

Algoritmos evolutivos aplicados en las neurociencias

Rafael Pérez Estrada y Claudia Cervantes Durán

Licenciatura en Tecnologías para la Información en Ciencias,
Escuela Nacional de Estudios Superiores, UNAM-Morelia.
Contacto: espfarmex@gmail.com

Resumen. La inteligencia artificial es un campo de estudio de gran interés para afrontar una gran cantidad de problemas tecnológicos y científicos. En el cómputo inteligente, las técnicas que involucran los algoritmos evolutivos están cobrando gran importancia en la solución a problemáticas de diversas áreas del conocimiento pues son técnicas simples pero poderosas que pueden adaptarse fácilmente a la mayoría de problemas. Específicamente en el área de las neurociencias existen casos de éxito donde la aplicación de estas técnicas ha sido fundamental en la comprensión de algunos fenómenos neurobiológicos y han producido resultados prometedores.

Palabras clave: Algoritmo, Evolutivo, Neurociencias, Inteligencia Artificial.

¿Qué pasaría si la inteligencia artificial imitara la evolución darwiniana? Esta es la pregunta que motivó la creación de lo que hoy llamamos cómputo evolutivo. En la búsqueda por nuevas estrategias que resuelvan problemas que la inteligencia artificial tradicional no puede resolver, la naturaleza nos da la solución. Este paradigma de la computación evolutiva se inspira en la teoría de la evolución y

selección natural de Darwin para afrontar problemas que otras técnicas no podrían. Estas soluciones usan técnicas que imitan la reproducción, competencia, selección y mutación para encontrar las mejores soluciones posibles (Simon et al., 2013).

Los algoritmos son una secuencia lógica y detallada de pasos para solucionar un problema. De manera general, lo que hacen los algoritmos

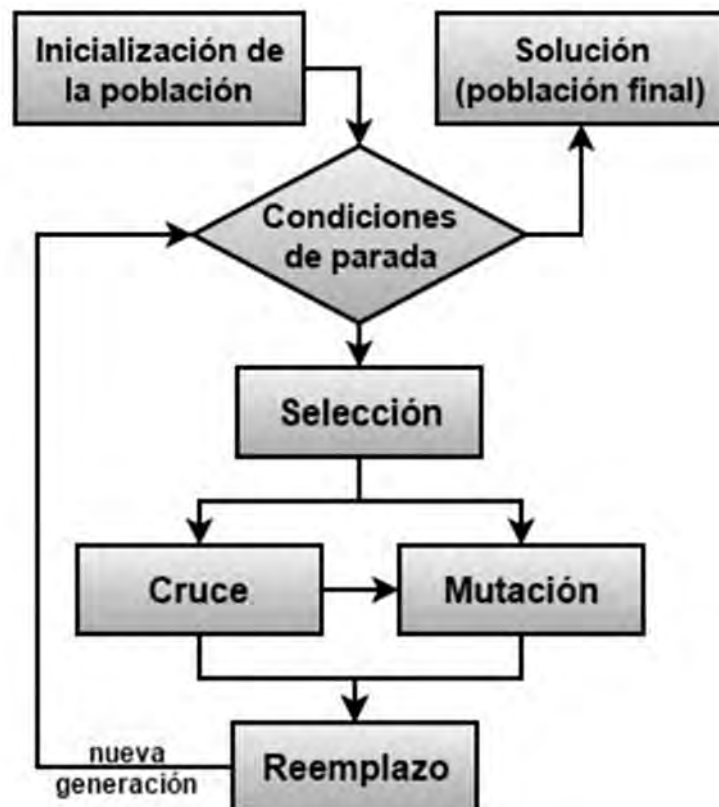


Figura 1. Diagrama de ejecución de un algoritmo evolutivo genérico (Larrodera, 2016)

evolutivos es generar un conjunto o población de soluciones iniciales que deben cumplir ciertos requisitos (condiciones de parada) para que puedan ser seleccionadas entre las mejores, luego se realizan cruces y mutaciones entre estas, lo que originaría nuevas y mejores soluciones que reemplazarían a las iniciales menos apropiadas. El procedimiento anterior se repite por muchas generaciones a través de las cuales las soluciones van “evolucionando” y solo quedan soluciones cada vez mejores hasta que se obtiene la solución final (ver figura 1) (Michalewicz et al., 1996; Larrodera, 2016).

Lo anterior responde a los postulados Darwinianos, los cuales mencionan que la evolución y la selección natural (selección de las mejores soluciones), con el tiempo, propician una mejora biológica para la especie (mejores soluciones) y por lo tanto mejores individuos (Oldroyd, 1986).

Estos algoritmos pertenecen a la parte de la inteligencia artificial denominada “*Soft computing*” pues se basan en encontrar soluciones aproximadas a la mejor solución. Los algoritmos de “*Soft computing*” realizan y calculan muy buenas (pero a veces inexactas) soluciones para problemas que son difíciles y/o complejos de resolver (Ibrahim, 2016). Esto podría parecer una desventaja en un principio, pero en ciertas situaciones es mejor encontrar una buena solución en segundos que encontrar la mejor solución en horas o incluso días, como en situaciones apremiantes que necesitan cálculos rápidos y suficientemente buenos como la navegación aérea o la respuesta a estímulos de las neuroprótesis (Dura-Bernal et al., 2017). Estos algoritmos suelen entrar dentro de la rama de la computación denominada “Computación Evolutiva” como se muestra en la Figura 2.

La rapidez, flexibilidad y adaptabilidad de estos algoritmos hacen que se puedan aplicar en prácticamente cualquier tipo de problema. Una de las áreas más interesantes donde se han




Figura 2. Tipos de algoritmos de computación evolutiva. Modificado de Dreżewski, 2018.

aplicado estas metodologías son las neurociencias. Existen varios trabajos relacionados con las neurociencias donde los algoritmos evolutivos arrojaron resultados reveladores sobre la estructura y función del sistema nervioso y sensorial. A continuación, se comentarán algunos de ellos.

Uso de los algoritmos evolutivos para el análisis de la neuroplasticidad cerebral.

En el estudio realizado por Arnab Roy y colaboradores (Roy et al., 2016) se usan las técnicas evolutivas para determinar la conectividad cerebral en diversas “regiones de interés neurológico” a través del tiempo y analizar si estas conexiones cambiaban (aumentaban o disminuían), lo cual indicaba un cambio en la actividad cerebral debido a la remodelación y establecimiento de las nuevas comunicaciones entre las neuronas (neuroplasticidad).

La neuroplasticidad puede verse como la capacidad del cerebro para modificar, cambiar y adaptar tanto la

estructura como la función a lo largo de la vida y en respuesta a la experiencia (Voss et al., 2017).

Estos cambios plásticos incluyen un sin número de procesos metabólicos, que dan lugar a la regeneración, reparación y reconexión, lo que ayuda a subsanar lesiones o defectos que lo aquejan. Usando los algoritmos evolutivos, el grupo de Roy y colaboradores evaluó la formación de nuevas conexiones entre las neuronas (sinapsis) de personas con lesiones en el sistema nervioso y las comparó con las de sujetos sanos por medio del análisis de imágenes de resonancia magnética. Las imágenes se tomaron con meses de diferencia para analizar los cambios en la estructura de las conexiones neuronales.

Los investigadores decidieron utilizar los algoritmos evolutivos para evaluar la actividad de pares de regiones de interés de la anatomía cerebral en busca de la presencia de nuevas conexiones lo que significaría la existencia de plasticidad neuronal en esa región.

Los investigadores dividieron el área cerebral en 8 regiones principales (4 pares), a partir de las cuales se tomó un par para evaluar su conectividad. Una vez con el par de regiones seleccionadas, estas se subdividieron con ayuda del algoritmo evolutivo. El algoritmo generó diferentes subregiones de las regiones principales y evaluó su conectividad. Esto ayudó a explorar de manera precisa y eficaz el espacio de estas regiones y definir un área mucho más específica como se indica en la siguiente imagen.

En la figura 3, las regiones en color morado representan zonas de interés neurológico, mismas que con ayuda del



Figura 3. Ilustración de resultados. Regiones de interés (morado). Algunas subregiones de alta plasticidad encontradas (verde, rosa, azul). (Roy, 2016).

algoritmo evolutivo se subdividen (zona de color diferente al morado). Estas subdivisiones representan un análisis más fino y eficiente en la búsqueda de conexiones neuronales en lugares más específicos. Esto demuestra a los neurofisiólogos que los cerebros lesionados cuentan con un mecanismo neuronal que permite a las personas con lesiones cerebrales recuperar, al menos en parte las funciones del sistema nervioso en el control del resto del organismo.

Las soluciones generadas por el algoritmo evolutivo mostraron regiones cerebrales con alta plasticidad, dichas regiones eran mucho más pequeñas que las regiones principales completas revelando la reciente interacción entre neuronas y regiones cerebrales que se establecen ante la necesidad de “reparar un cerebro dañado”. La identificación de regiones tan específicas de zonas de alta plasticidad cerebral puede ser objeto de futura investigación y de mucha ayuda para tratamientos de recuperación de lesiones cerebrales.

Algoritmo genético para analizar la percepción visual

Al analizar la percepción visual, la pregunta que se plantea es ¿cómo encontramos cosas en ambientes visuales complejos? ¿cómo percibimos el ambiente? ¿cómo a través del sentido de la vista, nuestro cerebro realiza procesos complejos como el descarte de colores y objetos? Para responder estas preguntas algunos investigadores de la universidad de Sydney y la universidad VU de Ámsterdam, decidieron hacer experimentos sobre la percepción visual apoyándose en los algoritmos evolutivos, específicamente algoritmos genéticos.

Los investigadores desarrollaron varias pruebas en las que a varios estudiantes se les pedía que buscaran una línea roja horizontal dentro de una cuadrícula donde había líneas de diferentes colores y orientaciones (Van der Burg et al., 2015), ver figura 4. En esta cuadrícula se presentaban 72 distractores más el objetivo. Todos los distractores podían ser de cualquiera de las combinaciones entre línea horizontal (0°), línea vertical (90°) o línea a 10° y podría ser del color rojo, azul o verde. La única restricción fue que sólo apareciera una vez la línea horizontal roja (objetivo).




Figura 4. Ejemplo de cuadrícula generada con objetivo señalado (Van der Burg et al., 2015).

En los experimentos, se determinó el tiempo que tardaban en encontrar el objetivo, con ello se obtuvo una calificación. Posteriormente, para evolucionar las soluciones utilizaron un algoritmo genético (un tipo de algoritmo evolutivo) que tenía la función de usar las cuadrículas con mejores calificaciones (las de menor tiempo en encontrar el objetivo) para generar nuevas cuadrículas que tentativamente reducirían el tiempo de reacción de los participantes. De esta forma se generaron cuadrículas de las cuales cada vez les costaba menos encontrar la solución.

Los resultados mostraron que los distractores que fueron disminuyendo para que fuera más fácil encontrar el objetivo, fueron las líneas rojas a 10°. Probablemente porque están muy cerca de ser la línea objetivo (línea roja 0°). Además, lo interesante es que los colores rojos disminuyeron significativamente, lo que sugiere que el distractor principal es el color y no la inclinación de la línea.

Lo impresionante de utilizar este tipo de algoritmos es que al usarlos se logró tener una secuencia de soluciones en las que fue más fácil de identificar al objetivo y no hubo necesidad de probar con todas las 8^{72} (más de cien mil decillones) combinaciones posibles. El algoritmo genético permitió encontrar mejores soluciones y explorarlas más rápido y de mejor manera.

Conclusión

El uso de algoritmos evolutivos puede beneficiar investigaciones en distintas áreas del conocimiento incluyendo las neurociencias mediante la búsqueda inteligente de las mejores

soluciones de los millones de opciones que pueda tener un problema para resolverse. Los algoritmos evolutivos logran de una forma rápida, óptima y flexible un enorme apoyo en la toma de decisiones que, en una situación de emergencia, significaría una disminución en los errores y pérdida de recursos. Por todo ello se busca desarrollar investigación de vanguardia que permita aprovechar todos estos recursos que la inteligencia artificial ofrece y las nuevas generaciones enfrentan el reto de hacerlo.

Referencias

- Drezewski, R., Dziuban, G., & Pajó k, K. (2018). The Bio-Inspired Optimization of Trading Strategies and Its Impact on the Efficient Market Hypothesis and Sustainable Development Strategies. *Sustainability*, 10(5), 1460. <https://doi.org/10.3390/su10051460>
- Dura-Bernal, S., Neymotin, S. A., Kerr, C. C., Sivagnanam, S., Majumdar, A., Francis, J. T., & Lytton, W. W. (2017). Evolutionary algorithm optimization of biological learning parameters in a biomimetic neuroprosthesis. *IBM journal of research and development*, 61(2-3), 1–6.14. <https://doi.org/10.1147/JRD.2017.2656758>
- Ibrahim, D. (2016). An Overview of Soft Computing. *Procedia Computer Science*, 102, 34–38. <https://doi.org/10.1016/j.procs.2016.09.366>
- Larrodera, S. (2016). Sistema inteligente basado en computación evolutiva y redes de neuronas para juegos de bloques. (Tesis de maestría, Universidad Politécnica de Madrid).
- Michalewicz, Z., & Schoenauer, M. (1996). Evolutionary algorithms for constrained parameter optimization problems. *Evolutionary computation*, 4(1), 1-32.
- Oldroyd, D. R. (1986). Charles Darwin's theory of evolution: A review of our present understanding. *Biology & Philosophy*, 1(2), 133–168. <https://doi.org/10.1007/bf00142899>
- Roy, A., Campbell, C., Bernier, R. A., & Hillary, F. G. (2016). An Evolutionary Computation Approach to Examine Functional Brain Plasticity. *Frontiers in neuroscience*, 10, 146. <https://doi-org.pbidi.unam.mx:2443/10.3389/fnins.2016.00146>
- Simon, D. (2013). *Evolutionary Optimization Algorithms*. Wiley.
- Roy, A., Campbell, C., Bernier, R. A., & Hillary, F. G. (2016). An Evolutionary Computation Approach to Examine Functional Brain Plasticity. *Frontiers in Neuroscience*, 10. <https://doi.org/10.3389/fnins.2016.00146>
- Van der Burg, E., Cass, J., Theeuwes, J., & Alais, D. (2015). Evolving the stimulus to fit the brain: A genetic algorithm reveals the brain's feature priorities in visual search. *Journal of Vision*, 15(2). <https://doi.org/10.1167/15.2.8>
- Voss, P., Thomas, M. E., Cisneros-Franco, J. M., & de Villers-Sidani, É. (2017). Dynamic Brains and the Changing Rules of Neuroplasticity: Implications for Learning and Recovery. *Frontiers in psychology*, 8, 1657. <https://doi.org/10.3389/fpsyg.2017.01657>