(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0106009
(43) 공개일자 2025년07월09일

(51) 국제특허분류(Int. Cl.)
G06F 30/23 (2020.01) *G06F 111/04* (2020.01)
G06F 111/06 (2020.01) *G06F 30/27* (2020.01)
(52) CPC특허분류
G06F 30/23 (2020.01)
G06F 30/27 (2020.01)
(21) 출원번호 10-2024-0000275
(22) 출원일자 2024년01월02일
심사청구일자 2024년01월02일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
최길수
인천광역시 미추홀구 토금남로 79, 101동 1408호(용현동, 우성아파트)
최민규
인천광역시 미추홀구 인하로148번길 15, 201호(용현동)
(74) 대리인
양성보

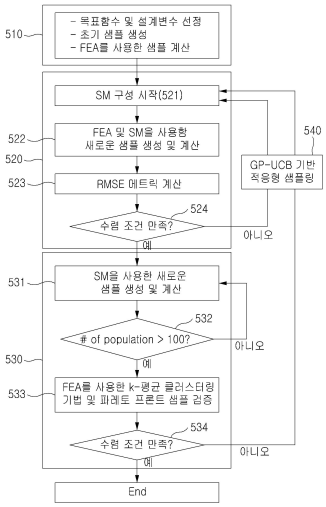
전체 청구항 수 : 총 8 항

(54) 발명의 명칭 **전기기기 최적설계 방법**

(57) 요 약

GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법 및 시스템이 제시된다. 본 발명에서 제안하는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법은 초기 설정부를 통해 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정 단계, 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계, 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계 및 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB(Gaussian Process-based Upper Confidence Bound) 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계를 포함한다.

대 표 도 - 도5



(52) CPC특허분류
G06F 2111/04 (2020.01)
G06F 2111/06 (2020.01)

이 발명을 지원한 국가연구개발사업
과제고유번호 1415188402
과제번호 P0017124
부처명 산업통상자원부
과제관리(전문)기관명 한국산업기술진흥원
연구사업명 신산업융합형임베디드시스템전문인력양성사업
연구과제명 신산업융합 생태계 구축을 위한 인공지능 기반 임베디드시스템 고급인력양성(3차년도)
과제수행기관명 인하대학교 산학협력단
연구기간 2023.03.01 ~ 2024.02.29

명 세 서

청구범위

청구항 1

초기 설정부를 통해 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정 단계;

대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계;

최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계; 및

상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB(Gaussian Process-based Upper Confidence Bound) 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계

를 포함하는 다목적 설계 최적화 방법.

청구항 2

제1항에 있어서,

상기 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계는,

상기 목적함수 및 제약조건에 따라 생성된 초기 샘플을 이용하여 FEA(Finite Element Analysis)을 사용한 새로운 샘플 계산을 수행하고, 계산된 FEA 결과를 대리모델 학습 데이터셋 집합에 통합하여 상기 대리 모델에 대한 예측 결과와 상기 FEA 계산 결과를 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성하는

다목적 설계 최적화 방법.

청구항 3

제1항에 있어서,

상기 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계는,

상기 대리모델에 대해 상기 메타휴리스틱 최적화 알고리즘을 사용하여 상기 목적 함수에 대하여 최적화 성능(Pareto front)을 식별하고, 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성하는

다목적 설계 최적화 방법.

청구항 4

제1항에 있어서,

상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계는,

활용과 탐색(exploitation and exploration)을 혼합한 GP-UCB에 대한 최적화 성능을 계산하고, GP-UCB 예측의 근사 오류로 인한 로컬 최소값 문제를 방지하기 위해 공간 채우기 기법을 사용하여 새로운 샘플을 생성하고, 상기 새로운 샘플을 대리모델 학습 데이터셋 집합에 추가한 후, 상기 대리모델을 구성하는 단계부터 다시 반복 수행하는

다목적 설계 최적화 방법.

청구항 5

기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정부;

설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 대리모델 구성부;

상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 최적화 수행부; 및

상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 GP-UCB 기반 적응형 샘플링부

를 포함하는 다목적 설계 최적화 시스템.

청구항 6

제5항에 있어서,

상기 대리모델 구성부는,

상기 목적함수 및 제약조건에 따라 생성된 초기 샘플을 이용하여 FEA(Finite Element Analysis)을 사용한 새로운 샘플 계산을 수행하고, 계산된 FEA 결과를 대리모델 학습 데이터셋 집합에 통합하여 상기 대리 모델에 대한 예측 결과와 상기 FEA 계산 결과를 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성하는

다목적 설계 최적화 시스템.

청구항 7

제5항에 있어서,

상기 최적화 수행부는,

상기 대리모델에 대해 상기 메타휴리스틱 최적화 알고리즘을 사용하여 상기 목적 함수에 대한 최적화 성능(Pareto front)을 식별하고, 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성하는

다목적 설계 최적화 시스템.

청구항 8

제5항에 있어서,

상기 GP-UCB 기반 적응형 샘플링부는,

활용과 탐색(exploitation and exploration)을 혼합한 GP-UCB에 대한 최적화 성능을 계산하고, GP-UCB 예측의 근사 오류로 인한 로컬 최소값 문제를 방지하기 위해 공간 채우기 기법을 사용하여 새로운 샘플을 생성하고, 상기 새로운 샘플을 대리모델 학습 데이터셋 집합에 추가한 후, 상기 대리모델을 구성하는 단계부터 다시 반복 수행하는

다목적 설계 최적화 시스템.

발명의 설명

기 술 분 야

[0001] 본 발명은 전기기기 최적설계 방법에 관한 것으로, 더욱 상세하게는 가우시안 프로세스 기반 접근방식을 이용한 전기 모터 설계 방법에 관한 것이다.

배 경 기 술

[0002] 전기자동차(Electric Vehicles; EV)가 주류로 부상함에 따라 전기모터의 성능 특성을 최적화하는 것이 매우 중요해졌다. 그러나 기존 모터 설계 방식의 한계가 명확해지고 있어 보다 강력하고 효율적인 설계 방법론이 요구되고 있다.

[0003] 회전하는 전기 모터는 복잡한 기하학적 구조와 비선형 자기 포화 특성으로 인해 해석적 접근법이 아닌 유한요소 해석(Finite Element Analysis; FEA)과 같은 수치적 방법을 사용하여 설계되는 경우가 많다. FEA와 같은 컴퓨터 시뮬레이션은 설계 과정에 도움이 되지만 다양한 성능 특성을 위한 전기기기의 최적화에는 어려움이 있다. 이러한 과제에는 설계 공간 전체에 대한 탐색을 필요로 하는 다변수 및 다목적 최적화 문제가 포함된다. 그러나 특히 설계 변수의 수가 증가함에 따라 FEA와 관련된 계산 비용은 전체 설계 공간 탐색을 비실용적으로 만든다.

[0004] 기존의 최적화 접근 방식의 한계에 대응하여 최근 몇 년 동안 메타휴리스틱 알고리즘 기반 기계 설계 최적화에 대한 연구가 활발히 진행되고 있다. 유전 알고리즘, PSO(Particle Swarm Optimization) 및 FEA 기반의 유사한 방법을 활용하는 기법이 연구되었다. 이러한 메타휴리스틱 알고리즘은 최적의 솔루션을 제공하지만 상당한 계산이 필요하여 상당한 계산 시간이 소요된다. 이를 해결하기 위해 최근 연구에서는 대리 보조 메타휴리스틱 알고리즘이 제안되었다. 종래기술에 예시된 접근 방식은 Kriging, 인공 신경망(Artificial Neural Networks; ANNs) 및 지원 벡터 회귀(Support Vector Machine; SVM)와 같은 대리 모델 활용(Surrogate Models; SMs)에 대한 체계적인 설계 최적화 프로세스를 제안한다. 이러한 접근 방식은 정확도를 손상시키지 않으면서 계산 시간을 크게 단축하지만 SM 구성 및 진화적 검색 알고리즘에 대한 효과적인 샘플 선택은 아직 완전히 논의되지 않았다.

[0005] SM의 정확성과 효율성은 학습에 사용되는 데이터셋의 품질 및 양과 밀접한 관련이 있다. 최적의 설계를 위해서는 학습 데이터셋이 전체 입력 공간을 대표해야 편향을 방지하고 대리 모델이 효과적으로 일반화될 수 있다. 데이터셋 선택의 중요한 역할에도 불구하고, 효율성과 빠른 수렴을 위한 데이터 선택 전략 최적화에 대한 전기기기 설계에 관한 연구는 부족하다.

선행기술문헌

비특허문헌

[0006] (비특허문헌 0001) [1] Choi, M.; Choi, G.; Bramerdorfer, G.; Marth, E. Systematic Development of a Multi-Objective Design Optimization Process Based on a Surrogate-Assisted Evolutionary Algorithm for Electric Machine Applications. Energies 2023, 16, 392. https://doi.org/10.3390/en16010392.

발명의 내용

해결하려는 과제

[0007] 본 발명이 이루고자 하는 기술적 과제는 전기기기의 최적 설계를 위한 가우시안 프로세스 기반 알고리즘 적용이라는 최첨단 접근 방식을 도입한 전기기기 최적설계 방법을 제공하는데 있다. 복잡하고 비선형적인 관계를 모델링하기 위한 가우시안 프로세스(Gaussian Process; GP)를 통해 설계 공간을 효율적으로 탐색할 수 있는 방법을 제공하고, 전기기기 설계에서 전반적인 성능을 향상시키면서 전력 밀도를 최대화하는 설계 구성을 식별하고자 한다.

과제의 해결 수단

[0008] 일 측면에 있어서, 본 발명에서 제안하는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법은 초기 설정부를 통해 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정 단계, 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계, 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계 및 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB(Gaussian Process-based Upper Confidence Bound) 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계를 포함한다.

[0009] 상기 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계는 상기 목적함수 및 제약조건에 따라 생성된 초기 샘플을 이용하여 FEA(Finite Element Analysis)을 사용한 새로운 샘플 계산을 수행하고, 계산된 FEA 결과를 대리모델 학습 데이터셋 집합에 통합하여 상기 대리 모델에 대한 예측 결과와 상기 FEA 계산 결과를 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성한다.

[0010] 상기 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계는 상기 대리모델에 대해 상기 메타휴리스틱 최적화 알고리즘을 사용하여 상기 목적 함수에 대하여 최적화 성능(Pareto front)을 식별하고, 미리 정해진 수렴 기준을 충족할 때까지 반복적으로 비교하여 만족하지 않을 경우 GP-UCB를 구성한다.

[0011] 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계는 활용과 탐색(exploitation and exploration)을 혼합한 GP-UCB에 대한 최적화 성능을 계산하고, GP-UCB 예측의 근사 오류로 인한 로컬 최소값 문제를 방지하기 위해 공간 채우기 기법을 사용하여 새로운 샘플을 생성하고, 상기 새로운 샘플을 대리모델 학습 데이터셋 집합에 추가한 후, 상기 대리모델을 구성하는 단계부터 다시 반복 수행한다.

[0012] 또 다른 일 측면에 있어서, 본 발명에서 제안하는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템은 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정부, 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 대리모델 구성부, 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 최적화 수행부 및 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 GP-UCB 기반 적응형 샘플링부를 포함한다.

발명의 효과

[0013] 본 발명의 실시예들에 따르면 EPS(Electric Power Steering) 모터의 최적 설계를 위해 복잡하고 비선형적인 관계를 모델링하기 위한 가우시안 프로세스(Gaussian Process; GP)를 적용하여 설계 공간을 효율적으로 탐색할 수 있는 방법을 제공하고, 전기기기 설계에서 전반적인 성능을 향상시키면서 전력 밀도를 최대화하는 설계 구성을 식별할 수 있다. 또한, 활용과 탐색을 혼합한 적응형 샘플링을 이용한 설계 최적화 과정을 통해 모형의 정확도와 수렴속도를 동시에 향상시킬 수 있다.

도면의 간단한 설명

[0014] 도 1은 본 발명의 일 실시예에 따른 추가 샘플링 예시를 비교하기 위한 도면이다.

도 2는 본 발명의 실시예에 따른 가우시안 프로세스와 GP-UCB의 입출력 관계를 보여줍니다.

도 3은 종래기술에 따른 최적화 프로세스를 설명하기 위한 흐름도이다.

도 4는 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링 방법을 설명하기 위한 흐름도이다.

도 5는 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법을 설명하기 위한 흐름도이다.

도 6은 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템의 구성을 나타내는 도면이다.

도 7은 본 발명의 일 실시예에 따른 72슬롯/8폴 IPMSM 기본 모델의 단면을 나타내는 도면이다.

도 8은 본 발명의 일 실시예에 따른 활용과 탐색 사이의 균형을 비교하기 위한 도면이다.

도 9는 본 발명의 일 실시예에 따른 수렴 속도를 비교하기 위한 도면이다.

도 10은 본 발명의 일 실시예에 따른 초기 샘플링에 대한 민감도를 설명하기 위한 도면이다.

도 11은 본 발명의 일 실시예에 따른 5번의 시뮬레이션 실행 간의 반복성 비교를 나타내는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0015] 전기기기의 효율적인 설계 최적화는 높은 전력 밀도, 효율성 및 낮은 진동을 포함하는 성능 기준을 충족하는 데 어려움을 겪고 있다. 기존 방식의 최적화 접근 방식은 종종 전역 솔루션을 찾지 못하거나 과도한 계산 시간의 문제점을 가지고 있다. 본 발명에서는 기존 방식의 한계에 대응하여 메타휴리스틱 알고리즘을 사용하는 대리 보조 최적화 프로세스에 가우시안 프로세스 기반 적응형 샘플링 기법을 통합하는 새로운 방법을 제안한다. 72슬롯/8폴 매입형 영구 자석(Interior Permanent Magnet; IPM) 모터에 대한 검증을 통해 제안하는 방식의 우수성을 확인하고, 기존 최적화 방식에 비해 향상된 활용-탐색 균형, 더 빠른 수렴 및 향상된 반복성을 확인하였다. 이하, 본 발명의 실시 예를 첨부된 도면을 참조하여 상세하게 설명한다.

[0017] 가우시안 프로세스는 Kriging 방법으로도 알려져 있으며 입력 및 출력 데이터를 기반으로 고차원 공간에서 데이터를 예측하는 보간 기법으로 사용된다. GP 알고리즘은 전기기기의 설계 최적화에 널리 적용되고, 사전 계산된 시뮬레이션 결과에서 대리 모델을 구성하여 계산 시간을 크게 단축하며, 특히 광범위한 비선형 수치 계산에 유용하다. 최근 연구에서는 최소 계산으로 필요한 정확도를 보장하는 대리 모델을 구축하는 데 중점을 두고 효율적이고 정확한 설계 탐색을 위한 적응형 샘플링을 통한 SBO(Surrogate-Based Optimization)의 효율성을 강조하고 있다.

[0018] 최적화 프로세스의 중추적인 기법인 적응형 샘플링은 설계 공간의 중요한 영역에 전략적으로 새로운 샘플을 도입하여 대리 모델을 반복적으로 개선한다. 기존 대리 모델의 응답 표면 정보에 의해 유도되는 이러한 개선은 대리 모델의 효율적인 구성을 촉진하여 샘플 크기와 계산 시간을 단축하고 정확도를 향상시킨다. 샘플 선택 기준에 대한 두 가지 주요 기술인 활용과 탐색은 프로세스의 효율성을 최적화하는 데 필수적인 역할을 한다.

[0019] 활용은 주어진 정보를 바탕으로 함수의 가장 좋은 값으로 예측된 점을 식별하여 다음 샘플을 생성하는 것으로 K-폴드 교차 검증과 LOOCV(Leave-One-Out Cross Validation) 등의 기법을 사용한다.

[0021] 도 1은 본 발명의 일 실시예에 따른 추가 샘플링 예시를 비교하기 위한 도면이다.

[0022] 도 1(a)는 초기 샘플링(111)에 대하여 활용을 이용한 추가 샘플링(112)을 적용한 경우의 제1 예시를 보여준다. 이 기법을 사용하면 효율적인 설계 공간 탐색이 가능하여 샘플 분포를 개선하고 최적의 점을 찾는 데 소요되는 시간을 줄일 수 있다는 장점이 있다. 그러나 관심 공간을 간과하지 않도록 주의가 필요하다. 반면, 탐색은 더 나은 결과로 이어질 수 있는 분산이 크거나 빈 공간으로 설계 공간으로부터 정보를 수집하기 위해 다음 샘플을 생성한다.

[0023] 도 1(b)는 초기 샘플링(121)에 대하여 탐사를 이용한 추가 샘플링(122)을 적용한 경우의 제2 예시를 보여준다. 샘플 간의 거리, 샘플의 분산, 공간 채우기를 기반으로 하는 기법은 불확실성을 줄이고 대리 모델의 예측 정확도를 향상시킬 수 있는 장점으로 인해 탐색에서 많이 사용된다. 그러나 불필요한 공간에서 샘플을 생성할 경우 계산 부담이 증가할 수 있다.

[0024] 본 발명에서는 다변량, 다중 목적 최적화 문제의 중요한 과제인 활용-탐색 트레이드오프를 다룬 가우시안 프로세스 기반 접근방식을 이용한 전기 모터 및 그 동작 방법을 제안한다.

[0025] 이러한 문제를 해결하기 위해 예상 개선(Expected Improvement; EI), 개선 확률(Probability of Improvement; PI), 신뢰 상한(Upper Confidence Bound; UCB)을 포함한 다양한 적응형 샘플링 알고리즘이 제안되었다.

[0026] 본 발명의 실시예에 따르면, 그 중에서 대리 모델의 정확성을 높이고 최적화 효율성을 향상시키기 위해 유연한 매개변수 조정 기능을 갖춘 효율적인 샘플링 접근 방식을 사용하는 가우시안 프로세스 기반 UCB(Gaussian Process-based UCB; GP-UCB) 샘플링 방법을 선택한다.

[0028] 도 2는 본 발명의 실시예에 따른 가우시안 프로세스와 GP-UCB의 입출력 관계를 보여줍니다.

[0029] 본 발명에서 제안하는 GP-UCB 기반 적응형 샘플링은 도 2의 선(210)과 같이 평균과 분산의 합이 가장 큰 데이터로부터 다음 샘플을 생성한다. 입력 변수 x에 대한 GP-UCB 함수 U(x)는 다음과 같이 표현될 수 있다:

[0030] $$U(x) = \mu(x) + \kappa\sigma(x) \quad (1)$$

[0031] 여기서 $\mu(x)$는 GP 회귀 분석으로 계산된 평균값, $\sigma(x)$는 분산, κ는 신뢰 한계의 특성을 제어하기 위한 하이퍼 파라미터이다. 하이퍼 파라미터가 클수록 상한값이 커지며, 알고리즘은 설계 공간의 현재 미개척 영역을 탐색하는 솔루션을 선호한다. 반면, κ가 작을 때 알고리즘은 고성능 솔루션을 찾는 데 더 중점을 둔다.

[0032] 1차원 설계 변수와 관련된 문제를 해결할 때 샘플링 프로세스는 전체 설계 공간에 대한 응답 계산을 포함하여 간단하다. 그러나 전기기기 설계에서 설계 변수의 풍부함으로 인해 "차원의 저주(curse of dimensionality)"가 발생하여 전체 설계 공간에 대한 철저한 탐색이 과도한 계산 시간 소모를 초래한다. 또한 e-모빌리티 응용을 위해 설계된 전기 모터는 일반적으로 토크, 질량, 비용 및 효율성을 포함한 다양한 목적함수를 포함한다. 본 발명의 실시예에서는 GP-UCB 기반 설계 최적화 프로세스를 두 사례 연구에 적용하여 다중 목적 다중 변수 문제에 대한 포괄적인 최적화 솔루션을 제안하고자 한다.

[0034] 도 3은 종래기술에 따른 최적화 프로세스를 설명하기 위한 흐름도이다.

[0035] 종래기술에 따른 최적화 프로세스는 초기 대리 모델을 구성하기 위해 실험 설계(Design of Experiment DOE) 기법을 통해 생성된 초기 샘플에서 시작하여 고려 중인 전기기기의 성능 응답을 근사화한다.

[0036] 먼저, 목적 함수 및 제약 조건을 설정하고, Doe 기반 초기 샘플을 생성한다(310). 초기 샘플을 이용하여 FEA를 사용한 샘플 계산을 수행하고(320), 대리 모델(Surrogate Models; SM)을 구성한다(330). 이후, 새로운 샘플을 생성하고 FEA(Finite Element Analysis) 및 SM 데이터를 사용하여 평가한다(340).

[0037] SM 정확성을 평가하여(350), 중지 기준 충족 여부를 판단하고(360), 충족하지 않을 경우SM 학습에 FEA 결과를 추가하여(370), 다시 대리 모델을 구성한다(330). 중지 기준을 충족할 경우 최적화 프로세스를 종료한다.

[0038] 도 3에 도시된 종래기술에 따른 최적화 프로세스에서는 SM의 예측 결과를 FE 계산 결과와 반복적으로 비교하고, 계산된 FEA(Finite Element Analysis) 결과를 모델 학습 집합에 통합하여 수렴 기준을 충족할 때까지 정확도를 높인다.

[0040] 도 4는 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링 방법을 설명하기 위한 흐름도이다.

[0041] 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링 방법은 목적 함수 및 제약 조건을 설정하고, Doe 기반 초기 샘플을 생성한다(410). 초기 샘플을 이용하여 FEA를 사용한 샘플 계산을 수행하고(420), 대리 모델(Surrogate Models; SM)을 구성한다(430).

[0042] 이후, SM 정확성을 평가하여(440), 중지 기준 충족 여부를 판단하고(450), 중지 기준을 충족할 경우 GP-UCB 기반 적응형 샘플링 과정을 종료한다.

[0043] SM 정확성을 평가하여(440), 중지 기준 충족 여부를 판단하고(450), 충족하지 않을 경우 GP-UCB를 구성한다(460). 구성된 GP-UCB의 파레토 프론트(pareto front)를 계산하고(470), 대표 샘플을 선택하여 학습 데이터셋에 추가한다(480). 그리고, 공간 채우기 기법을 사용하여 새로운 샘플을 생성하고, 학습 데이터셋에 추가한 후(490), FEA를 사용한 샘플 계산부터 다시 반복 수행한다(420).

[0044] 도 3(b)에 도시된 바와 같이 제안된 기법은 GP-UCB와 메타휴리스틱 알고리즘을 활용하여 주어진 목적 함수에 대한 최적화 성능(Pareto front)을 식별한다. 이 정보는 이후 SM 학습을 위한 후속 데이터셋을 생성하는 데 사용된다. 그러나 GP-UCB 예측은 근사 오류로 인해 로컬 최소값에 직면할 수 있음이 인정된다. 이러한 문제를 방지하기 위해 제안된 최적화 프로세스는 공간 채우기 기법을 통합하여 미발견 영역에서 추가 샘플을 생성한다. 이는 유전 알고리즘의 돌연변이와 유사한 효과를 가진다.

[0046] 도 5는 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법을 설명하기 위한 흐름도이다.

[0047] 본 발명의 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 방법은 초기 설정부를 통해

기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정 단계(510), 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성하는 단계(520), 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축하는 단계(530) 및 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB(Gaussian Process-based Upper Confidence Bound) 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택하는 단계(540)를 포함한다.

[0048] 단계(510)에서, 초기 설정부를 통해 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정을 수행한다.

[0049] 본 발명의 실시예에 따르면, 기기 설계에 의해 목적함수인 출력토크밀도, 제작비용, 효율 등을 개선할 수 있도록 핵심 설계변수를 선정하고 그 범위를 설정한다.

[0050] 본 발명의 실시예에 따른 초기 샘플 생성을 위해 여러 가지 샘플링 기법을 사용할 수 있으며, 예를 들어, LHS(Latin hypercube sampling)과 Sobol sequence 기법 등이 있다. 본 발명의 일 실시예에서는 LHS 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0051] 단계(520)에서, 대리모델 구성부를 통해 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성한다.

[0052] 본 발명의 실시예에 따르면, 설계공간(design space) 탐색을 효율적으로 수행할 수 있도록 설계변수와 목적함수와의 상관관계를 정의하는 수학적 모델(다시 말해, 대리모델)을 구성한다.

[0053] 본 발명의 실시예에 따르면, 대리모델 구축을 위해 여러 가지 수학적 근사모델링 기법을 적용할 수 있으며, 예를 들어, Kriging(Gaussian process, GP), ANNs(Artificial Neural Networks), SVR(Space Vector Regression) 등이 있다. 본 발명의 일 실시예에서는 GP 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0054] 단계(530)에서, 최적화 수행부를 통해 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축한다.

[0055] 본 발명의 실시예에 따르면, 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축한다.

[0056] 본 발명의 실시예에 따르면, 메타휴리스틱 기반 전역 최적화에 여러 가지 알고리즘이 적용될 수 있으며, 예를 들어, 입자 군집 최적화(Particle Swarm Optimization; PSO), 유전 알고리즘(genetic algorithm), 차등 알고리즘(differential algorithm) 등이 있다. 본 발명의 일 실시예에서는 유전 알고리즘의 일종인 NSGA-II(Non-dominated Sorting Genetic Algorithm) 알고리즘이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0057] 단계(540)에서, 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, GP-UCB(Gaussian Process-based Upper Confidence Bound) 기반 적응형 샘플링부를 통해 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택한다.

[0058] 단계(530) 및 단계(540)의 결과가 미리 정해진 수렴조건을 만족하지 못할 경우, 대리모델을 학습시키는 학습 데이터셋에 GP-UCB 기반 적응형 샘플링 기법으로 새로운 샘플을 선택하여 추가한다.

[0059] 본 발명의 실시예에 따르면, 능동형 샘플링에 여러 가지 기법이 사용될 수 있으며, 예를 들어, GP-UCB(Gaussian process upper confidence bound), EI(Expected Improvement), PI(Probability of Improvement) 등이 있다. 본 발명의 예시에서는 GP-UCB 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0060] 본 발명의 실시예에 따르면, 주어진 설계영역 내에서 목표로 하는 목적함수 및 구속조건을 만족하는 전기기기 모델을 얻을 수 있으며, 효율과 토크밀도와 같은 상호 이율배반 관계에 있는 목적함수를 동시에 달성할 수 있는 전기기기 최적설계기법을 적용할 수 있다. 또한 순수 FEA 연산으로 진행되는 기존 방법과 비교하여 대리모델 및 GP-UCB 기반 적응형 샘플링 기법을 적용하여 계산의 정확도를 유지하면서 설계 시간을 획기적으로 단축시킬 수 있는 효과가 있다.

[0062] 도 6은 본 발명의 일 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템의 구성을 나타내는 도면이다.

[0063] 본 실시예에 따른 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)은 프로세서(610), 버스(620), 네트워크 인터페이스(630), 메모리(640) 및 데이터베이스(650)를 포함할 수 있다. 메모리(640)는 운영체제(641) 및 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 루틴(642)을 포함할 수 있다. 프로세서(610)는 초기 설정부(611), 대리모델 구성부(612), 최적화 수행부(613) 및 GP-UCB 기반 적응형 샘플링부(614)를 포함할 수 있다. 다른 실시예들에서 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)은 도 6의 구성요소들보다 더 많은 구성요소들을 포함할 수도 있다. 그러나, 대부분의 종래기술적 구성요소들을 명확하게 도시할 필요성은 없다. 예를 들어, GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)은 디스플레이나 트랜시버(transceiver)와 같은 다른 구성요소들을 포함할 수도 있다.

[0064] 메모리(640)는 컴퓨터에서 판독 가능한 기록 매체로서, RAM(random access memory), ROM(read only memory) 및 디스크 드라이브와 같은 비소멸성 대용량 기록장치(permanent mass storage device)를 포함할 수 있다. 또한, 메모리(640)에는 운영체제(641)와 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 루틴(642)을 위한 프로그램 코드가 저장될 수 있다. 이러한 소프트웨어 구성요소들은 드라이브 메커니즘(drive mechanism, 미도시)을 이용하여 메모리(640)와는 별도의 컴퓨터에서 판독 가능한 기록 매체로부터 로딩될 수 있다. 이러한 별도의 컴퓨터에서 판독 가능한 기록 매체는 플로피 드라이브, 디스크, 테이프, DVD/CD-ROM 드라이브, 메모리 카드 등의 컴퓨터에서 판독 가능한 기록 매체(미도시)를 포함할 수 있다. 다른 실시예에서 소프트웨어 구성요소들은 컴퓨터에서 판독 가능한 기록 매체가 아닌 네트워크 인터페이스(630)를 통해 메모리(640)에 로딩될 수도 있다.

[0065] 버스(620)는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)의 구성요소들간의 통신 및 데이터 전송을 가능하게 할 수 있다. 버스(620)는 고속 시리얼 버스(high-speed serial bus), 병렬 버스(parallel bus), SAN(Storage Area Network) 및/또는 다른 적절한 통신 기술을 이용하여 구성될 수 있다.

[0066] 네트워크 인터페이스(630)는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)을 컴퓨터 네트워크에 연결하기 위한 컴퓨터 하드웨어 구성요소일 수 있다. 네트워크 인터페이스(630)는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)을 무선 또는 유선 커넥션을 통해 컴퓨터 네트워크에 연결시킬 수 있다.

[0067] 데이터베이스(650)는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화를 위해 필요한 모든 정보를 저장 및 유지하는 역할을 할 수 있다. 도 6에서는 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)의 내부에 데이터베이스(650)를 구축하여 포함하는 것으로 도시하고 있으나, 이에 한정되는 것은 아니며 시스템 구현 방식이나 환경 등에 따라 생략될 수 있고 혹은 전체 또는 일부의 데이터베이스가 별개의 다른 시스템 상에 구축된 외부 데이터베이스로서 존재하는 것 또한 가능하다.

[0068] 프로세서(610)는 기본적인 산술, 로직 및 GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)의 입출력 연산을 수행함으로써, 컴퓨터 프로그램의 명령을 처리하도록 구성될 수 있다. 명령은 메모리(640) 또는 네트워크 인터페이스(630)에 의해, 그리고 버스(620)를 통해 프로세서(610)로 제공될 수 있다. 프로세서(610)는 초기 설정부(611), 대리모델 구성부(612), 최적화 수행부(613) 및 GP-UCB 기반 적응형 샘플링부(614)를 위한 프로그램 코드를 실행하도록 구성될 수 있다. 이러한 프로그램 코드는 메모리(640)와 같은 기록 장치에 저장될 수 있다.

[0069] 초기 설정부(611), 대리모델 구성부(612), 최적화 수행부(613) 및 GP-UCB 기반 적응형 샘플링부(614)는 도 5의 단계들(510~540)을 수행하기 위해 구성될 수 있다.

[0070] GP-UCB 기반 적응형 샘플링을 이용한 다목적 설계 최적화 시스템(600)은 초기 설정부(611), 대리모델 구성부(612), 최적화 수행부(613) 및 GP-UCB 기반 적응형 샘플링부(614)를 포함할 수 있다.

[0071] 본 발명의 실시예에 따른 초기 설정부(611)는 기기 설계에 따른 목적함수를 개선하기 위한 설계변수를 선정하고, 상기 목적함수 및 제약조건을 정의하는 초기 설정을 수행한다.

[0072] 본 발명의 실시예에 따른 초기 설정부(611)는 기기 설계에 의해 목적함수인 출력토크밀도, 제작비용, 효율 등을 개선할 수 있도록 핵심 설계변수를 선정하고 그 범위를 설정한다.

[0073] 본 발명의 실시예에 따른 초기 설정부(611)는 초기 샘플 생성을 위해 여러 가지 샘플링 기법을 사용할 수 있으

며, 예를 들어, LHS(Latin hypercube sampling)과 Sobol sequence 기법 등이 있다. 본 발명의 일 실시예에서는 LHS 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0074] 본 발명의 실시예에 따른 대리모델 구성부(612)는 설계공간 탐색을 효율적으로 수행하기 위해 상기 설계변수와 목적함수와의 상관관계를 정의하는 대리모델을 구성한다.

[0075] 본 발명의 실시예에 따르면, 설계공간(design space) 탐색을 효율적으로 수행할 수 있도록 설계변수와 목적함수와의 상관관계를 정의하는 수학적 모델(다시 말해, 대리모델)을 구성한다.

[0076] 본 발명의 실시예에 따른 대리모델 구성부(612)는 대리모델 구축을 위해 여러 가지 수학적 근사모델링 기법을 적용할 수 있으며, 예를 들어, Kriging(Gaussian process, GP), ANNs(Artificial Neural Networks), SVR(Space Vector Regression) 등이 있다. 본 발명의 일 실시예에서는 GP 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0077] 본 발명의 실시예에 따른 최적화 수행부(613)는 상기 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축한다.

[0078] 본 발명의 실시예에 따른 최적화 수행부(613)는 대리모델을 이용하여 메타휴리스틱 최적화 알고리즘 계산 시간을 단축한다.

[0079] 본 발명의 실시예에 따른 최적화 수행부(613)는 메타휴리스틱 기반 전역 최적화에 여러 가지 알고리즘이 적용될 수 있으며, 예를 들어, 입자 군집 최적화(Particle Swarm Optimization; PSO), 유전 알고리즘(genetic algorithm), 차등 알고리즘(differential algorithm) 등이 있다. 본 발명의 일 실시예에서는 유전 알고리즘의 일종인 NSGA-II(Non-dominated Sorting Genetic Algorithm) 알고리즘이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0080] 본 발명의 실시예에 따른 GP-UCB 기반 적응형 샘플링부(614)는 상기 대리모델 및 상기 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, 상기 대리모델을 학습시키는 학습 데이터셋에 추가하기 위한 샘플을 능동형 샘플링 기법으로 선택한다.

[0081] 본 발명의 실시예에 따른 GP-UCB 기반 적응형 샘플링부(614)는 대리모델 구성 및 메타휴리스틱 최적화 알고리즘에 대한 미리 정해진 수렴조건을 만족하지 못할 경우, 대리모델을 학습시키는 학습 데이터셋에 GP-UCB 기반 적응형 샘플링 기법으로 새로운 샘플을 선택하여 추가한다.

[0082] 본 발명의 실시예에 따른 GP-UCB 기반 적응형 샘플링부(614)는 능동형 샘플링에 여러 가지 기법이 사용될 수 있으며, 예를 들어, GP-UCB(Gaussian process upper confidence bound), EI(Expected Improvement), PI(Probability of Improvement) 등이 있다. 본 발명의 예시에서는 GP-UCB 기법이 사용되었으나 이에 한정되지 않으며, 이외의 다른 기법 적용 시에도 유사한 효과를 기대할 수 있다.

[0083] 본 발명의 실시예에 따르면, 유한요소해석 프로그램을 이용한 계산 대신 대리모델을 활용하여 계산 시간을 절감할 수 있다. 또한, 활용과 탐색을 혼합한 GP-UCB 기반 적응형 샘플링 기법을 적용하여, 기존의 랜덤 샘플링 기법(LHS), 메타휴리스틱 최적화 기법(NSGA-II)과 대비했을 때 샘플 분포(non-dominated solutions)가 최적의 해가 존재하는 파레토 프론트(Pareto front) 부근에 더 집중되는 등 설계공간을 효율적으로 탐색하고, 더 나은 성능의 전역 해를 찾을 수 있도록 하여 최적화 성능을 개선할 수 있다. 또한, 활용과 탐색을 혼합한 GP-UCB 기반 적응형 샘플링 기법을 적용하여, 기존의 적응형 샘플링이 없는 기존의 대리모델 구축 기법 대비 대리모델의 예측 정확도(RMSE)를 개선하고 최적화 수렴 속도를 향상시킬 수 있다. 본 발명의 실시예에 따른 최적설계방법 적용 시 초기 샘플 구성에 따른 최적화 성능의 변동이 적으며 반복적인 최적화 수행 시 일관적인 결과(repeatability)를 얻을 수 있다.

[0085] 도 7은 본 발명의 일 실시예에 따른 72슬롯/8폴 IPMSM 기본 모델의 단면을 나타내는 도면이다.

[0086] 도 7을 참조하면, 본 발명의 실시예에 따른 적응형 샘플링 알고리즘을 검증하기 위해 사용된 사례 연구의 결과를 제시한다. 선택된 기준 모델은 매입형 영구 자석 동기 전동기(IPMSM)로, 고정자에 72개의 슬롯, 8개의 폴 및 헤어핀 권선이 특징이다. 이 기준 모델은 이러한 유형의 기계에서 일반적으로 나타나는 상당한 비선형성, 즉 깊은 자기 포화도의 존재로 인해 최적설계가 까다롭기 때문에 선택되었다. 도 7은 기본 IPMSM의 주요 설계 파라미터에 대한 단면을 보여주며, 표 1은 기준 모터의 주요 파라미터에 대한 정보를 제공한다.

[0087] <표 1>

Parameter	Value
Slot/Pole	72/8
Peak current density	25 Arms/mm2
Maximum current	400 Arms
Airgap length	0.75 mm
Rotor outer diameter	150 mm
Stator outer diameter	mm
Stack length	90 mm

[0088]

[0089] 본 발명의 실시예에 따른 사례 연구를 위한 두 가지 목적함수는 기계의 토크 밀도와 총 활성 물질 비용이며, 이는 다음과 같이 표시된다:

[0090] minimize: 1. $-(Tpk / m_{total})$ [Nm/kg]
2. *Active material cost* [$]

[0091] 여기서 Tpk는 최대 토크이고 m_{total}은 활성 물질의 총 질량이다.

[0092] 제안하는 알고리즘의 효과를 평가하기 위해 활용-탐색 균형, 수렴 속도, 초기 샘플링에 대한 민감도 및 반복성을 포함한 중요한 성능 메트릭을 검토한다. SM은 [11]에 설명된 GP 기반 알고리즘을 사용하여 설정되며, NSGA-II는 메타휴리스틱 최적화에 사용된다. NSGA-II 파라미터는 교차 확률 0.9와 돌연변이 확률 0.05를 포함한다. GP-UCB의 하이퍼 파라미터는 1로 설정되며, RMSE(평균 제곱근 오차)는 SM과 FEA 결과를 비교하고 수렴 기준으로 작용하는 핵심 메트릭이다. RMSE의 수학적 표현을 다음과 같이 나타낼 수 있다:

[0093]
$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i) \times 100\%} \quad (2)$$

[0094] 여기서 y_i는 FEA를 이용하여 계산한 i번째 데이터이고 $\hat{y}_i$ 는 SM에 의한 예측값이다.

[0095] 수렴은 RMSE 값이 모든 누적 FEA 산출 결과 평균의 0.5% 미만일 때 발생한다. 이는 다음과 같이 나타낼 수 있다:

[0096]
$$RMSE \leq \frac{1}{n}\sum_{i=1}^{n} y_i \times 0.5\% \quad (3)$$

[0098] 도 8은 본 발명의 일 실시예에 따른 활용과 탐색 사이의 균형을 비교하기 위한 도면이다.

[0099] 도 8(a)는 LHS를 사용한 샘플 분포, 도 8(b)는 NSGA-II를 사용한 샘플 분포, 도 8(c)는 GP-UCB를 사용한 샘플 분포, 도 8(d)는 파레토 프론트의 비교를 나타내는 도면이다.

[0100] 본 발명의 실시예에 따른 적응형 샘플링 기법은 활용과 탐색 사이의 균형을 최적화하여 종합적인 탐색을 촉진하는 동시에 최적의 솔루션을 포함할 가능성이 있는 영역을 이용하는 것을 목표로 한다. 도 8은 LHS(Latin hypercube sampling), NSGA-II(NSGA-II), 제안된 GP-UCB 기반 적응형 샘플링의 세 가지 샘플링 기법 간의 활용-탐색 균형을 비교한다. 특히, 도 8(d)는 GP-UCB 기반 방법의 우수한 성능을 보여주며, 동일한 수의 초기 200개 샘플로 최적화 성능을 향상시키고 그 근처에 샘플 분포를 집중시킨다. 또는 GP-UCB 기반 방법에 더 적은 수의 샘플이 사용되는 경우에도 다른 두 기법에 비해 유사한 성능을 달성할 수 있다.

[0102] 도 9는 본 발명의 일 실시예에 따른 수렴 속도를 비교하기 위한 도면이다.

[0103] 제안하는 GP-UCB 기반 적응형 샘플링은 도 9와 같이 가속 수렴을 보여준다. 50개의 샘플로 첫 번째 반복 동안 GP-UCB 기반 적응형 샘플링의 RMSE 값(0.57%)은 다른 방법의 RMSE 값(1.42% 및 2.25%)보다 성능이 뛰어나다. 실제로 GP-UCB 기반 적응형 샘플링의 RMSE 값은 한 번의 반복에서 식(3)에서 미리 정의된 수렴 조건을 거의 충족한다. 이러한 향상된 수렴 속도는 적응형 샘플링 기법이 불확실성이나 민감도가 높은 영역을 우선시하여 대리 모델을 보다 빠르게 재가공했기 때문이다. 결과적으로 GP-UCB 기반 적응형 샘플링은 LHS와 같은 랜덤 샘플링 기법에 의해 생성된 초기 샘플의 품질에 대한 민감도를 감소시켜 여러 최적화 실행 전반에 걸쳐 견고성을 보여준다.

[0105] 도 10은 본 발명의 일 실시예에 따른 초기 샘플링에 대한 민감도를 설명하기 위한 도면이다.

[0106] 최적화 프로세스의 성능은 초기 샘플 분포에 따라 달라질 수 있다. 도 10은 LHS의 5개의 독립적인 실행에서 생성된 샘플의 분포와 초기 최적화 성능을 보여준다. 도 10(a)는 5번의 초기 샘플링 실행(50개의 샘플 생성) 후 데이터 분포, 도 10(b)는 파레토 프론트 비교를 나타내는 도면이다.

[0107] 랜덤 샘플링 기법으로 생성된 각 데이터셋에 대해 최적화를 수행하면 반복성 문제가 발생할 수 있다. 제안하는 GP-UCB 기반 최적화 방법은 모델 정확도와 수렴 속도를 빠르게 향상시키기 위해 활용-탐색 균형을 맞추어서 이러한 반복성 문제를 완화하는 데 도움이 된다.

[0109] 도 11은 본 발명의 일 실시예에 따른 5번의 시뮬레이션 실행 간의 반복성 비교를 나타내는 도면이다.

[0110] 도 11(a)는 샘플 분포, 도 11(b)는 파레토 프론트 비교를 나타내는 도면이다. 여기서, 생성 수는 5개이고, 각 생성 당 50개 샘플에 대한 결과를 나타낸다. 도 11을 참조하면, GP-UCB 기반 적응형 샘플링이 5개의 최적화 실행에서 거의 동일한 최적화 성능 결과로 견고하다는 것이 입증되었음을 보여준다.

[0111] 요약하면, 제안된 GP-UCB 기반 적응형 샘플링 기법은 기존 방법을 능가하여 설계 공간 탐색, 활용-탐색 균형 개선, 더 빠른 수렴, 초기 샘플에 대한 민감도 감소 및 여러 최적화 실행에서 거의 동일한 최적화 성능에서 분명하게 나타나는 반복성 개선을 제공한다.

[0112] 본 발명의 실시예에 따르면, 전기기기 설계를 위해 GP-UCB 기반의 적응형 샘플링을 활용한 새로운 설계 최적화 과정을 제안했다. 제안하는 방법은 EV 응용을 위한 IPMSM을 활용한 사례 연구를 통해 적응형 샘플링이 없는 기존의 최적화 방법에 비해 우수한 성능을 입증했다. 특히 적응형 샘플링 기법은 활용-탐색 균형, 수렴 속도, 초기 샘플링에 대한 민감도, 반복성 등 주요 최적화 성능 척도를 크게 향상시켰다.

[0114] 이상에서 설명된 장치는 하드웨어 구성요소, 소프트웨어 구성요소, 및/또는 하드웨어 구성요소 및 소프트웨어 구성요소의 조합으로 구현될 수 있다. 예를 들어, 실시예들에서 설명된 장치 및 구성요소는, 예를 들어, 프로세서, 콘트롤러, ALU(arithmetic logic unit), 디지털 신호 프로세서(digital signal processor), 마이크로컴퓨터, FPGA(field programmable gate array), PLU(programmable logic unit), 마이크로프로세서, 또는 명령(instruction)을 실행하고 응답할 수 있는 다른 어떠한 장치와 같이, 하나 이상의 범용 컴퓨터 또는 특수 목적 컴퓨터를 이용하여 구현될 수 있다. 처리 장치는 운영 체제(OS) 및 상기 운영 체제 상에서 수행되는 하나 이상의 소프트웨어 애플리케이션을 수행할 수 있다. 또한, 처리 장치는 소프트웨어의 실행에 응답하여, 데이터를 접근, 저장, 조작, 처리 및 생성할 수도 있다. 이해의 편의를 위하여, 처리 장치는 하나가 사용되는 것으로 설명된 경우도 있지만, 해당 기술분야에서 통상의 지식을 가진 자는, 처리 장치가 복수 개의 처리 요소(processing element) 및/또는 복수 유형의 처리 요소를 포함할 수 있음을 알 수 있다. 예를 들어, 처리 장치는 복수 개의 프로세서 또는 하나의 프로세서 및 하나의 콘트롤러를 포함할 수 있다. 또한, 병렬 프로세서(parallel processor)와 같은, 다른 처리 구성(processing configuration)도 가능하다.

[0115] 소프트웨어는 컴퓨터 프로그램(computer program), 코드(code), 명령(instruction), 또는 이들 중 하나 이상의 조합을 포함할 수 있으며, 원하는 대로 동작하도록 처리 장치를 구성하거나 독립적으로 또는 결합적으로(collectively) 처리 장치를 명령할 수 있다. 소프트웨어 및/또는 데이터는, 처리 장치에 의하여 해석되거나 처리 장치에 명령 또는 데이터를 제공하기 위하여, 어떤 유형의 기계, 구성요소(component), 물리적 장치, 가상 장치(virtual equipment), 컴퓨터 저장 매체 또는 장치에 구체화(embody)될 수 있다. 소프트웨어는 네트워크로 연결된 컴퓨터 시스템 상에 분산되어서, 분산된 방법으로 저장되거나 실행될 수도 있다. 소프트웨어 및 데이

터는 하나 이상의 컴퓨터 판독 가능 기록 매체에 저장될 수 있다.

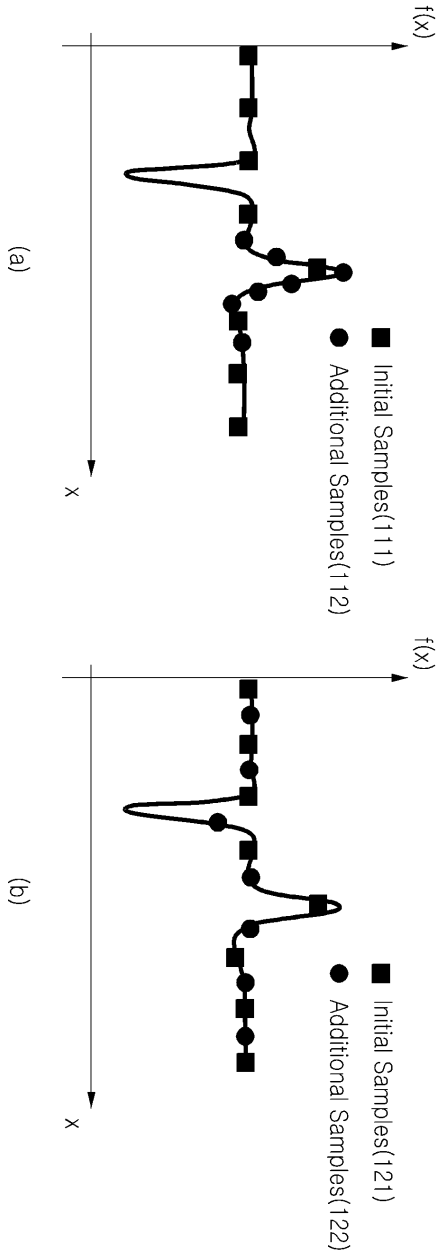
[0116] 실시예에 따른 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 실시예를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 당업자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광 매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 컴파일러에 의해 만들어지는 것과 같은 기계어 코드뿐만 아니라 인터프리터 등을 사용해서 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

[0117] 이상과 같이 실시예들이 비록 한정된 실시예와 도면에 의해 설명되었으나, 해당 기술분야에서 통상의 지식을 가진 자라면 상기의 기재로부터 다양한 수정 및 변형이 가능하다. 예를 들어, 설명된 기술들이 설명된 방법과 다른 순서로 수행되거나, 및/또는 설명된 시스템, 구조, 장치, 회로 등의 구성요소들이 설명된 방법과 다른 형태로 결합 또는 조합되거나, 다른 구성요소 또는 균등물에 의하여 대치되거나 치환되더라도 적절한 결과가 달성될 수 있다.

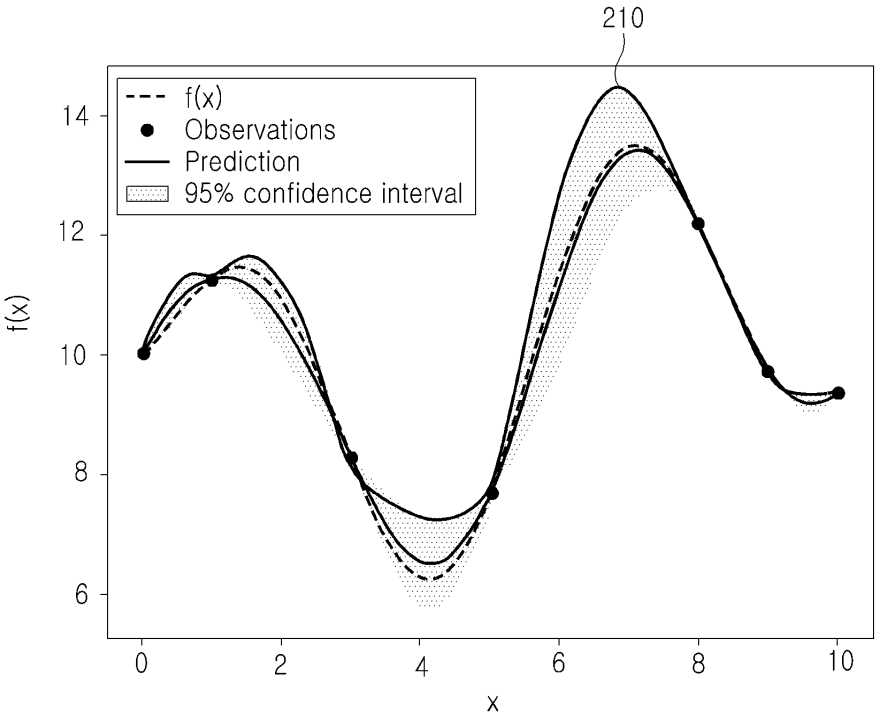
[0118] 그러므로, 다른 구현들, 다른 실시예들 및 특허청구범위와 균등한 것들도 후술하는 특허청구범위의 범위에 속한다.

도면

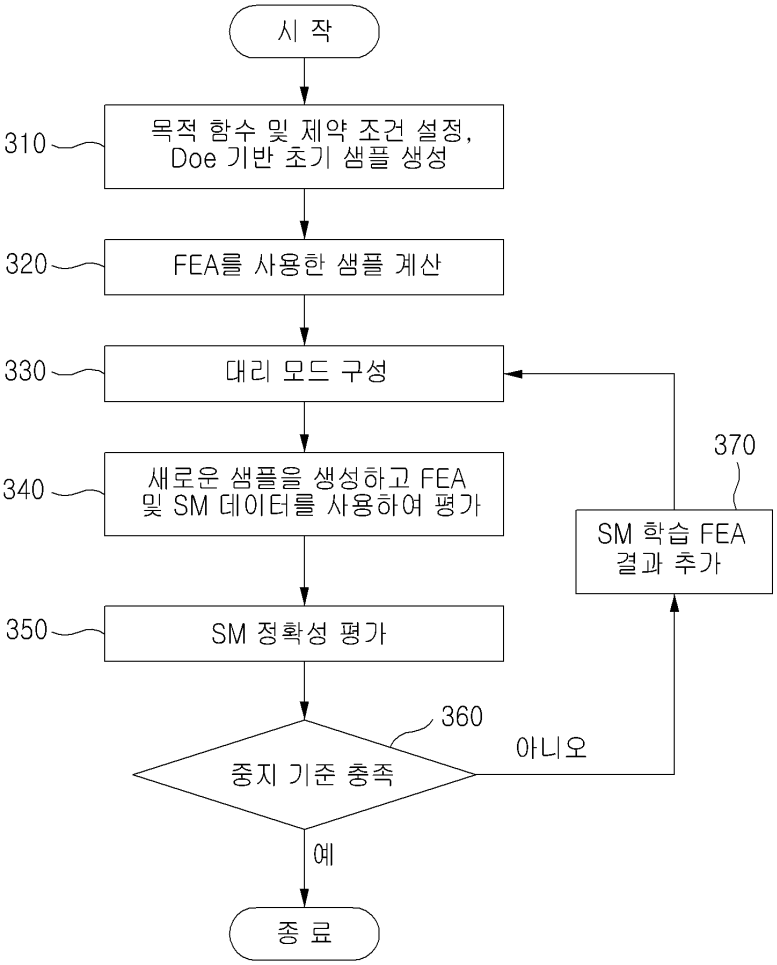
도면1


f(x)
x
(a)
Initial Samples(111)
Additional Samples(112)
f(x)
x
(b)
Initial Samples(121)
Additional Samples(122)

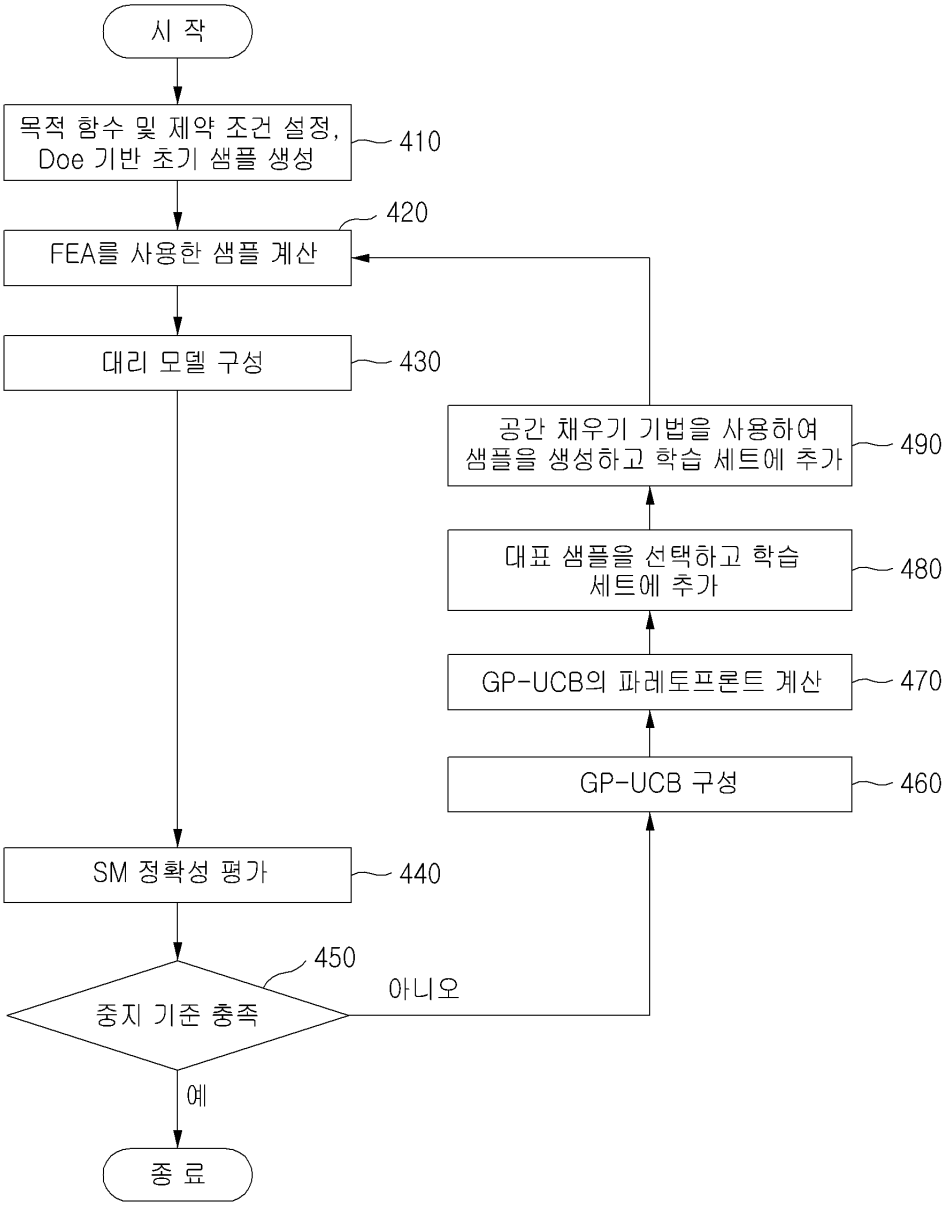
도면2


210
f(x)
Observations
Prediction
95% confidence interval
14
12
10
8
6
f(x)
0
2
4
6
8
10
x

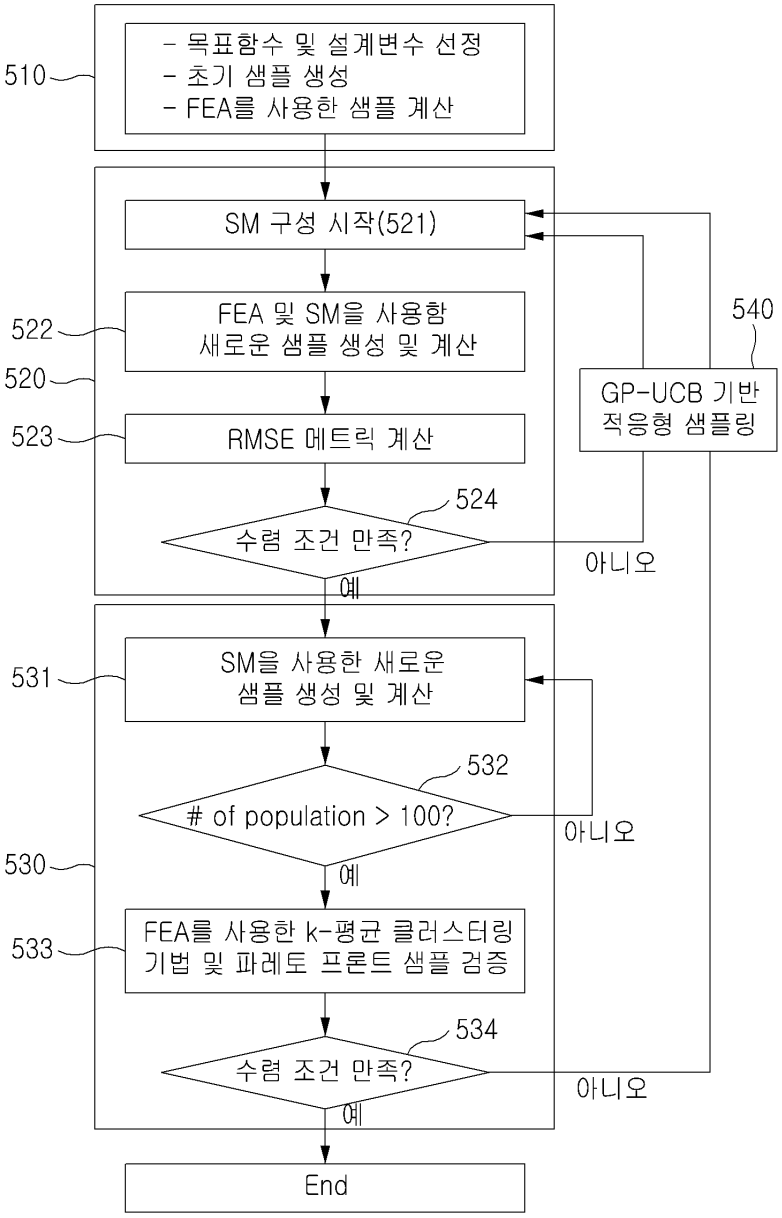
도면3


시 작
310
목적 함수 및 제약 조건 설정,
Doe 기반 초기 샘플 생성
320
FEA를 사용한 샘플 계산
330
대리 모드 구성
340
새로운 샘플을 생성하고 FEA
및 SM 데이터를 사용하여 평가
350
SM 정확성 평가
360
중지 기준 충족
아니오
예
370
SM 학습 FEA
결과 추가
종 료

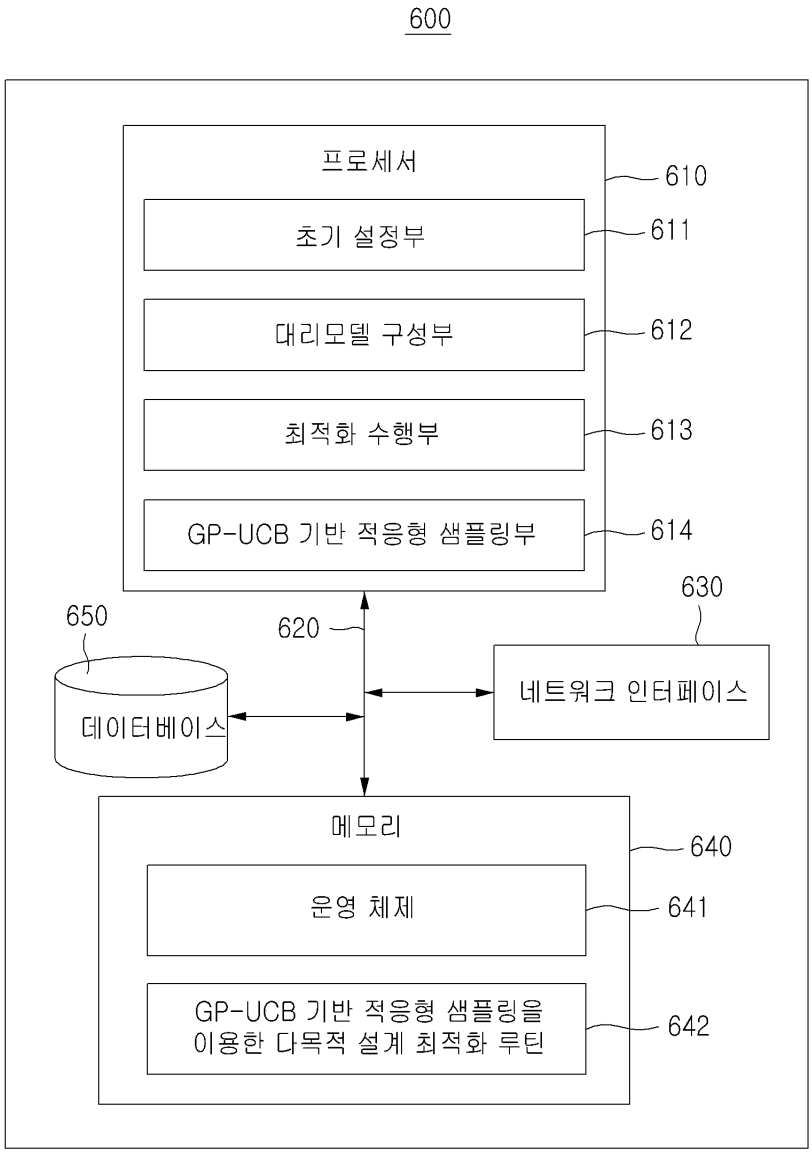
도면4


시 작
목적 함수 및 제약 조건 설정, Doe 기반 초기 샘플 생성
410
FEA를 사용한 샘플 계산
420
대리 모델 구성
430
SM 정확성 평가
440
중지 기준 충족
450
아니오
예
종 료
GP-UCB 구성
460
GP-UCB의 파레토프론트 계산
470
대표 샘플을 선택하고 학습 세트에 추가
480
공간 채우기 기법을 사용하여 샘플을 생성하고 학습 세트에 추가
490

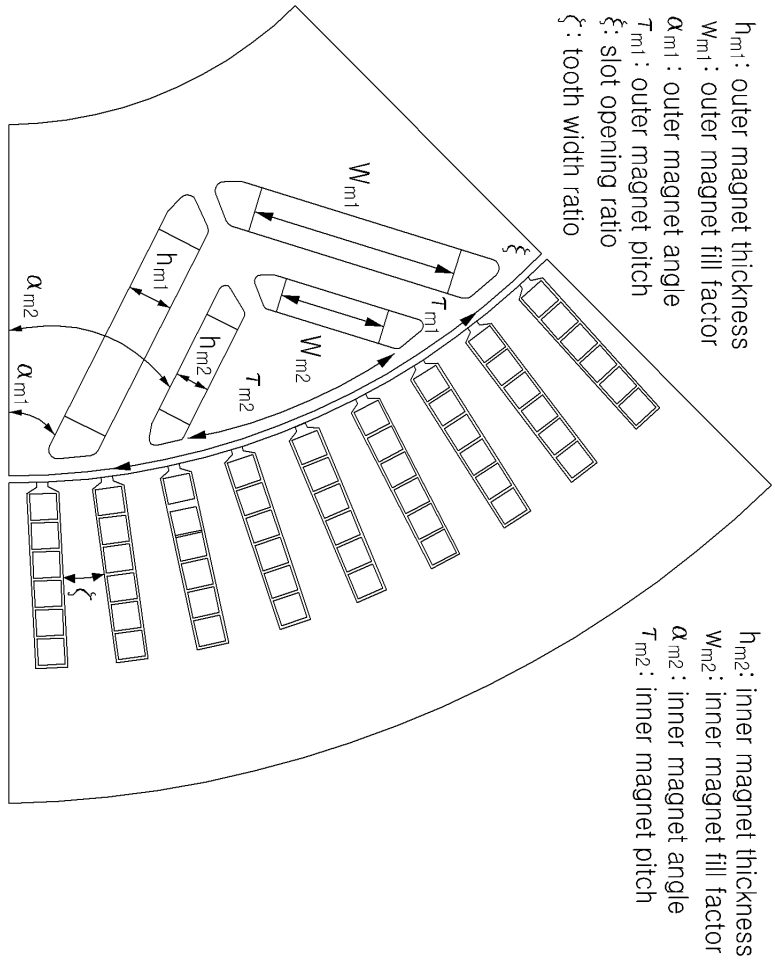
도면5


510
- 목표함수 및 설계변수 선정
- 초기 샘플 생성
- FEA를 사용한 샘플 계산
SM 구성 시작(521)
522
FEA 및 SM을 사용함
새로운 샘플 생성 및 계산
520
523
RMSE 메트릭 계산
524
수렴 조건 만족?
아니오
예
540
GP-UCB 기반
적응형 샘플링
531
SM을 사용한 새로운
샘플 생성 및 계산
532
# of population > 100?
아니오
예
530
533
FEA를 사용한 k-평균 클러스터링
기법 및 파레토 프론트 샘플 검증
534
수렴 조건 만족?
아니오
예
End

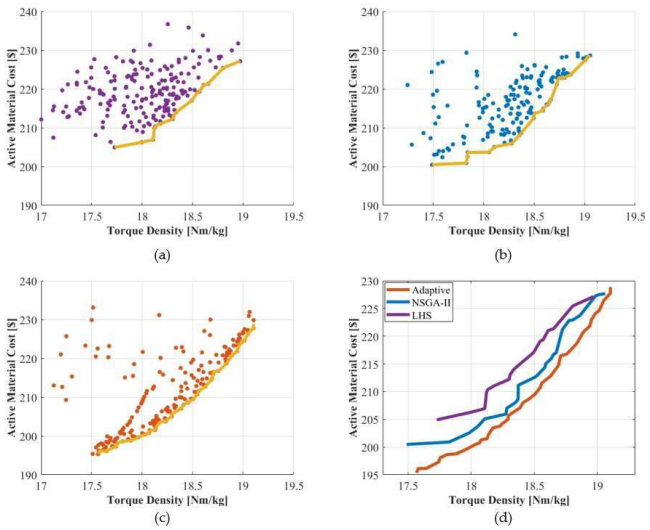
도면6


600
프로세서
610
초기 설정부
611
대리모델 구성부
612
최적화 수행부
613
GP-UCB 기반 적응형 샘플링부
614
630
650
620
네트워크 인터페이스
데이터베이스
메모리
640
운영 체제
641
GP-UCB 기반 적응형 샘플링을
이용한 다목적 설계 최적화 루틴
642

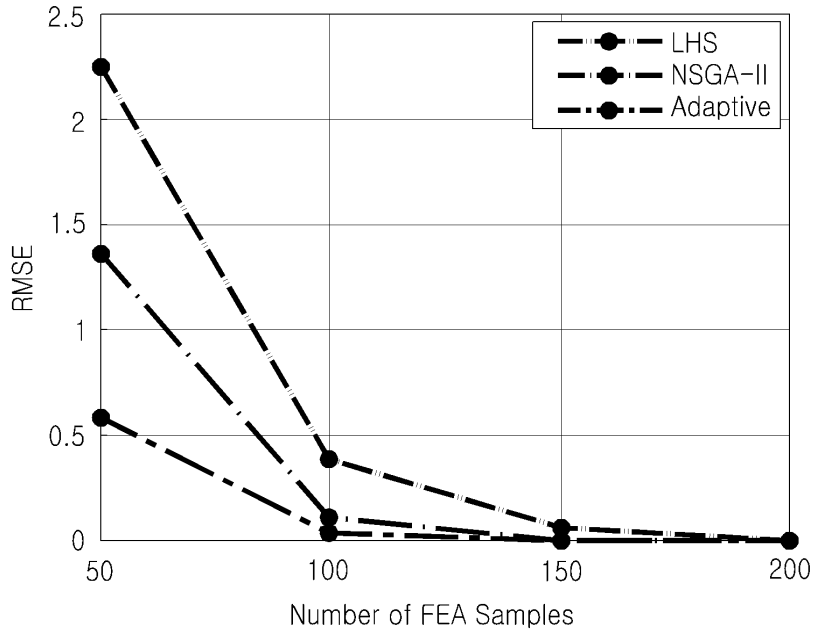
도면7


h_{m1}: outer magnet thickness
w_{m1}: outer magnet fill factor
α_{m1}: outer magnet angle
τ_{m1}: outer magnet pitch
ξ: slot opening ratio
ζ: tooth width ratio
h_{m2}: inner magnet thickness
w_{m2}: inner magnet fill factor
α_{m2}: inner magnet angle
τ_{m2}: inner magnet pitch

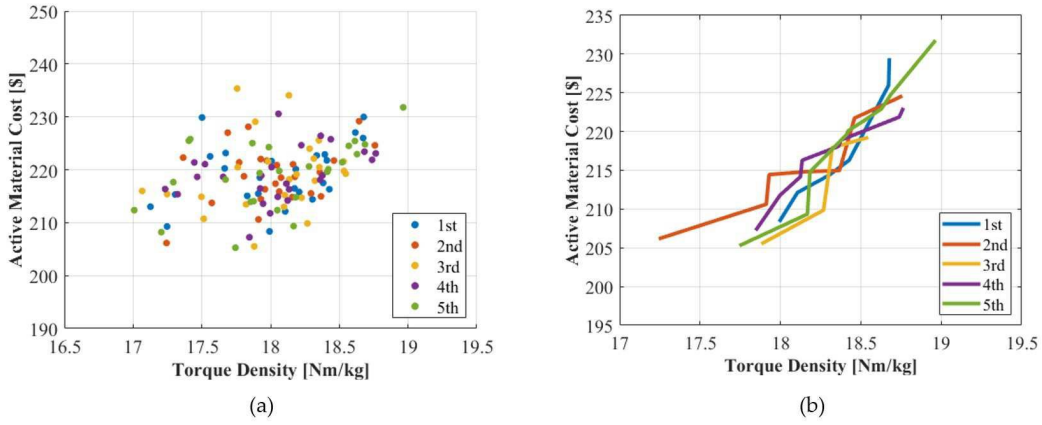
도면8


Active Material Cost [$]
Torque Density [Nm/kg]
(a)
(b)
(c)
(d)
Adaptive
NSGA-II
LHS

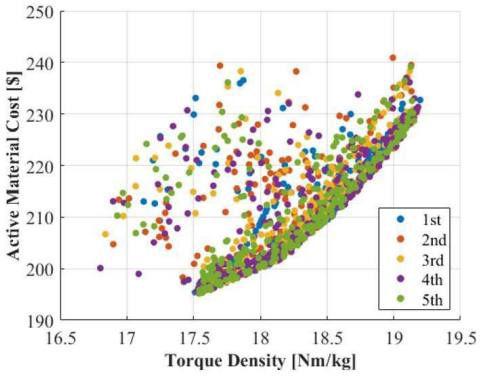
도면9


LHS
NSGA-II
Adaptive
RMSE
Number of FEA Samples
2.5
2
1.5
1
0.5
0
50
100
150
200

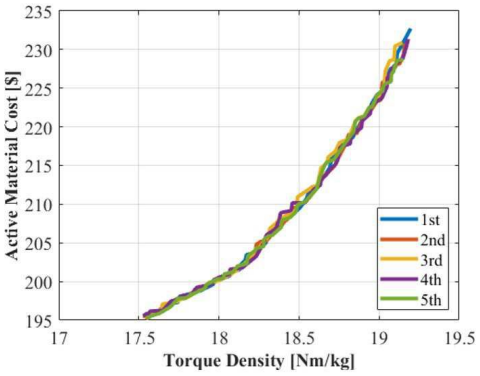
도면10


Active Material Cost [$]
Torque Density [Nm/kg]
1st
2nd
3rd
4th
5th
(a)
(b)

도면11


Active Material Cost [$]
Torque Density [Nm/kg]
1st
2nd
3rd
4th
5th

(a)


Active Material Cost [$]
Torque Density [Nm/kg]
1st
2nd
3rd
4th
5th

(b)