



**Universidad Veracruzana**

Cuerpo Académico Investigación y Aplicaciones de la  
Inteligencia Artificial UV-CA-197

# **Memorias del 4.º Seminario** **de Aprendizaje Computacional**

**Centro de Investigación en Inteligencia Artificial**

**Cuerpo Académico: Investigación y Aplicaciones de la  
Inteligencia Artificial**

**4 y 5 de diciembre de 2018**

**Xalapa, Veracruz**

# CONTENIDO

<b>Introducción</b>	i
<b>Un modelo macroeconómico basado en agentes</b> Alejandro Platas-López	1
<b>Evaluación de desempeño de los Métodos de Monte Carlo para balanceo de clases</b> Reynaldo Domínguez Castillo	3
<b>Un estudio sobre evolución diferencial en optimización robusta sobre el tiempo</b> José Yair Guzmán Gaspar	5
<b>Caracterización de poblaciones nativas de frijol (<i>Phaseolus vulgaris L.</i>) utilizando aprendizaje automático sobre histogramas de color</b> José Luis Morales Reyes	7
<b>Algoritmos evolutivos para composición algorítmica emocional</b> Luis Enrique Contreras Varela	9
<b>Aprendizaje Automático aplicado a cálculos de estructura nuclear con interés astrofísico</b> Joel de Jesús Mendoza Temis	16
<b>Inducción de Árboles de Decisión usando Evolución Diferencial</b> Rafael Rivera López	19
<b>Evaluación de desempeño del operador do (set) del Algoritmo Pearl para determinar su nivel de precisión en la estimación causal</b> Jenny Betsabé Vázquez Aguirre	21
<b>Algoritmos Genéticos en Problemas de Programación de Tareas</b> Octavio Ramos Figueroa	23
<b>Estudio de la viralidad a través de una clasificación difusa de mensajes en Twitter</b> Omar Rodríguez López	25
<b>Metaheurística eficiente para optimización binivel</b> Jesús Adolfo Mejía de Dios	30
<b>Ayudando al medio ambiente con inteligencia artificial</b> Miguel Hidalgo Reyes	31
<b>Tendencia de los enfoques meméticos en problemas de optimización</b> Saúl Domínguez Isidro	33
<b>Generación automática de aplicaciones móviles usando técnicas de Inteligencia Artificial</b> Viviana Yarel Rosales-Morales	35

## Introducción

El Centro de Investigación en Inteligencia Artificial a través del Cuerpo Académico “Investigación y Aplicaciones de la Inteligencia Artificial” tiene el gusto de compartir las memorias del 4.º Seminario de Aprendizaje Computacional (SAC), que se llevó los días 4 y 5 de diciembre en el Centro de Investigación en Inteligencia Artificial de la Universidad Veracruzana. En el marco de dicho evento investigadores de reconocido prestigio nacional realizaron la exposición de sus conocimientos a través de conferencias y los alumnos de la maestría y el doctorado en Inteligencia Artificial presentaron los avances de sus proyectos de investigación.

Las memorias del SAC representan una oportunidad de dar a conocer algunas de las líneas de investigación que trabajamos en el CIIA a través de artículos de divulgación al alcance de todo público interesado en incursionar en el área de IA. Este documento incluye Esperamos despertar tu interés en el área, para más información no dudes es revisar las páginas:

<https://www.uv.mx/cia/>

<https://es-la.facebook.com/CIAUV/>

[https://www.youtube.com/channel/UCF\\_0zc4G2di9oWhbFzx3JJw](https://www.youtube.com/channel/UCF_0zc4G2di9oWhbFzx3JJw)

### ATENTAMENTE

Dr. Nicandro Cruz Ramírez

[ncruz@uv.mx](mailto:ncruz@uv.mx)

Dr. Héctor Gabriel Acosta Mesa

[heacosta@uv.mx](mailto:heacosta@uv.mx)

Dr. Alejandro Guerra Hernández

[aguerra@uv.mx](mailto:aguerra@uv.mx)

Dr. Guillermo de Jesús Hoyos Rivera

[ghoyos@uv.mx](mailto:ghoyos@uv.mx)

Dr. Efrén Mezura Montes

[emezura@uv.mx](mailto:emezura@uv.mx)

MIA. Carlos Rubén de la Mora Basáñez

[cdelamora@uv.mx](mailto:cdelamora@uv.mx)

MIA. Rocío Erandi Barrientos Martínez

[rbarriendos@uv.mx](mailto:rbarriendos@uv.mx)

Dra. Marcela Quiroz Castellanos

[maquiroz@uv.mx](mailto:maquiroz@uv.mx)



## Un modelo macroeconómico basado en agentes

Alejandro Platas-López

Centro de Investigación en Inteligencia Artificial

Universidad Veracruzana

[alejandroplatasl@gmail.com](mailto:alejandroplatasl@gmail.com)

¿Alguna vez escuchaste en los noticieros palabras como tasa de desempleo, inflación o Producto Interno Bruto (PIB)? ¿Sabes de donde salen esos indicadores? En general, son resultado de las relaciones cotidianas entre los agentes económicos que forman parte de la sociedad, tales como empresarios, familias, burócratas o banqueros.

Entender con precisión cómo una o varias acciones individuales afectan a toda la sociedad, vista esta como un sistema, es una tarea sumamente compleja, de ahí la necesidad de abstraer la realidad en modelos, definidos como una versión simplificada, pero útil, del mundo.

Es posible distinguir dos tipos de modelos macroeconómicos. El primer tipo de modelos es denominado de arriba hacia abajo (*o Modelos de Equilibrio General*) en el que algunos o todos los agentes económicos son capaces de comprender la “pintura completa” y usar esta información superior (dada a través de sistemas de ecuaciones y con supuestos de equilibrio) para determinar sus planes óptimos.

El segundo tipo de modelos se ha llamado de abajo hacia arriba (*o Modelos Basados en Agentes*) en el que todos los agentes experimentan limitaciones cognitivas, en otras palabras, no pueden ver la “pintura completa”. Como consecuencia, estos agentes sólo son capaces de comprender y utilizar pequeños fragmentos de información, y actúan usando reglas simples de comportamiento, de las cuales emerge un comportamiento agregado, en el que es compatible el equilibrio agregado con los desequilibrios individuales entre los agentes, reproduciendo la dinámica macroeconómica. Cabe destacar que este enfoque tiene sus raíces en la vertiente de trabajo de los *agentes inteligentes*, el estudio de agentes autónomos, que surge de la comunidad de la inteligencia artificial (IA). Que daría lugar a un nuevo campo de la IA denominado Sistemas Multi-Agente.

Puestos sobre la mesa los dos enfoques, nosotros, como agentes económicos, parte de una sociedad, debemos plantearnos algunas preguntas sensatas al respecto ¿Regimos nuestras decisiones económicas a través de ecuaciones? ¿Tenemos cognición completa del sistema económico? La respuesta más humana en ambos casos es no.

Por ello una representación para el análisis macroeconómico que va más acorde con la realidad (reglas individuales de conducta y estructuras de interacción que son consistentes con observaciones empíricas) es el enfoque de abajo hacia arriba, en el cual podemos codificar a nuestros agentes con tanta heterogeneidad como sea necesaria para guiar a los tomadores de decisiones y ayudarnos a pronosticar.

## Un modelo macroeconómico basado en agentes

Para plantearlo de una forma práctica, imaginemos una economía con tres tipos de agentes: familias que venden su mano de obra a cambio de un salario y que compran bienes con sus ahorros y/o su ingreso; empresas que compran mano de obra, ya sea con recursos propios y/o con préstamos bancarios, y que venden bienes; y finalmente bancos, que venden dinero a un precio que conocemos como tasa de interés.

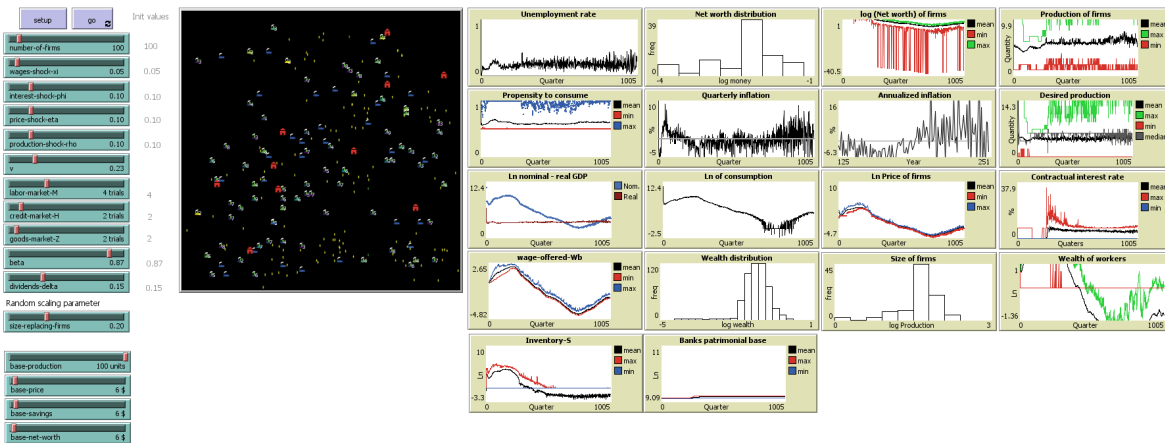


Figura 1. Resultados del modelo macroeconómico basado en agentes (enfoque de abajo hacia arriba).

Si codificamos algunas reglas de operación de los diferentes agentes y dejamos que interactúen durante un tiempo, obtendremos diferentes indicadores, como los que se muestran en la figura anterior. Por ejemplo, cambios en el precio de los bienes, lo que conocemos como inflación/deflación. También observaremos que no todas las familias logran prestar su mano de obra de manera continua a lo largo del tiempo, lo que da lugar a una tasa de desempleo. Y entre muchas otras variables más, nos daremos cuenta de que la producción de bienes no es constante, sino que tiene variaciones, por lo que comúnmente nos interesa conocer ese ritmo de crecimiento del PIB.

Si deseas conocer más acerca de los modelos basados en agentes, y de la emergencia de los indicadores macroeconómicos, te invito a buscar en la red: “Macroeconomics from the Bottom-up” y “Agent-based computational economics”.

## Evaluación de desempeño de los Métodos de Monte Carlo para balanceo de clases

Reynaldo Domínguez Castillo  
Centro de Investigación en Inteligencia Artificial  
Universidad Veracruzana  
[rdoguez@gmail.com](mailto:rdoguez@gmail.com)

Considere un problema en que se desea realizar una predicción; por ejemplo, predecir cuándo una persona es propensa a desarrollar diabetes. Para estudiar este problema como paso inicial es necesario realizar una recolección de datos que refleje las características de dos grupos, personas enfermas de diabetes y personas sanas, resulta relativamente sencillo construir un conjunto de datos en el que el 50% de las personas, sean enfermos con diabetes y el otro 50% sean personas que no están enfermas de diabetes.

A partir de este grupo de personas se extraen las características comunes que pueden reflejar cuando una persona padece o podría padecer diabetes y cuando una persona está o podría estar sana. Existen problemas en los que construir conjuntos de datos en los que la proporción de individuos sea equitativa no es mayor complicación. Sin embargo hay problemas en los que no es posible obtener grupos que estén distribuidos proporcionalmente, ejemplo de ello son las enfermedades que no son comunes, como los distintos tipos de cáncer. Resultaría muy complicado formar un grupo en el que existan 1000 personas con un tipo de cáncer y 1000 personas sanas. En el primer tipo de problema -diabetes- es posible contar con una base de datos en la que los individuos están distribuidos proporcionalmente respecto a la variable respuesta -si presenta o no la enfermedad-, el segundo problema -algún tipo de cáncer- es muy complicado que suceda lo mismo. Incluso la mayoría de las ocasiones en las que se construyen conjuntos de datos en enfermedades con características similares al cáncer, son casos en los que hay un 5 o 10% de personas enfermas contra un 95 o 90% de personas sanas.

Obtener un conjunto de datos para luego realizar predicción o inferencia de éste, es un problema que regularmente se relaciona con minería de datos o aprendizaje computacional, posiblemente estas sean de las áreas más conocidas de la Inteligencia Artificial.

Muchos de los problemas afines con minería de datos están relacionados con aprender o inferir, información o patrones a partir de un conjunto de datos, como los mencionados en los párrafos anteriores. Regularmente se construye un conjunto de datos que describe el problema que se desea estudiar, con estos datos se entrena un modelo el cual posteriormente es usado para en algunos casos clasificar nuevas observaciones del problema que se está estudiando.

La parte central de los problemas de minería de datos radica en contar con un buen conjunto de datos de entrenamiento. Si bien el aprendizaje supervisado no es la única forma de resolver problemas de minería de datos, esta es una de las

técnicas más usada para tratar estos problemas. La teoría asegura que los algoritmos de aprendizaje supervisado funcionan de manera correcta cuando los datos del problema que se desea estudiar están balanceados respecto a la variable respuesta, como en el ejemplo de la diabetes, en problemas como el de cáncer en que la distribución de los datos respecto a la variable respuesta no es proporcional, los resultados que se obtienen son malos para clasificar observaciones nuevas del colectivo minoritario.

La complicación para trabajar bases de datos no balanceadas radica en que los algoritmos de minería de datos no aprenden suficiente del colectivo minoritario. Como propuesta para resolver este problema se plantea probar un método de simulación, conocido como Gibbs Sampler, para generar datos artificiales del colectivo minoritario. Se plantea como método de generación Gibbs Sampler pues la teoría detrás de éste plantea que es una técnica de simulación en la que la distribución de los datos generados va a estar muy cerca de los datos originales.

Si bien existen diferentes técnicas o métodos para abordar el problema, la generación de datos artificiales es la más usada por lo simple que resulta realizarla. En la literatura existen distintos métodos para generar datos artificiales, sin embargo, ninguno de ellos garantiza un correcto funcionamiento en la mayoría de las situaciones, ni tiene un fundamento formal para usar estos métodos.

## Un estudio sobre evolución diferencial en optimización robusta sobre el tiempo

MCA José Yair Guzmán Gaspar  
Centro de Investigación en Inteligencia Artificial  
Universidad Veracruzana  
[yairguz@gmail.com](mailto:yairguz@gmail.com)

El ser humano, a través del tiempo, se ha enfrentado a diversos problemas para los que ha tenido que decidir entre diferentes maneras de encontrar una solución que satisfaga sus necesidades. Cuando se realiza esta toma de decisiones, por lo general, se trata de encontrar la mejor solución entre diversas posibles soluciones. Buscar la mejor solución entre un conjunto de soluciones que pueden ser tomadas se le llama *problema de optimización*.

Los problemas de optimización pueden ser encontrados en la ciencia, la tecnología y también en la vida cotidiana; un estacionamiento trata de acomodar los vehículos de tal manera que puedan estacionarse la mayor cantidad de vehículos, un inversionista podría tratar de maximizar las ganancias disminuyendo costos de producción, un ingeniero podría tratar de encontrar el mejor diseño de una herramienta en particular que se encuentre desarrollando.

Muchas veces, encontrar una buena solución se puede volver compleja cuando existe gran incertidumbre en el ambiente del problema que se trata de resolver; por ejemplo, para construir un puente sobre un río se debería tomar en cuenta los niveles máximos históricos a los que ha llegado el río, ya que de no hacerlo se correría un gran riesgo en épocas de lluvia. Otro ejemplo se podría ver cuando se trata de colocar las celdas solares, donde para su posicionamiento, existen diversos factores naturales a considerar. Para afrontar estos problemas con incertidumbre surge la optimización robusta, la cual busca encontrar una solución que se mantenga aceptable en presencia de ellas.

Para poder encontrar soluciones a problemas de optimización, la optimización o programación matemática trata de maximizar o minimizar una función real, tomando en cuenta las restricciones propias del problema. Diversos estudios se han llevado a cabo para resolver problemas de optimización, algunos de ellos son la optimización clásica por métodos analíticos, la programación lineal y los métodos de Khun-Thucker. Algunos problemas pueden ser muy complejos, y el tratar de resolverlos por métodos analíticos puede llevar mucho tiempo o incluso podrían resultar imposibles; sin embargo, otra manera de resolverlos es mediante métodos estocásticos, por medio de ellos se pueden encontrar aproximaciones a soluciones óptimas de problemas complejos, e incluso se puede llegar a encontrar los óptimos globales en muchos de ellos.

Los algoritmos evolutivos son métodos estocásticos dentro de los cuales se encuentra la evolución diferencial ED. La ED está basada en analogías de la



teoría de la evolución, donde a través de generaciones una población va adaptándose al ambiente en el que habita, mejorando así sus capacidades.

Existe otro tipo de problemas llamado problema de optimización dinámica donde el ambiente es cambiante a través del tiempo, esto quiere decir que el problema que tenemos que resolver depende del instante en el que estemos tratando de buscar la respuesta. Para ejemplificar este caso, imaginemos el almacén de una tienda departamental el cual debe mantener un cierto stock de tal forma que pueda abastecer las ventas que se realicen, pero sin tener una cantidad exagerada ya que esto podría causar depreciación de productos o tal vez los productos perecederos podrían no llegar a ser vendidos. Para ello se necesita tener la cantidad suficiente conforme se vayan vendiendo los productos.

Un enfoque utilizado para resolver este problema del almacén es optimizar la cantidad de productos para tener en todo momento un equilibrio en el stock. Mantener siempre la cantidad óptima de productos cada vez que los requerimientos de las ventas cambian es un ejemplo de resolución de problemas mediante un método llamado "Seguimiento Óptimo de Movimiento" (TMO por sus siglas en inglés), el cual, como su nombre lo indica, busca una solución cada vez que el ambiente cambia. Sin embargo, hacer los cambios necesarios para mantenerse siempre en un estado óptimo no siempre es posible, ya que los costos para implementarlo pueden ser altos, o incluso cuando se termine de implementar la solución, el ambiente podría haber cambiado nuevamente.

Dado los problemas que conlleva el implementar una solución cada vez que el ambiente cambia, surge una nueva manera de abordar los problemas dinámicos, lo que propone es encontrar una solución con calidad aceptable durante tantos ambientes como sea posible. Esta nueva forma de búsqueda de soluciones recibe el nombre de Optimización Robusta sobre el Tiempo (ROOT por sus siglas en inglés). Un ejemplo sería si imaginamos un problema de posicionamiento de paneles solares, podría ser conveniente ubicar las celdas solares de tal manera que permita una buena captación de luz el mayor tiempo posible, sin que se tenga que cambiar su posición cada vez.

La evolución diferencial ha sido estudiada ampliamente en TMO, y se ha probado su eficacia en encontrar soluciones en estos ambientes. Actualmente no existen registros de su comportamiento en problemas ROOT, pero pensamos que dado su buen desempeño en problemas TMO, podría ser capaz de tener un buen comportamiento en ambientes ROOT. Es por ello que se está realizando un estudio de la evolución diferencial para conocer su capacidad de encontrar soluciones robustas sobre el tiempo.

## **Caracterización de poblaciones nativas de frijol (*Phaseolus vulgaris* L.) utilizando aprendizaje automático sobre histogramas de color**

MIA. José Luis Morales Reyes

Centro de Investigación en Inteligencia Artificial

Universidad Veracruzana

[jluismorey@hotmail.com](mailto:jluismorey@hotmail.com)

México es el centro de origen del frijol, ¿Sabías que hay gran diversidad de variedades de frijol?, Algunas se cultivan para su comercialización a gran escala como las variedades que nos encontramos en mercados y supermercados, también, están conformadas por granos de similares características en color y forma. Por otro lado, las poblaciones nativas de frijol son un tipo de variedad local criolla que ha sido preservada de generación en generación para el consumo particular del agricultor siendo su principal fuente de alimentación.

Las poblaciones nativas de frijol no necesariamente están conformadas por granos de similares características, están se presentan con granos de distintos colores siendo heterogéneas.

La importancia del frijol radica en ser la base de la alimentación mexicana, es rica en nutrientes benéficos para la salud al contener proteínas, carbohidratos, vitaminas, fibra, entre otros compuestos antioxidantes benéficos para la salud.

El color es una propiedad física que presentan los granos de frijol, además, es utilizado para su clasificación. Una técnica adoptada para caracterizar el color es utilizando un espectrofotómetro, el cual es un equipo de laboratorio con una abertura de 8 mm donde se coloca el objeto a medir, el equipo solo obtiene el valor de una medición puntual justo en el lugar donde incide el haz de luz que emite para realizar la medición.

La limitación que presenta es que en la medición reporta una mínima muestra de color de la superficie del grano, para tratar de cubrir esa limitante el especialista tiene que realizar varias mediciones sobre el mismo grano, además, observando cuidadosamente el frijol que parece de un único tono de color contiene gran diversidad de tonos de color similares, imagínate la cantidad de tonos que presenta un grano de dos colores con pigmentos de otro color, no siendo suficiente, imagina lo que podrías obtener de una población conformada por granos de distintos colores. Te estarás preguntado ¿Cómo obtener todos esto patrones de color que presenta el grano? Con una cámara fotográfica configurada adecuadamente podrás adquirir imágenes con suficiente nitidez para capturar los patrones de color del grano de frijol.

Con la diversidad de poblaciones de frijol que existen es necesario disponer de una herramienta que nos ayude a clasificar utilizando la coloración. Si deseamos realizar una clasificación automática de poblaciones de frijol utilizando su coloración tendremos que hacer uso del procesamiento de imágenes digitales y aprendizaje automático, estas técnicas son relativas a la Inteligencia Artificial.

Caracterización de poblaciones nativas de frijol (*Phaseolus vulgaris* L.) utilizando aprendizaje automático sobre histogramas de color

Para diseñar un método será necesario preparar el sistema de visión automático y para tal fin, disponer de un entorno de iluminación controlado que brinde la iluminación necesaria para poder visualizar los patrones de color en los granos de frijol, de igual importancia, será necesario tratar la reducción del brillo de algunas poblaciones.

La cámara fotográfica que servirá para obtener las imágenes de las poblaciones de frijol deberá ser configurada para estandarizar la adquisición, por otra parte, una vez realizada la adquisición debemos proceder con el procesamiento de la imagen digital.

Los algoritmos de segmentación son herramientas que nos permiten separar objetos de interés y que resultan útiles al momento de excluir la información no relevante. Para la segmentación el algoritmo de crecimiento de región basado en color es adecuado para separar el fondo de los granos de frijol, este algoritmo recibe un pixel semilla y busca en la imagen los pixeles similares creciendo por las áreas donde se mantiene las mismas características.

Del color de la imagen digital de los granos de frijol es necesario realizar una representación que permita contener los pixeles obtenidos de una imagen. Una imagen digital puede ser representada como un histograma formado por los distintos valores que contiene la imagen, por lo tanto, de los patrones de color que obtenemos de los granos podemos formar histogramas con las frecuencias de los valores de los pixeles en 2 y 3 dimensiones, de esta forma, contenemos la información útil que ayudará a caracterizar a cada población de frijol.

Con la información obtenida necesitamos realizar la caracterización por color de las poblaciones de frijol, ahora los patrones de color expresados con histogramas podrán ser utilizados en el entrenamiento de algún algoritmo de aprendizaje automático supervisado, para identificar es necesario disponer de un conjunto de etiquetas que permita hacer referencia de las poblaciones.

Un algoritmo de aprendizaje supervisado que podemos implementar para la clasificación es k vecinos cercanos, su funcionamiento es el siguiente: para entrenarlo tendremos que proporcionarle el conjunto de histogramas relativos a las poblaciones de frijol junto con sus etiquetas descriptivas, luego, utilizando una métrica para medir la similitud el algoritmo realizará una comparación del nuevo ejemplo contra todos los ejemplos de referencia para escoger el histograma con mayor similitud, al finalizar asigna la etiqueta del histograma de la población que contiene similares características colorimétricas, de tal forma, que este procedimiento nos ayudará a clasificar automáticamente un nuevo ejemplo de población de frijol.

Te gusto el breve recorrido que nos llevo al proceso de clasificación automática, puedes obtener más información en el Centro de Investigación en Inteligencia Artificial de la Universidad Veracruzana o escribir al correo que aparece al principio del documento.

## Algoritmos evolutivos para composición algorítmica emocional

Luis Enrique Contreras Varela  
Centro de Investigación en Inteligencia Artificial  
Universidad Veracruzana  
[luisenrique.contreras.v@gmail.com](mailto:luisenrique.contreras.v@gmail.com)

La música es una de las actividades humanas más especiales, capaz de transportarnos a vívidas memorias con tan solo unas notas, es innegable su presencia en distintos aspectos de la vida. Una idea bastante arraigada que tenemos respecto a la música nos sugiere que para producir una pieza musical digna de ser escuchada, el compositor debe contar con una sensibilidad privilegiada, y quizás también, correr con la suerte de ser tocado con la varita mágica de la inspiración. Sin embargo, la visión anterior es tan solo una cara de la moneda, desde hace siglos los compositores han sabido tomar ventaja del pensamiento formal para elaborar música original en diferentes estilos y estéticas, causante de opiniones diversas en el público desde sus inicios.

### Pensamiento algorítmico en la historia de la música

Ya en tiempos medievales, donde la música era tarea de corte eclesiástico, se observan acercamientos a la composición algorítmica. En el siglo X, el monje Guido de Arezzo describe un método para la generación de melodías a partir de poemas. Más tarde, aparecerían máquinas mecánicas como el *Arca Musarithmica*, compuesta de palos de madera grabados con notas y figuras rítmicas. Dichas máquinas eran capaces de producir composiciones polifónicas simples sin necesidad de mucha intervención humana. Incluso a algunos de los compositores clásicos más famosos, como Bach y Mozart, se les atribuyen composiciones que se apoyan de métodos matemáticos, aleatorios y secuenciales. Después de la segunda guerra mundial, un estilo totalmente nuevo que rompió con toda convención se gestó en la escena musical, el serialismo. A pesar de su aparente complejidad, las piezas serialistas debían cumplir con una regla simple: tocar cada una de las 12 notas del sistema musical occidental (las teclas negras y blancas en una octava del piano) antes de poder repetir una nota.

### Primeras composiciones algorítmicas

Si bien, se aprecia el pensamiento algorítmico en los trabajos antes mencionados, no fue hasta 1956 que se aplicaron programas de computadora para obtener una composición musical. La *Illiad Suite* de Lejaren Hiller fue la primera pieza compuesta por un programa de computadora. En específico, en el cuarto movimiento se usó una tabla que definía la probabilidad de seleccionar una nota de acuerdo a la secuencia de notas anteriores. Posteriormente se crearían herramientas de software como el *Stochastic Music Programme* o *MUSICOMP*, permitiendo a los compositores generar fragmentos musicales usando subrutinas de estas herramientas. Algunos de los compositores contemporáneos, como John Cage o Iannis Xenakis, veían en la composición algorítmica oportunidades para crear experiencias artísticas posibles solo en sueños distantes.

## Inteligencia artificial, el paso siguiente

En los años posteriores, la composición algorítmica crecería hasta llegar a otras esferas del conocimiento, encontrando nuevos adeptos fuera de la academia musical. El interés que presenta la inteligencia artificial (IA) en la composición musical, al haber emulado con cierto grado de éxito otras actividades humanas difíciles, como jugar ajedrez, resumir un texto o conducir un auto, es simplemente el paso natural después de recibir a las computadoras en la labor composicional.

Las expectativas puestas en la IA permiten soñar en crear un compositor virtual que pueda cautivarnos en la misma medida que lo haría alguno de los grandes maestros, o si de imaginar se trata, que pudiese generar la partitura de una sinfonía elaborada específicamente para cada persona; considerando el estado emocional, las preferencias musicales y demás datos disponibles.

A pesar de que aún estamos lejos de escuchar en la radio canciones escritas por nuestro algoritmo favorito, diferentes técnicas de IA se han aplicado para generar sistemas de composición automática que, a pesar de sus limitaciones, han conseguido producir melodías capaces de engañar a más de uno.

## Representación musical en los sistemas de composición

Ahora bien, si quisiéramos construir nuestro propio algoritmo compositor hay un par de cuestiones esenciales que esclarecer. Lo primero es determinar qué se espera como resultado final, en otras palabras, ¿Queremos encontrar el acompañamiento adecuado a una melodía ya definida? ¿Una composición que pertenezca a un género o estilo en particular? ¿Tal vez un sistema improvisador de solos?

Después de determinar la salida esperada de nuestro sistema de composición, el siguiente paso consiste seleccionar los elementos musicales que deberían considerarse y cómo se van a representar en el sistema, de manera que éste pueda manipularlos. A la codificación de los elementos musicales en el sistema se le conoce como representación. Una forma de representación podría únicamente incluir la información melódica y rítmica, equivalente a las partes más importantes de una partitura, aunque podría indicar el timbre y los efectos que deben ser aplicados al interpretar la composición. En el caso de este trabajo y de muchos otros sistemas, se hace énfasis en la composición y no en la ejecución de la música generada.

La representación de un compás musical podría definirse a través de un arreglo finito de números enteros, donde las posiciones del arreglo sean análogas a momentos consecutivos en el tiempo y los valores señalen si se debe tocar una nota o guardar silencio por ese periodo. En un ejemplo simple, usando una representación como la anterior, el arreglo  $[5,7,9,5]$  puede traducirse en 4 notas consecutivas con las notas *Fa*, *Sol*, *La* y *Fa*, o lo que es lo mismo, las primeras notas de la famosa canción infantil *Martinillo*.

## ¿Cómo sabe el sistema compositor si su música es buena?

Una vez seleccionados los elementos musicales disponibles para nuestro algoritmo hemos acotado el conjunto de resultados posible. En este punto nuestro hipotético sistema compositor sabe qué es lo que esperamos recibir, y en principio, podría producir cualquiera de las piezas posibles usando una representación como la antes mencionada, pero, ¿Cómo hará el sistema para reconocer si las melodías que genera son buenas? Es necesario definir bajo qué criterios el algoritmo determinará la calidad de sus composiciones. Dicho de otro modo, cómo desarrollar un operador que compare una pieza musical *A* con otra pieza musical *B* y siempre seleccione la mejor. A cuestionamientos como el anterior se les conoce como juicios estéticos, y de acuerdo a Kant, son por definición subjetivos.

A pesar de no poder determinar de forma absoluta si una melodía es mejor que otra del mismo modo que podemos medir otras magnitudes, como la distancia o la temperatura, los trabajos en composición algorítmica han optado por alguna, o combinaciones, de las siguientes estrategias para la evaluación: usar valoración humana, aprender automáticamente de ejemplos, o bien, a través de reglas que definan la validez y la calidad de las composiciones.

### Evaluación interactiva humano-sistema

La primera opción reconoce que automatizar el “buen gusto” es una tarea muy complicada y dirige la vista a la habilidad de las personas para calificar una obra, método de evaluación vigente en el mundo del arte. El sistema le presenta al evaluador fragmentos de las piezas generadas para que éste les asigne una calificación. De este modo, el sistema puede encontrar patrones en las composiciones cuya calificación haya sido sobresaliente, y usarlos para asemejarse cada vez más a la música que produjo dichos patrones. A esta forma de evaluación se le conoce como evaluación interactiva. Desafortunadamente existen algunos problemas al decantarse por este enfoque, por un lado, la mayoría de las personas no tendría problema en escuchar atentamente un par de canciones y dar su opinión. Pero si se necesitara evaluar las composiciones en cada paso del sistema o si los avances llegasen después de muchas piezas calificadas, muy pocas personas estarían dispuestas a escuchar cientos de composiciones poco musicales y posiblemente desagradables (al menos en un comienzo).

### Aprender de la buena música, aprendizaje automático

La siguiente alternativa para calificar la salida de un sistema de composición automática es a través de una de las metodologías de la IA más importantes, el aprendizaje automático, donde a partir de un conjunto de datos es posible obtener modelos que generalicen la distribución de probabilidad del fenómeno estudiado, y así, hacer predicciones del futuro usando el modelo que se obtuvo de los datos. En el contexto musical el conjunto de datos se convierte en una colección de

melodías existentes, comúnmente de un mismo estilo o compositor, que sirven de estética objetivo para crear composiciones que se asemejen a las piezas musicales del conjunto de entrenamiento.

Los sistemas que aplican aprendizaje automático, especialmente las redes neuronales, han llamado la atención por su capacidad de generar música en el estilo de nuestros compositores favoritos; diversos trabajos han conseguido replicar con un parecido considerable los hábitos musicales de Bach o Charlie Parker, entre otros. A pesar del reconocimiento recibido, la pertinencia de usar como metodología imitar el trabajo otros músicos y llamar a eso composición es debatible: ¿De qué sirve replicar el trabajo de cualquiera de estos personajes si ya contamos con su obra para deleitarnos? Si tan solo el hecho de construir sistemas que generen arte ya es en sí mismo cuestionable, es evidente que con solo “copiar” de los grandes será complicado llegar al compositor virtual que se planteó algunos párrafos antes.

### Evaluación de calidad basada en reglas e indicadores

Finalmente, la otra manera que existe para determinar la calidad de una composición musical es a través de reglas que describan las características que debería presentar una buena composición. Pequeño problemón el encontrar un conjunto de reglas que sirvan como receta de cocina para elaborar música agradable, o al menos interesante. Tan es así que muchas estrategias para definir el conjunto de reglas han sido probadas.

Para comenzar es importante destacar que hay muchas formas de definir las reglas que de manera muy general podrían resumirse en dos grupos: Una vía es elaborarlas de forma que el seguimiento de las reglas defina la construcción de nuevas piezas musicales. Bajo este enfoque se encuentran métodos como la elaboración de gramáticas, cuyas reglas de sustitución pueden ser aplicadas sucesivamente para obtener nuevas melodías, o bien, podríamos definir la composición musical como un problema de satisfacción de restricciones, de forma que solo las composiciones que cumplen con dichas restricciones son tomadas en cuenta.

La segunda opción requiere cuantificar diversos elementos en las composiciones, como el tipo de intervalos (separación entre dos notas contiguas), la variedad en las figuras rítmicas o las notas, etc. Después de conseguir las puntuaciones específicas para cada indicador, la calidad de las piezas musicales generadas por el sistema se asigna en función de la proximidad de los puntos obtenidos a valores específicos. La regla es mientras más cercanos sean los valores de una pieza a los valores objetivos, mejor es la composición. Esta información puede ser integrada para producir progresivamente melodías con mejores calificaciones, dicho de otro modo, que la calificación de las piezas producidas por el sistema sea vista como una función a optimizar.



## Evolucionar melodías, una idea interesante

Siguiendo la segunda alternativa, al considerar la composición musical como una tarea que se puede optimizar, los algoritmos evolutivos aparecen como una opción atractiva que ha conseguido ser (junto con las redes neuronales) una de las técnicas más usadas para composición automática. Este tipo de algoritmos está inspirado en el proceso de evolución de las especies que planteó Darwin, una idea bastante razonable si se considera que es un método con éxito probado por millones de años.

Un algoritmo evolutivo presenta una analogía entre la evolución y un proceso de optimización: De manera muy superficial, la teoría de la evolución plantea que los individuos en un ecosistema compiten entre ellos por sobrevivir y reproducirse. Donde, en principio, solo los más aptos alcanzarán dichos objetivos. En el caso de los algoritmos evolutivos se trabaja con una población de soluciones a un problema de optimización, cuyos individuos virtuales también pretenden sobrevivir y dejar descendencia (en vez de reproducción sexual los individuos tienen un intercambio aleatorio de bits). Al igual que en los procesos naturales de evolución, las peores soluciones al problema en la población perecerán y nuevos individuos ocuparán su lugar. En ambos casos, las modificaciones genéticas y la supervivencia de los más aptos, dará lugar a individuos cada vez más fuertes en su respectivo entorno.

Al usar un algoritmo evolutivo para composición musical, una población de piezas musicales es generada de manera aleatoria. En un comienzo las composiciones en la población son considerablemente desagradables, sin embargo, la calidad de las melodías mejorará progresivamente. Conforme las melodías mutan y se combinan entre ellas, resultando en fragmentos musicales con notas y ritmos diferentes, estas son evaluadas usando una función de calidad, cuyo resultado dictamina las posibilidades de que las características de las mejores melodías permanezcan en la población a través de sus descendientes.

## Nuestra propuesta, un algoritmo evolutivo creador de melodías

En este contexto y después de sondear otros enfoques, nuestra propuesta para composición algorítmica se decantó por usar algoritmos evolutivos. La tarea es producir melodías monofónicas de corta duración. En específico, nuestro sistema implementa un algoritmo evolutivo multi-objetivo, donde no solo existe una función de calidad sino un conjunto de ellas que debe ser optimizado simultáneamente.

Hasta el momento dos esquemas para la valoración de las piezas han sido implementados: El primer método de calificación está basado en la ley de potencia de Zipf, la cual describe la relación entre la frecuencia de los eventos de un fenómeno y su puesto en el ranking de frecuencias. En un fenómeno *zipfiano* el evento más frecuente ocurre dos veces más que el segundo evento más frecuente, tres veces más que el tercero, cuatro que el cuarto, y así sucesivamente. En la música es común que los intervalos musicales consonantes



(aquellos que son más agradables al oído) aparezcan más a menudo que los disonantes, o también que algunas notas sean tocadas más veces que otras. Algunos trabajos evaluaron diversos eventos musicales y encontraron que la música de varios compositores clásicos presenta distribuciones zipfianas. Para este esquema de evaluación, nuestro sistema considera tres indicadores basados en la regla de potencia de Zipf: el ajuste zipfiano de las notas presentes en la composición, las figuras rítmicas y los intervalos melódicos.

La segunda alternativa para determinar la calidad de las composiciones es a través de la cuantificación de un conjunto de buenas prácticas que se enseña a los estudiantes de música, evaluadas estadísticamente en un corpus misceláneo, en el que se incluyen piezas clásicas de Bach, Mozart y Beethoven; composiciones medievales y algunas canciones de cuna. Un subconjunto de los indicadores descritos por los autores en el estudio fue contemplado para definir las funciones objetivo a optimizar por el algoritmo evolutivo. En específico se evalúa la densidad de notas y silencios (el índice de notas tocadas durante un periodo de tiempo), el nivel de síncope (estrategia musical para hacer énfasis en tiempos inesperados, muy relacionada con el baile), la tasa de consonancia/disonancia en los intervalos y la tasa de notas fuera de la tonalidad (considerando como tonalidad aquella que minimiza el valor de dicha tasa). La selección de estos indicadores, con representación de componentes rítmicos y tonales, permite describir el problema de composición como minimizar la distancia entre el valor de cada medición a los valores objetivo en todos los indicadores. Por ejemplo, al fijar el valor objetivo del ajuste a la tonalidad en 0, después de cada generación, los individuos de la población reducirán dicho valor, resultando en melodías cada vez menos chocantes al oído que aquellas que incluían notas que causaban disonancias en las generaciones pasadas.

### ¿Y dónde queda la emoción?

Las melodías generadas por nuestro sistema utilizando ambos esquemas de evaluación presentan características musicales deseables y resultan agradables hasta cierto punto (especialmente con el segundo enfoque, usando los indicadores melódicos) pero distan de causar grandes impresiones. Estos resultados nos recuerdan claramente que la música compuesta por humanos casi siempre tiene una carga emocional muy fuerte, a diferencia de las melodías (“sin alma”) que producen los sistemas, ¿Qué tal si incluimos el factor emocional en el modelado de los sistemas? en caso de conseguirlo podríamos utilizar la emoción como uno de los parámetros principales. En ese escenario sería posible pedir a los nuevos sistemas de composición automática, con habilidades emocionales, hacernos “una canción melancólica para contemplar el atardecer” o tal vez “algo enérgico y motivador para hacer ejercicio”.

Respecto a lo anterior, se han desarrollado algunas propuestas de sistemas que generen música que expresa cierta emoción, así como análisis emocional de bases de datos de música. Las estrategias son análogas a las descritas para la

evaluación de la calidad musical, puesto que la emoción es otro elemento considerablemente subjetivo.

Poder medir la emoción en una composición es atractivo también fuera de la academia, empresas dedicadas al streaming de música, como Spotify, trabajan en modelos de emoción en la música, requisito para elaborar listas de reproducción basadas en la emoción.

Actualmente se trabaja en modificar el esquema de evaluación, usando un modelo de emoción musical que define un plano emocional de dos dimensiones: la *valencia*, indica qué tan positiva o negativa es la pieza, y la *estimulación*, la cual mide la energía de la composición, de la calma a la sorpresa. Con ese modelo de emociones se pretende construir un nuevo esquema de evaluación que permita crear composiciones que expresen una emoción en particular, y por qué no, en un futuro permitir al usuario interactuar con el sistema para ser coautor de las melodías producidas.

## Conclusiones

La composición algorítmica, independientemente de sus resultados actuales y las posibilidades que tiene de ser tomada en cuenta como arte válido, resulta ser un buen ejemplo del papel que tiene la inteligencia artificial en nuestra vida diaria. Tomando una de las características más humanas, la creatividad, como caso de estudio; en este caso enfocándose en la música (la composición algorítmica es solo una rama de un área más grande, conocida como creatividad computacional). La IA cuestiona nuestro entendimiento de la creatividad y otros elementos de la condición humana. La creación de música hecha con algoritmos sigue estando en pañales, pero a su corta edad ya nos hace cuestionamientos interesantes... Y, a fin de cuentas, ¡no suena tan mal!

## **Aprendizaje Automático aplicado a cálculos de estructura nuclear con interés astrofísico**

Dr. Joel de Jesús Mendoza Temis  
Facultad de Física  
Universidad Veracruzana  
[joemendoza@uv.mx](mailto:joemendoza@uv.mx)

Sin duda alguna, una de las preguntas más interesantes que la ciencia aun no ha sido capaz de responder por completo es ¿Cómo produce la naturaleza sus elementos?, y en particular, ¿Cuál es el origen de los elementos más allá del Hierro, los denominados metales pesados (Heavy Metals \m/)?.


Para contarles bien esta historia, les propongo el siguiente experimento pensado (Gedankenexperiment), imaginen por un momento que se encuentran en el dominio del universo microscópico, allá donde las leyes de la mecánica cuántica rigen todo lo que ocurre, ahora bien, digamos que deciden pesar un racimo de uvas (en esta analogía, esto equivaldría a pesar un núcleo), posteriormente se les ocurre volver a pesar el mismo racimo, pero esta vez en sus uvas y el tallo por separado (en esta analogía, equivaldría a pesar a los protones y los neutrones que componen un núcleo), el resultado de estas mediciones, estimados lectores es que sorprendentemente la masa de este racimo de uvas (un núcleo) es mas ligera que la suma de sus constituyentes por separado (neutrones y protones), a esta propiedad del universo microscópico se le denomina "defecto de masa", y debido a la ecuación más famosa en la física,  $E=mc^2$ , se traduce en la fuente de energía en las estrellas.

De tal forma que el conocimiento de las masas nucleares es fundamental para cálculos de interés astrofísico como por ejemplo entender la evolución estelar y con ello responder la pregunta planteada en el principio de este manuscrito, pero ¿Acaso este el final de nuestra historia?, la respuesta es no, esto último no es del todo cierto, así que permítanme exponerles brevemente cual es el estado del arte en el campo de la astrofísica nuclear, se sabe que los procesos nucleares que dan origen a la energía radiada por las estrellas, en particular estrellas con masas superiores a 8 masas solares son responsables del origen (nucleosíntesis) de los elementos hasta el Hierro y el Níquel; se especula que los procesos de captura de partículas -donde por partículas me refiero a: electrones, protones, neutrones y algunos núcleos ligeros- son responsables del origen de los elementos más exóticos que existen en la naturaleza.

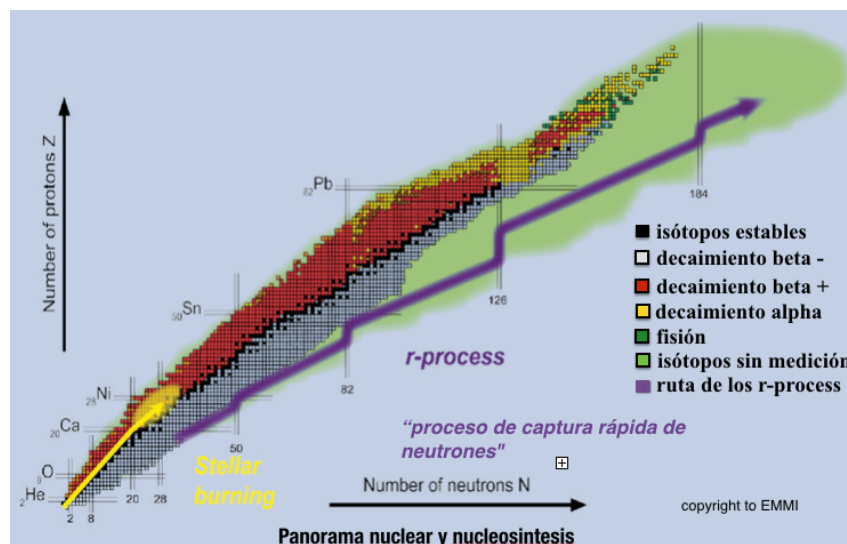
Es tiempo de platicarles en que consiste mi chamba; la investigación que yo efectuó trata de responder un par de preguntas igualmente interesantes, ¿Cuál es la probabilidad de que alguna reacción nuclear ocurra en ambientes astrofísicos extremos? y ¿Cuál es la generación de energía debida a todas las reacciones nucleares en ambientes astrofísicos extremos?. En particular, he explorado los procesos de captura rápida de neutrones (los denominados r-process), los cuales son responsables de la producción (Nucleosíntesis) de alrededor de la mitad de

los núcleos que existen en la naturaleza. Sin embargo, entender la física detrás de estos procesos no es un problema fácil, esto es porque los r-process:

- 1) Tienen lugar en escenarios astrofísicos extremos, que involucran materia eyectada muy rica en neutrones, procedente ya sea de una estrella de neutrones tras un evento de supernova, o de la fusión de un par de estrellas de neutrones<sup>1</sup> (ver representación artística).



- 2) Involucran núcleos muy exóticos que no han podido ser medidos experimentalmente, puesto que decaen muy rápido (viven billonésimas de segundo) o simplemente no es posible producirlos en el laboratorio, consecuentemente debemos hacer uso de modelos teóricos. Para ilustrarles lo complicado de la situación les invito a ver la figura de abajo, en la cual les muestro el denominado panorama nuclear (una representación en función del numero de neutrones  $N$  y el numero de protones  $Z$ , de todos los isótopos que nuestros modelos teóricos predicen que existen en la naturaleza).




- 3) Requieren simulaciones numéricas muy costosas (una red que incluye del orden 135000 reacciones nucleares en las que participan 9000 núcleos).

<sup>1</sup> Como nota para los lectores interesados, el 17 de Agosto de 2017, se detectaron las ondas gravitacionales procedentes de la fusión de un par de estrellas de neutrones, no solo eso, también se midieron las curvas de luz, y se estimó que en un solo

Ahora bien después de tanto choro mareador, se preguntarán, ¿Que tiene que ver todo esto con la Inteligencia Artificial y el Aprendizaje maquina?. Resulta que como indique con anterioridad, uno de los requisitos fundamentales para modelar dichos procesos son las masas nucleares de núcleos muy exóticos, la primera alternativa debería ser resolver el denominado "problema de muchos cuerpos usando la mecánica cuántica" pero resulta que no es posible resolver analíticamente mas allá del problema de tres cuerpos, se pueden efectuar simulaciones numéricas pero conforme se van agregando mas partículas el problema se hace mas complicado e inclusive imposible de resolver, así que esta no es una buena estrategia a seguir, otra alternativa, seria hacer uso de las herramientas de la mecánica estadística, lamentablemente el núcleo es un sistema con relativamente pocas partículas (por ejemplo un núcleo como el  $^{238}\text{U}$ , tiene 238 nucleones) consecuentemente las propiedades medias de los nucleones de los que está compuesto un núcleo no bastan para una buena descripción. Es así mis estimados lectores, que el problema las masas nucleares esta situado inconvenientemente en medio.

Con el paso del tiempo, nos hemos dado cuenta que nuestro problema, pertenece a los denominados "sistemas mesoscópicos", en los cuales, las fluctuaciones con respecto a las propiedades medias son importantes para describir el sistema, en este tenor, hemos estado haciendo fenomenología (ajustando datos experimentales) en una primera etapa, para que una vez conocidas las propiedades medias, nos encarguemos de describir las fluctuaciones en una segunda etapa, es aquí, donde hemos hecho uso de herramientas desde reconocimiento de patrones hasta redes neuronales, y mas recientemente, como una inquietud personal motivada por la cercanía al Centro de Investigación en Inteligencia Artificial de la UV, he querido incorporar herramientas de machine learning para modelar estas fluctuaciones, las cuales, se muestran por ejemplo en el gráfico de contornos de abajo.



Espero que me hayan podido acompañar hasta el final, recuerden que aun no hay veredicto final para esta historia, la naturaleza nunca deja de sorprendernos.

## Inducción de Árboles de Decisión usando Evolución Diferencial

Rafael Rivera López  
Departamento de Sistemas y Computación  
Instituto Tecnológico de Veracruz  
[rrivera@itver.edu.mx](mailto:rrivera@itver.edu.mx)

El aprendizaje automático provee a la minería de datos con procedimientos que permiten analizar y construir modelos a partir de un conjunto de datos. Los árboles de decisión, las redes neuronales artificiales y las máquinas de vectores de soporte han sido ampliamente utilizados para construir modelos predictivos. El uso de una técnica de aprendizaje automático para construir un modelo a partir de un conjunto específico de instancias de entrenamiento depende del nivel requerido de interpretabilidad, escalabilidad y robustez del modelo producido. En particular, los árboles de decisión se caracterizan por sus altos niveles de interpretabilidad y robustez, y aunque se sabe que un criterio greedy no garantiza encontrar una solución óptima, estos clasificadores generalmente se construyen a través de una estrategia de partición recursiva (C4.5, CART y OC1) para dividir el conjunto de entrenamiento en cada etapa de su proceso de inducción.

Dado que las metaheurísticas utilizan procedimientos de búsqueda inteligente que combinan sus habilidades de exploración y explotación, proporcionando una mejor manera de descubrir las relaciones entre los atributos del conjunto de entrenamiento, su aplicación para construir clasificadores permite que éstos sean más compactos y precisos que los inducidos con los métodos tradicionales. Es importante señalar que para obtener árboles de decisión cercanos al óptimo, el esquema de codificación utilizado por una metaheurística debe representar correctamente sus elementos simbólicos: condiciones de prueba y etiquetas de clase. Los esquemas de representación usados por los Algoritmos Genéticos y la Programación Genética son capaces de codificar estos elementos, y se han aplicado para inducir árboles de decisión. Sin embargo, esto es un desafío para otras metaheurísticas como el algoritmo de Evolución Diferencial y el método de Optimización de Enjambre de Partículas, que han demostrado ser muy eficientes para resolver problemas complejos, pero se diseñaron para manejar valores continuos.

Dado que el algoritmo de Evolución Diferencial es una de las metaheurísticas más poderosas para resolver problemas de optimización numérica, lo aplicamos para construir árboles de decisión a través de dos estrategias: por su uso dentro de un esquema de partición recursiva tradicional, y al utilizarlo para realizar una búsqueda global en el espacio de los árboles posibles. En el primer caso, Evolución Diferencial busca los coeficientes de hiperplano que son más apropiados para dividir mejor un conjunto de instancias de entrenamiento, optimizando algún criterio de partición. Evolución Diferencial se aplica tantas veces como nodos internos se necesiten para construir un árbol de decisión oblicuo. Por otro lado, Evolución Diferencial lleva a cabo una búsqueda global para tratar de encontrar un árbol de decisión cercano al óptimo. Cada individuo en la población codifica solo los nodos internos de un árbol binario completo

almacenado en un vector de parámetros de valor real con una longitud fija. El tamaño de este vector se determina utilizando el número de atributos y número de etiquetas de clase del conjunto de entrenamiento cuyo modelo se induce. Para obtener un árbol de decisión factible, primero se analiza el vector para construir un árbol parcial con solo nodos internos, y luego se usa el conjunto de entrenamiento para insertar los nodos hoja. Con esta estrategia se pueden obtener dos tipos de árboles: árboles de decisión univariable y oblicuos.

El uso del algoritmo de Evolución Diferencial para encontrar los hiperplanos de un árbol de decisión oblicuo es muy intuitivo, ya que los valores de los coeficientes del hiperplano se toman de un espacio continuo, y esta metaheurística se diseñó para optimizar vectores de valores reales. Sin embargo, la construcción de árboles de decisión univariable utilizando vectores de valores reales es una tarea más complicada. Para solventar este problema se diseñó un procedimiento que permite seleccionar el atributo que se usará para construir la condición de prueba de cada nodo interno del árbol de decisión. Este procedimiento aplica un esquema de mapeo que utiliza el orden ascendente de los parámetros de un individuo y las instancias de entrenamiento para construir un árbol de decisión univariable. Una vez que el proceso evolutivo alcanza su condición de término, el mejor individuo en la población final se refina para reemplazar los nodos de hoja no óptimos con subárboles, y se aplica un procedimiento de poda para reducir el posible sobreajuste provocado por la aplicación de este refinamiento. Este procedimiento permite inducir árboles de decisión factibles con un número diferente de nodos, aunque el individuo se representa utilizando un vector de parámetros de longitud fija.

Para obtener estimaciones confiables del rendimiento predictivo de las dos estrategias implementadas, y para comparar sus resultados con los logrados por otros métodos de clasificación, se aplica un procedimiento de validación cruzada estratificada en el estudio experimental. Dado que el proceso evolutivo para encontrar un árbol de decisión casi óptimo utiliza la precisión de entrenamiento de cada árbol como su valor de adecuación, los árboles de decisión en la última población podrían sobreentrenarse, y el árbol con la mejor precisión de entrenamiento en esta población podría mostrar una peor capacidad predictiva. Con el objetivo de mitigar los efectos de este sobreentrenamiento, se utiliza un esquema alternativo para seleccionar un árbol de decisión de la población de árboles entrenados. Este esquema utiliza un subconjunto de instancias del conjunto de datos que no se utilizan en el proceso de validación cruzada, para determinar una precisión independiente para cada árbol de decisión en la población final y así seleccionar el mejor árbol usando este nuevo valor. Esta nueva precisión se denomina precisión de selección, así que el árbol con la mejor precisión de selección en la población final se utiliza para calcular la precisión de la prueba. Finalmente, un análisis estadístico de estos resultados sugiere que nuestro enfoque es mejor como método de inducción de árboles de decisión en comparación con otros métodos de aprendizaje supervisado. Además, nuestros resultados son comparables a los obtenidos con otros clasificadores Random Forest y un clasificador basado en perceptrones multicapa.



## **Evaluación de desempeño del operador do (set) del Algoritmo Pearl para determinar su nivel de precisión en la estimación causal**

Jenny Betsabé Vázquez Aguirre

Centro de Investigación en Inteligencia Artificial

Universidad Veracruzana

[jennybey13@gmail.com](mailto:jennybey13@gmail.com)

Las Redes Bayesianas son una excelente herramienta para la descripción de relaciones entre variables de un fenómeno, a partir de éstas es posible realizar predicción y actualización de creencias, dado que son modelos que reflejan el suceso en términos de probabilidades. Algunas aplicaciones están relacionadas con los sistemas expertos, detección de fallos y anomalías en sistemas computacionales, diagnóstico y detección de enfermedades, incluso en investigaciones policiales, sin embargo, éstas por sí mismas no tienen la capacidad de detectar la fuerza con la que sus relaciones pueden ser o no causas probables o potenciales entre sí, es decir, las Redes Bayesianas convencionales únicamente muestran la fuerza de sus relaciones en términos de dependencia condicional.

Pero ¿qué sucede cuando hablamos de relaciones causales?, muchas veces se han confundido los términos de Redes Bayesianas, dependencia y correlación con causalidad. Las Redes Bayesianas Causales tienen el objetivo de identificar que las relaciones existentes en sus variables (arcos entre nodos) pueden ser causales, encontrando en éstas causas potenciales, mismas que se pueden dar en tres sentidos: causas directas (de un padre al hijo), causas indirectas (ancestros a hijos) y causas intermedias (entre ancestros o padres). Judea Pearl desde 1997 propuso un método (operador-do) que trata de encontrar relaciones causales a partir de la intervención de una variable que se encuentra en una Red Bayesiana convencional. Actualmente la implementación del método no existe de manera gratuita y las implementaciones basadas en su modelo propuesto no realizan el cálculo de probabilidad en términos de causalidad.

Si bien la literatura promete mucho asegurando que el método propuesto es bueno para encontrar causalidad, también es verdad que no existe ningún estudio que lo compruebe, ni que mencione las condiciones adecuadas bajo las cuales el método funciona correctamente. Por esta razón, se pretende realizar una evaluación de la técnica propuesta por Pearl, esperando validar su fuerza para encontrar relaciones causales a partir de la actualización e intervención de una Red Bayesiana.

El experimento propuesto para llevar a cabo la evaluación del desempeño del operador consta de probar el método en dos conjuntos experimentales de bases de datos a partir de las cuales se construyan las Redes Bayesianas, uno de ellos que no contengan variables con relaciones causales y otro en el que a priori se sepa que dentro de estas bases sí existen causalidad (validada por expertos); una vez realizados los experimentos, se pretende encontrar suficiente evidencia estadística para determinar que el método es adecuado para estimar relaciones causales en Redes Bayesianas donde se sabe que existe causalidad y rechazar la



Evaluación de desempeño del operador do (set) del Algoritmo Pearl para determinar su nivel de precisión en la estimación causal

causalidad para aquellas redes donde se sabe que no existe este tipo de relaciones.

El objetivo de este trabajo es poder determinar el nivel de eficiencia del operador mencionado y conocer las condiciones adecuadas para la implementación, a fin de contar con una herramienta eficaz realizar pruebas de causalidad de variables en un fenómeno.

Finalmente, una implementación que permita realizar pruebas de causalidad realizando intervención de variables sobre una Red Bayesiana, da la posibilidad de reducir costos en la reproducción de experimentos en los que el monto de experimentación es muy elevado o en áreas donde se realiza experimentación con seres vivos, ya que sería posible reducir las pruebas sobre los estos al intervenir o manipular únicamente las redes.

## Algoritmos Genéticos en Problemas de Programación de Tareas

Mtro. Octavio Ramos Figueroa  
Centro de Investigación en Inteligencia Artificial  
Universidad Veracruzana  
[oivatco.rafo@gmail.com](mailto:oivatco.rafo@gmail.com)

Actualmente, existe un gran interés en la comunidad científica por resolver problemas relacionados con la industria, principalmente en la toma de decisiones y la optimización de procesos. Uno de los problemas que generalmente se presenta en este ámbito está relacionado con la distribución eficiente de tareas (o trabajos) en un conjunto de máquinas (o procesadores), donde cada trabajo puede requerir de cierto tiempo de procesamiento de acuerdo a la máquina que lo procesa. Este tipo de problemas toma gran relevancia debido al impacto económico que puede tener, ya que entre mejor se optimiza la distribución de los trabajos, se acelera la producción, lo que se ve reflejado en mayores ganancias para la empresa. De manera general, a este tipo de problemas se les conoce como problemas de Programación de Tareas (PT). Existen diferentes variantes de problema, donde pueden incluirse restricciones relacionadas con la distribución de los trabajos y/o las características de las máquinas. Incluso, en ocasiones se deben considerar elementos relacionados con el suministro de recursos como: combustible, electricidad y/o recursos humanos.

Por ejemplo, una de las variantes más simples de PT es aquella que consiste en la distribución de un conjunto de trabajos  $N$  en un conjunto de máquinas  $M$  de tal forma que se reduzca tanto como sea posible el tiempo requerido para procesar todos los trabajos<sup>2</sup>. En la Figura 1 se describe gráficamente el problema PT.




Imagen 1. Problema PT con 12 trabajos que pueden ser procesados en 3 máquinas diferentes.

<sup>2</sup> Graham, R. L., Lawler, E. L., Lenstra, J. K., & Kan, A. R. (1979). Optimization and approximation in deterministic sequencing and scheduling: a survey. In *Annals of discrete mathematics* (Vol. 5, pp. 287-326). Elsevier.

Cuando se aborda un problema de PT como el presentado en la Figura 1, existe una gran cantidad de soluciones que pueden ser generadas, una por cada combinación posible, y esta cantidad crece de manera exponencial conforme aumenta el número de tareas. A los problemas de optimización que tienen su base en la combinación de sus elementos (en este caso los trabajos y las máquinas) se les conoce como problemas combinatorios. Este tipo de problemas son considerados intrigantes, porque generalmente son fáciles de definir y entender, pero pueden llegar a ser muy difíciles de resolver, tal es el caso de PT.

Inicialmente, los problemas combinatorios fueron atacados empleando técnicas de optimización matemática. Sin embargo, debido a su alta complejidad, los métodos tradicionales son generalmente incapaces de encontrar la mejor opción. Esto derivado del tamaño del espacio de búsqueda (en este caso el número de soluciones que se pueden generar con todas las combinaciones de trabajos y máquinas). Lo antes mencionado motivó el surgimiento de las metaheurísticas, que si bien no garantizan encontrar la mejor solución, permiten encontrar una solución de calidad y en un tiempo relativamente corto.

En la literatura especializada se puede observar que una de las metaheurísticas más utilizada para resolver problemas de optimización combinatoria son los algoritmos genéticos<sup>3</sup>. El proceso de búsqueda de un algoritmo genético parte de la generación de una población inicial (conjunto de soluciones potenciales al problema) usualmente de forma aleatoria. Posteriormente, las soluciones de la población son mejoradas de forma iterativa empleando operadores de variación (principalmente de cruce y mutación) hasta que se cumple un criterio de paro (encontrar la solución óptima, agotar el número máximo de iteraciones disponibles, entre otros). Cabe resaltar que el éxito de un algoritmo está estrechamente relacionado con la identificación de los métodos apropiados para realizar cada proceso. Lo que ha motivado el estudio del impacto de cada método que se utiliza; así como el desarrollo de estrategias para determinar qué métodos son los más adecuados. Desde la forma de representar las soluciones, hasta la forma en la que se elige como heredar los genes de padres a hijos.

Al igual que los algoritmos genéticos, existen muchas otras metaheurísticas que se inspiran en fenómenos naturales, tal es el caso del algoritmo de abejas artificiales, la optimización por colonia de hormigas, el sistema inmune artificial, las redes neuronales y el algoritmo de gravedad, por mencionar algunos.

Actualmente, existe una gran necesidad por resolver problemas combinatorios como PT, debido a su impacto directo en la industria. Cuando se resuelve un problema de optimización combinatoria, uno de los principales retos consiste en identificar que método de solución se debe emplear, se pueden utilizar los algoritmos existentes, combinaciones de los mismos o incluso se pueden proponer nuevos, decisiones que se toman en base a la complejidad del problema de interés.

---

<sup>3</sup> Nicholson, M. (1998). Genetic Algorithms and grouping problems. *Software: Practice and Experience*, 28(10), 1137-1138.

## **Estudio de la viralidad a través de una clasificación difusa de mensajes en Twitter**

### **(El Sentimiento de lo Artificial)**

Mtro. Omar Rodríguez López

Centro de Investigación en Inteligencia Artificial

Universidad Veracruzana

[jacquesmonfort@hotmail.com](mailto:jacquesmonfort@hotmail.com)

El desarrollo tecnológico propiciado por la investigación científica multidisciplinaria de la última era es el padre reconocible de la revolución digital, de insospechadas proporciones, que experimentamos en la actualidad. La automatización industrial y la conectividad, impulsada por las redes de comunicación, nos han permitido entrar en una etapa digital dorada, un momento histórico donde las fronteras de lo posible se diluyen en el terreno de lo moral y donde la velocidad de crecimiento es el fin común.

Como lo hiciera la revolución industrial con el surgimiento de las máquinas de vapor y el ferrocarril, esta etapa de maravillas tecnológicas ha transformado el vivir diario, dejando tras de sí un constructo social regido por las directivas de lo digital, haciéndonos esclavos, literalmente, del placer culposo de la manipulación de lo binario, lacayos del cero y el uno.

Hoy, como consecuencias del progreso, poseemos comodidades y capacidades inimaginables para nuestros ancestros, atados a la fe de lo divino, pero sufrimos carencias jamás vistas e irremediablemente seguimos siendo víctimas de la obsesión humana por el conocimiento. Queremos saber más, el por qué funcionan las cosas y cómo mejorarlas.

Es en este contexto de inquietud moral, digital y científica donde lo humanista transmuta y alcanza una calidad cuantitativa, medible por la estadística y observable desde la perspectiva analítica de la ciencia dura. Nuestra sociedad es el laboratorio de nuevas corrientes que buscan ir más allá y conocer por qué actuamos como lo hacemos, por qué se imponen unas ideas sobre otras y cuáles son los mecanismos, si pueden caracterizarse, detrás de nuestras preferencias. Somos, pues, hijos de la ciencia de datos y, más concretamente, descendientes del análisis de sentimientos.

Ya en los albores de las redes sociales podía sospecharse cierta relevancia subyacente al concepto que proponían: conectividad pura. La idea de poder compartir opiniones y contenido sin importar las distancias ni los individuos de por medio terminó de establecer las bases de la acelerada exposición que hoy día tenemos sobre infinidad de temas; una a una las limitaciones de la comunicación humana cayeron y migraron, en forma de recuerdos, a las pláticas del pasado.

El potencial oculto del entramado digital de las redes sociales no tardó en descubrirse y pronto recibió la atención de los buscadores de tesoros, que nos regalaron, uno a uno, los trabajos que hoy utilizamos como puntos de referencia.

Una comparación directa entre estos esfuerzos resulta injusta ante las diferencias insalvables en sus enfoques, pero sin duda alguna ofrecen una gran variedad de pensamientos: análisis de sentimientos en Facebook, Twitter, en reseñas de productos de tiendas digitales... El límite, como pronto averiguaríamos, era la creatividad.

La complejidad del mundo y el implacable progreso que determina los usos y costumbres de la población han dictado, desde hace varios años, que el presente y futuro de nosotros como especie, para bien o para mal, estará íntimamente ligado a lo digital: comunicaciones, transacciones, trámites, entretenimiento, trabajo... todos los aspectos del buen vivir forman parte ya del gran conglomerado electrónico que silenciosamente ha consumido nuestra vida. Las redes sociales son tan solo uno de los tantos pilares de estudio que han concentrado los esfuerzos de muchos que deseosos buscan las respuestas a problemas particulares.

Las interacciones en estas plataformas, ya sea con texto, imágenes o videos, son indispensables en la rutina, se han convertido en una extensión física y psicológica de nosotros como individuos; plasmamos en ellas las trivialidades del convivir y las inquietudes de la existencia; transmitimos ideales y deseos, doblegamos a algunos con nuestra ética y caemos convencidos ante otros más influyentes. El nivel de expresión humana en las redes sociales ha superado lo visto por cualquier otro medio de comunicación en la historia y genera interrogantes respecto a los mecanismos ocultos en la viralidad de las ideas. ¿Qué la promueve? ¿Puede caracterizarse para todos los casos? ¿Qué relaciones existen entre un mensaje y su difusión?

Hablar de análisis de sentimientos evoca más de una posibilidad y sin una contextualización previa recuerda el eterno conflicto entre lo social y lo exacto, lo cuantitativo y lo cualitativo. Conversar de análisis y sentimientos parece atentar contra la frontera de la fe y los hechos, pero es necesario identificar la naturaleza infecciosa que toda forma de comunicación posee.

Por sentimientos entonces deberemos entender la intencionalidad—también llamada polaridad—que un mensaje contiene y que ha sido generada por el emisor, de modo que pueda ser etiquetado en una escala emocional que, tradicionalmente, puede partir de las siguientes categorías: positivo, negativo y neutro. El análisis del mensaje, cualesquiera que sean las herramientas disponibles, tiene por finalidad mostrar, con cierto grado de confiabilidad, la emoción de quien lo ha creado; se quiere reconocer la felicidad, enojo, neutralidad o agresividad del emisor, tarea nada sencilla ni alejada de la subjetividad propia de la comunicación entre seres humanos.

¿Cómo puede ser entonces que nosotros, entusiastas feligreses de la inteligencia artificial, tengamos el descaro de pregonar el dominio de lo analítico sobre lo emocional? La revisión de la literatura científica de esta maravillosa área muestra un avance lento pero constante en diferentes direcciones: investigaciones

dedicadas a detectar opiniones sobre temas específicos; extensiones de la escala de polaridad; trabajos sobre el funcionamiento del lenguaje y su relación con el contenido que compartimos; análisis de imágenes publicadas por usuarios de la red... solo es cuestión de entender por dónde comenzar.

El primer reto es sin duda la selección de la escala de clasificación, que carga con la precisión del proceso o, dicho de otro modo, con la variedad de emociones que pueden detectarse. Seleccionar una escala con pocas categorías, como la tricotomía anteriormente expuesta—positividad, negatividad y neutralidad—significa agrupar mensajes con la mayor generalidad posible, imposibilitando un análisis a profundidad ante la falta de un orden entre los mensajes etiquetados. ¿Qué opinión refleja más tristeza? ¿Cuál contiene más felicidad?

Los claros y oscuros de la existencia no pueden ser estudiados con la lupa de lo discreto esperando obtener conclusiones generalizables, se requiere de un mejor mecanismo capaz de reflejar la incertidumbre inherente a nuestra condición humana, se necesita entrar en los dominios de un sistema lógico distinto, flexible pero oscuro: la lógica difusa.

Propuesta como una alternativa para la modelación de los procesos del mundo real, la lógica difusa ha servido como enlace entre los mundos otrora separados de lo incierto y lo numérico, creando en el proceso sistemas capaces de manejar reglas tan variables que no tienen cabida en el esquema booleano tradicional. Sus postulados soportan sin problemas los esquemas informales de la comunicación en redes sociales y facilitan la categorización de los mensajes, logrando con ello una extensión de la escala tricotómica al incluir subcategorías que definen un orden entre opiniones de misma polaridad. Preguntar qué mensaje refleja más enojo o felicidad tiene validez bajo un esquema difuso.

Sin embargo y pese a las consideraciones anteriores, la selección de una escala por sí misma no permite la detección de sentimientos, con lo que resulta más que necesario entrar al terreno de la Inteligencia Artificial, de sus modelos, algoritmos y teorías sobre aprendizaje.

La brecha que separa a los paradigmas del aprendizaje supervisado y no supervisado sugiere la existencia de un gran catálogo de oportunidades para la experimentación en el análisis de sentimientos. El uso de diccionarios, conjuntos de mensajes previamente etiquetados y tablas de reglas gramaticales es la moneda común bajo el modelo supervisado, donde se requiere de un mecanismo para entrenar a los algoritmos antes de la clasificación y que contrasta con su contraparte no supervisada, donde se apela a procedimientos como la agrupación automática de mensajes con la firme intención de clasificar sin depender de la presencia de datos de entrenamiento.

Ambas aproximaciones poseen puntos a favor y en contra. La subjetividad propia de la comunicación humana hace que los dos paradigmas tengan problemas, llevando sus resultados a un contexto probabilista, donde todo está sujeto a

errores y la única certeza es la variabilidad de los mismos. Para los algoritmos supervisados existe el abismal problema de la obtención del conjunto de entrenamiento, ligado totalmente a la interpretación. El etiquetado de grandes conjuntos de palabras con miras a la creación de un lexicón—grandes listas de términos asociados a un valor de polaridad—no puede separarse del componente humano, que depende enteramente de quien lee las palabras y el momento en que lo hace, de modo tal que la cuantificación emocional de los términos no es, matemáticamente hablando, única.

Por otro lado, los intentos no supervisados, si bien buscan superar las dificultades presentadas por sus contrapartes, sufren de la falta de un mecanismo adecuado para la evaluación de sus resultados y por tanto de un punto de referencia que les permita conocer más sobre su desempeño. Esta imposibilidad no hace más que mostrar la dificultad de los retos en el análisis de sentimientos y que van más allá de las consideraciones técnicas típicas de la Inteligencia Artificial o de las suposiciones de la lógica difusa. Entramos en un área que danza grácilmente entre la filosofía de nuestras expresiones y las construcciones matemáticas que usamos para comprender el mundo, un baile que lleva años desarrollándose y que todavía hoy es incapaz de combinar ambas partes satisfactoriamente.

Y si bien la obtención de una clasificación confiable—hasta donde se permita el uso del término estando en un contexto de incertidumbre—es una tarea titánica y reservada para los valientes, lo es también el estudio de la viralidad en las redes sociales, algo que pasamos por alto diariamente pero que construye y modifica todo sin piedad. Los misterios detrás de la popularidad de pocos y el anonimato de la gran mayoría se ha sugerido que son producto del grafo oculto en cualquier red social y que es, en esencia, el esqueleto de nuestras interacciones. Los intentos por esclarecer las propiedades matemáticas necesarias para garantizar un flujo constante de información han estado bajo la lupa de decenas de curiosos pero pocos han obtenido resultados alentadores que permitan entender por qué un mensaje en particular gana miles de vistas y otros cientos de millones no.

Es entendible que se hayan hecho grandes esfuerzos desde la perspectiva de los modelos gráficos probabilistas—entidades estudiadas en la así llamada teoría de grafos—al ofrecer estos un enlace, al menos en principio, entre lo cualitativo y cuantitativo de una red. El flujo de información y sus teorías descansan enteramente en los trabajos dedicados a establecer una receta para crear el grafo perfecto para la comunicación y tiene suficiente robustez gracias a los resultados matemáticos conseguidos a la fecha. Sin embargo, intentar llevar los grafos al mundo de lo emocional e intentar responder únicamente con ellos las interrogantes propias de la popularidad de un contenido, es insuficiente.

Teorizar sobre un mundo pequeño y el así llamado principio de los seis grados de separación—que dicta que podemos comunicarnos con cualquier persona del planeta usando, en promedio, sólo seis intermediarios—sirve como punto de partida en este misterioso asunto, siendo la continuación natural la inclusión del análisis de sentimientos. La combinación de estas dos áreas promete grandes

resultados no sólo en la práctica—con experimentación constante y variada—sino también en el desarrollo teórico que arroje explicaciones sobre las tendencias conductuales de nuestra sociedad.

La viralidad, en el contexto digital, parece sugerir la inclusión, en la ecuación para resolverla, de modelos evolutivos, estructuras dinámicas que reflejen las nuevas conexiones dentro de la red, las amistades más recientes de sus usuarios, los nuevos seguidores y todos aquellos cambios imposibles de registrar en el contexto purista de la teoría de grafos. La ciencia de las redes, creada como una opción para el estudio de eventos dinámicos usando modelos gráficos probabilistas, surge como la gran alternativa proveedora de soluciones y nuevas perspectivas.

Más allá de las aplicaciones comerciales del análisis de sentimientos, explotadas descaradamente por las grandes corporaciones del siglo veintiuno, el conocer y entender mejor los factores detrás de la difusión de los mensajes en una red social es clave para comprendernos como elementos funcionales de la sociedad, para conocernos como especie y dilucidar tan solo un poco de la gran cadena evolutiva que nos ha traído a donde estamos. Aprender de nuestros errores es vital pero observar de primera mano los mecanismos que utilizamos para permitir que se cometan es imprescindible si queremos tener un futuro que presumir, una realidad que disfrutar y un legado que dejar.

### ¿Quieres saber más?

- De Albornoz, J. C., Plaza, L., Gervás, P., & Díaz, A. (2011, April). A joint model of feature mining and sentiment analysis for product review rating. In *European conference on information retrieval* (pp. 55-66). Springer, Berlin, Heidelberg.
- Pang, B., & Lee, L. (2004, July). A sentimental education: Sentiment analysis using subjectivity summarization based on minimum cuts. In *Proceedings of the 42nd annual meeting on Association for Computational Linguistics* (p. 271). Association for Computational Linguistics.
- Tellez, E. S., Miranda-Jiménez, S., Graff, M., Moctezuma, D., Suárez, R. R., & Siordia, O. S. (2017). A simple approach to multilingual polarity classification in twitter. *Pattern Recognition Letters*, 94, 68-74.
- Pla, F., & Hurtado, L. F. (2013, September). ELiRF-UPV en TASS-2013: Análisis de sentimientos en Twitter. In *XXIX Congreso de la Sociedad Española para el Procesamiento del Lenguaje Natural (SEPLN 2013)*. TASS (pp. 220-227).
- Sampson, T. D. (2012). *Virality: Contagion theory in the age of networks*. U of Minnesota Press.
- Watts, D. J. (2004). *Six degrees: The science of a connected age*. WW Norton & Company.
- Lin, Y. R., Margolin, D., Keegan, B., Baronchelli, A., & Lazer, D. (2013). # bigbirds never die: Understanding social dynamics of emergent hashtag. *arXiv preprint arXiv:1303.7144*.
- Izquierdo García, M. (2018). BIG DATA: APLICACIÓN AL ANÁLISIS DE SENTIMIENTOS EN AEROLÍNEAS.



### **Metaheurística eficiente para optimización binivel**

Jesús Adolfo Mejía de Dios, Efrén Mezura Montes

Centro de Investigación en Inteligencia Artificial

Universidad Veracruzana

[jesusmejded@gmail.com](mailto:jesusmejded@gmail.com), [emezura@uv.mx](mailto:emezura@uv.mx)

Existe un tipo de problema de optimización que está siendo de interés actualmente, puesto que sus propiedades son útiles para resolver ciertos problemas reales. Dicho problema es conocido como Optimización binivel. La optimización binivel es un problema de optimización que contiene como restricción otro problema de optimización anidado. En 1934, Von Stackelberg fue el primero que introdujo este tipo de problemas mientras desarrollaba teoría sobre Estructura del Mercado y Equilibrio. Luego, se observó que hay problemas de la vida real que mantienen esta estructura anidada, donde cualquier solución o decisión tomada por una autoridad de nivel superior (líder) que para optimizar sus objetivos, se ve afectado por la respuesta de entidades de nivel inferior (seguidores) quienes buscarán optimizar sus propios resultados o procesos. Para comprender este concepto, se da el siguiente ejemplo.

Suponga que la empresa CIIAutpoistas tiene una red de carreteras de cuota en todo el territorio mexicano. José tiene que viajar de la ciudad A a la ciudad B pasando por diversas casetas que le cobrarán una tarifa establecida por cada caseta que se encuentre en su recorrido. José (como muchos otros automovilistas) quisiera pagar la menor cantidad de dinero en peaje mientras sigue la ruta más corta entre la ciudades A y B. La empresa CIIAutpoistas sabe los planes de José y debe elaborar un plan para evitar pérdida de ganancias (maximizar ingresos). María egresó del Centro de Investigación en Inteligencia Artificial y con las herramientas adquiridas resolvió el problema de la empresa. ¿Cómo lo hizo? Modeló el problema como uno de optimización binivel donde las acciones de la empresa se modelaron como el nivel superior, y las acciones de José formaron parte del nivel inferior, es decir, María propuso un algoritmo basado en inteligencia artificial para resolver tal problemática donde CIIAutopistas maximiza sus ganancias mientras José minimiza gastos en peaje y tiempo de recorrido.

Como se observó en el ejemplo anterior, la optimización binivel puede ser útil para modelar problemas reales de alto impacto. En la literatura especializada se reportan diferentes problemas resueltos con optimización binivel tales como el manejo de tránsito, problemas de transporte, problemas en economía, entre otros. Debido a la estructura jerárquica de este tipo de problemas, en 1992 se probó que se trata de un problema NP-duro. Tan complicado es este problema que incluso para el caso más simple donde el nivel inferior tiene un único óptimo global, no es posible encontrar la solución exacta en tiempo polinomial. Por lo tanto, para problemas reales la complejidad computacional puede aumentar considerablemente. Lo que significa que dichos problemas no pueden ser solucionados a corto plazo. Por tal motivo es necesario proponer algoritmos eficientes para aproximar soluciones en poco tiempo.

## Ayudando al medio ambiente con inteligencia artificial

Dr. Miguel Hidalgo Reyes  
Red de Ambiente y Sustentabilidad  
Instituto de Ecología A.C.  
[miguel.hidalgo@inecol.mx](mailto:miguel.hidalgo@inecol.mx)

Cuando escuchamos hablar de desarrollo sustentable o sustentabilidad pocos sabemos que participan tres componentes importantes: el social, el económico y el ecológico. Los expertos en la materia han identificado que la intersección entre estos tres componentes se relaciona con una sustentabilidad débil y, por lo tanto, es necesario hacer modificaciones para ser más justos con el medio ambiente.

Lo anterior significa que la afectación hacia la biodiversidad es una constante que impacta directamente a los ecosistemas. Actualmente, no es extraño escuchar entre la población que el clima de una ciudad determinada presenta lluvias muy fuertes o que ahora llueve en periodos inusuales de tiempo; o que la ausencia de alguna especie del ecosistema es signo de alarma entre los habitantes de una comunidad.

En el caso de Veracruz, y particularmente en Xalapa, contamos todavía con remanentes de Bosque Mesófilo de Montaña. Si aún no has tenido la oportunidad de conocerlo, puedes visitar este ecosistema que se encuentra contiguo al Instituto de Ecología, o bien, en alguna de las 7 islas denominadas, Archipiélago de Bosques y Selvas de la Región Capital del Estado de Veracruz<sup>4</sup>.

Retomando el concepto de biodiversidad, es importante dar a conocer que existe una Institución encargada de monitorear el capital natural de México, y esta se llama CONABIO<sup>5</sup>. Para monitorear todo este capital, se requiere del apoyo de la tecnología y de un conjunto de personas dispuestas a realizar recorridos de campo. Es decir, este equipo de personas se encarga de instalar cámaras y grabadoras de sonido especiales para registrar a las especies dentro del territorio nacional. Esto conduce a la generación de datos importantes en materia ambiental, por ejemplo: imágenes satelitales de alta definición, registros sonoros de aves o murciélagos, datos cuantitativos de altura, diámetro y densidad de los árboles, entre otros. Cabe señalar que estos datos ambientales, además de ser recopilados, se someten a un análisis y procesamiento con el propósito de obtener un conocimiento útil. Y precisamente, en estos pasos, es donde entra en juego la inteligencia artificial.

Dicho lo anterior, sería válido preguntar, ¿Cómo se aplica la inteligencia artificial a los datos ambientales? Y para responder esta pregunta se deben considerar dos aspectos: el primero es la naturaleza de los datos (su formato, sus características y sus valores) y el segundo es el tipo de modelo que se requiere (descriptivo, predictivo o una combinación de los dos). Por ejemplo, una imagen satelital

---

<sup>4</sup> <http://www.custodiosanpxalapa.org/>

<sup>5</sup> <https://www.gob.mx/conabio>

representa una fotografía de alta resolución y, con un procesamiento mediante computadora y técnicas especiales de inteligencia artificial, es posible distinguir los diferentes ecosistemas o los cuerpos de agua. En el caso de los registros sonoros, la inteligencia artificial se aplica para aprender los diferentes cantos de las aves y, de ese modo, realizar una clasificación por especie.

No obstante, quiero destacar otro tipo de información ambiental muy importante y muy valiosa en la toma de decisiones. Esta información se relaciona con la Constitución Mexicana, las leyes y sus reglamentos, donde la inteligencia artificial también cuenta con una aplicación apropiada.

Los documentos de ley se encuentran representados principalmente por texto. Estos documentos tienen un formato no estructurado, es decir, los párrafos y los enunciados son de diferente tamaño y los documentos difieren entre sí. Solo por dimensionar el número de documentos legislativos, en el caso de México contamos con leyes generales y federales, reglamentos, normas oficiales mexicanas, constituciones y leyes estatales, entre otros. Además, México participa en poco más de 70 tratados internacionales enfocados en la protección del patrimonio biocultural.

Pero ¿por qué razón prestar atención a estos documentos? La respuesta radica en que la legislación mexicana en materia ambiental requiere ser revisada y analizada para detectar posibles incoherencias, deliberadas o no, y así proteger a los ecosistemas frente a riesgos y amenazas. En este importante reto, se debe recurrir a la minería de textos y al procesamiento de lenguaje natural, áreas que utilizan las técnicas y los algoritmos de la inteligencia artificial.

Para situar el contexto, la ley general del equilibrio ecológico y la protección al ambiente (LGEEPA) tiene reglamentos importantes, en materias como las áreas naturales protegidas y el ordenamiento ecológico, entre otros. En opinión de expertos, al interior de esta ley existen deficiencias en las evaluaciones de impacto ambiental y también se han presentado casos en donde dos leyes se contraponen, por ejemplo, la LGEEPA y la Ley Minera.

Sin duda el reto es desafiante en varios aspectos: primero, por la cantidad de documentos a recopilar y procesar para obtener un corpus<sup>6</sup> en materia ambiental; segundo, la extracción de tópicos que permitan clasificar los documentos y tercero, y no menos importante, el análisis semántico.

Al final, la recompensa de este arduo trabajo debe traducirse en capacidades que ayuden a los tomadores de decisiones a contar con información coherente y oportuna, con el propósito de incidir en la elaboración de mejoras políticas públicas en materia ambiental.

---

<sup>6</sup> Según el DRAE se define como: conjunto lo más extenso y ordenado posible de datos o textos científicos, literarios, etc., que pueden servir de base a una investigación.

## Tendencia de los enfoques meméticos en problemas de optimización

Dr. Saúl Domínguez Isidro  
Laboratorio Nacional de Informática Avanzada  
[saul.dominguez@lania.edu.mx](mailto:saul.dominguez@lania.edu.mx)

Muchos problemas del mundo real, pueden ser modelados mediante funciones, las cuales pueden estar sujetas o no, a diversos factores que restringen las posibles soluciones al problema. En este sentido, mediante algún método de optimización es posible encontrar las variables óptimas de la función, la cual representa al problema a resolver. Sin embargo, existen problemas que por su naturaleza no pueden ser resueltos mediante los métodos de optimización tradicionales, ya sea porque no pueden representarse numéricamente, o porque en algún punto no cumplen criterios específicos para ser optimizados.

Es entonces, donde los algoritmos heurísticos son aplicables. Dentro de la diversidad de algoritmos, se pueden identificar los algoritmos evolutivos (AEs), los cuales se caracterizan por emular el proceso de adaptación de los individuos para un entorno específico. Un AE estándar, representa una solución como un vector con las variables del problema a optimizar, nombrado individuo. Inicialmente un AE genera de forma aleatoria una población de individuos, los cuales son recombinados y mutados mediante operadores que emulan fases de reproducción y mutación de los seres vivos, de tal forma que los individuos más aptos tienen mayores probabilidades de generar descendientes y/o mantenerse en futuras generaciones. Esta aptitud es medida con el modelo del problema, pudiendo ser una función matemática o en algunos casos el resultado de una simulación.

Los algoritmos evolutivos han demostrado ser eficientes en la búsqueda de soluciones competitivas para diversos tipos de problemas. Sin embargo, la diversidad de problemas, así como la complejidad de estos en el mundo real, ha permitido el desarrollo de diversos mecanismos que doten de mayores capacidades a estos algoritmos permitiendo mejorar la obtención de resultados en términos de eficacia.

Dentro de estos enfoques, se encuentran los algoritmos meméticos (MAs) que se caracterizan por integrar operadores de búsqueda local dentro del ciclo principal de un algoritmo poblacional (tales como los AEs) con el objetivo de promover la explotación en el espacio de búsqueda (conjunto de todas las soluciones posibles del problema), logrando una sinergia entre el buscador global y local. En general, este tipo de algoritmos son una clase especial de algoritmos híbridos, los cuales, a pesar de no ser relativamente nuevos, su uso ha sido prominente con el pasar de los años, esto debido a los beneficios de que ofrece la exploración de regiones del espacio de búsqueda.

La forma de integrar los operadores de búsqueda local dentro de un AE no es tan simple como parece, ya que hay que considerar todos los parámetros involucrados en la operación del buscador global, así como los parámetros incidentes en la búsqueda local. Por otra parte, la regla de pivote (mecanismo de explotación del

buscador local) junto con el tipo de problema que se quiere resolver resultan en una tarea poco trivial en la coordinación algorítmica de los componentes del MA.

Esta problemática ha promovido el desarrollo de diversos estudios que buscan encontrar mecanismos eficientes en la integración de los componentes algorítmicos del MA. Esto ha permitido el desarrollo de enfoques más eficientes para problemas de optimización complejos, así como MAs más sofisticados en términos de implementación y funcionamiento.

La diversidad de enfoques ha generado diferentes clasificaciones de MAs, en diversos ámbitos, tales como, clasificación por tipos de problemas que son resueltos, tipos de algoritmos poblacionales en los cuales se basan, tipos de operadores de búsqueda local utilizados o tipos de mecanismos de coordinación. Así mismo, de acuerdo a las características de estos enfoques, se pueden distinguir tres generaciones que enmarcan las tendencias en el diseño:

- La primera generación de MAs comprende a los enfoques que combinan la búsqueda global con un operador de búsqueda local, logrando una sinergia entre exploración y explotación.
- Por otra parte, la segunda generación abarca a los MAs que integran múltiples optimizadores locales, incluyendo un mecanismo de coordinación de buscadores locales, cuya elección del optimizador incide en los descendientes.
- Finalmente, los MAs de tercera generación integra a los MAs con características de la segunda generación pero que son capaces de aprender la trayectoria de evolutiva y la elección del buscador local, logrando un comportamiento adaptativo en la coordinación de los operadores de búsqueda local.

Aunque los enfoques meméticos de generaciones más reciente han demostrado un alto desempeño en la búsqueda de soluciones en ciertos tipos de problemas, diversos trabajos del estado del arte recientes, enfocados en resolver problemas de optimización aplicados, (resuelven instancias reales), reportan implementaciones de enfoques meméticos de primera generación, algunos de segunda generación y muy pocos de tercera generación. Este hecho puede indicar la falta de difusión de las tendencias de los MAs y los beneficios que éstos pueden aportar en la solución de problemas de optimización complejos. Así mismo, es necesario complementar aquellos trabajos enfocados al estudio algorítmico de MAs, con la resolución de instancias reales de problemas de optimización.

Finalmente, las diferentes características de los AEs, así como otros algoritmos de optimización basados en población, tales como: los algoritmos de inteligencia colectiva, sistemas inmunes artificiales, entre otros; dejan latente el desarrollo de nuevos enfoques meméticos, los cuales, de acuerdo con la tendencia en términos de diseño, deberían utilizar mecanismos que permitan cierta autonomía en la coordinación de componentes y así mejorar su eficiencia.

## **Generación automática de aplicaciones móviles usando técnicas de Inteligencia Artificial**

Viviana Yarel Rosales-Morales  
Centro de Investigación en Inteligencia Artificial  
Universidad Veracruzana  
[viviana\\_rosales@outlook.com](mailto:viviana_rosales@outlook.com)


El desarrollo de un conjunto de nuevos métodos computacionales para la generación automática de aplicaciones móviles basado en imágenes, e implementando técnicas de inteligencia artificial tales como procesamiento de imágenes, reconocimiento de patrones, redes neuronales o Deep Learning (Aprendizaje profundo), por mencionar algunas, pretende impactar directamente en el área de la ingeniería de software y en el ciclo de vida de desarrollo de software. Con este conjunto de nuevos métodos computacionales se pretende reducir el tiempo de desarrollo en al menos las dos primeras etapas del ciclo de vida del desarrollo de software (Análisis y Diseño), generando automáticamente las interfaces gráficas de usuario a partir del procesamiento de una imagen digital.

Es decir, a través del uso de técnicas de inteligencia artificial para la generación automática de aplicaciones móviles se pretende reducir el tiempo de desarrollo de software y por ende el costo del mismo. Lo anterior implica una contribución directa en el área de las ciencias computacionales, concretamente en la Ingeniería de Software estableciendo un nuevo enfoque y/o paradigma para el proceso de desarrollo automático de aplicaciones móviles de una forma más ágil, intuitiva y novedosa. Este nuevo enfoque abre las puertas a nuevas formas de analizar, diseñar y desarrollar aplicaciones móviles, el enfoque se basa en el procesamiento de una imagen digital previamente definida que representa un patrón de diseño de interfaz de usuario, el cual será generado automáticamente como interfaz de usuario con su propia funcionalidad, los patrones de diseño de interfaz de usuario contemplados son: Login, Dashboard y Carousel, por mencionar algunos, y agregando tantos como sea posible.

En la literatura, aun no se reporta un esquema de generación automática de aplicaciones móviles mediante el uso de técnicas de inteligencia artificial usando patrones de diseño de interfaz de usuario y una imagen como entrada, lo que pone sobre relieve la originalidad y novedad del proyecto, teniendo en cuenta que la generación automática de aplicaciones en un área bastante activa en cuanto a las ciencias computacionales, el impacto del proyecto reside en la reducción del tiempo/costo del ciclo de vida del desarrollo de software.

Por lo tanto, se propone un nuevo enfoque de desarrollo de software basado en imágenes, que permita la generación automática de código fuente para aplicaciones móviles a partir del uso de técnicas de inteligencia artificial. La idea es utilizar el procesamiento de imágenes y el reconocimiento de patrones, entre otras técnicas, para identificar los patrones de diseño de interfaz de usuario contenidos en una imagen y con esta información generar automáticamente el

código fuente de la aplicación para ser ejecutado en diversas plataformas de software y en diversos dispositivos móviles, tal como se muestra en la figura 1.



*Figura 2. Generación automática de aplicaciones móviles*

Con la implementación de la propuesta y su prueba de concepto a través del desarrollo de una herramienta de software para la generación automática de código fuente basada en imágenes y haciendo uso de técnicas de inteligencia de artificial se espera reducir el tiempo de desarrollo de software y ayudar a los desarrolladores a hacer más dinámico el intercambio de ideas con el usuario final de las aplicaciones, ayudando en al menos las dos primeras etapas del ciclo de vida del desarrollo de software. Con este proyecto se espera también romper paradigmas en el desarrollo de software proponiendo un nuevo enfoque de desarrollo basado en imágenes.