

KẾT HỢP THUẬT TOÁN TỐI ƯU TRƯỜNG ĐIỆN TỪ VÀ TỐI ƯU ĐA VŨ TRỤ: CHIẾN LƯỢC LAI SONG SONG VÀ CHIA SẼ THÔNG TIN VỚI ỨNG DỤNG TRONG CÁC BÀI TOÁN TỐI ƯU

Đinh Nguyễn Trọng Nghĩa^{1*}, Dương Thị Thúy Nga²

¹Trường Đại học Công Thương Thành phố Hồ Chí Minh

²Trường Đại học Tài nguyên Môi trường Thành phố Hồ Chí Minh

*Email: nghiadnt@huit.edu.vn

Ngày nhận bài: 25/11/2024; Ngày nhận bài sửa: 15/01/2025; Ngày chấp nhận đăng: 03/3/2025

TÓM TẮT

Bài báo này đề xuất một chiến lược kết hợp giữa thuật toán Tối ưu trường điện từ (Electromagnetic Field Optimizer - EFO) và tối ưu Đa vũ trụ (Multi-Verse Optimizer - MVO) bằng cách sử dụng phương pháp chạy song song kết hợp với chia sẻ thông tin định kỳ, gọi là EFO-MVO. Phương pháp kết hợp này khai thác ưu điểm của từng thuật toán: EFO có khả năng khai thác cục bộ tốt, trong khi MVO có ưu thế trong khám phá toàn cục. Để đánh giá hiệu suất của EFO-MVO, chúng tôi đã thực nghiệm trên 6 hàm kiểm chứng phổ biến: Sphere, Rastrigin, Rosenbrock, Ackley, Griewank, và Zakharov. Kết quả cho thấy rằng EFO-MVO đều đạt được kết quả tối ưu vượt trội so với các thuật toán riêng lẻ EFO, MVO, và Genetic Algorithm (GA). Phương pháp EFO-MVO chứng minh được hiệu quả trong việc tránh các cực trị cục bộ và hội tụ nhanh chóng về nghiệm tối ưu, cho thấy tiềm năng ứng dụng mạnh mẽ trong các bài toán tối ưu hóa phức tạp.

Keywords: Thuật toán tối ưu hóa lai, Electromagnetic Field Optimizer (EFO), Multi-Verse Optimizer (MVO), Hàm kiểm chứng, Kết hợp metaheuristic.

1. MỞ ĐẦU

Trong những năm gần đây, các thuật toán tối ưu hóa metaheuristic đã trở thành công cụ quan trọng trong việc giải quyết các bài toán phức tạp và phi tuyến [1]. Các bài toán tối ưu hóa thực tế thường có không gian tìm kiếm lớn, đa cực trị và đòi hỏi khả năng hội tụ nhanh, do đó việc phát triển các phương pháp tối ưu hóa hiệu quả hơn là một nhu cầu cấp thiết [2]. Hai trong số các thuật toán metaheuristic mới được phát triển, Electromagnetic Field Optimizer (EFO) [3] và Multi-Verse Optimizer (MVO) [4], đã cho thấy tiềm năng lớn nhờ vào khả năng khai thác cục bộ và khám phá toàn cục, mỗi thuật toán có những ưu điểm và hạn chế riêng biệt.

EFO được giới thiệu bởi Abedinpourshotorban và cộng sự vào năm 2016 [3], mô phỏng các lực điện từ giữa các hạt trong trường điện từ. Các hạt trong EFO chịu tác động bởi lực hút hoặc đẩy tùy thuộc vào độ phù hợp của chúng, với các giải pháp tốt hơn thu hút các hạt xung quanh để tối ưu hóa cục bộ. Điều này giúp EFO có khả năng khai thác mạnh mẽ ở các vùng tiềm năng, tuy nhiên thuật toán có thể gặp khó khăn khi cần tìm kiếm trên toàn bộ không gian lớn với nhiều cực trị cục bộ.

MVO được Mirjalili [4] và cộng sự phát triển vào năm 2015, lấy cảm hứng từ lý thuyết đa vũ trụ, nơi các vũ trụ với các mức độ phù hợp khác nhau giãn nở và trao đổi vật chất. MVO có khả năng khám phá không gian tìm kiếm rộng lớn, giúp tránh rơi vào các cực trị cục bộ. Tuy nhiên, MVO thường hội tụ chậm hơn ở các vùng cục bộ, điều này có thể hạn chế khả năng khai thác giải pháp chi tiết.

Mặc dù EFO và MVO đã cho thấy hiệu quả khi được áp dụng độc lập, sự kết hợp giữa chúng có thể mang lại những cải tiến vượt trội hơn, khi EFO và MVO bổ trợ nhau trong quá trình tối ưu hóa. Trong bài báo này, chúng tôi đề xuất một thuật toán lai mới, gọi là EFO-MVO, kết hợp chạy song song giữa EFO và MVO với cơ chế chia sẻ thông tin định kỳ. Chiến lược này nhằm khai thác ưu thế của mỗi thuật toán, với MVO phụ trách khám phá không gian toàn cục và EFO tinh chỉnh giải pháp tại các khu

vực cục bộ. Đồng thời, thông tin về các giải pháp tốt nhất sẽ được chia sẻ giữa hai thuật toán, giúp cải thiện khả năng hội tụ và tránh được cực trị cục bộ.

Để đánh giá hiệu quả của EFO-MVO, chúng tôi thực nghiệm trên 6 hàm kiểm chứng nổi tiếng trong tối ưu hóa, bao gồm: Sphere, Rastrigin, Rosenbrock, Ackley, Griewank, và Zakharov. Chúng tôi cũng so sánh EFO-MVO với các thuật toán thành phần EFO và MVO, cũng như Genetic Algorithm (GA) - một thuật toán metaheuristic truyền thống, nhằm xác định tính ưu việt của phương pháp kết hợp này.

Kết quả thực nghiệm cho thấy EFO-MVO không chỉ đạt hiệu suất tốt hơn so với các thuật toán riêng lẻ mà còn hội tụ nhanh hơn và hiệu quả hơn trong các bài toán có nhiều cực trị cục bộ. Kết quả này khẳng định rằng việc kết hợp EFO và MVO trong một mô hình song song và chia sẻ thông tin có thể là một chiến lược tối ưu hóa hứa hẹn, có tiềm năng ứng dụng trong các bài toán thực tế như lập lịch, tối ưu hóa mạng, và gợi ý danh mục đầu tư.

2. CÁC CÔNG TRÌNH LIÊN QUAN

Sự kết hợp giữa các thuật toán metaheuristic đã trở thành một hướng nghiên cứu quan trọng nhằm tận dụng các ưu điểm của từng thuật toán và khắc phục những hạn chế của chúng [5]. Các công trình trước đây đã chứng minh rằng các phương pháp lai hóa này có thể mang lại hiệu suất vượt trội trong việc giải quyết các bài toán tối ưu hóa phức tạp, đặc biệt là những bài toán có nhiều cực trị cục bộ và không gian tìm kiếm lớn.

Một trong những phương pháp kết hợp nổi bật là sự lai hóa giữa Genetic Algorithm (GA) và Particle Swarm Optimization (PSO) [6]. Nghiên cứu của Rahmat-Samii và cộng sự (2019) [6] đã đề xuất một chiến lược lai hóa giữa hai thuật toán này bằng cách sử dụng GA để khám phá toàn cục và PSO để tinh chỉnh cục bộ. Trong phương pháp này, GA được sử dụng để tìm kiếm các vùng tiềm năng trong không gian, trong khi PSO đảm nhiệm vai trò tối ưu hóa giải pháp trong các vùng đó. Kết quả cho thấy rằng sự kết hợp này giúp giảm thiểu nguy cơ rơi vào các cực trị cục bộ và cải thiện tốc độ hội tụ.

Bên cạnh đó, sự kết hợp giữa Differential Evolution (DE) và Ant Colony Optimization (ACO) [7] cũng đã thu hút sự quan tâm đáng kể. Công trình của Zhang và cộng sự (2018) [7] đã đề xuất một thuật toán lai DE-ACO, trong đó DE chịu trách nhiệm khai thác các giải pháp tiềm năng bằng cách sử dụng phép biến đổi vi phân, còn ACO đóng vai trò điều hướng các lối đi tiềm năng trong không gian tìm kiếm thông qua cơ chế pheromone. Kết quả thực nghiệm trên các bài toán tối ưu hóa liên tục và rời rạc cho thấy DE-ACO mang lại hiệu suất cao hơn đáng kể so với các thuật toán đơn lẻ.

Một ví dụ khác là sự kết hợp giữa Simulated Annealing (SA) và Tabu Search (TS), được đề xuất bởi Katsigiannis (2012) [8]. Trong công trình này, phương pháp lai này sử dụng để giải bài toán tối ưu kích thước cho các hệ thống điện năng tự trị nhỏ (SAPS) sử dụng năng lượng tái tạo tại vùng Chania, Hy Lạp. Phương pháp lai này tận dụng ưu điểm của SA trong khám phá không gian tìm kiếm và TS trong khai thác cục bộ, nhằm tối thiểu hóa chi phí năng lượng ((sic)/kWh). Kết quả thực nghiệm và phân tích độ nhạy cho thấy phương pháp SA-TS vượt trội về chất lượng giải pháp và tốc độ hội tụ so với SA hoặc TS riêng lẻ.

Ngoài ra, sự kết hợp giữa Harmony Search (HS) và Firefly Algorithm (FA) cũng được nghiên cứu bởi Bongale và cộng sự (2019) [9]. Công trình này đề xuất một giao thức lai cho bầu chọn đầu cụm trong mạng cảm biến không dây (WSN) dựa trên thuật toán Firefly và Harmony Search, nhằm tối ưu hóa tiêu thụ năng lượng và tăng hiệu quả truyền dữ liệu. Quy trình bầu chọn đầu cụm được chia thành hai cấp độ: cấp đầu sử dụng Harmony Search để chọn ban đầu các nút đầu cụm tối ưu, sau đó Firefly được sử dụng để tinh chỉnh dựa trên mật độ nút, độ nén cụm và năng lượng tiêu thụ. Kết quả thực nghiệm trên trình mô phỏng NS 2.34 cho thấy giao thức lai vượt trội so với các giao thức LEACH, LEACH-C, EOICHD và Firefly đơn thuần về tiêu chí năng lượng và tuổi thọ mạng.

Zhou và cộng sự (2017) [10] đã đề xuất một thuật toán lai đa mục tiêu MOHABC (Multi-Objective Hybrid Artificial Bee Colony) để giải quyết bài toán dịch vụ và lựa chọn tối ưu (SCOS) trong sản xuất đám mây, với mục tiêu tối ưu cả chất lượng dịch vụ và tiêu thụ năng lượng từ góc độ kinh tế và môi trường. Thuật toán kết hợp Pareto dominance để định hướng tìm kiếm, cuckoo search với Levy flight nhằm duy trì đa dạng quần thể, và chiến lược học toàn diện để cân bằng khả năng khai thác và khám

phá. Kết quả thực nghiệm cho thấy MOHABC vượt trội so với các thuật toán đa mục tiêu khác trong bài toán SCOS.

Những công trình nêu trên đã khẳng định rằng sự kết hợp giữa các thuật toán metaheuristic là một hướng đi triển vọng, không chỉ cải thiện hiệu suất tối ưu hóa mà còn tăng tính linh hoạt và khả năng áp dụng của các thuật toán vào các bài toán thực tế phức tạp. Các nghiên cứu này là tiền đề quan trọng để phát triển các chiến lược lai hóa mạnh mẽ và sáng tạo hơn trong lĩnh vực tối ưu hóa hiện đại.

3. MÔ TẢ THUẬT TOÁN ĐỀ XUẤT

3.1. Electromagnetic Field Optimizer (EFO)

EFO là một thuật toán metaheuristic được phát triển dựa trên nguyên lý hoạt động của trường điện từ, trong đó các giải pháp (cá thể) được mô phỏng như các hạt mang điện tích. Thuật toán sử dụng lực hút và lực đẩy để điều chỉnh vị trí của các cá thể, với mục tiêu tìm kiếm các nghiệm tối ưu. Các hạt có fitness tốt hơn đóng vai trò như các nguồn lực hút mạnh, thu hút các hạt khác về phía mình. Ngược lại, các hạt có fitness thấp hơn sẽ tạo lực đẩy, loại bỏ các giải pháp kém tiềm năng ra khỏi vùng tìm kiếm.

3.1.1. Nguyên lý hoạt động

EFO hoạt động dựa trên việc phân chia các cá thể trong quần thể thành hai nhóm:

Hạt phát sinh lực hút (Hạt tốt): Là các giải pháp có fitness tốt hơn trong quần thể. Các hạt này có xu hướng thu hút các hạt khác, giúp tinh chỉnh giải pháp trong vùng lân cận.

Hạt phát sinh lực đẩy (Hạt kém): Là các giải pháp có fitness thấp. Lực đẩy từ các hạt này giúp loại bỏ các giải pháp kém và thúc đẩy việc tìm kiếm các vùng không gian khác.

3.1.2. Quá trình tối ưu hóa

Khởi tạo quần thể: Các cá thể ban đầu được khởi tạo ngẫu nhiên trong không gian tìm kiếm.

Tính lực điện từ: Từng cá thể được đánh giá fitness và chịu tác động bởi lực hút hoặc lực đẩy dựa trên vị trí và fitness của các hạt khác.

Cập nhật vị trí cá thể: Các hạt di chuyển về phía hạt tốt hơn hoặc bị đẩy ra xa, dựa trên giá trị fitness và lực điện từ.

Lặp lại: Tiếp tục tính toán lực và cập nhật vị trí cho đến khi đạt tiêu chí dừng (số vòng lặp tối đa hoặc đạt nghiệm tối ưu).

3.1.3. Khả năng khai thác cục bộ tốt

Một trong những điểm mạnh của EFO là khả năng khai thác cục bộ. Lực hút được thiết kế để tập trung các hạt quanh các giải pháp tốt, giúp tinh chỉnh giải pháp trong các vùng tiềm năng. Khi các hạt di chuyển về phía các nguồn lực hút mạnh, chúng dần hội tụ về các vùng cục bộ có fitness cao hơn. Điều này làm cho EFO đặc biệt hiệu quả trong việc tối ưu hóa chi tiết các vùng không gian lân cận của giải pháp tốt nhất hiện tại.

Tuy nhiên, khả năng khám phá toàn cục của EFO lại bị hạn chế, đặc biệt khi quần thể hội tụ sớm quanh một cực trị cục bộ. Đây là lý do mà EFO thường được kết hợp với các thuật toán khác có khả năng khám phá mạnh mẽ hơn, như MVO, để cải thiện hiệu suất tối ưu hóa trên không gian tìm kiếm rộng lớn.

3.2. Multi-Verse Optimizer (MVO)

MVO là một thuật toán metaheuristic được phát triển dựa trên lý thuyết đa vũ trụ, trong đó các giải pháp được mô phỏng như các vũ trụ có mức độ phù hợp (fitness) khác nhau. Ý tưởng chính của MVO là khai thác mối quan hệ giữa các vũ trụ thông qua các cơ chế như giãn nở (inflation) và trao đổi vật chất (material exchange). Các vũ trụ có fitness tốt hơn sẽ giãn nở mạnh hơn, thu hút các vũ trụ kém hơn để trao đổi thông tin và tìm kiếm các giải pháp tốt hơn.

3.2.1. Nguyên lý hoạt động

MVO sử dụng cơ chế giãn nở và trao đổi vật chất giữa các vũ trụ để tối ưu hóa. Các giải pháp tốt hơn (vũ trụ có fitness cao) đóng vai trò như nguồn lực hút, điều hướng các giải pháp khác tiến về phía

chúng, giúp khám phá các vùng không gian rộng lớn. Cơ chế này mang lại cho MVO khả năng khám phá toàn cục mạnh mẽ, đặc biệt trong các bài toán có không gian tìm kiếm rộng lớn và nhiều cực trị cục bộ.

3.2.2. Quá trình tối ưu hóa

Khởi tạo quần thể: Các giải pháp ban đầu (vũ trụ) được tạo ngẫu nhiên trong không gian tìm kiếm.

Tính toán fitness: Mỗi vũ trụ được gán một giá trị fitness dựa trên tỷ lệ thuận với fitness của nó. Vũ trụ tốt hơn sẽ fitness mạnh hơn, làm tăng khả năng thu hút các vũ trụ khác.

Trao đổi vật chất: Các vũ trụ kém hơn có xu hướng trao đổi vật chất với vũ trụ tốt hơn, dẫn đến sự cải thiện các giải pháp.

Thay thế và cập nhật: Các vũ trụ được thay thế nếu giải pháp mới tốt hơn, từ đó cải thiện quần thể.

Lặp lại: Quá trình fitness và trao đổi vật chất được thực hiện liên tục cho đến khi đạt tiêu chí dừng (số vòng lặp tối đa hoặc đạt nghiệm tối ưu).

3.2.3. Ưu thế trong khám phá toàn cục

MVO có khả năng khám phá toàn cục vượt trội nhờ cơ chế fitness và trao đổi vật chất, cho phép nó tìm kiếm các vùng không gian mới thay vì bị giới hạn trong một khu vực cụ thể. Đặc biệt, các vũ trụ kém liên tục bị thu hút bởi các vũ trụ tốt hơn, giúp mở rộng không gian tìm kiếm và tăng khả năng thoát khỏi các cực trị cục bộ. Khả năng khám phá toàn cục của MVO rất hữu ích trong các bài toán tối ưu hóa phức tạp, trong đó có nhiều các cực trị cục bộ làm các thuật toán dễ mắc kẹt.

Mặc dù MVO có khả năng khám phá mạnh mẽ, nhưng nó lại hội tụ chậm hơn khi tiếp cận các nghiệm tối ưu. Điều này là do cơ chế trao đổi vật chất không đủ hiệu quả để tinh chỉnh chi tiết các giải pháp trong vùng lân cận của cực trị toàn cục. Hạn chế này khiến MVO gặp khó khăn trong khai thác cục bộ, đặc biệt ở giai đoạn sau của quá trình tối ưu hóa.

3.3. Ý tưởng kết hợp thuật toán EFO và MVO

EFO và MVO là hai thuật toán metaheuristic với các đặc điểm bổ sung lẫn nhau, tạo nên cơ sở lý tưởng cho sự kết hợp. EFO nổi bật với khả năng khai thác cục bộ mạnh mẽ, khi sử dụng lực hút và lực đẩy để tập trung vào tinh chỉnh các giải pháp xung quanh vùng lân cận của cực trị hiện tại. Tuy nhiên, chính điều này lại khiến EFO dễ mắc kẹt tại các cực trị cục bộ, đặc biệt khi không gian tìm kiếm rộng lớn và phức tạp. Ngược lại, MVO lại có ưu thế vượt trội trong khám phá toàn cục, nhờ cơ chế fitness và trao đổi vật chất giữa các giải pháp, giúp mở rộng không gian tìm kiếm và tránh rơi vào các cực trị cục bộ. Tuy nhiên, MVO lại gặp hạn chế ở giai đoạn hội tụ cuối cùng do khả năng tinh chỉnh giải pháp chi tiết kém hiệu quả.

Việc kết hợp EFO và MVO giúp tận dụng thế mạnh của cả hai thuật toán, đồng thời khắc phục những hạn chế riêng lẻ. MVO có thể đảm nhận vai trò dẫn dắt tìm kiếm toàn cục, đưa quần thể đến gần các vùng không gian có tiềm năng cao, trong khi EFO sẽ tinh chỉnh các giải pháp trong vùng này để đạt được các nghiệm tối ưu. Hơn nữa, chiến lược chia sẻ thông tin định kỳ giữa hai thuật toán đảm bảo rằng cả khả năng khám phá và khai thác đều được cân bằng trong suốt quá trình tối ưu hóa. Điều này không chỉ giúp cải thiện tốc độ hội tụ mà còn tăng độ chính xác của các giải pháp, đặc biệt trên các bài toán có không gian tìm kiếm phức tạp và nhiều cực trị cục bộ. Sự kết hợp này không chỉ hợp lý mà còn hứa hẹn mang lại hiệu suất vượt trội trong các bài toán tối ưu hóa thực tế.

3.4. Thuật toán kết hợp đề xuất

Nghiên cứu này đề xuất một phương pháp kết hợp giữa EFO và MVO bằng cách sử dụng chiến lược chạy song song với cơ chế chia sẻ thông tin định kỳ, gọi là EFO-MVO. Mục tiêu chính của phương pháp kết hợp này là tận dụng sức mạnh khai thác cục bộ của EFO và khả năng khám phá toàn cục của MVO, từ đó đạt được sự cân bằng tốt hơn giữa khai thác và khám phá trong quá trình tối ưu hóa.

Thuật toán EFO-MVO gồm bốn bước chính: (1) Khởi tạo, (2) Tìm kiếm song song, (3) Chia sẻ thông tin, và (4) Cập nhật và tiếp tục tìm kiếm. Dưới đây là mô tả chi tiết từng bước.

Bước 1: Khởi tạo

Thuật toán bắt đầu bằng việc khởi tạo hai quần thể giải pháp ngẫu nhiên cho EFO và MVO, với các giá trị trong mỗi cá thể được chọn ngẫu nhiên trong giới hạn không gian tìm kiếm. Mỗi cá thể được đánh giá dựa trên giá trị hàm fitness để xác định mức độ phù hợp.

Bước 1.1: Tạo ngẫu nhiên các giải pháp cho quần thể của EFO (P_{EFO}) và quần thể của MVO (P_{MVO}).

Bước 1.2: Tính giá trị fitness cho từng cá thể trong mỗi quần thể, từ đó xác định các giải pháp ban đầu tốt nhất của EFO và MVO.

Bước 2: Tìm kiếm song song

Trong bước này, cả EFO và MVO sẽ tiến hành tìm kiếm giải pháp tối ưu một cách song song. Mỗi thuật toán sẽ áp dụng các quy tắc riêng của mình để điều chỉnh vị trí của các cá thể.

Đối với EFO: Mỗi cá thể chịu tác động của lực hút và đẩy dựa trên giá trị fitness của nó. Các cá thể có fitness tốt hơn sẽ tạo ra lực hút mạnh hơn, trong khi các cá thể có fitness thấp hơn sẽ bị đẩy ra xa. Điều này giúp các cá thể EFO tập trung vào khai thác cục bộ.

Đối với MVO: Các cá thể trong MVO sẽ thực hiện quá trình giãn nở và trao đổi vật chất, trong đó các giải pháp tốt hơn sẽ mở rộng để thu hút các giải pháp kém hơn. Điều này giúp MVO khám phá không gian rộng hơn và tránh rơi vào các cực trị cục bộ.

Bước 3: Chia sẻ thông tin định kỳ

Sau một số vòng lặp nhất định (khoảng chia sẻ định kỳ k), hai thuật toán sẽ trao đổi thông tin về các giải pháp tốt nhất của mình. Bằng cách chia sẻ các giải pháp có fitness tốt nhất giữa EFO và MVO, mỗi thuật toán có thể cải thiện quá trình tìm kiếm của mình bằng cách khai thác các thông tin từ thuật toán còn lại.

Bước 3.1: Sau mỗi k vòng lặp, các giải pháp tốt nhất từ P_{EFO} và P_{MVO} sẽ được trao đổi giữa hai thuật toán.

Bước 3.2: Mỗi thuật toán sẽ cập nhật quần thể của mình bằng cách thêm vào các giải pháp tốt nhất từ thuật toán còn lại, giúp tăng cường khả năng hội tụ và tránh cực trị cục bộ.

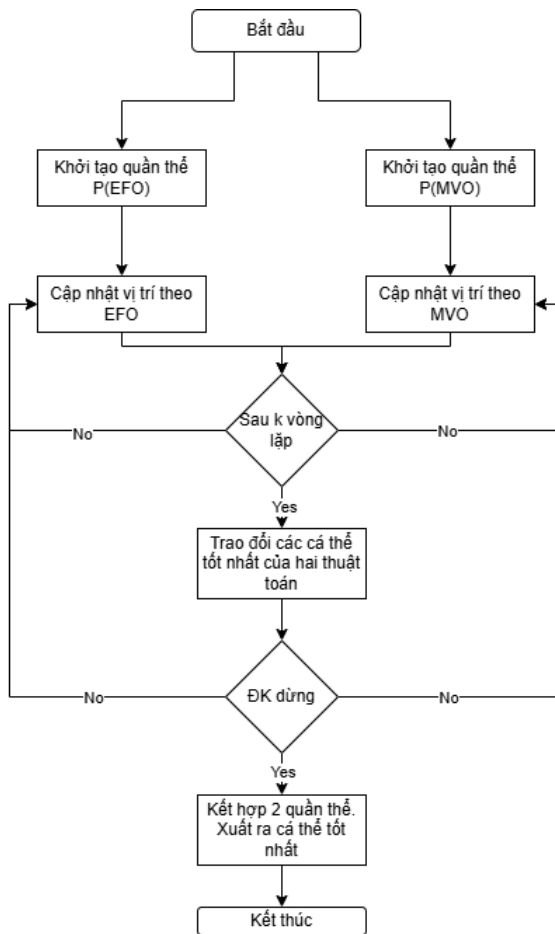
Bước 4: Cập nhật và tiếp tục tìm kiếm

Sau khi thực hiện chia sẻ thông tin, cả hai thuật toán sẽ cập nhật quần thể và tiếp tục quá trình tối ưu hóa. EFO sẽ khai thác các giải pháp từ MVO và tiếp tục tinh chỉnh cục bộ, trong khi MVO sẽ mở rộng không gian tìm kiếm dựa trên các giải pháp mà nó nhận được từ EFO.

Đối với EFO: Các giải pháp từ MVO được đưa vào quần thể sẽ được tinh chỉnh theo cơ chế lực điện từ để tiếp tục tìm kiếm các giải pháp tốt hơn trong phạm vi cục bộ.

Đối với MVO: Các giải pháp từ EFO được đưa vào quần thể sẽ giúp MVO mở rộng không gian tìm kiếm và tăng khả năng khám phá toàn cục.

Thuật toán EFO-MVO tận dụng tốt ưu điểm của từng thuật toán thành phần: khả năng khai thác mạnh mẽ của EFO giúp tập trung vào việc tối ưu hóa cục bộ, trong khi khả năng khám phá toàn cục của MVO giúp tăng cường tìm kiếm trên không gian rộng lớn. Cơ chế chia sẻ thông tin định kỳ giữa hai thuật toán còn giúp tối ưu hóa nhanh hơn, giảm thiểu nguy cơ rơi vào cực trị cục bộ và cải thiện độ hội tụ của thuật toán.



Hình 1. Sơ đồ thuật toán kết hợp EFO và MVO

Thuật toán 1. Mã giả thuật toán kết hợp EFO-MVO

Khởi tạo quần thể EFO P_EFO kích thước N trong không gian D chiều

Khởi tạo quần thể MVO P_MVO kích thước N trong không gian D chiều

Tính fitness từng cá thể trong P_EFO và P_MVO

Set x_EFO_best = best solution in P_EFO

Set x_MVO_best = best solution in P_MVO

For iter = 1 to MaxIter:

--- Bước 1: Chạy tối ưu EFO ---

For each individual in P_EFO:

 Tính lực điện từ (lực hút, lực đẩy)

 Cập nhật vị trí dựa trên lực điện từ

 Áp dụng điều kiện biên

 Tính lại fitness

End For

Set x_EFO_best = best solution in P_EFO

--- Bước 2: Chạy tối ưu MVO ---

For each individual in P_MVO:

 Tính hệ số giãn nở

 Trao đổi chất giữa các vũ trụ

 Cập nhật vị trí sử dụng quy tắc MVO

 Apply boundary constraints

 Tính lại fitness

End For

Set x_MVO_best = best solution in P_MVO

--- Bước 3: Trao đổi thông tin định kỳ ---

If iter % k == 0:

 Chia sẻ các cá thể tốt nhất giữa P_EFO và P_MVO:

 Thay các cá thể tệ nhất trong P_EFO bằng các cá thể tốt nhất trong P_MVO

 Thay các cá thể tệ nhất trong P_MVO bằng các cá thể tốt nhất trong P_EFO

 Tính lại fitness cả 2 quần thể

End If

End For

--- Chọn lọc giữa hai thuật toán ---

Set x_best = best solution in P_MVO và P_EFO

Set f_best = best fitness in P_MVO và P_EFO

Return x_best, f_best

4. THỰC NGHIỆM VÀ ĐÁNH GIÁ TRÊN CÁC HÀM THỬ NGHIỆM

Các thí nghiệm được thực hiện trên máy tính sử dụng bộ vi xử lý Intel Core i5, RAM 16GB, hệ điều hành Windows 11, và môi trường Python 3.12. Các thuật toán được thử nghiệm bao gồm EFO-MVO, EFO, MVO, và Genetic Algorithm (GA), được áp dụng trên sáu hàm kiểm chứng phổ biến trong tối ưu hóa, bao gồm Sphere, Rastrigin, Rosenbrock, Ackley, Griewank, và Zakharov. Các thuật toán được thực thi trong 1000 vòng lặp, với kích thước quần thể 20 cá thể và không gian tìm kiếm có 10 chiều (dim = 10). Công thức và phạm vi biến của các hàm được trình bày chi tiết trong Bảng 1.

Việc lựa chọn sáu hàm kiểm chứng này nhằm mục đích đánh giá hiệu suất của thuật toán trên các không gian tìm kiếm có đặc điểm đa dạng và mức độ phức tạp khác nhau. Sphere là một hàm lồi đơn giản, thường được sử dụng để đánh giá khả năng khai thác cục bộ và tốc độ hội tụ của thuật toán. Rastrigin và Ackley là những hàm không lồi có nhiều cực trị cục bộ, giúp kiểm tra khả năng khám phá toàn cục và tránh rơi vào bẫy cực trị cục bộ. Rosenbrock, với cấu trúc "hố sâu", đặt ra thách thức đối với các thuật toán tối ưu hóa trong việc điều chỉnh giải pháp trong không gian phi tuyến phức tạp. Trong khi đó, Griewank và Zakharov được sử dụng để đánh giá khả năng tối ưu hóa trên các không gian có đặc tính phi tuyến và tính đa dạng cao.

Các hàm này không chỉ phản ánh các đặc điểm quan trọng của nhiều bài toán tối ưu hóa thực tế mà còn được sử dụng rộng rãi trong nghiên cứu về các thuật toán metaheuristic. Chúng giúp đánh giá một cách khách quan hiệu suất của thuật toán, đồng thời cho phép so sánh với các phương pháp trước đây trong cùng lĩnh vực. Ngoài ra, không gian tìm kiếm của các hàm này được định nghĩa trên các khoảng giá trị rộng, chẳng hạn như [-5, 5] cho Rastrigin và [-600, 600] cho Griewank, giúp kiểm tra khả năng khám phá và khai thác của thuật toán trong các môi trường tối ưu hóa có độ phức tạp khác nhau.

Bảng 1. Công thức toán học và thông số của các hàm thử nghiệm được sử dụng trong thực nghiệm

Hàm	Công thức	Phạm vi	Cực trị
Sphere	$\sum x_i^2$	[-2,2]	0
Rastrigin	$10n + \sum [x_i^2 - 10\cos(2\pi x_i)]$	[-5,5]	0
Rosenbrock	$\sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (1 - x_i)^2]$	[-5.12,5.12]	0
Ackley	$-20\exp\left(-0.2\sqrt{\frac{1}{n}\sum x_i^2}\right) - \exp\left(\frac{1}{n}\sum \cos 2\pi x_i\right) + 20$	[-32,32]	0
Griewank	$1 + \frac{1}{4000}\sum x_i^2 - \prod \cos\left(\frac{x_i}{\sqrt{i}}\right)$	[-600,600]	0
Zakharov	$\sum x_i^2 + \left(\sum 0.5ix_i\right)^2 + \left(\sum 0.5ix_i\right)^4$	[-5,10]	0

3.1. Kết quả thực nghiệm

Bảng 2 dưới đây tóm tắt giá trị fitness tốt nhất đạt được của các thuật toán trên 6 hàm kiểm chứng.

Kết quả thực nghiệm cho thấy rằng EFO-MVO vượt trội hơn so với các thuật toán thành phần EFO, MVO, và thuật toán cổ điển GA trên tất cả các hàm kiểm chứng, bao gồm cả các hàm đơn giản như Sphere và các hàm phức tạp với nhiều cực trị cục bộ như Rastrigin và Ackley. Điều này khẳng định rằng phương pháp lai hóa giúp khai thác tối ưu thể mạnh của cả hai thuật toán thành phần, từ khả năng khai thác cục bộ của EFO đến khả năng khám phá toàn cục của MVO, đồng thời tận dụng cơ chế chia sẻ thông tin để cải thiện hiệu quả tối ưu hóa.

Bảng 2. Giá trị fitness tốt nhất của các thuật toán trên các hàm kiểm chứng

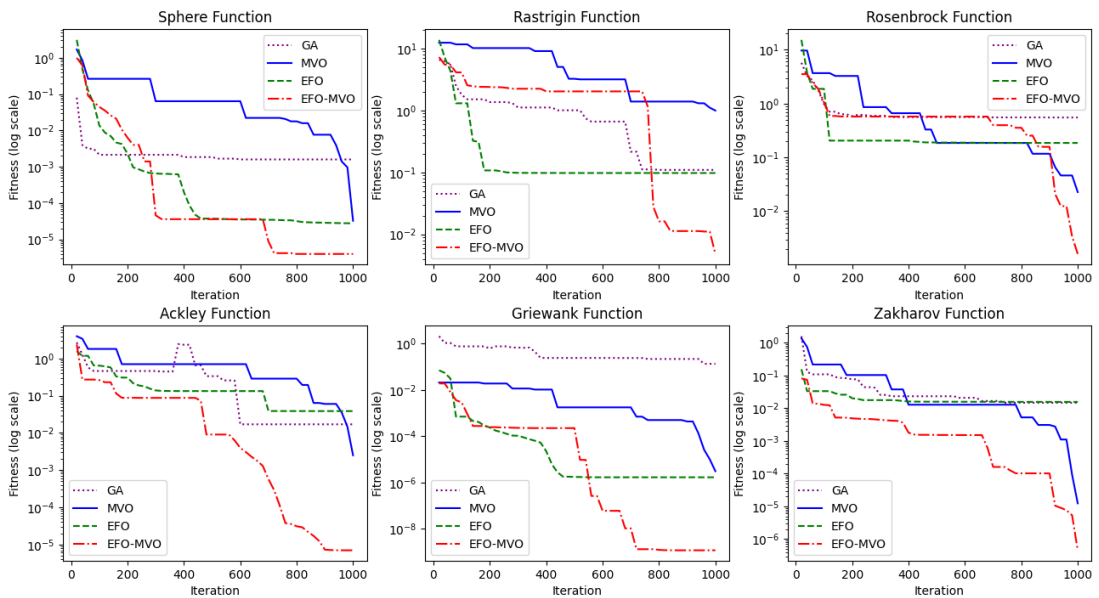
Hàm	EFO	MVO	GA	EFO-MVO
Sphere	2.78E-05	3.26E-05	1.60E-03	3.98E-06
Rastrigin	0.0976	0.9969	0.1095	0.0048
Rosenbrock	0.1856	0.0227	0.5519	0.0016
Ackley	0.0386	0.0025	0.017	6.97E-06
Griewank	1.68E-06	3.10E-06	0.135	1.18E-09
Zakharov	0.0156	1.24E-05	0.0147	4.55E-07

Trên hàm Sphere, với đặc điểm là một hàm lồi đơn giản, EFO-MVO đạt giá trị fitness tốt nhất (3.98e-06), vượt xa EFO (2.78e-05), MVO (3.26e-05), và GA (1.60e-03). Điều này cho thấy sự kết hợp giữa khám phá và khai thác giúp EFO-MVO hội tụ nhanh hơn. Với các hàm phức tạp như Rastrigin và Ackley, nơi chứa nhiều cực trị cục bộ, EFO-MVO vẫn duy trì sự vượt trội với giá trị lần lượt là 0.0048 và 6.97e-06, so với EFO, MVO, và GA. Kết quả này chứng minh rằng cơ chế chia sẻ thông tin định kỳ trong EFO-MVO giúp thuật toán tránh được cực trị cục bộ và tiến tới các giải pháp toàn cục hiệu quả hơn.

Trên các hàm như Rosenbrock, Griewank, và Zakharov, vốn đòi hỏi sự cân bằng giữa khả năng tìm kiếm toàn cục và khai thác cục bộ, EFO-MVO tiếp tục đạt giá trị fitness thấp nhất. Với Rosenbrock, giá trị của EFO-MVO là 0.0016, vượt xa các giá trị của EFO (0.1856), MVO (0.0227), và GA (0.5519). Tương tự, trên hàm Griewank, EFO-MVO đạt 1.18e-09, thấp hơn đáng kể so với EFO (1.68e-06), MVO (3.10e-06), và GA (0.1350). Trên hàm Zakharov, EFO-MVO đạt giá trị 4.55e-07, tiếp tục khẳng định khả năng hội tụ chính xác và nhanh chóng của phương pháp lai. Những kết quả này cho thấy rằng sự kết hợp của EFO và MVO không chỉ cải thiện tốc độ hội tụ mà còn tăng cường độ chính xác trong việc đạt nghiệm tối ưu.

3.2. Phân tích biểu đồ

Ngoài các kết quả số liệu, các biểu đồ biểu diễn fitness theo số vòng lặp (Hình 2) đã minh họa rõ ràng hiệu suất vượt trội của EFO-MVO so với các thuật toán EFO, MVO, và GA trên từng hàm kiểm chứng. Trên tất cả các hàm, đường biểu diễn của EFO-MVO cho thấy tốc độ giảm fitness nhanh hơn đáng kể, đặc biệt trong các vòng lặp đầu tiên, chứng minh rằng sự kết hợp giữa khả năng khai thác cục bộ của EFO và khả năng khám phá toàn cục của MVO đã giúp tăng tốc độ hội tụ một cách hiệu quả. Điều này nhấn mạnh ưu thế của EFO-MVO trong việc đạt đến nghiệm tối ưu toàn cục nhanh hơn so với các thuật toán còn lại.



Hình 2. Biểu đồ thể hiện fitness các hàm theo số vòng lặp

Hơn nữa, trên các hàm phức tạp như Rastrigin và Ackley, nơi tồn tại nhiều cực trị cục bộ, các đường biểu diễn của EFO và MVO thường bị chững lại ở các giá trị fitness cao, thể hiện rằng chúng gặp khó khăn trong việc thoát khỏi các cực trị cục bộ. Ngược lại, EFO-MVO tiếp tục giảm sâu, cho thấy khả năng tránh các cực trị cục bộ và tiến tới cực trị toàn cục hiệu quả hơn. Đặc biệt, cơ chế chia sẻ thông tin định kỳ giữa EFO và MVO đã giúp EFO-MVO tận dụng được các giải pháp tốt nhất trong từng giai đoạn tìm kiếm, làm nổi bật sự vượt trội của thuật toán lai này.

So với GA, các đường biểu diễn cho thấy tốc độ giảm fitness của GA chậm hơn đáng kể so với EFO-MVO trên tất cả các hàm kiểm chứng. Điều này minh chứng rằng các thuật toán metaheuristic hiện đại như EFO-MVO không chỉ vượt trội về chất lượng giải pháp mà còn có khả năng hội tụ nhanh hơn so với các thuật toán cổ điển. Hình 2 đã củng cố thêm kết luận rằng EFO-MVO là một phương pháp tối ưu hóa mạnh mẽ và hiệu quả, đặc biệt trên các bài toán có không gian tìm kiếm phức tạp và nhiều cực trị cục bộ.

4. KẾT LUẬN VÀ PHƯƠNG HƯỚNG PHÁT TRIỂN

Bài báo này đã đề xuất và thực nghiệm một phương pháp lai hóa mới, EFO-MVO, kết hợp giữa Electromagnetic Field Optimizer (EFO) và Multi-Verse Optimizer (MVO) thông qua chiến lược chạy song song và chia sẻ thông tin định kỳ. Kết quả thực nghiệm trên 6 hàm kiểm chứng phổ biến, bao gồm Sphere, Rastrigin, Rosenbrock, Ackley, Griewank, và Zakharov, đã chứng minh rằng EFO-MVO vượt trội so với các thuật toán đơn lẻ EFO, MVO, và thuật toán cổ điển GA cả về tốc độ hội tụ lẫn chất lượng giải pháp. Thuật toán lai hóa này cho thấy khả năng hội tụ nhanh, tránh được các cực trị cục bộ và đạt được nghiệm tối ưu toàn cục ngay cả trên các bài toán tối ưu hóa phức tạp. Những kết quả này khẳng định tính hiệu quả và tiềm năng của EFO-MVO trong lĩnh vực tối ưu hóa hiện đại.

Trong tương lai, chúng tôi dự kiến mở rộng áp dụng EFO-MVO vào các bài toán thực tế nhằm đánh giá tính hiệu quả của thuật toán này trong các lĩnh vực ứng dụng khác nhau. Một số hướng nghiên cứu tiềm năng bao gồm: bài toán lập lịch, nhằm tối ưu hóa việc phân bổ tài nguyên và thời gian; tối ưu hóa danh mục đầu tư, nơi yêu cầu cân bằng giữa rủi ro và lợi nhuận trong tài chính; và bài toán vận tải, như tối ưu hóa tuyến đường hoặc phân phối hàng hóa. Ngoài ra, việc cải tiến cơ chế lai hóa để tăng cường khả năng mở rộng thuật toán trên các bài toán đa mục tiêu cũng là một hướng đi quan trọng. Những nghiên cứu tiếp theo sẽ tập trung vào việc đánh giá sâu hơn tính hiệu quả của EFO-MVO trên các bài toán thực tế phức tạp, từ đó khẳng định vai trò của nó như một công cụ tối ưu hóa mạnh mẽ và linh hoạt.

TÀI LIỆU THAM KHẢO

1. Abualigah, L., Elaziz, M.A., Khasawneh, A.M. - Meta-heuristic optimization algorithms for solving real-world mechanical engineering design problems: A comprehensive survey, applications, comparative analysis, and results. *Neural Comput & Applic* **34** (2022) 4081–4110. <https://doi.org/10.1007/s00521-021-06747-4>
2. Hifi, Mhand, M'Hallah, Rym - A literature review on circle and sphere packing problems: models and methodologies, *Advances in Operations Research* 150624 (2009). <https://doi.org/10.1155/2009/150624>
3. Hosein Abedinpourshotorban, Siti Mariyam Shamsuddin, Zahra Beheshti, Dayang N.A. Jawawi - Electromagnetic field optimization: A physics-inspired metaheuristic optimization algorithm, *Swarm and Evolutionary Computation* **26** (2016) 8-22. <https://doi.org/10.1016/j.swevo.2015.07.002>
4. Mirjalili, S., Mirjalili, S.M. & Hatamlou, A. - Multi-verse optimizer: a nature-inspired algorithm for global optimization. *Neural Comput & Applic* **27** (2016) 495–513. <https://doi.org/10.1007/s00521-015-1870-7>
5. Ting, T.O., Yang, X.S., Cheng, S., Huang, K. - Hybrid metaheuristic algorithms: Past, present, and future. In: Yang, X.S. (eds) *Recent Advances in Swarm Intelligence and Evolutionary Computation. Studies in Computational Intelligence* **585**. Springer, Cham (2015). https://doi.org/10.1007/978-3-319-13826-8_4

6. Rahmat-Samii Y. - Genetic algorithm (GA) and particle swarm optimization (PSO) in engineering electromagnetics, 17th International Conference on Applied Electromagnetics and Communications, 2003. ICECom 2003, Dubrovnik, Croatia (2003) 1-5. <http://doi.org/10.1109/ICECOM.2003.1290941>
7. Zhang X, Xue Y, Lu X, Jia S. - Differential-evolution-based coevolution ant colony optimization algorithm for bayesian network structure learning. *Algorithms* **11** (2018). <https://doi.org/10.3390/a11110188>
8. Katsigiannis Y.A, P. S. Georgilakis and E. S. Karapidakis - Hybrid simulated annealing-tabu search method for optimal sizing of autonomous power systems with renewables, in *IEEE Transactions on Sustainable Energy* **3** (3) (2012) 330-338. <http://doi.org/10.1109/TSTE.2012.2184840>
9. Bongale, A.M., Nirmala, C.R. & Bongale, A.M. - Hybrid cluster head election for WSN based on firefly and harmony search algorithms. *Wireless Pers Commun* **106** (2019) 275-306. <https://doi.org/10.1007/s11277-018-5780-8>
10. Zhou, J., & Yao, X. - A hybrid approach combining modified artificial bee colony and cuckoo search algorithms for multi-objective cloud manufacturing service composition. *International Journal of Production Research* **55** (16) (2017) 4765-4784 <https://doi.org/10.1080/00207543.2017.1292064>

ABSTRACT

COMBINING EFO AND MVO: A PARALLEL HYBRID AND INFORMATION SHARING STRATEGY APPLIED TO OPTIMIZATION PROBLEMS

Dinh Nguyen Trong Nghia^{1*}, Duong Thi Thuy Nga²

¹*Ho Chi Minh City University of Industry and Trade*

²*Ho Chi Minh City University of Natural Resources and Environment*

*Email: nghiadnt@huit.edu.vn

This paper proposes a hybrid strategy combining the Electromagnetic Field Optimizer (EFO) and the Multi-Verse Optimizer (MVO) using a parallel execution approach with periodic information sharing, called EFO-MVO. This hybrid method leverages the advantages of each algorithm: EFO's strong local exploitation and MVO's effective global exploration. To evaluate the performance of EFO-MVO, we conducted experiments on six well-known benchmark functions: Sphere, Rastrigin, Rosenbrock, Ackley, Griewank, and Zakharov. The results demonstrate that EFO-MVO consistently achieves superior optimization outcomes compared to standalone EFO, MVO, and Genetic Algorithm (GA). The EFO-MVO method effectively avoids local optima and converges quickly to the global optimum, indicating its robust potential for complex optimization problems.

Keywords: Hybrid Optimization Algorithm, Electromagnetic Field Optimizer (EFO), Multi-Verse Optimizer (MVO), Benchmark Functions, Metaheuristic Combination.