

Mixed Algorithm 개발과 이를 이용한 직류 모터의 최적설계

*오 용환, *정 태경, **김 민규
*중앙대학교 전기공학과, **삼성전자 자동화 연구소

Optimal Design of DC motor using Mixed Algorithm

*Yong-Hwan Oh, *Tae-Kyung Chung, **Min-Kyu Kim

*Dept. of Electrical Eng., Chung Ang Univ., **FA Research Inst., Samsung Electronics Co.,Ltd.

Abstract - This paper discusses the development of a new optimization algorithm for DC motor design. In principle, the new algorithm utilizes a mixed method that consists of genetic algorithms in conjunction with direct search method. The genetic algorithms are used for locating the global optimum region while the direct search method is used to achieve objective function convergence. In order to validate the effectiveness, the new algorithm has been applied to an actual DC motor. Field and torque characteristics of the DC motor are computed using finite element method and the principle of virtual work, respectively.

1. 서 론

최적화 알고리즘은 크게 두 가지 분류로 구분할 수 있다. 즉 확률론적(stochastic) 알고리즘과 결정론적(deterministic) 알고리즘이다. 각각의 알고리즘은 그들 자신들 고유의 장점과 단점을 가지고 있다. 확률론적 알고리즘의 장점은 다음과 같다: 1) 미분을 필요로 하지 않는다. 2) 전역 해(global optimum)를 찾을 확률이 매우 높다. 3) 출발시점에 독립적이다.

그러나 이러한 장점에 반해 단점은 결정론적 알고리즘 보다 훨씬 더 많은 목적 함수 계산을 해야한다는 것이다. 즉 수렴 속도가 늦다는 점이다.

이에 반해 결정론적 알고리즘은 목적 함수의 미분을 이용해 최소값을 찾는다. 이 알고리즘의 효율은 출발 시점, 기울기의 도출의 정확성, 선 탐색(line search)을 행하는 데 사용되는 방법 그리고 정지 기준(stopping criteria) 등에 의존하고 있다. 일반적으로 이 알고리즘은 주어진 함수가 유일해질 때 전역 해(global optimum)를 갖는 것을 제외하고는 지역 해(local optimum)값이다 [1]. 이 알고리즘의 단점은 미분 과정이 필요하다는 것과 전역 해(global optimum)를 얻었다는 확신을 할 수 없다는 것이다.

이논문에서 제안된 새로운 알고리즘은 두 가지 방법 즉 확률론적 알고리즘과 결정론적 알고리즘의 접근방법을 알고리즘에 기초로 하고 있다.

확률론적 접근방법으로 유전 알고리즘(GAs)을 사용하였고 결정론적 접근방법으로 직접 탐색 방법(direct search method)이 이용되었다.

이 두 알고리즘을 합한 근거는 첫째로 GAs는 전역 해(global optimum)를 찾는데 효율적이고, 둘째로 직접 탐색 방법(direct search method)은 수렴 속도를 높이는데 효율적이라는 것이다.

이 두 알고리즘을 연결시킨 방법론은 본론에서 자세히 다루기로 하겠다.

2. 본 론

2.1 GAs와 Direct Search Method

유전 알고리즘은 자연 선택(natural selection), 재생산

(reproduction), 교배(crossover), 돌연변이(mutation) 등 생태계에서 발생되는 진화 과정을 기반으로 한 확률론적 알고리즈다. 다른 알고리즘과 구별되는 GAs의 진행과정은 다음의 4가지로 설명된다. 1) GAs는 확률론적(probabilistic) 변이법칙을 이용한다. 2) GAs는 출발점이 필요 없이 많은 점을 가진 집단(population)으로 시작한다. 3) GAs는 파라미터의 값을 코드화해서 작업한다. 이 코드는 생물체의 자연 유전자와 비슷하다. 4) GAs는 지금 세대의 정보를 다음 세대로 전달해 준다 [2]. GAs는 많은 다른 환경 속에서 적응되어진 자연의 능력을 기본개념으로 했기 때문에 어떠한 상황에서도 유동적이지 않다. 또한 매우 넓은 범위에서의 탐색과 목적 함수의 형상을 완전히 알지 못하는 상황에서도 효율적이기 때문에 전역 해(global optimum)를 찾을 수 있다 [3]. 그럼 1은 GAs의 순서도이다.

다른 한편으로 GAs는 전역 해가 있는 영역으로의 탐색 속도는 비교적 매우 빠른 편이나 그 영역을 찾은 후에 실제 수렴해 가는 속도는 비교적 느린 편이다 [4]. 그러므로 최종해를 찾는데 결정론적 알고리즘보다 훨씬 많은 세대수 즉 많은 목적 함수를 계산해야 하는 단점이 있다. 또한 변수의 비트에 의한 조작이므로 변수들의 비트 길이에 정확도가 매우 의존적이다. 따라서 정확도가 떨어진다.

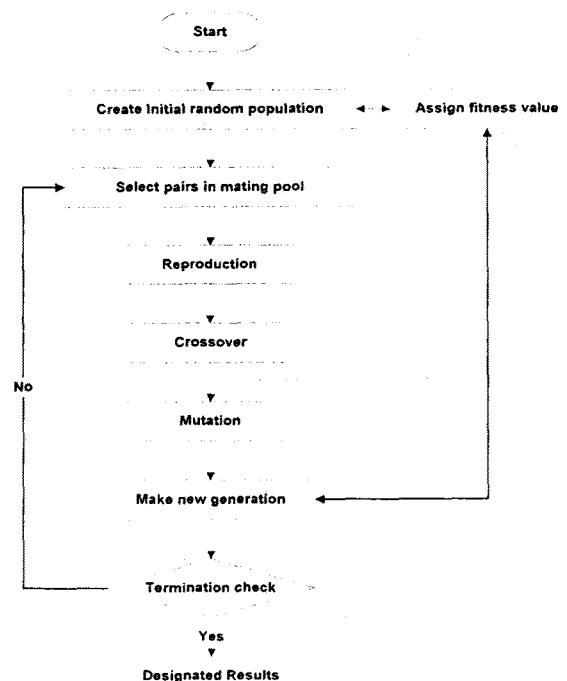


그림 1. 유전알고리즘의 순서도

결정론적 알고리즘의 하나인 직접 탐색 방법(direct search method)은 임의 방향(random direction)을 기본으로 최적해를 찾는 방법이다. 이 방법은 다음과 같은 특성을 지닌다: 1) 목적함수의 미분이 필요하지 않다. 2) 최적해를 구하기 위해서 적절한 시작점이 주어져야 한다. 이 방법의 효율은 이점에 매우 의존적이다. 그러므로 신중히 시작점을 선택해야 한다. 3) 최적조건에 만족할 때까지 단계적으로 반복 과정을 거쳐 해에 이른다. 4) 이 방법의 수렴속도는 매우 빠르고 이 장점은 확률론적 알고리즘에서 가장 필요로 되는 기능이다 [5]. 그러나 직접 탐색 방법(direct search method)의 가장 큰 단점은 그 해는 목적함수가 유일해(unimodal)가 아니면 지역해일 가능성이 매우 크다. 즉 최종해가 전역해, 즉 최적해임을 신뢰하기가 매우 힘들다 [4].

2.2 Mixed Method

이 논문에서 제안한 mixed method는 유전 알고리즘(genetic algorithms)과 직접 탐색 방법(direct search method)의 장점을 최대한으로 이용하였다. 이들 두 알고리즘의 장점을 극대화시키기 위해서 새 알고리즘의 원리는 다음과 같다. GAs는 알고리즘의 시작에서 전역해가 놓인 영역을 찾을 때까지 진행한다 [4]. 현재의 지점이 전역해가 있는 영역에 위치하면 이 점은 직접 탐색 방법(direct search method)의 특성 중 두 번째에 해당하는 시작점의 최적의 점이 된다. 따라서 다음 단계는 직접 탐색 방법으로 진행한다. 이 지점에서 직접 탐색 방법을 적용하는 2가지 이유는 다음과 같다: 1) 목적함수의 계산을 최소화하므로 수렴속도를 개선시킬 수 있다. 2) 이 지점으로부터 직접 탐색 방법을 적용해서 얻은 최종해는 GAs의 비트길이의 의존하는 해에 비해서 더욱 더 정확한 해를 얻을 수 있다.

제안된 mixed method의 주요 아이디어는 GAs로부터 직접 탐색 방법으로 넘어가는 시점을 최적으로 알아내는 것이다. 즉 최적의 조건식이 필요한 것이다. GAs로부터 얻어진 영역이 전역해가 있는 영역인지에 대한 근거가 필요한 것이다. 이 논문에서 이 문제를 (1)식으로 조건식을 제안했다. 평균 목적함수의 값과 가장 좋은 목적함수의 값의 차이를 ϵ 으로 놓고 ϵ 을 목적함수의 형태에 따라 변동 시켜 적절한 값을 책정한다. 이 논문에서는 ϵ 을 가장 좋은 목적함수의 값의 5%로 써 취했다. 근거는 가장 좋은 목적함수의 값과 평균 목적함수의 값의 차이가 적다는 것은 집단의 모든 점들이 한 영역에 들어왔다는 증거이기 때문에 많은 점을 가진 집단을 가지고 시작하는 GAs로써는 이 때의 위치가 전역해가 있는 영역임을 증명하는 충분한 근거를 제공한다.

다음에서는 최대값이 1인 sinc 함수 즉 식 (2)를 예제로써 최대 값을 mixed method와 CGAs(conventional GAs)로 비교하여 구하였다. 여기서 변수의 수는 세개이다. Mixed method는 알고리즘의 변화 시점을 식(1)에 대해서 택하였다.

Mixed method의 수렴성능을 표 1에서 CGAs와 비교하여 보였다.

$$|Fitness_{avg} - Fitness_{best}| < \epsilon. \quad (1)$$

$$F = \frac{\sin c \sum_{i=1}^3 |X_i - 3.14|}{\sum_{i=1}^3 |X_i - 3.14|} \quad (2)$$

표 1에서 보인 값들은 10회를 실행해서 얻은 결과를 평균하여 보인 결과 값들이다. 표 1에서 알 수 있듯이 목적함수의 계산 수가 CGAs보다 훨씬 적음을 알 수 있다. 그리고 구해진 해 또한 CGAs는 1에 정확히 도달하지 못한데 반해 mixed method는 정확히 1에 도달했음을 알

수 있다. 이 논문에서는 보이지 않았지만 DeJong 함수 6개에 적용한 결과, 성능을 위와 같이 입증할 수 있었다. 위의 예는 mixed method의 장점과 논문에서 의도하는 결과를 잘 입증해 주고 있다.

표 1. Mixed method 와 Conventional의 결과 값

	Cost func.	Call No.	Average Result
Mixed Method	639.4	1	
CGAs	1294.0	0.9999906	

Mixed method와 CGAs의 수렴특성을 그림 2와 그림 3에 제시하였다. 그림 2는 목적함수의 값이 0.976727에서 직접 탐색 방법으로 전환했음을 보여 주고 있다. 그 이후 10세대도 지나기 전에 정확히 1을 찾아 수렴했다. 반면 CGAs의 해는 0.999994이고 또한 mixed method의 비해 세대수 또한 일등히 많음을 볼 수 있다.

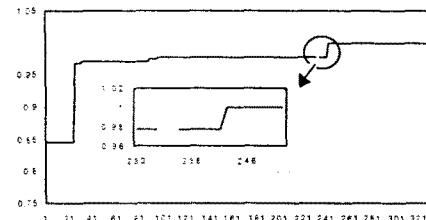


그림 2. Mixed method의 수렴 특성

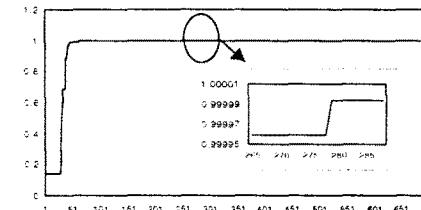


그림 3. Conventional GAs의 수렴 특성

2.3 직류모터의 최적설계

제안된 알고리즘을 직류모터의 최적설계에 적용하였다. 코킹 토크를 목적함수로 정하고 토크의 크기를 구속조건(constraint)으로 선택하였다. 그림 4는 최적설계에 이용된 직류모터의 단면적이다. 이 예제에서 설계변수는 회전자자의 치높이(H_{ir}), 회전자자의 치폭의 반($W_{ir}/2$) 그리고 자석의 가장자리의 두께(W_m)이다.

직류모터의 특성을 해석하고 문제를 푸는데 유한요소법(Finite Element Analysis)이 이용되었다. 토크의 계산을 위해서 virtual work의 기본개념이 이용되었다 [6]. 코킹 토크를 계산하기 위해서 로터의 각을 -14도에서 14도까지 돌려 각각의 토크값을 계산하였다.

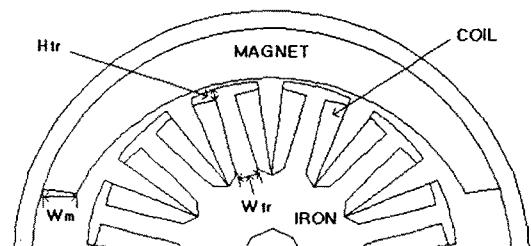


그림 4. 직류 모터의 단면적

이 예제에서 목적함수의 식은 다음과 같다.

$$\text{Objective Function} = \sqrt{\frac{\sum_{i=1}^n (\tau_i - M)^2}{n}}, \quad (3)$$

여기서 τ 는 i 번쨰의 각의 토크값,
 M 은 모든 각들에서의 평균 토크값,
 n 은 총 계산해야 할 각들의 수이다.

그림 5는 코킹 토크의 최적화 과정이다. 그림에서 가로축은 세대수를, 세로축은 식(3)에서 얻어진 값이다. 그림에서 전역해 주위까지 수렴해 들어갔다. 그 지점의 값은 0.038470 ($kg \cdot cm$)이다. 이후에 직접 탐색 방법으로 과정을 진행해 나가서 수십 세대가 지난 후에 목적 함수의 값이 0.037352 ($kg \cdot cm$)에서 수렴했다.

그림 6과 그림 7은 최적 설계된 결과를 나타낸 것이다. 그림 6은 공극에서의 mesh가 잘 잘려진 것을 볼 수 있다. node의 수는 2427개이고 요소의 수는 4789개이다. 그림 7은 적용된 모델의 flux의 형태를 보였다.

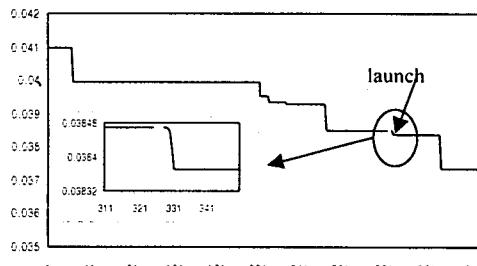


그림 5. 코킹 토크 최적화 과정
 (constraint $1.25 kg \cdot cm$)

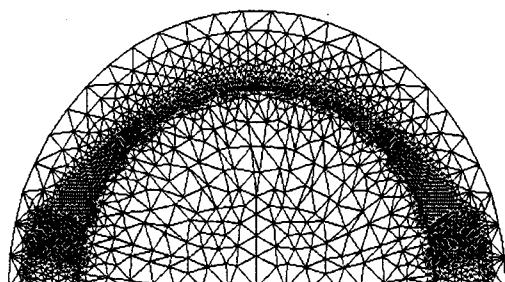


그림 6. 최적화 모델의 mesh diagram

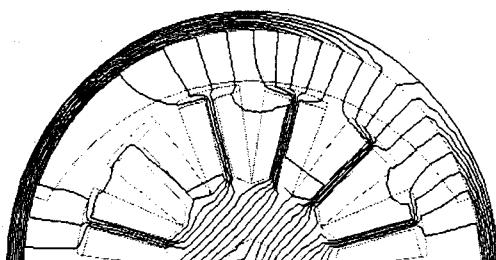


그림 7. 최적화 모델의 flux line

그림 8은 최적화 되기 전의 모델과 최적화된 모델의 토크를 각각의 각도에 따라서 나타난 것이다. 원래의 토크의 평균은 $1.395 (kg \cdot cm)$ 그리고 코킹 토크는 $0.073190 (kg \cdot cm)$ 이다. 최적 설계된 직류모터의 토크의 평균은 $1.31 (kg \cdot cm)$ 이고 코킹 토크는 $0.037352 (kg \cdot cm)$ 이다. 원래의 모델과 비교해 보면 코킹 토크는 $0.073190 (kg \cdot cm)$ 에서 $0.037352 (kg \cdot cm)$ 로 약 반으로 감소하였지만 토크 평균은 93.90681% 로 줄어서 매우 효율적이게 설계되었음을 알 수 있다.

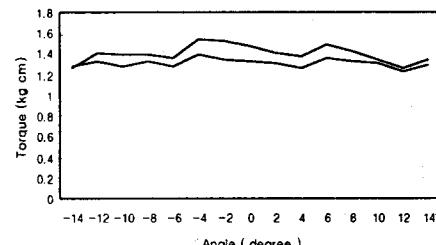


그림 8. 최적 설계 적용이전의 모델과 최적 설계된 모델의 토크 프로파일

3. 결 론

직류모터의 최적 설계를 하기 위해서 mixed method라는 새로운 알고리즘을 개발하여 이 논문에서 제안하였다. mixed method는 유전알고리즘(GAs)과 직접 탐색 방법(direct search method)을 결합하여 만들어졌다. mixed method의 장점은 더욱 빠른 수렴속도 그리고 더욱 높은 정확도이다. 이는 mixed method를 CGAs(conventional genetic algorithms)와 비교해 봄으로써 쉽게 알 수가 있었다. 직류모터의 특성을 해석하는데 유한요소법(Finite Element Analysis)을 이용하였다. 위에 제시된 예제의 결과를 통해서 제안된 알고리즘이 전기 기기의 최적설계를 위해 매우 유용함을 알 수 있었다.

[참 고 문 헌]

- [1] J.A. Vasconcelos, R.R. Saldanha, L. Krahenbuhl, A. Nicolas, "Genetic Algorithm Coupled with a Deterministic Method for Optimization in Electromagnetics", IEEE Trans. on Mag., vol. 33, no. 2, pp. 1860-1863, March 1997.
- [2] D.E. Goldberg, Genetic Algorithm Search, Optimization & Machine Learning, Reading, Massachusetts: Addison-Wesley Publishing Company, Inc., 1989.
- [3] Alessandra Fanni, Michele Marchesi, Antonio Serri and Mariangela Usai, "A Greedy Genetic Algorithm for Continuous Variables Electromagnetic Optimization Problems", IEEE Trans. on Mag., vol. 33, no. 2, pp. 1900-1903, March 1997.
- [4] O.A. Mohammed and G.F. Uler, "A Hybrid Technique for the Optimal Design of Electromagnetic Devices Using Search and Genetic Algorithms", IEEE Trans. on Mag., vol. 33, no. 2, pp. 1931-1934, March 1997.
- [5] S.Rao Singiresu, Engineering Optimization, Theory and Practice: John Wiley & Sons, Inc., 1996.
- [6] J.L. Coulomb and G. Meunier, "Finite Element Implementation of Virtual Work Principle for Magnetic of Electric Force and Torque Computation", IEEE Trans. on Mag., vol. 19, no 5, pp. 1894-1896, September 1984.