www.komputersapiens.org

KOMPUTER SAPIENS

Revista de Divulgación de la Sociedad Mexicana de Inteligencia Artificial

Año 11
Volumen 2
Mayo-Agosto 2019

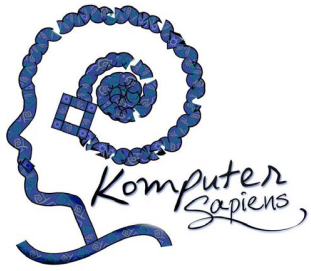


TUTORES INTELIGENTES: VALIDACIÓN, PERFILES Y AFECTIVIDAD

LA IA EN AGRICULTURA, CLIMA, COSMOLOGÍA, PROPIEDAD INTELECTUAL Y CONVERSIONES

APRENDIZAJE PROFUNDO PARA PLN

SEGUIDORES DE LÍNEAS Y DETECCIÓN DE OBSTÁCULOS MÓVILES



Contenido

Optimización de una red convolucional para la predicción la velocidad del viento
Pág. 7 ⇒por Hector Rodriguez-Rangel, Emmanuel F. Ramírez-Hernández, Luis A. Morales, Juan J. Flores y J. Armando Guerra

Una Aplicación de las Redes Neuronales Artificiales en la Cosmología
Pág. 12 ⇒ por Isidro Gómez Vargas, Ricardo Medel Esquivel, Ricardo García Salcedo y J. Alberto Vázquez

Validación de un Sistema Tutor Inteligente Web para el aprendizaje de las Matemáticas
Pág. 18 ⇒ por Alfonso Rosas Escobedo, Erica María Lara Muñoz y N. Sofía Huerta Pacheco

Obtención de perfiles de tutores académicos utilizando técnicas de Soft Computing
Pág. 23 ⇒ por M. Rosario Vazquez, Rafael Sánchez-Lara, Y. El Hamzaoui y Patricia Zavaleta-Carrillo

La agricultura de precisión impulsada por la Inteligencia Artificial
Pág. 29 ⇒ por Rogelio B. Olvera Rosales, Julio C. Ramos Fernández, Marco A. Márquez Vera Issac Hernández Santos

Pronóstico de Velocidad de Viento por Medio de un Conjunto de Modelos
Pág. 34 ⇒ por Hector Rodriguez-Rangel, Juan R. Valenzuela-Barraza, Carlos Lara-Alvarez, Luis A. Morales Rosales y Giovanni Manjarrez

Sistema Tutor Afectivo para la enseñanza de métodos numéricos de Euler y Runge-Kutta
Pág. 40 ⇒ por Gustavo Padrón Rivera, Cristina Joaquin Salas, Pedro Omar Silva Vásquez y Ricardo Serrano Herrera

Inclusión de la Inteligencia Artificial en Disputas Legales sobre Propiedad Intelectual
Pág. 45 ⇒ por Rodrigo Vidal-López y José A. Hernández-Servín

Redes Neuronales Recurrentes y su uso para la conversión de cadenas
Pág. 51 ⇒ por Jared D.T. Guerrero-Sosa, Víctor Hugo Menéndez-Domínguez y Víctor Uc-Cetina

Procesamiento de lenguaje natural con aprendizaje profundo
Pág. 56 ⇒ por Fernando Pech May, Luis A. López Gómez y Jorge Magaña Govea

Detección de Obstáculos Móviles Aplicada a la Conducción Autónoma Vehicular
Pág. 62 ⇒ por Lauro Reyes Cocoletzi, Ivan Olmos Pineda y J. Arturo Olvera López

Construyendo robots seguidores de línea avanzados
Pág. 67 ⇒ por Leonardo Romero, Moisés García, Antonio Camarena-Ibarrola e Ignacio Juárez-Campos

Columnas

Sapiens Piensa. Editorial pág. 2

e-Tlakuilo pág. 4

Estado del IArte pág. 5

Sakbe pág. 6

IA & Educación pág. 73

Deskubriendo Konocimiento pág. 75

ARTÍCULO ACEPTADO

Una Aplicación de las Redes Neuronales Artificiales en la Cosmología

Isidro Gómez Vargas, Ricardo Medel Esquivel, Ricardo García Salcedo y J. Alberto Vázquez

La búsqueda científica de un modelo que describa al Universo ha producido sofisticadas exploraciones cosmológicas y una inmensidad de datos observacionales. Para explorar y analizar esta información, la ciencia computacional resulta imprescindible.

El idilio entre cosmología y computación podría ser tema de varios libros; en este artículo nos centraremos en una aplicación de las redes neuronales artificiales (RNAs) en la estimación de parámetros de modelos cosmológicos.

La cosmología y sus datos

La cosmología es la ciencia que estudia el Universo a gran escala, donde las galaxias pueden ser descritas como puntos (Figura 1). Su objetivo es describir el origen, evolución, composición y destino del Universo a través de teorías físicas que se confrontan con observaciones astronómicas.

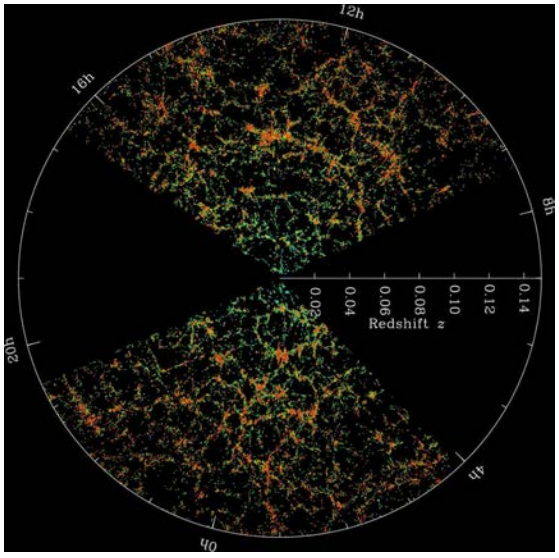


Figura 1. Distribución de galaxias locales generada con los datos del SDSS[1].

En la actualidad, el modelo cosmológico que mejor describe los datos observacionales es el modelo de materia oscura fría con constante cosmológica (abreviado ΛCDM). Se basa en la teoría general de la relatividad de Einstein, el Big Bang, la existencia de materia oscura fría (solo detectable por efectos gravitacionales) y de energía oscura (componente misterioso que produce la expansión acelerada del Universo).

Sin embargo, el modelo ΛCDM es incapaz de explicar algunas cuestiones físicas importantes. Esto ha propiciado la generación de una amplia gama de modelos, algunos basados en teorías alternas a la relatividad general y otros en hipótesis sobre la existencia de materia no ordinaria.

La cosmología es una ciencia muy singular debido a su objeto de estudio. El Universo es un sistema único, de fronteras inaccesibles, que debe estudiarse desde adentro sin la posibilidad de realizar experimentos. Esto exige dos características metodológicas en la cosmología contemporánea: análisis intensivo de datos y estadística bayesiana.

Jim Gray[2] pronosticó el advenimiento de un cuarto paradigma en la ciencia. El primer paradigma ocurrió hace mil años cuando la ciencia era descriptiva y empírica; el segundo tuvo su inicio con las investigaciones de Isaac Newton al adquirir un carácter teórico; el tercero surgió en el siglo XX, al incorporar simulaciones computacionales. El cuarto paradigma sería la ciencia de datos o *e-ciencia*, una mezcla de ciencia empírica-teórica con análisis computacional de una cantidad exorbitante de datos [1].

Información sobre supernovas, galaxias, radiación cósmica de fondo, oscilaciones acústicas de bariones y otros fenómenos cósmicos es recolectada desde la Tierra o el espacio. Proyectos como COBE[3], WMAP[4], el satélite Planck[5] y el SDSS[6] proveen un laboratorio cosmológico con datos importantes para validar o descartar modelos teóricos. Esta nueva etapa en el estudio del Universo se conoce como *cosmología de precisión*.

Además, dentro de pocos años, el telescopio LSST[7] fotografiará toda la bóveda celeste con la cámara más

[1] Fuente: www.sdss.org/science/orangepie
[2] Premio Turing en 1998, creador del concepto de Cubo de Datos y desarrollador de la base de datos del SDSS.
[3] science.nasa.gov/missions/cobe
[4] map.gsfc.nasa.gov
[5] www.phy.cam.ac.uk/research/research-groups/ap/plank
[6] SDSS son las siglas de Sloan Digital Sky Survey (www.sdss.org)
[7] www.lsst.org

© 2019 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

grande jamas construida (3.2 Gigapixeles), y se estima que recopilará 15 Terabytes por noche. Se vislumbra que la gestión y minería de datos del telescopio sean la parte técnica más difícil del proyecto. Por otro lado, el próximo radiotelescopio más grande del mundo, SKA[8], colectará aproximadamente 14 exabytes por día, suficientes datos como para llenar 15 millones de iPods de 64 GB; además, su computadora central tendrá el poder de, más o menos, 100 millones de unidades de procesamiento.

Puede apreciarse que la cosmología contemporánea, con su torrente de datos, cristaliza en una realidad la visión de Jim Gray del cuarto paradigma.

El análisis de los datos cosmológicos requiere de técnicas estadísticas y computacionales para ajustar los parámetros de los modelos teóricos. En este contexto, las RNAs y otras técnicas de inteligencia artificial pueden aportar sus virtudes.

La inferencia bayesiana

La inferencia estadística utilizada en cosmología tiene como fundamento el teorema de Bayes, una controvertida aplicación de la probabilidad condicional con más de dos siglos de historia, que ha conquistado grandes logros. Dada su naturaleza predictiva, se puede afirmar que el teorema de Bayes ha sido pionero del aprendizaje automático, de hecho, se puede emplear para detectar spam y hacer diagnósticos médicos [2].

Al lector interesado en la inferencia bayesiana se le recomienda la Ref. [2] para una introducción, la Ref. [3] presenta un tratamiento más formal y la Ref. [4] es una buena guía en el contexto cosmológico.

En la prueba de modelos teóricos, el teorema de Bayes adquiere el siguiente aspecto:

$$P(\theta|D,H) = \frac{P(D|\theta,H)P(\theta|H)}{P(D|H)},$$

donde D representa el conjunto de datos observacionales, H es la hipótesis (modelo) y θ el conjunto de parámetros (un modelo lineal, por ejemplo, tendría como parámetros libres la pendiente de una recta y su ordenada al origen). La probabilidad *previa* $P(\theta|H)$[9] representa nuestro conocimiento de los parámetros θ antes de considerar los datos observables. Esta probabilidad se modifica a través de la *verosimilitud* $P(D|\theta,H)$ al incluir datos experimentales D. El objetivo final es obtener la probabilidad *posterior* $P(\theta|D,H)$, que representa el estado de nuestro conocimiento de los parámetros del modelo al considerar la información de los datos. La constante de normalización $P(D|H)$, o *evidencia bayesiana*, es el promedio de la *verosimilitud* sobre la probabilidad *previa*:

$$P(D|H) = \int d^N\theta P(D|\theta,H)P(\theta|H),$$

donde N es la dimensión del espacio de parámetros. Esta cantidad, fundamental en la comparación de modelos, es una constante que puede omitirse en la estimación de parámetros.

La *verosimilitud* se determina al suponer una distribución estadística para los datos D, la probabilidad *previa* se define a partir de conocimientos preliminares. Al calcular la distribución *posterior*, se pueden obtener predicciones basadas en el modelo teórico y en las observaciones empleadas.

La estimación de parámetros encuentra el valor más probable de éstos, a la luz de los datos. En cosmología, los parámetros son las principales cantidades que describen el Universo; como no existe una teoría fundamental que las prediga, sus valores deben estimarse estadísticamente.

Esto se realiza mediante muestreos aleatorios en el espacio de parámetros e iteraciones del teorema de Bayes hasta que los resultados alcanzan un estado estacionario. Los valores de los parámetros en ese momento conforman la mejor estimación y también se pueden conocer las regiones de confianza.

Como ejemplo, la Figura 2 muestra gráficas resultantes de una inferencia bayesiana. A la derecha, la distribución *posterior* 1-Dimensional con la región más probable del parámetro Ω_m. La imagen de la derecha representa la distribución *posterior* 2-Dimensional, con regiones de probabilidad de los parámetros Ω_m y Ω_b; la parte interna representa la región de confianza 1σ (68.3 %), mientras que la externa corresponde a 2σ (95.4 %).

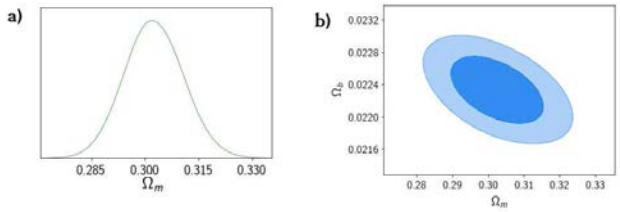


Figura 2. Distribución *posterior*: a) 1-Dimensional, b) 2-Dimensional.

En cosmología, como en otras ciencias, la inferencia bayesiana se implementa, en general, mediante métodos Monte Carlo vía Cadenas de Markov (MCMC), con algoritmos como Metropolis-Hastings, Gibbs u otras propuestas de muestreo.

El espacio de parámetros que exploran estos algoritmos tiene tantas dimensiones como parámetros tiene el modelo. Un número grande de parámetros produce funciones de probabilidad muy complejas. Así, a pesar de

[8] www.itweb.co.za/content/mraYAyqowZnqJ38N

[9] Las probabilidades involucradas son condicionales, por ejemplo: $P(\theta|D,H)$ es la probabilidad de que ocurra θ dado que han ocurrido D y H.

que los algoritmos MCMC suelen generar buenas estimaciones, también gastan muchos recursos computacionales. Dado que los modelos cosmológicos suelen tener al menos seis parámetros, diversos grupos de investigación han desarrollado códigos especializados, por ejemplo: CosmoMC[10] y CosmoSIS[11].

En algunos casos, además de la estimación de parámetros es necesario comparar modelos para determinar al mejor. La comparación de dos modelos distintos se realiza mediante el cociente de los valores de la *evidencia bayesiana* de ambos. Esto suele ser difícil o imposible de obtener analíticamente, incluso mediante cómputo en paralelo el cálculo puede tomar varias semanas.

La *evidencia bayesiana* es significativa porque penaliza a los modelos con mayor número de parámetros, a través de la distribución previa. Así, se obedece la Navaja de Occam, una guía filosófica que establece: "En igualdad de condiciones, la explicación más sencilla suele ser la más probable". En otras palabras, mientras más sencillo sea un modelo, es mejor.

Los métodos MCMC son buenos para estimar parámetros, pero ineficaces al calcular la *evidencia bayesiana*, por ello se han propuesto otros algoritmos, más eficientes, en este ámbito. Tal es el caso del muestreo anidado propuesto por John Skilling [5].

Muestreo anidado

La idea de John Skilling fue simplificar la integral de la *evidencia bayesiana* mapeando todo el espacio de parámetros a un intervalo unidimensional. El problema se reduce a calcular una integral de una dimensión; los contornos de las regiones con distinta probabilidad, ordenados, se mapean a un intervalo cerrado de 0 a 1 (Figura 3). Además, el muestreo se produce después de ordenar un primer muestreo más pequeño. Cada nuevo elemento de la muestra se compara con el de menor probabilidad y, en cada nueva iteración, el espacio de parámetros se reduce, aglomerando los nuevos puntos muestreados en una zona de probabilidad de alta ocurrencia.

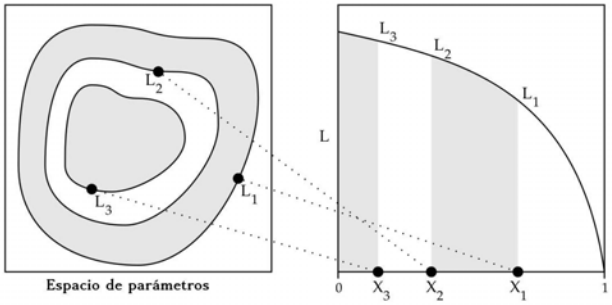


Figura 3. Propuesta de John Skilling. **Fuente: [5].**

El radiotelescopio SKA colectará 14 exabytes por día, suficientes datos para llenar 15 millones de iPods de 64 GB.

Las necesidades de la cosmología han motivado mejoras en el muestreo anidado. MULTINEST [6], por ejemplo, agrupa los puntos del muestreo mediante el algoritmo k-means y ha resultado ser bastante robusto, capaz de reducir el número de muestreos en uno o dos órdenes de magnitud respecto a los métodos MCMC [6] y por su éxito ha sido empleado en diversas disciplinas.

Optimizar el recorrido del espacio de parámetros, como hace MULTINEST con k-means, abre la puerta para que algoritmos de aprendizaje automático ayuden a mejorar las herramientas con las que se analizan los secretos del Universo.

El perceptrón multicapa (PMC)

Una de las arquitecturas de RNAs más simples y populares, desde hace un par de décadas, es el PMC (Figura 4).

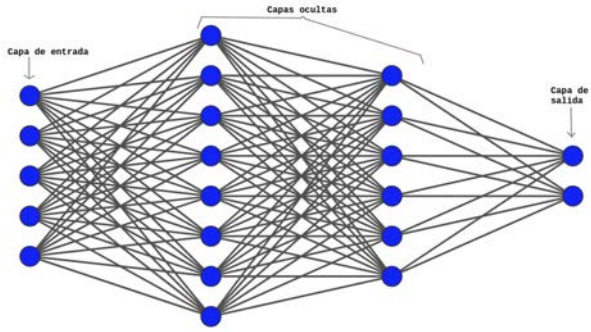


Figura 4. Arquitectura del PMC.

El Teorema Universal de Aproximación [7] establece que una RNA, con al menos tres capas, se puede aproximar a cualquier función, siempre que su función de activación esté localmente acotada, sea continua por partes y no sea un polinomio. Además, mientras mayor número de nodos posean sus capas ocultas más precisión tendrá la aproximación.

[10] https://cosmologist.info/cosmomc
[11] https://bitbucket.org/joezuntz/cosmosis

© 2019 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

Las funciones de activación asociadas al PMC (por ejemplo, sigmoide o *tanh*) cumplen los requerimientos del Teorema Universal de Aproximación.

SKYNET

SKYNET, desarrollado por el mismo grupo de MULTINEST, es un algoritmo que consiste en una RNA capaz de realizar regresión, clasificación, estimación de densidad, agrupamiento y reducción dimensional. En el artículo donde los autores liberan el código [8], se prueba en las tareas mencionadas mediante ejemplos de juguete y aplicaciones astrofísicas sencillas.

La RNA utilizada es un PMC de tres capas con una función de activación sigmoide. Los autores encontraron que el número óptimo de nodos en la capa oculta, para las estimaciones cosmológicas, está entre 50 y 100.

Una característica sobresaliente de SKYNET es su método de pre-entrenamiento: utiliza los muestreos de MULTINEST como entradas del PMC, lo cual reduce el tiempo de entrenamiento.

¿Qué hacer si dos modelos distintos se ajustan igual de bien a las observaciones? La respuesta es simple: compararlos.

En el caso de la estimación de parámetros, la función objetivo de la RNA es el logaritmo de la función de *verosimilitud*, dada por una función de ajuste chi-cuadrada. El algoritmo optimiza su función objetivo en cada iteración, evita sobre-ajuste y garantiza convergencia [8].

BAMBI

BAMBI (Blind Accelerated Multimodal Bayesian Inference) [9] es un algoritmo de los autores de MULTINEST y SKYNET. Su relevancia radica en que, para problemas típicos de cosmología, el tiempo de cálculo de la función de *verosimilitud* se reduce de segundos a milisegundos [9].

A diferencia de SKYNET, pretende sustituir en algún momento los cálculos resultantes del muestreo anidado. Sin embargo, se entrena con ellos y sus predicciones las va comparando con las respectivas salidas del muestreo anidado. Una vez que se alcanza la precisión establecida, prescinde del cálculo de las funciones de *verosimilitud* y emplea la RNA entrenada para etapas posteriores.

En problemas de estimación de parámetros simples, el tiempo que se pierde entrenando la RNA no es fructífero. No obstante, cuando se trata de funciones multivariables, el tiempo invertido en el entrenamiento, se recompensa en una disminución del tiempo total. Más aún, mientras mayor complejidad tengan el modelo o los datos observacionales, más eficiente es BAMBI comparado con MULTINEST y la precisión de los resultados es del mismo orden.

Ejemplo

Para ilustrar y comprobar el funcionamiento de MULTINEST y BAMBI, hemos implementado un ejemplo sencillo mediante la interfaz en Python de [10][12].

Elegimos el casquete de un paraboloide circular como función de objetivo (Figura 5):

$$z = f(x, y) = x^2 + y^2$$

Se siguieron las especificaciones de las Refs. [6,8,9]: BAMBI calculó el 75 % de las muestras mediante MULTINEST, y las restantes vía un PMC.

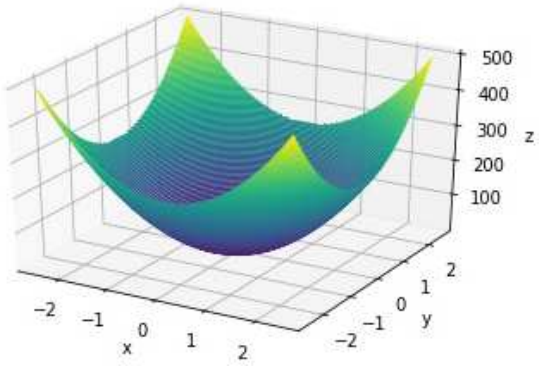


Figura 5. Paraboloide (función objetivo).

Una manera de validar los resultados de estos algoritmos y, en general, de cualquier método MCMC o de estimación de parámetros, es verificar si los puntos muestreados reproducen la función objetivo. Para este ejemplo (Figura 6), ambos algoritmos alcanzaron una precisión similar y satisfactoria. En la Figura 7, se puede apreciar la evolución del muestreo con BAMBI.

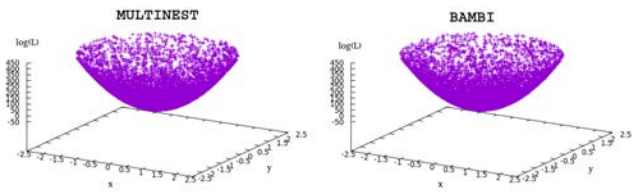


Figura 6. Resultados de MULTINEST y BAMBI.

[12]Se utilizó pyBambi: `pybambi.readthedocs.io`

...la cosmología mantendrá la mirada atenta en los avances de la inteligencia artificial.

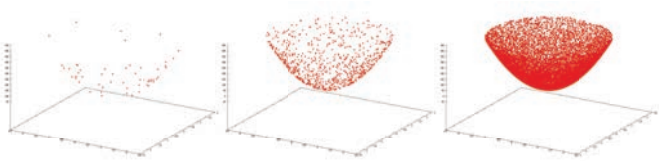


Figura 7. Etapas inicial, intermedia y avanzada del muestreo con BAMBI.

También realizamos un comparativo entre los tiempos de ejecución con diferentes números de evaluaciones de la función de *verosimilitud* con ambos algoritmos (Tabla 1).

Tabla 1. Tiempos de ejecución para evaluaciones de la *verosimilitud*.

No. Eval.	Tiempo MULTINEST	Tiempo BAMBI
1 000	0.3 s	0.7 s
10 000	7.1 s	4.2 s
100 000	735.4 s	75.9 s

Nótese que mientras más se evalúa la función *verosimilitud*, mejor desempeño tiene BAMBI gracias a su RNA. En modelos complejos, como los cosmológicos, la función *verosimilitud* se debe evaluar millones de veces y métodos que optimicen los cálculos son necesarios.

Por último, en la Tabla 2 se muestra que al utilizar BAMBI no se pierde precisión en el cálculo de la *evidencia bayesiana*.

Tabla 2. Cálculos de la *evidencia bayesiana*.

	MULTINEST	BAMBI
Log(Evidencia)	$-0{,}782 \pm -0{,}06$	$-0{,}783 \pm -0{,}06$

Conclusiones

La estimación de parámetros de un modelo teórico mediante el muestreo anidado es una alternativa a los métodos MCMC y, además, permite calcular la *evidencia bayesiana* para comparación de modelos. Sin embargo, el uso de la RNA para evaluar las funciones de probabilidad mejora la velocidad y no pierde precisión.

La generación de datos cosmológicos seguirá a la alza en próximos años. Será crucial escudriñarlos para mejorar nuestra concepción del Universo y la cosmología mantendrá la mirada atenta en los avances de la inteligencia artificial. ✷

Agradecimientos. Al CONACYT, ICF-UNAM y CICATA-Legaria-IPN. Este trabajo fue parcialmente apoyado por los proyectos SIP 20180252 y SIP 20190237 del IPN. J.A.V. agradece el apoyo proporcionado a los proyectos FOSEC SEP-CONACYT Investigación Básica A1-S-21925 y UNAM-PAPIIT IA102219.

REFERENCIAS

1. Hey, T., Tansley, S. y Tolle, K. (2014). Jim Gray sobre la e-ciencia: un método científico transformado. En *Hey, T. et al. (Eds.) El cuarto paradigma. Descubrimiento científico intensivo en datos*. México, UAM, 17-23.
2. Castro Ortega, P. (2017). El Teorema de Bayes. Aproximándonos a la verdad. *RBA Coleccionables*.
3. Sivia, D. y Skilling, J. (2006). Data analysis: a Bayesian tutorial. *OUP Oxford*.
4. Padilla, L., Tellez, L. O., Escamilla, L. y Vazquez J. A. (2019). Cosmological parameter inference with Bayesian statistics. arXiv:1903.11127 [astro-ph.CO].
5. Skilling, J. (2006). Nested sampling for general Bayesian computation. *Bayesian analysis*. 1(4), 833-859.
6. Feroz, F., Hobson, M. P. y Bridges, M. (2009). MultiNest: an efficient and robust Bayesian inference tool for cosmology and particle physics. *Monthly Notices of the Royal Astronomical Society*. 398(4), 1601-1614.
7. Hornik, K., Stinchcombe, M. y White, H. (1990). Universal approximation of an unknown mapping and its derivatives using multilayer feedforward networks. *Neural networks*. 3(5), 551-560.
8. Graff, P., Feroz, F., Hobson, M. P. y Lasenby, A. (2014). SKYNET: an efficient and robust neural network training tool for machine learning in astronomy. *Monthly Notices of the Royal Astronomical Society*. 441(2), 1741-1759.
9. Graff, P., Feroz, F., Hobson, M. P. y Lasenby, A. (2012). "BAMBI: blind accelerated multimodal Bayesian inference". *Monthly Notices of the Royal Astronomical Society*. 421(1), 169-180.
10. Buchner, J., Georgakakis, A., Nandra, K., Hsu, L., Rangel, C., Brightman, M. y Kocevski, D. (2014). X-ray spectral modelling of the AGN obscuring region in the CDFS: Bayesian model selection and catalogue. *Astronomy & Astrophysics*. 564, p. A125.

© 2019 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691

SOBRE LOS AUTORES



Isidro Gómez Vargas es licenciado en física y matemáticas y, en la actualidad, estudiante de doctorado en tecnología avanzada del IPN. Ganó segundo lugar del "Premio de Ensayo Innovación Educativa 2016" y en el "XIX Concurso Internacional de Cuento Navideño, Súbito, Breve y Electrónico". En su doctorado estudia la estimación de parámetros cosmológicos mediante técnicas estadísticas y computacionales.



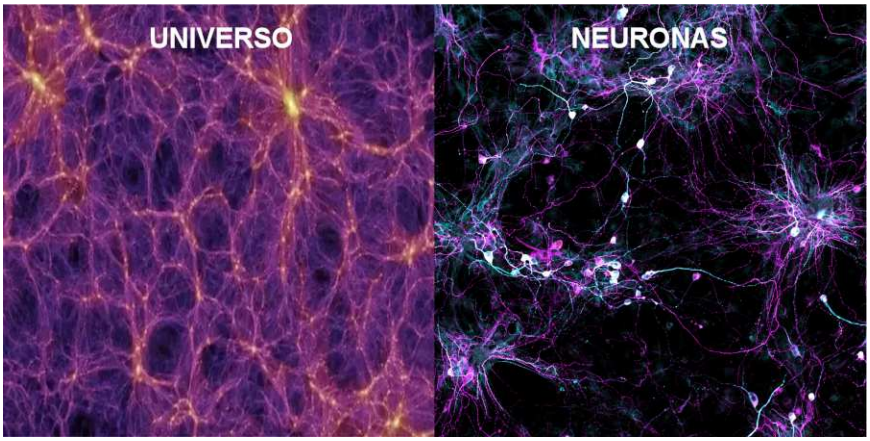
Ricardo Medel Esquivel es egresado de la Escuela Superior de Física y Matemáticas, actualmente cursa el Doctorado en Tecnología Avanzada en el Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada Unidad Legaria del Instituto Politécnico Nacional, donde desarrolla un proyecto sobre análisis de datos cosmológicos. Ha publicado libros de texto y otros materiales educativos de nivel Secundaria en Ediciones Castillo. En 2018 el IPN le otorgó el Diploma a la Cultura, en reconocimiento a algunos de sus trabajos literarios y de educación.



Ricardo García Salcedo es profesor titular en el Departamento de Física Educativa en el Centro de Investigación en Ciencia Aplicada y Tecnología Avanzada Unidad Legaria del Instituto Politécnico Nacional. Licenciado y maestro en Ciencias por la Universidad Autónoma del Estado de México, doctorado en Ciencias por el Depto. de Física del CINVESTAV-IPN. Su investigación se centra en la cosmología, especialmente los modelos de energía oscura y TIC en la enseñanza de la Física.



J. Alberto Vázquez es investigador del Instituto de Ciencias Físicas (ICF) de la UNAM. Previo a su incorporación al ICF, fue catedrático CONACYT asociado al CINVESTAV, IPN. Estancia postdoctoral en el Laboratorio Nacional Brookhaven, NY. Doctorado y Maestría otorgados por el Kavli Institute for Cosmology de la Universidad de Cambridge, UK. Su investigación se enfoca en la exploración y análisis de observaciones cosmológicas, en el estudio de modelos de Energía oscura e Inflacionarios, a través de la estadística Bayesiana y el computo científico.



"La vida y la mente tienen un patrón abstracto común o un conjunto de propiedades organizacionales básicas. Las propiedades funcionales características de la mente son una versión enriquecida de las propiedades funcionales que son fundamentales para la vida en general. La mente es literalmente realista."

—Godfrey-Smith, P. (1996). Complexity and the Function of Mind in Nature. *Cambridge University Press* —

© 2019 - Sociedad Mexicana de Inteligencia Artificial ISSN 2007-0691