* organizado hacia mediados de la década del 80 por la *National Science Foundation* con el objetivo de determinar las prioridades para la adquisición de software y hardware de procesamiento gráfico para sus centros de supercomputación, herramientas que se venían usando desde hacía algunos años para intentar dar cuenta del resultado de las simulaciones, aunque de manera increíblemente

limitada. Ya Richard Hamming había observado que “el propósito de la computación es el *insight*, no los números” (Hamming 1962, p. 4), por lo que el objetivo de esta nueva disciplina era utilizar herramientas visuales para poder entender los resultados de los modelos con los que estaban trabajando.

La visualización es un método de computación. Transforma lo simbólico a lo geométrico, permitiendo a los investigadores observar sus simulaciones y computaciones. Las visualizaciones ofrecen un método para ver lo no visto. Enriquece el proceso de descubrimiento científico y fomenta profundos e inesperados *insights*. En muchos campos está revolucionando la manera en la que los científicos hacen ciencia. (McCormick *et al.*, 1989, p. 3)

Es, desde el vamos, una actividad interdisciplinar dado que nuclea tanto a los científicos que realizan las simulaciones y los experimentos como también a expertos de distintas áreas, entre las que se incluyen gráficos computacionales, procesamiento de imágenes, visión computacional, diseño asistido por computadoras, procesamiento de imágenes y el estudio de interfaces de usuario.

Este reporte también es conocido por haber introducido la analogía de las fuentes de datos como una manguera contra incendio, “por lo que lo único que podemos hacer es almacenar los números que generan”. Ya el reporte del *workshop* incluía entre las fuentes de datos no sólo a las supercomputadoras sino también a satélites en órbita, datos de sondas espaciales, radiotelescopios, instalaciones instrumentales de ciencias geofísicas y escáneres médicos como TACs e IRM.

Una de las oportunidades interesantes que vino con la implementación de la visualización científica fue la posibilidad de interactuar con las simulaciones mientras se estaban ejecutando, pudiendo cambiar parámetros y ver los resultados casi en tiempo real:

La computación visual interactiva es un proceso por el cual los científicos se comunican con los datos manipulando su representación visual durante el procesamiento. Este proceso más sofisticado de navegación les permite a los científicos dirigir, o modificar dinámicamente, a las computaciones mientras ocurren. (McCormick *et al.*, 1989, p. 4)

El uso de la visualización científica está cada vez más extendido, en particular en aquellas ciencias que logran explotar más el paradigma computacional. Uno de los ejemplos más impactantes en las que las visualizaciones han mostrado tener un rol fundamental en la producción de conocimiento es la realizada en 2003 por el *Advanced Visualization Laboratory del National Center for Supercomputing Applications* en Illinois, sobre la simulación de un tornado y la supercelda que lo creó, un fenómeno bastante poco comprendido.

Para su estudio las visualizaciones tanto de simulaciones como de observaciones fotográficas y de radar cumplen un rol muy importante para echar luz sobre el fenómeno. El ejemplo es particularmente interesante puesto que permitió observar la creación de un tornado secundario, desprendido del embudo del tornado principal, fenómeno que se había observado pocas veces

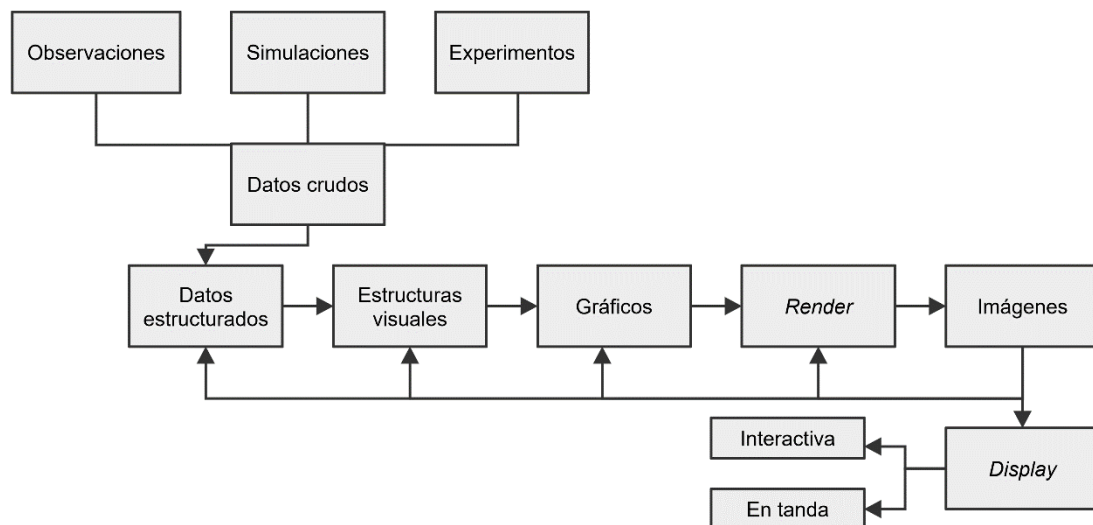
en la naturaleza. Tras ser visto en la visualización, los investigadores pensaron que se trataba de un error y consultaron a los expertos en tornados quienes confirmaron la rareza del evento².

El proceso de visualización científica.

Al igual que el proceso de KDD, la visualización científica puede verse como una secuencia de transformaciones que se realizan sobre los datos, desde la fuente hasta obtener una representación pictórica del resultado de la simulación o del experimento. Este proceso es altamente iterativo en tanto cada vez que se obtiene un resultado se puede decidir volver atrás y, por ejemplo, volver a correr la simulación ajustando algunos parámetros o, incluso, tener que corregir el modelo matemático o la versión en computacional del mismo.³

El proceso comienza con los datos en crudo llegando a una etapa de filtrado o de *enriquecimiento*, en la que, por ejemplo, se elimina ruido del instrumental o se interpolan puntos para los cuales se han calculado valores o simplemente se toman muestras (*subsampling*) de datos que a efectos prácticos son iguales, de manera de lidiar con una base de menor tamaño (en algunos casos estos datos pueden ser agregados a la hora de hacer la visualización final).

Tras el filtrado los datos son mapeados a estructuras u objetos geométricos abstractos, sobre los que no hay una receta fija y dependen, muchas veces, de criterios estéticos.⁴ Hacia el final del proceso encontramos el *render* final, que convierte a los objetos geométricos abstractos en imágenes visuales terminadas, ya sea produciendo animaciones, visualizaciones interactivas o imágenes fijas (*batch*).⁵



² El video producido, junto con las imágenes y las descripciones pueden encontrarse en el sitio web de la NCSA: <http://access.ncsa.illinois.edu/Stories/supertwister/>.

³ En esta reconstrucción seguimos a Wright (2007).

⁴ Cf, por ejemplo, (Cox, 2006, p. 98).

⁵ Se han realizado experimentos incluyendo el uso de sonidos y *feedback* háptico pero el corazón de la actividad permanece en torno a lo visual.

Fig 3. Esquema del proceso de visualización. Las flechas ascendentes indican los bucles más usuales.
Ilustración propia.

Una mirada integradora sobre el análisis visual: KDD y visualización.

La actividad científica se vuelve cada vez más multidisciplinaria, acompañada por la creciente cantidad de simulaciones y experimentos a gran escala que los científicos han sido capaces de realizar. Todo ello hace que se produzcan enormes bases de datos, que crecen continuamente a medida que la capacidad de cómputo aumenta de escala, ya en el orden de la petaescala sostenida y con la posibilidad de llegar a escalas aún mayores en los próximos años. A esto se le ha llamado ciencia *data-driven*. Darle sentido a esos datos, esto es, convertirlos en conocimiento se ha vuelto una de las tareas principales de la ciencia, objetivo para el cual las técnicas de análisis y de visualización científica cumplen un rol crítico en el proceso de descubrimiento. Como hemos señalado, esta última en particular busca hacer uso de nuestra amplia capacidad cognitiva visual para lidiar con los datos y comprender no sólo los fenómenos increíblemente complejos que podemos estudiar sino también los modelos que usamos para ello. Aproximadamente la mitad de nuestro cerebro está destinado al procesamiento visual, con algunos autores (Russ, 2012, p. 1) atribuyéndole el sesenta por ciento de las estimulaciones sensoriales que recibe el cerebro al sistema visual y la visualización científica es una técnica que nos permite explotar este hecho.

Para ilustrar a qué nos referimos, si se nos permite el juego de palabras, recurriremos a Larry Smarr (1985) quién simuló el comportamiento de un gas en la proximidad de un agujero negro y obtuvo un resultado de 1,25 mil millones valores numéricos y encontró que la producción de imágenes computarizadas le permitieron traducir esa “desastrosa pila de números en ciencia entendible” (Smarr, 1985, p. 404)

Sin embargo, la exploración visual de los datos parece no ser del todo apreciada. Un reporte del Advanced Scientific Computing Research del Departamento de Energía de EE.UU. lo exponía así:

La exploración visual de los datos está, sin embargo, bastante despreciada. Una de las razones es la tendencia a ver a los gráficos de computadora y la visualización como una manera de mostrar resultados científicos. Pero el campo de la exploración visual de los datos es mucho más que “lindas imágenes”. El verdadero poder proviene de la integración de representaciones visuales interactivas en el proceso fin-a-fin (*end-to-end*⁶) de descubrimiento científico, vinculando al espectacular entendimiento visual de la mente humana con el problema científico con el que se trata. (Johnson *et al.*, 2007, p. 4)

Creemos que, en muchos casos, son éstas técnicas las que permiten la comparación de datos

⁶ Nos resulta particularmente interesante esta idea, tomada del principio *end-to-end* de la infraestructura de redes. Según este principio, el margen de confiabilidad que se obtiene es mayor cuando se trabaja sobre los extremos de los procesos que en los nodos intermedios. De esta manera se busca garantizar robustez y confiabilidad en procesos con un gran número de pasos intermedios, sin descuidar una administración eficiente de recursos.

que provienen de fuentes muy distintas⁷. De esta manera es posible generar *insights* sobre el comportamiento de la naturaleza así como colaborar con la validación los modelos y los experimentos, además del tradicional rol de facilitar la transmisión de la información al público en general y en contextos de educación.

La visualización es una parte integral de la producción de conocimiento pero no es sólo el proceso de “ver los datos” sino que, integrando métodos de análisis automático antes y después de la representación permite generar conocimiento. La integración de ambos métodos es cada vez más importante dados el tamaño y la complejidad de las bases de datos científicas actuales.

Por ello es que creemos que es legítimo preguntarse si el uso de las técnicas de visualización científica son meramente herramientas útiles, por cuál es el estatus epistémico de estas técnicas. Humphreys se encargó de responder la primera pregunta:

Sin embargo, las representaciones visuales no son meramente útiles; en muchos casos son necesarias por la abrumadora cantidad de datos generados por los instrumentos modernos, algo que fue identificado [...] como el problema de la cantidad de datos. (Humphreys, 2004, p. 113)

¿Podría aplicarse el concepto de modelo de datos para dar cuenta de qué es lo que sucede cuando técnicas de visualización son aplicadas al resultado de un experimento o de una simulación numérica?

En un artículo de 1962, que sin dudas puede considerarse como un clásico de la filosofía de la ciencias, Patrick Suppes sostenía la visión de que los modelos teóricos y los modelos de experimentos no se comparaban directamente con los “datos crudos” sino con los llamados por él “modelos de datos”, aunque estos tengan la misma estructura lógica. Un punto similar ha sido sostenido por Jim Woodward en 1989, insistiendo en que las teorías no explican datos sino fenómenos y que son estos los usados para poner a prueba las teorías, y los fenómenos se construyen desde los datos mediante inferencias hacia abajo (*downwards*). Es claro que las técnicas estadísticas son las herramientas principales para la generación de estos “modelos de datos” desde los datos mismos.

Más recientemente, Harris (2002) ha mostrado cómo es posible utilizar el lenguaje de los modelos de datos para simplificar la discusión sobre el estado de los datos y las técnicas de manipulación de los mismos. Muchas veces trabajamos con “modelos de los datos” creados

⁷ Por mencionar un ejemplo, señalando la comparación entre las observaciones y las simulaciones del tifón Herb de 1996, Bob Wilhelmson señalaba que “esta comparación de los datos observados y los modelados revela algunos de los desafíos que tienen que ser considerados cuando se comparan conjuntos de datos de fuentes distintas. También muestra que aun cuando dos conjuntos de datos difieren en muchos aspectos, comparaciones útiles pueden hacerse empleando visualizaciones en 3D y técnicas de animación para comparar características de estructura y movimiento” (Wilhelmson *et al.*, 2005)

mediante técnicas estadísticas, y lo mismo sucede cuando en lugar de los datos de una serie de observaciones usamos la curva que encontramos mediante un proceso de ajuste de curva (*curve fitting*). Hacia el final de su artículo, señala que

Se puede ver que un modelo de datos puede ser el nivel más bajo de representación de lo que sucede. Es específico del experimento que se tiene a mano. Sin embargo, no es una mera copia de lo que sucede. En cambio, incorpora elementos de la teoría para crear una representación que contiene características relevantes para el científico (Harris, 2002, p. 1516).

Entonces, una vez que se obtiene la visualización ¿es un modelo de datos? Creemos que esta no es una respuesta fructífera. La visualización sí es una “representación de lo que sucede” pero lo que le otorga el valor, al menos en un contexto de descubrimiento, no es su estructura lógica sino el aspecto visual de la representación (e incluso puede generar un *insight* que ayude a comprender mejor el fenómeno). Una de las razones por la que podemos decir que no se trata de esta clase de modelos es por el recurso al modelo teórico del fenómeno, que a veces es necesario para crear una visualización. El modelo de datos claramente no hace uso de ningún supuesto teórico sobre lo estudiado.

Con esta idea no estamos criticando la existencia de una jerarquía de modelos, incluso en la partición que hace el mismo Suppes. Está claro que distintas clases de modelos hacen de intermediarios entre modelos, de camino de los modelos generales a los modelos “más cercanos” a los fenómenos. El punto es que muchas veces nos vemos obligados a hacer modelos de modelos en términos que sean cognitivamente accesibles, en tanto todavía nos encontramos en un momento de la ciencia que necesita de los humanos. Creemos que la visualización científica cumple parte de este rol “mediador”, entre modelos y entre nosotros.

Quizás el proceso para obtener una visualización pueda justificarse luego formalmente, quizás incluso ser axiomatizado, pero si prestamos atención a las prácticas científicas, y hacerlo nos ha enseñado más acerca de qué es y cómo funciona la ciencia que cualquier descripción teórica clásica, vemos que los datos crudos ni las primeras instancias de “modelos de datos” que son construidos en vistas de una visualización alcanzan para entender un fenómeno.

Hacia el final de su artículo, Suppes señalaba que

Por mi parte, un punto de preocupación ha sido mostrar que al moverse del nivel de la teoría al nivel del experimento, no tenemos que abandonar los métodos formales de análisis. Desde un punto de vista conceptual, la distinción entre matemática pura y aplicada es espuria -- ambas lidian con entidades conjunto teóricas, y lo mismo es cierto de la teoría y el experimento. (Suppes, 1962, p. 260)

Quizás lo sea pero sólo en una reconstrucción posterior. Uno puede reducir la geometría al álgebra pero para nuestros cerebros humanos, un plano es mucho más que un conjunto. Y si de entender se trata, una imagen *vale* más que una gigantesca base de datos.

Hemos argumentado que la visualización científica se ha ganado un lugar en las prácticas científicas al facilitar la comprensión y el manejo de grandes volúmenes de datos, al hacerlos un poco más asequibles. Tradicionalmente la producción de imágenes estaba limitada a la transmisión del conocimiento, pero a partir de avances en el poder de computación y almacenamiento de datos, la visualización científica ha ido cobrando preponderancia en el contexto de descubrimiento también. El análisis visual es una herramienta invaluable no sólo para estudiar ciertos fenómenos sino también para estudiar modelos de fenómenos, y que se integra al proceso de descubrimiento de conocimiento en bases de datos. Discutimos, en este punto, la noción de modelo de datos de Suppes para mostrar cómo las visualizaciones científicas difieren de dichos modelos, en parte por su vinculación con modelos teóricos del fenómeno en cuestión. Por último sostuvimos que la visualización científica cumple un rol de mediación entre modelos entre sí por un lado, y hacia nosotros también.

Claro que esto va a ser así sólo suponiendo que obtener una imagen es algo posible en principio. Muchas veces, obtener una visualización científica es imposible dada la naturaleza del fenómeno que se está estudiando o por la dimensionalidad misma de los datos. Muchas veces en estos casos se hace uso de algún elemento para representar algún subconjunto de los datos pero este elemento de representación no es una visualización científica, si no que entra dentro de lo que se denomina visualización de información. Algunos de estos métodos visuales son los que se usan para lidiar con lo que se conoce como *big data*, entre muchos otros que han sido de reciente interés científico debido al aumento en nuestra capacidad de generar y almacenar datos de origen científico. Estudiar este “nuevo paradigma” científico creado por la cantidad de datos disponibles será el objeto de próximos trabajos.

Bibliografía

- Cox, D. (2006) Metaphoric mappings: The art of visualization. In *Aesthetic computing*, Paul Fishwick (ed), MIT Press, 89-114.
- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996) From data mining to knowledge discovery in databases. *AI magazine*, 17(3), 37-54.
- Hamming, R.W. (1962) *Numerical methods for scientists and engineers*. McGraw-Hill.
- Harris, T. (2003) Data models and the acquisition and manipulation of data. *Philosophy of Science*, 70(5), 1508-1517.
- Humphreys, P. (2004) *Extending ourselves computational science, empiricism, and scientific method*. New York: Oxford University Press.
- Humphreys, P. (2009) The Philosophical Novelty of Computer Simulation Methods. *Synthese*, 169(3), 615-626.
- Johnson *et. al.* (2007) *Visualization and Knowledge Discovery: Report form the DOE/ASCR Workshop on Visual Analysis and Data Exploration at Extreme Scale*.
- McCormick, B.H., T.A. DeFanti, M.D. Brown (1987) Visualization in Scientific Computing, *Computer Graphics* 21(6).
- Piatetsky-Shapiro, G. (1991) Knowledge Discovery in Real Databases: A Report on the IJCAI-89 Workshop. *AI Magazine* 11(5): 68–70.
- Russ, J. C. (2012) *Computer-Assisted Microscopy: The Measurement and Analysis of Images*; Springer.
- Simon, H. A. (1971) "Designing Organizations for an Information-Rich World" in: Martin Greenberger, *Computers, Communication, and the Public Interest*, Baltimore. MD: The Johns Hopkins Press.
- Smarr, L (1985) "An approach to complexity: Numerical computations"; *Science* 228 (4698); pp. 403-408.
- Suppes, P. (1962) "Models of Data", in Ernest Nagel, Patrick Suppes and Alfred Tarski (eds.), *Logic, Methodology and Philosophy of Science: Proceedings of the 1960 International Congress*. Stanford: Stanford University Press, 252-261
- Wilhelmson, R., Middleton, D., & Scheitlin, T. (2005) Visualization in Weather and

Climate Research en *The Visualization Handbook*, Johnson, C. & Hansen, D. (eds.). Elsevier.

- Woodward, J. (1989) Data and phenomena. *Synthese*, 79(3), 393-472.
- Wright, H. (2007). *Introduction to Scientific Visualization*. Springer.