

Fundamentos en Humanidades
Universidad Nacional de San Luis – Argentina
Año XI – Número I (21/2010) 133/150 pp.

Un nuevo paradigma computacional basado en una antigua investigación biológica

**A new computational paradigm based on an ancient
biological research**

Leticia Cecilia Cagnina

Universidad Nacional de San Luis
lcagnina@unsl.edu.ar

(Recibido: 03/03/09 – Aceptado: 10/05/09)

Resumen

La naturaleza dinámica y adaptativa de la vida en general y, de la inteligencia humana en particular, es soportada por aproximaciones computacionales que modelan esas condiciones. Esto ha dado origen a uno de los paradigmas exitosamente usado en las ciencias de la computación, la Inteligencia Colectiva.

Abstract

The dynamic and adaptive nature of life in general and of human intelligence in particular is supported by computational approximations that model those conditions. It gives rise to one of the paradigm successfully used in computer science: Swarm Intelligence.

Palabras clave

inteligencia artificial - paradigma - inteligencia colectiva - comportamiento social - particle swarm optimization

Key words

artificial intelligence - paradigm - swarm intelligence - social behavior - particle swarm optimization

1. Introducción

El desarrollo de algoritmos está orientado al diseño de modelos que permiten resolver problemas complejos. En particular, la modelización de la inteligencia biológica y natural, ha resultado de gran éxito dando a lugar a los conocidos algoritmos inteligentes. Estos algoritmos forman parte de un importante campo de las ciencias de la computación, la inteligencia artificial (IA), la cual es una combinación de varias disciplinas de investigación como computación, psicología, sociología y biología.

Es tarea de la IA, el estudio de mecanismos adaptativos que permiten o facilitan el comportamiento inteligente de sistemas computacionales, en ambientes complejos y dinámicos. Estos mecanismos se encuentran clasificados en paradigmas, los cuales se caracterizan por la habilidad de aprender o adaptarse a nuevas situaciones, y así generalizar, abstraer, descubrir y asociar información. Los paradigmas son: Redes Neuronales Artificiales, Computación Evolutiva, Sistemas Difusos e, Inteligencia Colectiva (en inglés *Swarm Intelligence*). Aunque en un principio sólo los tres primeros eran considerados paradigmas, con el advenimiento de nuevas técnicas de resolución de problemas basadas en antiguas investigaciones biológicas, fue inminente la aparición del cuarto paradigma. Técnicas individuales pertenecientes a estos paradigmas han sido aplicadas exitosamente en la resolución de diversos problemas.

El término paradigma posee sus raíces en la palabra griega *paradeigma* (modelo o ejemplo), aunque un significado más contemporáneo es el utilizado por el filósofo y científico Thomas Kuhn para referirse al conjunto de prácticas que definen una disciplina científica durante un período de tiempo.

Este trabajo está organizado de la siguiente manera, la Sección 2 presenta brevemente los comienzos de la IA. Sección 3 desarrolla brevemente el concepto de paradigma, según Kuhn. Sección 4 introduce el paradigma Inteligencia Colectiva. El propósito de la Sección 5 es la descripción de uno de los modernos algoritmos del paradigma Inteligencia Colectiva, que ha demostrado su eficacia en la resolución de un sinnúmero de problemas. El estudio de la producción del conocimiento científico (circunstancias históricas, psicológicas y sociológicas) del paradigma Inteligencia Colectiva, es decir la epistemología del mismo, es presentado en la Sección 6. Finalmente, la Sección 7 presenta conclusiones.

2. Breve historia de la Inteligencia Artificial

Aristóteles (384-322 a.C.) fue posiblemente el primero en utilizar el concepto de Inteligencia Artificial (IA), cuando comenzó a explicar y codificar estilos de razonamiento deductivo (*silogismos*). Luego, Ramón Llull (1235-1316) desarrolló *Ars Magna*, una máquina formada por un conjunto de ruedas, cuyo objetivo era el de responder diversas preguntas (una ilusión hasta el día de hoy). El matemático Gottfried Leibniz (1646-1716) estudió la existencia del *calculus philosophicus*, álgebra universal que puede ser usada para representar conocimiento en un sistema deductivo. Una de las contribuciones más importantes fue la de George Boole (1815-1864), quien inventó el álgebra de Boole y, gracias a este aporte, es considerado uno de los fundadores de las ciencias de la computación. En 1879, Gottlieb Frege (1848-1925) desarrolló los fundamentos del cálculo de predicados, el cual junto a la lógica proposicional de Boole, constituyeron las primeras herramientas de IA.

A comienzos de 1950 Alan Turing (1912-1954), quien estudió cómo las máquinas podrían imitar los procesos del pensamiento humano, publicó el trabajo *The chemical basis of morphogenesis*, el primer estudio relacionado a la "vida artificial". En 1956 John McCarthy (nacido en 1927) y Claude Shannon (1916-2001) coeditaron un volumen titulado *Automata Studies*, en el que la mayoría de artículos trataban sobre los fundamentos matemáticos de la teoría de autómatas. En base a ello, McCarthy decidió acuñar el término Inteligencia Artificial, y utilizarlo como nombre de una conferencia celebrada en Dartmouth ese mismo año. Por esto, se le adjudica a McCarthy el título de padre de la IA.

Desde 1956 a 1969 se realizó mucha investigación modelando Sistemas Neuronales Artificiales: *Perceptrones* de Rosenblatt, *Adaline* de Widrow y Hoff, Redes Neuronales de Minsky y Papert. Luego, hasta mediados de 1980, la investigación sobre Sistemas Neuronales Artificiales entró en un proceso de hibernación.

El campo de la lógica Difusa tuvo su mayor aporte en 1965 con Lotfi Zadeh (nacido en 1921), permaneciendo activo hasta mediados de 1980.

El desarrollo de la Computación Evolutiva comenzó con los Algoritmos Genéticos en los años 1950 con el trabajo de Alex Frasier (1923-2002). Sin embargo, John Holland (nacido en 1929), considerado el padre de la computación evolutiva, fue quien modelizó algorítmicamente los elementos de la teoría de la evolución de Darwin (Darwin, 1859).

Eugene Marais (1871-1936), poeta sudafricano, fue uno de los primeros que produjo una contribución significativa en el área de la Inteligencia

Colectiva, con el estudio del comportamiento social de simios y hormigas. La modelización algorítmica del comportamiento colectivo animal surgió en 1990, con el trabajo de Marco Dorigo (Colonias de Hormigas) y, en 1995, con el desarrollo de Eberhart y Kennedy (*Particle Swarm Optimization*). Este último es un algoritmo de optimización que simula el comportamiento de una bandada de pájaros, un enjambre o un cardumen.

3. El concepto paradigma según Kuhn

Thomas Kuhn establece: “Considero a los paradigmas como realizaciones científicas universalmente reconocidas que, durante cierto tiempo, proporcionan modelos de problemas y soluciones a una comunidad científica” (1970: viii). De esta manera, los paradigmas resultan ser un marco o una perspectiva bajo la cual se analizan los problemas y se tratan de resolver. Estas macro teorías se aceptan de forma general por toda la comunidad científica y se utilizan como base para realizar investigación. A esto último Kuhn le otorga un nombre: “ciencia normal significa investigación basada firmemente en una o más realizaciones científicas pasadas, realizaciones que alguna comunidad científica particular reconoce, durante cierto tiempo, como fundamento para su práctica posterior” (1970: 10).

Cuando una serie de episodios de desarrollo no acumulativo reemplaza a un antiguo paradigma completamente o en parte, Kuhn considera que se produce una “revolución científica”. También ocurre una revolución cuando nuevas situaciones concluyen en que un paradigma no es capaz de resolver todos los problemas inherentes a ellas, y estos problemas persisten por varios años, acumulándose, y volviéndose así una crisis. Esa crisis supone la proliferación de un nuevo paradigma, con vista a resolver dichos problemas. Refiriéndose a esto último, Kuhn dice: “El surgimiento de un paradigma afecta a la estructura del grupo que practica en ese campo. En el desarrollo de una ciencia natural, cuando un individuo o un grupo producen, por primera vez, una síntesis capaz de atraer a la mayoría de los profesionales de la generación siguiente, las escuelas más antiguas desaparecen gradualmente. Su desaparición se debe, en parte, a la conversión de sus miembros al nuevo paradigma. Pero hay siempre hombres que se aferran a alguna de las viejas opiniones y, simplemente, se les excluye de la profesión que, a partir de entonces, pasa por alto sus trabajos. El nuevo paradigma implica una definición nueva y más rígida del campo” (1970: 18-19).

Los paradigmas son una herramienta muy útil en cualquier campo de investigación. Las transiciones o los nuevos paradigmas suponen revoluciones científicas, las cuales cumplen el patrón usual de desarrollo de

una ciencia madura. De allí la importancia de los paradigmas dentro de las ciencias. Y aunque las ciencias de la computación son relativamente nuevas (comparadas a otras ciencias), el surgimiento de nuevos paradigmas demuestra la madurez que posee.

4. El paradigma Inteligencia Colectiva

Los primeros investigadores avocados a la Inteligencia Artificial (IA) llegaron a una importante conclusión: “el individuo tiene una fuerte tendencia a asociarse con otro, a sociabilizar” (Kennedy y Eberhart, 2001: xv). Como IA es una forma de modelar la inteligencia y el comportamiento humano, es natural pensar que se podrían modelizar individuos en un contexto social, interactuando unos con otros. De esta forma, información relevante puede ser intercambiada, así como reglas, conocimiento, experiencia y creencias. En la naturaleza este proceso puede ser observado en grupos de animales como bandadas y manadas, cuando un individuo detecta la presencia de un depredador o encuentra comida, y transfiere esa información a los demás del grupo, los cuales imitan el comportamiento del primero.

El comportamiento social ayuda a cada miembro de la especie a adaptarse al ambiente, y de esa forma, todos los del grupo pueden beneficiarse. Esta es la concepción de la Inteligencia Colectiva.


En general, cuando en el área computacional se habla de *swarm* (cúmulo, enjambre, conjunto de individuos) se hace referencia a un grupo desorganizado de “cosas” moviéndose en un espacio común (el que representa un espacio matemático de búsqueda de soluciones) en forma irregular y caótica, aunque todos los individuos permanecen juntos. Esta analogía promovió el diseño de algoritmos de optimización muy efectivos.

Uno de los algoritmos más recientes de este paradigma es *Particle Swarm Optimization*, el cual imita a una bandada de pájaros (posibles soluciones), en busca de alimento (el óptimo, la solución al problema). Todos los individuos del algoritmo recorren el espacio de búsqueda en un tiempo acotado y, al finalizar, retornan la mejor solución hallada.


5. Un algoritmo de Inteligencia Colectiva: *Particle Swarm Optimization*

Particle Swarm Optimization (PSO) es una técnica de optimización (1) global, basada en el comportamiento social que muestran las bandadas.


Esta heurística fue presentada en el año 1995 por James Kennedy y Russell Eberhart (1995). Surgió de un estudio realizado en base a las investigaciones de C. W. Reynolds (1987) junto con las de F. Heppner (Heppner y Grenander, 1990), referidas a las simulaciones de los grupos de pájaros (bandadas). Reynolds estaba intrigado por la coreografía ejecutada por las aves, y Heppner, zoólogo, interesado en las reglas subyacentes al vuelo sincrónico de los animales. Los creadores de PSO también utilizaron las conclusiones del sociobiólogo E. O. Wilson sobre las bandadas: “En teoría, al menos, los miembros individuales de la bandada se benefician de los descubrimientos y experiencias previas de los demás miembros




1.1 Las partículas (círculos) son inicializadas en una posición aleatoria dentro del espacio de búsqueda.



1.2 Comienza el proceso de búsqueda y las partículas “vuelan” intentando encontrar mejores posiciones.



1.3 Una instancia más avanzada del algoritmo. La atracción a la mejor solución es inminente.



1.4 Fin del algoritmo. Todas las partículas convergen a la solución del problema.

Figura 1. Cuatro estados de la ejecución del algoritmo PSO.

(atracción), cuando realizan la búsqueda de alimento” (1975: 209). Esta afirmación sugiere que la acción de compartir información entre individuos de un mismo grupo, ofrece una ventaja evolutiva que permite el éxito de la agrupación. Esta hipótesis fue fundamental en el desarrollo del método.

Técnicamente, PSO es un procedimiento de búsqueda poblacional (*swarm*), en donde cada individuo es denominado “partícula”. Cada partícula en el *swarm* representa una solución candidata al problema de optimización que se pretende resolver. En PSO, las partículas “vuelan” a través de un espacio de búsqueda multidimensional, ajustando en cada instante de tiempo, su posición en el espacio. Este ajuste es realizado en base a la mejor posición encontrada previamente por la partícula y en base a la mejor posición encontrada por alguno de sus vecinos en el *swarm*. De esta forma todas las partículas se van dirigiendo progresivamente a la zona del espacio en donde se encuentra la solución del problema (zona de alimento en la analogía de las aves). La Figura 1 ilustra el proceso mostrando la inicialización del algoritmo (1.1), una etapa posterior en el proceso de búsqueda (1.2), luego de varias iteraciones cuando la atracción hacia la mejor zona del espacio de búsqueda es más importante (1.3), y finalmente, cuando las partículas convergen en la solución del problema (1.4).

La *performance* (aptitud o *fitness*) de cada individuo es medida en base al valor de la función que representa el problema a resolver.

Básicamente el algoritmo PSO posee las siguientes características:

- un enjambre de partículas (simulando una bandada) realiza, inicialmente, una búsqueda aleatoria de la solución, en un espacio matemático que tenga tantas dimensiones como el problema a resolver.
- sólo hay una “mejor” solución en el espacio de búsqueda en cada momento.
- cada partícula no sabe donde está la “mejor” solución, pero conoce a qué distancia se encuentra de ella, en cada iteración (vuelo) del algoritmo.
- las partículas conocen a qué distancia están del resto de individuos.
- la estrategia es: seguir a la partícula que se encuentre más cerca de la “mejor” solución (atracción).

En la Figura 2 se ejemplifica un problema de dos dimensiones, en donde los dos montículos centrales corresponden a los óptimos del problema, uno local y otro global. Suponiendo que se trata de un problema de maximización, el montículo más alto corresponde a la mejor solución del problema (el óptimo global). Una vez inicializado el *swarm*, las partículas busca-




Figura 2. PSO para resolver un problema 2D.

rán el óptimo recorriendo (volando) el espacio de búsqueda. Esto es realizado matemáticamente, mediante actualizaciones de posiciones y velocidades. Las velocidades corresponden a la dirección que cada partícula tomará para dirigirse a su punto de atracción. Tanto posición como velocidad son vectores de coordenadas, y existe uno de cada tipo asociado a cada partícula.

Como ya se describió, en PSO las partículas se mueven guiadas por su propia trayectoria y por la posición de las partículas óptimas actuales (las más cercanas a la “mejor” solución). El vector que almacena la mejor trayectoria, o posición encontrada por la partícula suele ser denominado *pbest* (*personal best*). El vector correspondiente al mejor valor obtenido por cualquier partícula del *swarm*, es denominado *gbest* (*global best*). Luego, la optimización se realiza en cada paso de tiempo (iteración), mediante la actualización de los vectores. En esta actualización se aplican las siguientes ecuaciones:

$$v_i = v_i + c_1 * rand() * (pbest_i - x_i) + c_2 * rand() * (gbest - x_i)$$

$$x_i = x_i + v_i$$

Donde v_i es la velocidad de la i -ésima partícula del *swarm* y x_i su correspondiente posición. $rand()$ es un valor continuo aleatorio entre 0 y 1, c_1 y c_2 son factores de aprendizaje (representan la proporción de memoria individual o colectiva, respectivamente, que heredará la partícula actualizada). Otros parámetros importantes de PSO son: cantidad de individuos en el *swarm* y cantidad de iteraciones que se utilizarán hasta retornar el resultado. Todos los valores de variables (parámetros del algoritmo) son fijados luego de realizar numerosas pruebas empíricas con la función que se desea optimizar.

La Figura 3 muestra un pseudocódigo del algoritmo PSO.


```

Fase de Inicialización del swarm:
  Por cada partícula  $i$ ,  $i \in [1..N]$ 
    Por cada dimensión  $d$ ,  $d \in [1..D]$ 
      setear  $x_{id}$  con un valor aleatorio en el rango  $[Xmin..Xmax]$ 
      setear  $pbest_{id}$  a  $x_{id}$ 
      setear  $v_{id}$  con un valor aleatorio en el rango  $[Vmin..Vmax]$ 
    FinPor
    Calcular el  $fitness_{x_i}$ 
    setear  $valor\_fitness\_pbest_i$  con  $fitness_{x_i}$ 
    setear  $gbest$  con  $x_i$  si el  $fitness_{x_i}$  es mejor que  $valor\_fitness\_gbest$ 
  FinPor
Fase de Búsqueda:
  Mientras no se alcance la condición de parada
    Por cada partícula  $i$ ,  $i \in [1..N]$ 
      Por cada dimensión  $d$ ,  $d \in [1..D]$ 
        calcular  $v_{id}$ 
        calcular  $x_{id}$ 
      FinPor
      calcular  $fitness_{x_i}$ 
    FinPor
    actualizar  $gbest$  con  $x_i$  si valor  $fitness_{x_i}$  es mejor que  $valor\_fitness\_gbest$ 
    actualizar  $pbest_j$  y  $valor\_fitness\_pbest_i$  si  $fitness_{x_i}$  es mejor que  $pbest_j$ 
  FinMientras
Reportar resultados.

```

Figura 3. Pseudocódigo del algoritmo PSO.

La heurística PSO se ha utilizado exitosamente en la resolución de diversos problemas.

En el rubro artístico, se utiliza esta tecnología para la creación de ambientes interactivos complejos. Por ejemplo: la película animada de Disney “El Rey León” para recrear las escenas donde interactúan los bisontes (ñus), y la película “El Señor de los Anillos” que hizo uso de esta tecnología en las escenas de combate.

Aunque una de las primeras aplicaciones en la que PSO debutó, fue en el entrenamiento de Redes Neuronales *feed-forward* (Eberhart y Kennedy, 1995; Kennedy, 1997). Los estudios preliminares demostraron que PSO era eficiente en el entrenamiento de estas redes particulares, y fue así que posteriormente se utilizó para cualquier arquitectura de redes. Los resultados eran rápidos y seguros, y el algoritmo funcionaba bien en el aprendizaje de las redes, sea supervisado o no. También se empleó PSO en la selección de la arquitectura de redes como se muestra en un trabajo de Zhang, Shao y Li (2000). Estas Redes Neuronales fueron utilizadas en problemas reales como el análisis de temblores en las personas (Eberhart y Hu, 1999), para la detección del Mal de Parkinson o, para estimar el

estado de carga de baterías con el fin de evitar sobrecarga (Peng, Chen y Eberhart, 2000).

También, PSO fue utilizado para el entrenamiento de Redes Neuronales empleadas en la estabilización de controladores en sistemas de potencia (Hirata, Ishigame y Nishigaito, 2002) (electricidad, por ejemplo). Otras aplicaciones incluyen el entrenamiento de redes para predecir niveles de polución (Lu, Fan y Lo, 2003), problemas de tráfico (Srinivasan, Loo y Cheu, 2003), y juegos de dos personas (Messerschmidt y Engelbrecht, 2004).

Particle Swarm ha sido utilizado para coevolucionar agentes en juegos de probabilidades, de suma cero –por ejemplo el *tic-tac-toe* (Messerschmidt y Engelbrecht, 2004)–, de suma no-cero –el Dilema del Prisionero (Franken y Engelbrecht, 2004), por ejemplo– y basados en tablero –como ajedrez o ubicación de n-reinas (Hu, Eberhart y Shi, 2003)–.

La tarea de *Clustering* o agrupamiento tiene como objetivo la formación de grupos de datos que poseen alguna similitud. Esa similitud generalmente se mide en base a la distancia euclidiana que existe entre los elementos. Con base en esto, el problema de *clustering* se reduce a uno de optimización. Entre las aplicaciones de PSO para agrupamiento se puede encontrar la clasificación de imágenes (Omran, Engelbrecht y Salman, 2005), y de datos en general (van der Merwe y Engelbrecht, 2003). Tillet (2002) aplicó PSO para el agrupamiento de nodos en redes ad hoc.

PSO es empleado en un gran número de aplicaciones relacionadas al diseño. Por ejemplo el diseño de: alas de aviones (Venter y Sobieszczanski-Sobieski, 2002), antenas (Gies y Rahmat-Samii, 2003), circuitos (Coello Coello, Luna y Aguirre, 2003), estabilizadores de sistemas de potencia (Abido, 2002), sistemas concurrentes óptimos (Zhang y Xue, 2001) y, armaduras (Schutte y Groenwold, 2003) (diseño industrial).

La planificación y planeamiento son tareas cotidianas, y PSO ha sido aplicado para resolverlas. Están presentes en un sinnúmero de aplicaciones. Algunas de ellas incluyen: planeamiento de la ruta que debe seguir un avión (Secrest, 2001), despacho en sistemas de potencia (El-Gallad, El-Hawary, Sallam y Kalas, 2002) (electricidad, por ejemplo), asignación de tareas (Salman, Ahmad y Al-Madani, 2002) (actividades industriales u otras áreas), problema del viajante y, control de válvulas en la combustión interna de motores.

6. Fundamento epistemológico de la Inteligencia Colectiva

Desde el comienzo de la historia escrita, ha estado presente la especulación de cómo distinguir cosas vivientes de las no-vivientes. Aunque

esta distinción parece obvia, no lo fue en un principio. Aristóteles explicó el fenómeno de la vida con los mismos conceptos que utilizó en física y metafísica, es decir, especificando forma, acto y fin. Él creía que “todo lo que tiene alma difiere de lo que no la tiene en que el primero muestra vida...”. Así lo especificó en su obra Tratado del Alma: “... la palabra vivir tiene muchos sentidos, y decimos que una cosa vive si está presente en ella cada una de las cosas siguientes: mente o pensamiento, sensación, movimiento o reposo en el espacio, además del movimiento que implica la nutrición y el crecimiento o corrupción”.

En el siglo 17, William Harvey descubrió que la sangre circulaba en nuestro cuerpo, bombeada por el corazón. El impacto de su noticia fue inmediato y profundo ya que los conocimientos sobre cómo funcionaba el cuerpo humano, se mantenían cuestionables. Harvey pensaba que la física era reducible a la mecánica y que el cuerpo humano era análogo a una máquina. Sin embargo, siguiendo una antigua tradición, argumentaba que la máquina humana se mantenía en funcionamiento por el calor generado en el corazón. Aunque las investigaciones se acercaban mucho a lo que realmente distingue un ser vivo de uno que no lo es, algunas cuestiones como la teoría del funcionamiento del cuerpo, aún no se develaban del todo.

Posteriormente, Descartes notó: “examinado las funciones que podrían existir en este cuerpo, encontré precisamente todo lo que podría existir en nosotros sin necesariamente poseer el poder de pensar, y consecuentemente, sin tener nuestra alma...” (1984: 27). Con esta afirmación hizo surgir la famosa dicotomía entre la mente y el cuerpo. Esta separación es muy importante ya que aísla lo físico (el cuerpo) de lo no tangible (alma, pensamiento, etc.) y de esa forma permite el estudio por separado de ambas entidades.

La distinción entre las cosas del cuerpo y las de la mente despertó el interés de investigadores quienes, en los comienzos, crearon artilugios para imitar el comportamiento de partes físicas del cuerpo humano (extremidades ortopédicas hoy en día, y complejas maquinarias en la antigüedad). Si bien esto ha sido relativamente sencillo, no ha resultado igual con la imitación (computacional) de los procesos mentales, el comportamiento humano, los sentimientos, etc. Año tras año la brecha entre estos procesos y su recreación computacional, intenta ser reducida con el Test de Turing (Russell y Norving, 2003).

Con el surgimiento de la IA, no sólo los procesos mentales humanos fueron utilizados para modelizar algoritmos, sino que también el comportamiento observado en animales.

A fines de la década de 1970, el sociobiólogo E. O. Wilson (1978) propuso una interesante elaboración: lanzar una moneda al aire y adivinar qué cara sale. Él dijo que si todo el conocimiento de la ciencia física fuera enfocado en el experimento, el resultado sería totalmente predecible. Luego, él sugirió lanzar “algo” más interesante que una moneda... una abeja?! Una abeja tiene memoria, puede aprender y reacciona a estímulos. Wilson afirmó: “si se tuviera conocimiento del sistema nervioso de la abeja, el comportamiento posible y algo de historia de ella, se podría predecir su trayectoria de vuelo en el experimento del lanzamiento. Esta idea de Wilson se transformó en uno de los pilares de la Inteligencia Colectiva.

Una década posterior, Richard Dawkins (1987) en *The Blind Watchmaker* mostró lo que podría ser el primer programa de “vida artificial”. Él hizo creaturas gráficas llamadas *biomorphus* codificadas con un cromosoma de 9 genes. Cada gen podía tomar el valor de 1 a 9 y codificaba reglas para el desarrollo de las creaturas, a través de la mutación. El hipotético usuario podía generar una población de *biomorphus* con genes aleatorios, seleccionar uno que parezca interesante, y luego reproducirlo para crear una generación de hijos, mutando alguno de los genes del padre. Este proceso podía repetirse hasta que el usuario lo desee. El resultado del proceso: la evolución de la población.

Ese es el principio que utilizan todos los algoritmos computacionales poblacionales: elaborar aleatoriamente un conjunto de soluciones (población de individuos), seleccionar algunos utilizando algún criterio (selección de padres), crear nuevas soluciones partiendo de las soluciones elegidas (nueva población de hijos), e ir chequeando cuál es la mejor solución encontrada en cada momento para retornarla al finalizar.

La primera técnica computacional en utilizar la idea de Dawkins fue el Algoritmo Genético (Bäck, Fogel y Michalewicz, 2000) y, posteriormente, un sinnúmero de técnicas pertenecientes a diversos paradigmas. Más recientemente se puede citar a PSO (Kennedy y Eberhart, 1995).

El paradigma de Inteligencia Colectiva es relativamente nuevo (Bäck, Fogel y Michalewicz, 2000; Fleischer, 2005; Pedrycz, 2002), y ha sido objeto de controversias antes de pasar a ser un paradigma reconocido mundialmente. El asunto es que con el surgimiento de nuevas investigaciones basadas en observaciones animales realizadas décadas atrás, se encontró un hábil mecanismo de búsqueda de soluciones, justamente lo que un buen algoritmo computacional requiere. Estas investigaciones concluyeron en la imitación del proceso social animal que permite mover un grupo de animales hacia un objetivo específico: Inteligencia Colectiva. Estas técnicas son claramente un conjunto de nuevos mecanismos basa-

dos en la misma idea social, y muy distinta a la concepción de las técnicas de los otros paradigmas. O sea, surgió un nuevo paradigma.

Kuhn denomina paradigma a una clase de convergencia social de científicos, en un espacio de decisión teórico que revoluciona el estado actual de la ciencia: “un paradigma es lo que los miembros de una comunidad científica comparten, e inversamente, una comunidad científica consiste de hombres que comparten un paradigma” (1970: 176). Los científicos acuerdan el uso de terminología y métodos de investigación, entre otras cosas.

En la analogía de PSO se puede decir que también ocurre una “revolución” Kuhniana, cuando un individuo encuentra una mejor región del espacio de búsqueda y comienza a atraer a sus compañeros a ese lugar (Kennedy y Eberhart, 2001). De esta forma todos los individuos están compartiendo ciencia normal (todos buscan una solución específica, todos tienen un mismo objetivo) y uno de ellos resuelve el dilema (encuentra el óptimo).

En las décadas del 60 y 70, teóricos evolutivos propusieron una correspondencia entre los procesos científicos y evolutivos, que continúa hasta estos días (Dawkins, 1987; Campbell, 1974; Popper, 1972; Lorenz, 1973). En esta visión, un individuo miembro de una especie representa una hipótesis acerca de las propiedades lógicas del ambiente. La validación de la hipótesis es mostrada con la supervivencia del individuo. Este enfoque de aprendizaje inductivo conduce a la mejora constante de la predicción de los aspectos más importantes del ambiente. En PSO, el mejor individuo representa al más apto, el que sobrevivió al proceso evolutivo, por eso es el que se devuelve como resultado del algoritmo.

El proceso de decisión utilizado en los algoritmos poblaciones para realizar la búsqueda de óptimos, en particular PSO, ejemplifica una tendencia que ha sido ampliamente considerada como un error, cuando es vista en relación a la cognición humana (Kennedy y Eberhart, 2001). Karl Popper revolucionó la metodología científica persuadiéndonos que es imposible confirmar una hipótesis, sólo es posible desaprobarla. Él ejemplificó: “si has visto un millón de cisnes blancos y nunca en tu vida has visto alguno de otro color, no puedes probar que todos los cisnes son blancos” (1959: 378). Luego, un sólo cisne negro desaprobará la sentencia antes escrita. La metodología científica moderna está basada en la filosofía del testeo de la hipótesis nula, es decir, se trata de probar que la hipótesis es falsa (se busca el cisne negro). Entonces, una hipótesis no puede ser testeada a menos que sea falsificable. La tarea del científico será identificar qué

podría suceder si la hipótesis fuera falsa y, luego, descubrir si esos eventos pueden ocurrir en una situación experimental.

Aunque es lógicamente imposible probar una hipótesis solamente acumulando teorías que la sustenten, esto es exactamente lo que cualquier persona haría. Los psicólogos cognitivos denominan a esta tendencia *confirmation bias*: la predisposición a buscar irracionalmente la confirmación de nuestras creencias (sin utilizar la falsificación).

Klayman y Ha (1987) estudiaron la posibilidad de que la falsificación no sea una buena estrategia para determinar la verdad o falsedad de una hipótesis. Ellos concluyeron que las personas tienden a usar una “estrategia de testeo positivo”, la cual resulta de probar todos los casos en los que se espera que se cumpla la hipótesis. Y esa es la heurística usada por defecto. Ellos también concluyeron que esa es una buena estrategia de testeo.

Otra manera de ver el proceso de búsqueda algorítmica de soluciones es a través de la comparación entre verdad y certeza. Normalmente las personas que resuelven problemas no requieren el conocimiento de que algo es verdadero, sino que basta con un cierto nivel de certeza. Karl Popper anunció en una entrevista realizada por el escritor John Horgan: “debemos distinguir entre verdad, la cual es objetiva y absoluta, y certeza que es subjetiva” (1996: 36). Ajustando las hipótesis hacia una posición de consenso y testeando casos que confirmen lo que se cree, son formas de incrementar las certezas. Aunque es posible deducir certezas en la ausencia de verdades, las dos no son independientes. Es así que las estrategias que incrementan las certezas pueden servir para descubrir verdades también.

Como ya se estableció previamente, en PSO los individuos se mueven hacia los lugares del espacio más prometedores, y esto supone que la *confirmation bias* es fundamental a esta estrategia. Más aún, esta suposición es una *confirmation bias* social elaborada: los individuos de la población no sólo buscan confirmar sus propias hipótesis sino que también la de sus vecinos, yendo todos hacia el óptimo.

7. Conclusiones

El hombre constantemente tiende a investigar, descubrir e inventar cosas tan variadas que van desde lo microscópico a lo cósmico, lo cual incluye el origen de la vida, las dinámicas de la ecología planetaria y la evolución del comportamiento social. Es así que cada una de estas ideas se ha utilizado en una ciencia relativamente moderna como es la com-

putación, dando nacimiento a una importante rama llamada Inteligencia Artificial. Con los años se fueron sumando técnicas algorítmicas basadas en procesos naturales humanos, como las Redes Neuronales Artificiales, Sistemas Difusos y Computación Evolutiva. Estas dieron origen a paradigmas que se emplearon por muchos años. Pero la investigación no cesó, y nuevas heurísticas se plantearon en base a sistemas biológicos animales. Esto dio origen a un nuevo paradigma: Inteligencia Colectiva, el cual no fue reconocido como tal en los primeros años de su surgimiento.

Hoy en día los algoritmos pertenecientes al paradigma Inteligencia Colectiva son muy usados, por la eficacia en resolver problemas de diversos tipos y magnitudes.

En este trabajo se ha realizado un recorrido histórico desde las primeras concepciones de la Inteligencia Artificial, pasando por la fundamentación de un nuevo paradigma como es Inteligencia Colectiva, hasta arribar a un moderno y eficiente algoritmo computacional.

Agradecimientos

Mi más sincero agradecimiento al Dr. Ramón Sanz Ferramola y a la Mg. Ana Medina por su valioso aporte en la corrección de este trabajo.

San Luis, 20 de febrero de 2009

Notas

1- Optimización se refiere al proceso de ajustar un sistema hasta obtener la mejor solución posible. A veces una buena es suficientemente aceptable.

Referencias Bibliográficas

Abido, M. (2002). Optimal Power Flow using Particle Swarm Optimization. *International Journal of Electrical Power and Energy Systems*, 24(7), 563–571.

Bäck, T., Fogel, D. y Michalewicz, Z. (2000). *Evolutionary Computation*. Vol. 1 y 2. Institute of Physics Publ., Bristol.

Campbell, D. (1974). Evolutionary Epistemology. En P. A. Schilpp. *The philosophy of Karl R. Popper* (412-463). LaSalle, IL, USA: Open Court (Publisher).

Coello Coello, C., Luna, E. y Aguirre, A. (2003). Use of Particle Swarm Optimization to Design Combinational Logic Circuits. *Lecture Notes on Computer Science*. N° 2606, 398-409. Springer-Verlag.

Darwin, C. (1859). *On the Origin of Species by Means of Natural Selection or Preservation of Favoured Races in the Struggle for Life*. London: Murray.

Dawkins, R. (1987). *The Blind Watchmaker: why the evidence of evolution reveals a universe without design*. New York.

Descartes, R. (1984). *Discurso del método*. México: Editorial Porrúa.

Eberhart, R. y Hu, X. (1999). *Human Tremor Analysis using Particle Swarm Optimization*. Proceeding of the IEEE Congress on Evolutionary Computation, vol. 3, págs 1927–1930.

Eberhart, R. y Kennedy, J. (1995). *A New Optimizer using Particle Swarm Theory*. Proceeding of the Sixth International Symposium on Micromachine and Human Science, pág. 39. Japón.

El-Gallad, A., El-Hawary, M., Sallam, A. y Kalas, A. (2002). *A Particle Swarm Optimizer for Constrained Economic Dispatch with Prohibited Operating Zones*. Canadian Conference on Electrical and Computer Engineering, págs 78–81.

Fleischer, M. (2005). *Foundations of Swarm Intelligence: From Principles to Practice*. Disponible on-line en <http://arXiv:nlin/0502003v1>.

Franken, N. y Engelbrecht, A. (2004). *PSO approaches to Co-Evolve IPD Strategies*. IEEE Congress on Evolutionary Computation, págs 356–363.

Gies, D. y Rahmat-Samii, Y. (2003). *Reconfigurable Antenna Array Design using Parallel PSO*. Proceedings of the IEEE Society International Conference on Antennas and Propagation, págs 177–180.

Heppner, F. y Grenander, U. (1990). *A stochastic nonlinear model for coordinated bird flocks*. Washington, DC: Krasner, The Ubiquity of Chaos. AAAs Publications.

- Hirata, N., Ishigame, A. y Nishigaito, N. (2002). *Neuro Stabilizing Control Based on Lyapunov Method for Power System*. Proceeding of the 41st SICE Annual Conference, vol. 5, págs 3169–3171.
- Horgan, J. (1996). *The End of Science: Facing the Limits of Science in the Twilight of the Scientific Age*. New York: Broadway Books.
- Hu, X., Eberhart, R. y Shi, Y. (2003). *Swarm Intelligence for Permutation Optimization: a Case Study on n-queens Problem*. Proceeding of the IEEE Swarm Intelligence Symposium, págs 243–246, USA.
- Kennedy, J. (1997). *The Particle Swarm: Social Adaptation of Knowledge*. Proceedings of the IEEE International Conference on Evolution Computation.
- Kennedy, J. y Eberhart, R. (1995). *Particle Swarm Optimization*. Proceeding of the IEEE International Conference on Neural Networks realizada en Piscataway, NJ, USA.
- Kennedy, J. y Eberhart, R. (2001). *Swarm Intelligence*. Morgan Kaufmann.
- Klayman, J. y Ha, Y. (1987). Confirmation, disconfirmation, and information in hypothesis-testing. *Psychological Review*, 94, pp. 211-228.
- Kuhn, T. (1970). *The Structure of Scientific Revolutions*. University of Chicago Press.
- Lorenz, K. (1973). *Behind the Mirror: a Search for a Natural History of Human Knowledge*. New York: Harcourt Brace Jovanovich.
- Lu, W., Fan, H. y Lo, S. (2003). Application of Evolutionary Neural Network Method in Predictiong Pollutant Levels in Downtown Area of Hong Kong. *Neurocomputing*. Vol. 51, pp. 387–400.
- Messerschmidt, L. y Engelbrecht, A. (2004). Learning to Play Games using a PSObased Competitive Learning Approach. *IEEE Transactions on Evolutionary Computation*. Vol. 8(3), pp. 280–288.
- Omran, M., Engelbrecht, A. y Salman, A. (2005). Particle Swarm Optimization Method for Image Clustering. *International Journal on Pattern Recognition and Artificial Intelligence*, pp. 297–322.
- Pedrycz, W. (2002). *Computational intelligence as an emerging paradigm of software engineering*. ACM International Conference Proceeding Series; Vol. 27. Proceedings of the 14th international conference on Software engineering and knowledge engineering.
- Peng, J., Chen, Y. y Eberhart, R. (2000). *Battery Pack State of Charge Estimator Design using Computational Intelligence Approaches*. Proceeding of the Annual Battery Conference on Applications and Advances, págs 173–177.

Popper, K. (1959). *The Logic of Scientific Discovery*. New York: Basic Book.

Popper, K. (1972). *Objective Knowledge: An evolutionary Approach*. England: Clarendon Press.

Reynolds, C. (1987). Flocks, herds and schools: a distributed behavioral model. *Computer Graphics*, 21(4):25-34.

Russell S. y Norving P. (2003). *Artificial Intelligence. A Modern Approach*. New Jersey: Prentice Hall.

Salman, A., Ahmad, I. y Al-Madani, S. (2002). Particle Swarm Optimization for Task Assignment Problem. *Microprocessors and Microsystems*. 26(8), 363–371.

Schutte, J. y Groenwold, A. (2003). Sizing Design of Truss Structures using Particle Swarms. *Structural and Multidisciplinary Optimization*. 25(4), 261–269.

Secret, B. (2001). *Travelling Salesman Problem for Surveillance Mission Planning using Particle Swarm Optimization*. Tesis de Licenciatura, Air University.

Srinivasan, D., Loo, W. y Cheu, R. (2003). *Traffic Incident Detection using Particle Swarm Optimization*. Proceedings of the IEEE Swarm Intelligence Symposium, págs 144–151.

Tillett, J., Rao, R., Sahin, F. y Rao, T. (2002). *Cluster-Head Identification in Ad Hoc Sensor Networks using Particle Swarm Optimization*. Proceedings of IEEE International Conference on Personal Wireless Communications, págs 201–205.

van der Merwe, D. y Engelbrecht, A. (2003). *Data Clustering using Particle Swarm Optimization*. Proceedings of IEEE Congress on Evolutionary Computation, vol. 1, págs 215–220.

Venter, G. y Sobieszcanski-Sobieski, J. (2002). *Multidisciplinary Optimization of Transport Aircraft Wings using Particle Swarm Optimization*. Ninth AIAA/ISSMO Symposium on Multidisciplinary Analysis and Optimization.

Wilson, E. (1975). *Sociobiology: The new synthesis*. Cambridge, MA: Belknap Press.

Wilson, E. (1978). *On Human Nature*. Cambridge, MA: Harvard University Press.

Zhang, C., Shao, H. y Li, Y. (2000). *Particle Swarm Optimization for Evolving Artificial Neural Network*. Proceedings of the IEEE International Conference on Systems, Man, and Cybernetics, págs 2487–2490.

Zhang, F. y Xue, D. (2001). Optimal Concurrent Design Based upon Distributed Product Development Life-Cycle Modelling. *Robotics and Computer-Integrated Manufacturing*, 17(6), 469–486.