(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2021-0031277
(43) 공개일자 2021년03월19일

(51) 국제특허분류(Int. Cl.)
G06N 3/12 (2006.01) *B01D 53/56* (2006.01)
(52) CPC특허분류
G06N 3/126 (2013.01)
B01D 53/56 (2013.01)
(21) 출원번호 10-2019-0113035
(22) 출원일자 2019년09월11일
심사청구일자 2019년09월11일

(71) 출원인
인하대학교 산학협력단
인천광역시 미추홀구 인하로 100(용현동, 인하대학교)
(72) 발명자
황성원
서울특별시 서초구 동광로32길 7 (반포동, 삼창골든빌라) 101동 301호
신연주
경기도 시흥시 신천로 88 (신천동, 디오쉐르빌) 나동 401호
(74) 대리인
이원희

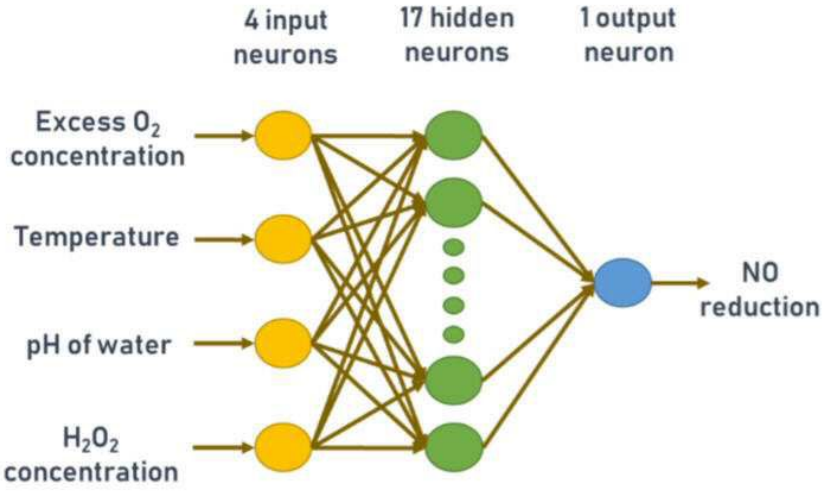
전체 청구항 수 : 총 12 항

(54) 발명의 명칭 **질소산화물 저감 시스템 및 그 방법**

(57) 요 약

본 발명은 인공 신경망 알고리즘 및 유전자 알고리즘을 이용한 질소산화물 저감 시스템 및 그 방법에 관한 것에 관한 것으로, 질소산화물 저감 시스템이 인공신경망(ANN)을 이용하여 질소산화물 저감 모델을 생성하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 학습하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 검증하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델의 입력 변수들에 대하여, 유전자 알고리즘(GA)을 이용하여 최적화하는 단계를 포함할 수 있다.

대 표 도 - 도17



명 세 서

청구범위

청구항 1

질소, 산소 및 연료 가스 중 적어도 어느 하나가 공급되는 공기 주입부; 가열기; 물탱크; 과산화수소(H2O2) 주입부;LNG 주입부;NG 배출부;를 포함하고,

인공신경망(ANN)을 이용하여 질소산화물 저감 모델을 생성하는 모델 생성부;

상기 생성된 질소산화물 저감 모델을 학습하는 모델 학습부;

상기 생성된 질소산화물 저감 모델을 검증하는 모델 검증부; 및

유전자 알고리즘(GA)을 이용하여 상기 생성된 질소산화물 저감 모델의 입력 변수들을 최적화하는 변수 최적화부를 포함하는 질소산화물 저감 시스템

청구항 2

제1항에 있어서,

상기 질소산화물 저감 모델은 온도, 산소 농도, ph 또는 과산화수소수 농도 중 적어도 어느 하나의 입력 변수를 포함하는 질소산화물 저감 시스템.

청구항 3

제1항에 있어서,

상기 모델 생성부는,

신경망 구조를 결정하고, 상기 신경망 구조에서 숨겨진 계층 수를 결정하며, 상기 신경망 구조에서 숨겨진 계층의 뉴런 수를 결정하는 질소산화물 저감 시스템.

청구항 4

제3항에 있어서,

상기 신경망 구조는 3 계층 피드 포워드 신경망인 것을 특징으로 하는 질소산화물 저감 시스템.

청구항 5

제1항에 있어서,

상기 모델 학습부는 입력 데이터 및 출력 데이터를 -1 내지 1 사이의 값으로 정규화하는 질소산화물 저감 시스템.

청구항 6

제2항에 있어서,

상기 입력 변수는 온도, 산소 농도, ph 및 과산화수소수에 가중치가 적용된 것을 특징으로 하는 질소산화물 저감 시스템.

청구항 7

질소산화물 저감 방법에 있어서,

질소산화물 저감 시스템이 인공신경망(ANN)을 이용하여 질소산화물 저감 모델을 생성하는 단계;

상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 학습하는 단계;

상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 검증하는 단계;

상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델의 입력 변수들에 대하여, 유전자 알고리즘(GA)을 이용하여 최적화하는 단계를 포함하는 질소산화물 저감 방법.

청구항 8

제7항에 있어서,

상기 질소산화물 저감 모델은 온도, 산소 농도, ph 또는 과산화수소수 농도 중 적어도 어느 하나의 입력 변수를 포함하는 질소산화물 저감 방법.

청구항 9

제7항에 있어서,

상기 질소산화물 저감 모델을 생성하는 단계는,

상기 질소산화물 저감 시스템이 신경망 구조를 결정하는 단계;

상기 질소산화물 저감 시스템이 상기 신경망 구조에서 숨겨진 계층 수를 결정하는 단계; 및

상기 질소산화물 저감 시스템이 상기 신경망 구조에서 숨겨진 계층의 뉴런 수를 결정하는 단계를 포함하는 질소산화물 저감 방법.

청구항 10

제9항에 있어서,

상기 신경망 구조는 3 계층 피드 포워드 신경망인 것을 특징으로 하는 질소산화물 저감 방법.

청구항 11

제7항에 있어서,

상기 질소산화물 저감 모델을 학습하는 단계는 입력 데이터 및 출력 데이터를 -1 내지 1 사이의 값으로 정규화하는 단계를 더 포함하는 질소산화물 저감 방법.

청구항 12

제8항에 있어서,

상기 입력 변수는 온도, 산소 농도, ph 및 과산화수소수에 가중치가 적용된 것을 특징으로 하는 질소산화물 저감 방법.

발명의 설명

기 술 분 야

[0001] 본 발명은 질소산화물 저감 시스템 및 그 방법에 관한 것으로, 보다 구체적으로 인공 신경망 알고리즘 및 유전자 알고리즘을 이용한 질소산화물 저감 시스템 및 그 방법에 관한 것이다.

배 경 기 술

[0002] 침지형 연소 기화기(Submerged Combustion Vaporizer, 이하, SCV라 지칭함)는 일반적으로 액화 천연 가스 (이하, LNG라 지칭함) 터미널에서 사용되어 LNG를 기화하고 천연 가스를 국내 산업 시장에 공급한다.

[0003] 연소 과정에서 나오는 가스에는 대기 오염 물질이 포함되어 있다. 여기에는 일산화 질소 (NO)와 이산화질소(NO2)가 포함되며 일반적으로 질소산화물(NOx)로 알려져 있다. 현존하는 연구에 따르면 질소산화물(NOx)는 환경과 인간에 대한 부정적인 영향을 심각하게 끼치고 있다. 예를 들어, 질소산화물(NOx)는 광화학 스모그 및 산성비의 형성에 관여하며, 입자상 물질 (PM)을 생성하는 중간 물질에 해당한다.

[0004] 방출된 질소산화물(NOx)가 헤이즈 (haze)와 같은 환경 문제를 야기하는 것으로 관찰되면, 그 규제는 최근에 더

욱 제한적이다. 예를 들어, 한국에서 2015 년 이후 청정 공기 보존법 개정에 따라 연소 공정에서 질소산화물(NOx)에 대한 허용 배출 기준이 강화되었다. 또한 EU 회원국은 NEC (National Emissions Reduction Commitments)를 통해 2030 년까지 질소산화물(NOx) 배출량을 줄이겠다 고 약속했다. 특히, 질소산화물(NOx)는 주로 연소 공정에서 생산되며 도로 운송 및 폐기물 처리와 같은 공급원에서도 생산된다.

[0005] 도 1은 한국 국립 환경 연구원에서 얻은 것으로, 한국의 질소산화물(NOx) 배출원 비율을 나타낸다. 에너지 산업, 제조 및 비산업 부문의 총 연소 공정이 질소산화물(NOx) 배출량의 거의 60 %를 차지한다는 점을 주목할 필요가 있다. 연소 과정은 일반적으로 공기 중에서 발생합니다. 연소 온도가 높으면 대기 중의 특정 양의 N_2가 O_2와 반응하여 질소산화물(NOx)를 형성한다.

[0006] 액체 연료를 사용하는 보일러에 대한 질소산화물(NOx) 규제는 최근 한국에서 강화되었다. 예컨대, 2001 년 6 월 30 일 이전에 설치된 시설은 130ppm 미만의 질소산화물(NOx)를 배출해야 하고 2015 년 이후의 새로운 시설은 50ppm 미만의 질소산화물(NOx)를 방출해야 한다.

[0007] 질소산화물(NOx)은 천연 가스 액화 설비에서 SCV의 연소 구역에서 생산되는 반면 액화 천연 가스 (LNG)는 기화된다. 오픈 랙 기화기는 일반적으로 LNG를 천연 가스로 기화시키는 데 사용된다.

[0008] 도 2는 SPP (Sumitomo Precision Products)에서 제조한 SCV의 개략도이다. 천연가스(NG)는 연소를 위해 연료로서 SCV에 공급된다. LNG는 온수 내부의 튜브 번들을 통해 흐르면서 기화되며, 탱크에 설치된 버너에서 가열된다. 버너는 질소산화물(NOx) 가스를 포함하여 뜨거운 배기 가스를 방출한다. 마지막으로, 물을 통과하는 가스는 배출 스택으로 배출된다. 질소산화물(NOx)의 일부는 물로 흡수되고 나머지는 대기로 방출된다.

[0009] 앞서 논의한 바와 같이, SCV로부터의 질소산화물(NOx)는 새로운 환경 규제를 충족시키기 위해 감소되어야 한다. 따라서, 선택적 촉매 환원 (SCR), 선택적 비 촉매 환원 (SNCR) 및 화학적 세정(스크러빙)을 포함하는 다양한 기술들이 검토되었다. SCR 또는 SNCR은 업계에서 질소산화물(NOx)를 줄이기 위해 일반적으로 사용되고 있다. 그러나, 연소 구역으로부터의 가스가 물 탱크의 바닥에서 급격히 냉각되기 때문에, 낮은 작동 온도로 인해 이러한 기술을 적용하는 것은 적절하지 않은 것으로 관찰되었다.

선행기술문헌

특허문헌

[0010] (특허문헌 0001) (US) 등록특허 8453431 B2 (2013.06.04.)

발명의 내용

해결하려는 과제

[0011] 본 발명은 상기 문제점을 해결하기 위해 안출된 것으로서, SCV의 연도 가스(flue gas)에서 질소산화물(NOx)를 효율적으로 감소시키기 위한 질소산화물 저감 시스템 및 그 방법을 제안하고자 한다.

[0012] 본 발명의 기술적 과제들은 이상에서 언급한 기술적 과제들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0013] 본 발명의 일 실시예에 따른 질소산화물 저감 시스템은 질소, 산소 및 연료 가스 중 적어도 어느 하나가 공급되는 공기 주입부; 가열기; 물탱크; 과산화수소(H2O2) 주입부;LNG 주입부;NG 배출부;를 포함하고, 인공신경망(ANN)을 이용하여 질소산화물 저감 모델을 생성하는 모델 생성부; 상기 생성된 질소산화물 저감 모델을 학습하는 모델 학습부;상기 생성된 질소산화물 저감 모델을 검증하는 모델 검증부; 및 유전자 알고리즘(GA)을 이용하여 상기 생성된 질소산화물 저감 모델의 입력 변수들을 최적화하는 변수 최적화부를 포함할 수 있다.

[0014] 본 발명의 일 실시예에 따른 질소산화물 저감 모델은 온도, 산소 농도, ph 또는 과산화수소수 농도 중 적어도 어느 하나의 입력 변수를 포함할 수 있다.

[0015] 본 발명의 일 실시예에 따른 모델 생성부는, 신경망 구조를 결정하고, 상기 신경망 구조에서 숨겨진 계층 수를

결정하며, 상기 신경망 구조에서 숨겨진 계층의 뉴런 수를 결정할 수 있다.

[0016] 본 발명의 일 실시예에 따른 질소산화물 저감 시스템의 신경망 구조는 3 계층 피드 포워드 신경망인 것을 특징으로 할 수 있다.

[0017] 본 발명의 일 실시예에 따른 모델 학습부는 입력 데이터 및 출력 데이터를 -1 내지 1 사이의 값으로 정규화할 수 있다.

[0018] 본 발명의 일 실시예에 따른 질소산화물 저감 시스템의 입력 변수는 온도, 산소 농도, ph 및 과산화수소수에 가중치가 적용될 수 있다.

[0019] 본 발명의 일 실시예에 따른 질소산화물 저감 방법은 질소산화물 저감 시스템이 인공신경망(ANN)을 이용하여 질소산화물 저감 모델을 생성하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 학습하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델을 검증하는 단계; 상기 질소산화물 저감 시스템이 상기 생성된 질소산화물 저감 모델의 입력 변수들에 대하여, 유전자 알고리즘(GA)을 이용하여 최적화하는 단계를 포함할 수 있다.

[0020] 본 발명의 일 실시예에 따른 질소산화물 저감 방법의 상기 질소산화물 저감 모델을 생성하는 단계는, 상기 질소산화물 저감 시스템이 신경망 구조를 결정하는 단계; 상기 질소산화물 저감 시스템이 상기 신경망 구조에서 숨겨진 계층 수를 결정하는 단계; 및 상기 질소산화물 저감 시스템이 상기 신경망 구조에서 숨겨진 계층의 뉴런 수를 결정하는 단계를 포함할 수 있다.

[0021] 본 발명의 일 실시예에 따른 질소산화물 저감 방법에서 질소산화물 저감 모델을 학습하는 단계는 입력 데이터 및 출력 데이터를 -1 내지 1 사이의 값으로 정규화하는 단계를 더 포함할 수 있다.

발명의 효과

[0022] 본 발명의 일 실시예에 따른 질소산화물 저감 시스템 및 그 방법은 질소산화물(NOx)를 최대로 감소시킬 수 있는 작동 조건을 검색할 수 있고, 질소산화물을 효율적으로 감소 시킬 수 있다.

[0023] 또한 본 발명은 공정 변수가 복잡한 다른 배출 감소 시스템에도 적용할 수 있는 이점이 있다.

[0024] 본 발명은 수학적으로 모델링하기 어렵고 시스템의 매개 변수를 최적화하기 위해 상당한 계산 부하가 필요한 시스템의 모델링 및 최적화에서 우수한 성능을 나타낸다.

[0025] 본 발명의 일 실시예에 따라 ANN-GA 모델을 사용하면 공정의 경제성을 평가하는 데 유용하다.

[0026] 본 발명의 효과들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0027] 도 1은 한국 국립 환경 연구원에서 얻은 것으로, 한국의 질소산화물(NOx) 배출원 비율을 나타낸다.

도 2는 SPP (Sumitomo Precision Products)에서 제조한 SCV의 개략도이다.

도 3은 질소산화물(NO_x)의 환원 반응의 개념도이다.

도 4는 배기 가스에서 NOx 제거 효율을 최대화하기 위해 수정된 SCV의 개략도를 나타낸다.

도 5는 NOx 감소를 위한 실험 장치의 개념도이다.

도 6은 15 ℃, pH 7 및 0 %의 H_2O_2에서 NO 환원에 대한 과량의 O_2 농도의 영향을 나타낸다.

도 7은 8 % O_2, pH 7 및 0 %의 H_2O_2에서 NO 감소에 대한 온도의 영향을 나타낸다.

도 8은 8% O_2, 15 ℃ 및 0 %의 H_2O_2에서 NO 환원에 대한 pH의 영향을 나타낸다.

도 9는 8 % O_2, 15 ℃ 및 pH 7에서 NO 환원에 대한 H_2O_2 농도의 영향을 나타낸다.

도 10은 MLP 아키텍처를 나타낸다.

도 11은 항등 함수, 도 12는 단계 함수, 도 13은 시그모이드 함수, 도 14는 탄젠트 함수를 나타낸다.

도 15는 유전자 알고리즘의 표준 순서도를 나타낸다.

도 16은 상이한 수의 숨겨진 뉴런에 대한 ANN 예측 모델 성능 (MSE)을 나타낸다.

도 17은 본 발명의 일 실시예에 따른 NOx 감소 시스템의 ANN 모델 구조를 나타낸다.

도 18은 SCV 시스템의 NO 감소에 대한 실험 값과 예측 값의 분포를 나타낸다.

도 19는 모든 실험 결과의 오차 막대를 나타낸다.

도 20은 ANN 모델에 의한 예측 결과에서 NO 환원에 대한 pH 및 과량의 O_2 농도의 영향을 나타낸다.

도 21은 최적의 피트니스 함수 값을 나타낸다.

도 22는 ANN 예측 모델에서 얻은 NO 감소 값을 최적 조건에서 실험한 검증 결과를 나타낸다.

발명을 실시하기 위한 구체적인 내용

[0028] 본 발명은 다양한 변경을 가할 수 있고 여러 가지 실시예를 가질 수 있는 바, 특정 실시예들을 도면을 참조하여 상세하게 설명하도록 한다. 그러나, 이는 본 발명을 특정한 실시 형태에 대해 한정하려는 것이 아니며, 본 발명의 사상 및 기술 범위에 포함되는 모든 변경, 균등물 내지 대체물을 포함하는 것으로 이해되어야 한다. 각 도면을 설명하면서 유사한 참조부호를 유사한 구성요소에 대해 사용하였다.

[0029] 제1, 제2, A, B 등의 용어는 다양한 구성요소들을 설명하는데 사용될 수 있지만, 상기 구성요소들은 상기 용어들에 의해 한정되어서는 안된다. 상기 용어들은 하나의 구성요소를 다른 구성요소로부터 구별하는 목적으로만 사용된다. 예를 들어, 본 발명의 권리범위를 벗어나지 않으면서 제1 구성요소는 제2 구성요소로 명명될 수 있고, 유사하게 제2 구성요소도 제1 구성요소로 명명될 수 있다. 및/또는 이라는 용어는 복수의 관련된 기재 항목들의 조합 또는 복수의 관련된 기재 항목들 중의 어느 항목을 포함한다.

[0030] 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급될 때에는 그 다른 구성요소에 직접적으로 연결되어 있거나 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 할 것이다. 반면에, 어떤 구성요소가 다른 구성요소에 "직접 연결되어" 있다거나 "직접 접속되어" 있다고 언급된 때에는, 중간에 다른 구성요소가 존재하지 않는 것으로 이해되어야 할 것이다.

[0031] 본 출원에서 사용한 용어는 단지 특정한 실시예를 설명하기 위해 사용된 것으로, 본 발명을 한정하려는 의도가 아니다. 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 출원에서, "포함하다" 또는 "가지다" 등의 용어는 명세서상에 기재된 특징, 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것이 존재함을 지정하려는 것이지, 하나 또는 그 이상의 다른 특징들이나 숫자, 단계, 동작, 구성요소, 부품 또는 이들을 조합한 것들의 존재 또는 부가 가능성을 미리 배제하지 않는 것으로 이해되어야 한다.

[0032] 다르게 정의되지 않는 한, 기술적이거나 과학적인 용어를 포함해서 여기서 사용되는 모든 용어들은 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자에 의해 일반적으로 이해되는 것과 동일한 의미를 가지고 있다. 일반적으로 사용되는 사전에 정의되어 있는 것과 같은 용어들은 관련 기술의 문맥 상 가지는 의미와 일치하는 의미를 가지는 것으로 해석되어야 하며, 본 출원에서 명백하게 정의하지 않는 한, 이상적이거나 과도하게 형식적인 의미로 해석되지 않는다.

[0033] 명세서 전체에서, NOx는 질소산화물을 지칭하고, NO는 일산화질소, NO_2는 이산화질소, SCV는 침지형 연소 기화기를 지칭한다. 명세서 및 청구범위 전체에서, 어떤 부분이 어떤 구성 요소를 포함한다고 할 때, 이는 특별히 반대되는 기재가 없는 한 다른 구성 요소를 제외하는 것이 아니라 다른 구성 요소를 더 포함할 수 있다는 것을 의미한다.

[0034] 이하, 본 발명에 따른 바람직한 실시예를 실험예, 모델 및 실험 결과를 활용하여 자세히 설명한다.

[0036] **A.실험**

[0037] **A.1 실험 설계**

[0038] 도 3은 질소산화물(NO_x)의 환원 반응의 개념도이다. SCV 작동 중에는 소량의 일산화질소(NO)만 일반적으로 이산화질소(NO_2)로 변환되고, 이산화질소는 탱크 내부의 물에 흡수된다. 기본 반응에는 두 단계가 포함된다. 먼저, 수학식 (1)에서 NO_2가 생성되도록 NO 산화가 일어난다. 둘째, NO_2는 수학식 (2)에 표현된 바와 같이, 물을 질산을 생성하는 물에 흡수된다(연도 가스(flue gas)를 대기로 방출하기 전에 HNO_3 생성)에 흡수된다.

수학식 1

[0039] Reaction 1. $2NO + O_2 \rightarrow 2NO_2$

수학식 2

[0040] Reaction 2. $3NO_2 + H_2O \rightarrow 2HNO_3 + NO$

[0041] 질소산화물(NOx)은 물을 매체로 사용하는 공정에서 효율적으로 제거되지 않는다. 이 연구에서 물에 H_2O_2를 첨가하여 다음 수학식 (3) 및 수학식 (4)에 의해 NOx의 제거 효율을 증가시킨다.

수학식 3

[0042] Reaction 3. $NO + H_2O_2 \rightarrow NO_2 + H_2O$

수학식 4

[0043] Reaction 4. $NO_2 + H_2O_2 \rightarrow 2HNO_3$

[0045] 도 4는 배기 가스에서 NOx 제거 효율을 최대화하기 위해 수정된 SCV의 개략도를 나타낸다.

[0046] 연소 직후에 과량의 O_2의 가스 스트림이 연도 가스에 주입된다. 이어서, 혼합 가스는 물을 포함하는 탱크의 바닥에 작은 가스 기포 형태로 분배된다. 수학식 (3)에 나타낸 바와 같이, 물에 H_2O_2를 주입하여 반응을 향상시킨다. 결과적으로, 더 많은 양의 NO가 적절하게 용해되고 물에 흡수되는 NO_2로 전환된다. 반응이 일어나면 수학식 (4)와 같이 질산 (HNO_3)이 생성되어 물의 pH가 점차 낮아진다. 물의 pH를 제어하기 위해, 황산 (H_2SO_4) 또는 차아 염소산 나트륨 (NaOCl)을 첨가하여 산성 또는 염기성 조건을 생성 하였다. 참고로 질산은 환경에 유해하다. 따라서, 아래 수학식 (5)와 같은 반응으로 처리 될 수 있다.

수학식 5

[0047] $HNO_3\,(aq) + NH_3\,(g) \rightarrow NH_4NO_3$

[0048] 기체 암모니아는 질산 수용액과 반응하여 질산 암모늄 (NH4NO3)을 생성하고. 비료로 사용될 수 있다.

[0050] **A.2 실험 설정**

[0051] 도 5는 NOx 감소를 위한 실험 장치의 개념도이다.

[0052] 실험에 사용된 재료는 공기, N_2 (99.9 %) 가스, NO (99 % N2 및 1 % NO) 가스, H_2SO_4 (1-2 %) 수용액, NaOCl (10 %) 수용액 및 H_2O_2 (34.5 %)이다.

[0053] 실험은 도 5와 같이 미니 파일럿 스케일로 설정되었다. 가스는 N_2 및 NO의 가스로 채워진 실린더에 의해 공급된다. 질량 유량 제어기를 사용하여 두 스트림의 유량을 제어한다. O_2 농도를 표준 상태에서 8 %로 유지하기 위해 외부 공기를 주입하고 회전계로 제어하여 추가 공기를 별도로 주입한다.

[0054] 실린더 및 공기의 가스는 3방(three-way) 밸브를 통해 혼합되고, 혼합물은 탱크로 분배되며, 여기서 NO와 반응이 일어난다. 60m의 물로 채워진 $1m^3$의 탱크 부피가 사용된다. 기존 SCV 시스템과 유사한 조건을 만들기 위해 탱크 바닥에 여러 개의 작은 기포를 생성하는 여러 개의 구멍이 있도록 파이프를 뚫었다. H_2O_2의 존재 또는 부재하에 수용액을 제조하였다. 물의 H_2SO_4 및 NaOCl 용액의 주입량을 제어하여 용액의 초기 pH 값을 조정하고, 값을 pH 미터 (HORIBA F-51, 일본)로 측정 하였다. 실험 동안, 가열 코일을 사용하여 물의 온도를 필요한 수준으로 유지 하였다. 실험이 완료된 후, 휴대용 가스 분석기 (Madur GA-21, 폴란드)와 NOx 분석기 (반도체 타입, Thermo Environmental 42C NO-NO2-NOx 가스 방출 분석기, 미국)를 사용하여 입구 및 출구 스트림에서 가스 농도 (즉, NO, NO_2 및 O_2)를 ppm으로 측정했다. 일반적으로, 약 20 분 후에 안정한 조건이 달성되었고, 일단 안정화되면 가스의 농도가 측정되었다.

[0055] 각 변수의 하한과 상한은 이전 연구를 기반으로 결정되었다. 첫째, 초과 O_2 농도의 범위는 8 ~ 13 %로 설정되었다. 또한, 물의 pH 범위는 동일한 방식으로 3 내지 11로 설정되었다. H_2SO_4 또는 NaOCl 용액을 첨가하여 물의 pH를 조정 하였다. 수온의 경우, SCV의 실제 작동 온도가 이 실험에 적용되었고, 그 범위는 10 내지 28 ℃로 설정되었다. 마지막으로, H2O2 농도는 0 내지 0.2 %로 설정되었다. 실험 조건과 각 변수의 범위는 표 1에 요약되어 있다.

[0056] [표 1]

Table 4. Experimental conditions and range of each variable.

		Experimental conditions	
Concentration of NO_x in the flue gas (ppm)		100 – 200	
Volumetric flow rate of the gas (L/min)	N_2		65
	NO (N_2+NO)		0.8
	Air		40
NO_x of the exhaust gas from stack (ppm)		Max. 50	
Amount of water in the water bath (L)		600	
Experimental variables	Concentration of excess O_2 (%)	8 – 13	
	Temperature of the water bath (°C)	10 – 28	
	pH of the water in bath	3 – 11	
	Concentration of H_2O_2 (%)	0 – 0.2	

[0057]

[0058] **A.3 실험 결과 및 분석**

[0059] **실험 결과**

[0060] SCV는 일반적으로 탱크 내 15 ° C의 수온에서 작동하며 연소 구역에서 과잉 산소 농도가 8 %이다. 정상적인 작동 조건에서 NO는 흡수를 통해 약 16 ~ 17 % 제거된다. NOx 환원 실험은 과잉의 O_2 농도, 물의 온도, 물의 pH 및 H_2O_2 농도의 4 가지 공정 변수를 조작함으로써 다양한 작동 조건 하에서 수행되었다. NO 감소의 효율은 수학식 (6)을 사용하여 계산되었다.

수학식 6

$$\text{NO reduction (\%)} = \frac{[NO]_i - [NO]_f}{[NO]_i} \times 100$$

[0061]

[0062] 여기서, NO_i - ppm의 NO의 입구 농도, NO_f - ppm의 출구 농도를 의미한다.

[0064] **실험 결과 분석**

[0065] 도 6 내지 도 9는 연도 가스의 NO 감소량에 대한 각 공정 변수의 영향을 보여준다. 보다 구체적으로 도 6은 15 ℃, pH 7 및 0 %의 H_2O_2에서 NO 환원에 대한 과량의 O_2 농도의 영향을 나타내고, 도 7은 8 % O_2, pH 7 및 0 %의 H_2O_2에서 NO 감소에 대한 온도의 영향을 나타내고, 도 8은 8% O_2, 15 ℃ 및 0 %의 H_2O_2에서 NO 환원에 대한 pH의 영향을 나타내고, 도 9는 8 % O_2, 15 ℃ 및 pH 7에서 NO 환원에 대한 H_2O_2 농도의 영향을 나타낸다.

[0066] 도 6에서 볼 수 있듯이 과도한 O_2 농도는 NO 제거를 증가 시켰으며, NO 감소는 O_2의 약 9-10 %에서 극대화되었다. 수온과 관련하여, 도 7에 도시 된 바와 같이 수온이 19℃를 초과하면 NO 감소가 증가하기 시작한다. 그러나, 수온을 증가시키는 것은 비용이 많이 들고 추가 연도 가스를 생성 할 수 있다. 물의 pH와 관련하여, 도 8에 도시 된 바와 같이 물의 pH가 대략 5 일 때 NO 감소는 비교적 높다. 반대로, H_2O_2의 주입은, 도 9에 도시 된 바와 같이 NO의 제거에 유의미한 영향을 미치지 않았다. H_2O_2는 비용이 많이 들고 대량으로도 효과적이지 않기 때문에 소량이 물에 주입된다.

[0067] NO의 감소를 최대화하기 위해, 4 개의 변수가 NO 감소의 총량에 어떤 영향을 미치는지 조사하고 최적의 작동 값을 결정해야 한다. 따라서 공정 변수 값이 변경 될 때 시스템의 동작을 이해하기 위해 이 연구에서 대리 모델(surrogate model)이 개발되었다. 이후 GA 최적화는 개발된 모델과 통합되어 NO 제거를 최대화하면서 최적의 조건을 결정한다.

[0069] **B.대리 모델(surrogate model)의 개발**

[0070] 수학적 모델링은 시스템의 동작을 이해하고 입력의 변화에 따라 출력을 예측하는 강력한 기술이다. 특히 선형으로 작동하는 시스템을 예측하는 것이 더 쉽다. 그러나 비선형 시스템의 경우 입력 변경에 따라 출력을 이해하고 예측하기가 상당히 어렵다. 특히 반응 시스템은 여러 변수를 나타내며 상관 관계의 복잡성이 매우 높다. 따라서 시스템의 정확한 예측은 수학적 모델링을 통해 상당히 어려워진다. 따라서, 비선형 행동을 나타내는 엔지니어링 시스템의 출력을 예측하기 위해 수학적 모델링 대신 몇 가지 대안적인 접근 방식이 개발되었다.

[0071] 최근 인공 지능 (AI)의 개발로 비선형 동작을 효율적으로 예측할 수 있는 모델을 만드는 것이 가능하다. 따라서 많은 현존하는 연구에 따르면 빅 데이터 분석 및 AI 모델링은 다양한 시스템에 대한 정확한 결과를 예측한다.

[0072] 본 발명에서는 기계학습의 알고리즘인 인공 신경망(Artificial Neural Network, ANN)을 사용하여 수정된 SCV를 모델링하고, SCV 시스템이 비선형 동작을 나타내는 4개의 입력 변화에 대한 NO 감소를 예측하도록 모델링한다.

[0074] **B.1 인공 신경망 모델(ANN model)**

[0075] ANN 적용을 위한 일반적인 절차에는 다음 단계가 포함된다.

[0076] 1. 기계 학습을 위한 데이터 수집 (즉, 시스템의 입력 및 출력 데이터)

[0077] 2. 신경망 아키텍처의 선택.

[0078] 3. ANN의 훈련.

[0079] 4. ANN의 검증.

[0080] 5. 새로운 입력에 대한 ANN 시뮬레이션.

[0081] ANN에서는, 인공 뉴런으로 알려진 노드를 기반으로 하며 신호는 한 뉴런에서 다른 뉴런으로 전송된다. 뉴런은 서로 연결되어 있으며, 각 링크는 수치를 나타낸다. 가중치는 중요도를 나타내며 링크간에 분산된다.

[0082] 또한 ANN은 특정 수의 레이어, 각 레이어의 인공 뉴런, 각 레이어의 활성화 기능 및 훈련 알고리즘으로 구성된 네트워크 아키텍처로 특징 지어진다. 일반적으로 다층 컨셉트론(Multi-Layer Perceptron, MLP)가 사용되며, 이것은 피드 포워드 인공 신경망의 클래스에 해당한다. 피드 포워드는 계층 간 연결이 항상 하위 계층에서 상위 계층으로 연결됨을 의미한다. MLP는 입력 레이어, 출력 레이어 및 그 사이에 하나 이상의 숨겨진 레이어로 구성된다. 도 10은 MLP 아키텍처를 나타낸다.

[0083] NOx 환원 시스템에서, 입력 변수는 초과 O_2 농도, 온도, 물 pH 및 H_2O_2 농도를 포함한다. 출력 변수는 공급 입구 및 배기 가스 출구에서 ppm으로 측정 된 NO의 양으로부터 계산된 백분율로 NO 감소에 해당한다. 실험을 통해 명시적 입력 및 출력 데이터 쌍이 수집되고 학습 데이터로 제공된다.

[0084] ANN을 사용하여 강력하고 정확한 모델을 만들려면 신경망의 아키텍처를 올바르게 고려해야 한다. 먼저 숨겨진 레이어 수를 선택해야 한다. 문제의 복잡성을 증가시키면 필요한 숨겨진 계층의 수가 증가한다. 그 후, 숨겨진 계층의 뉴런 수를 결정하기 위해 시행 착오 방법이 구현되었다. 일반적으로 이 모델은 훈련 데이터만을 기반으로 훈련되기 때문에 숨겨진 뉴런의 수가 비교적 많은 경우, 모델은 과적합된다. 반대로, 숨겨진 뉴런의 수가 너무 적으면 모델에 적합하지 않다.

[0085] 피드 포워드 신경망에서, 신호는 수학식 7에 의해 j 및 i 뉴런으로 임의의 (n-1) 층(레이어로 지칭될 수 있음)에서 (n)층으로 전송된다. 출력 신호는 프로세스를 반복하여 결정된다.

수학식 7

[0086] $$a_i^n = \mathrm{F}_n\left(\sum_j w_{i,j}^n a_j^{n-1} + b_i^n\right)$$

[0087] 여기서, 은 레이어 n에 전송되는 신호, b은 레이어 n의 바이어스 벡터, 은 (n-1) 층과 n 층의 가중 메트릭스 연결, F 은 n층의 활성화 함수를 나타낸다.

[0088] 활성화 함수는 전달 함수라고 하며 입력 신호를 선형 또는 비선형 출력 신호로 변환한다. 일반적으로 사용되는 기능은 도 11 내지 도 14에 표시된 것과 같이 항등 함수, 단계 함수, 시그모이드 함수 및 쌍곡 탄젠트 시그모이드 (tanh) 함수이다. 항등 함수는 주로 선형 근사에 사용되고, 단계 함수는 어려운 한계 함수라고도 하며 분류 및 패턴 인식에서 결정을 내리는 뉴런에 사용된다. 시그모이드 함수는 주로 역 전파 신경망에서 사용되고 시그모이드 함수의 출력 범위는 0 ~ 1이다. 반면, tanh 함수의 출력 범위는 -1에서 1이고, tanh의 추가 너비는 소실 구배 문제를 해결할 수 있다.

[0089] 신경망 훈련의 목표는 신경망의 가중치를 조정하여 실험 응답과 ANN 모델에 의해 예측된 응답 사이의 오류를 최소화하는 것이다. 따라서 일반적으로 Levenberg-Marquardt (LM), Bayesian Regularization (BR) 및 Gradient Descent (GD) 알고리즘이 사용된다.

[0090] 개발된 모델의 성능을 검증하기 위해 여러 연구에서 다양한 측정 기준을 사용했다. 상관 계수 (R), 분산의 절대 비율 (R^2), 평균 제곱 오차 (MSE) 및 평균 절대 백분율 오차 (MAPE)는 일반적으로 수학식 (8) 내지 수학식 (10)에 표시된 대로 사용된다. MSE가 낮고 R 값이 1에 가까우면 ANN 모델이 우수한 성능과 높은 정확도를 나타낸다. 또한 MAPE의 이상적인 범위는 'MAPE < 5 %'로 간주된다.

수학식 8

$$R = \sqrt{\left[1 - \left\{\frac{\sum_{i=1}^{n}(t_i - o_i)^2}{\sum_{i=1}^{n} o_i^2}\right\}\right]}$$

[0091]

수학식 9

$$MSE = \frac{[\sum_{i=1}^{n}(t_i - o_i)^2]}{n}$$

[0092]

수학식 10

$$MAPE = \left[\sum_{i=1}^{n}\left|\frac{(t_i - o_i)}{t_i}\right|\right] \times \frac{100}{n}$$

[0093]

[0094] 여기서, n은 총 데이터 수, 실험적으로 측정된 값, 는 예측 값을 나타낸다.

[0096] **B.2 유전자 알고리즘 (Genetic Algorithm, GA) 최적화**

[0097] 본 발명의 일 실시예에서는 유전자 알고리즘 (GA)을 ANN 모델에 통합하여 최적화 문제를 해결하고자 한다. 유전자 알고리즘(GA)은 스칼라 값만 요구하며 목적 함수 형태의 전제 조건은 없다. ANN 모델과 유전자 알고리즘(GA)의 하이브리드 기술은 복잡한 프로세스를 모델링하고 최적화하는 강력한 도구이며, 응답 표면 방법 (response surface method, RSM)의 성능을 능가하는 성능을 보여준다. 본 발명의 일 실시예는 SCV의 작동 조건은 GA를 사용하여 연도 가스의 NOx 감소를 최대화함으로써 최적화 된다.

[0098] 유전자 알고리즘(GA)는 개별 솔루션의 모집단를 반복해서 변경하면서 운영된다. 여기에는 선택, 교차 및 돌연변이가 포함되므로 유전적 진화 이론과 유사하다. 모집단은 해당 피트니스 함수로 정의된 최적 솔루션으로 "진화"한다.

[0099] 도 15는 유전자 알고리즘의 표준 순서도를 나타낸다.

[0101] **C.결과**

[0102] **C.1 ANN 모델**

[0103] MATLAB 소프트웨어(MathWorks Inc., USA)를 사용한 실험 데이터에 기초하여 최종 NO 감소를 예측하기 위해 ANN 모델이 개발되었다. 본 발명의 일 실시예에서는 3 계층 피드 포워드 신경망을 사용한다. 구체적으로, 입력 계층은 4 개의 뉴런을 포함하고, 숨겨진 계층은 17 개의 뉴런을 포함하고, 출력 계층은 단일 뉴런을 포함한다. 입력 뉴런은 실험 변수 (즉, 과량의 O_2 농도, 온도, 물 pH 및 H_2O_2 농도)를 나타내고, 출력 뉴런은 NO 감소를 나타냈다. 숨겨진 뉴런의 수는 시행 착오 방법을 통해 결정된다.

[0104] 도 16은 상이한 수의 숨겨진 뉴런에 대한 ANN 예측 모델 성능 (MSE)을 나타낸다.

[0105] 도 16을 참조하면, 숨겨진 뉴런의 수를 17로 설정했을 때 평균 제곱 오차 (MSE)가 가장 작은 것으로 나타났다. ANN 모델에 사용된 함수는 숨겨진 뉴런에 대한 쌍곡 탄젠트 시그모이드(tanh) 함수이다. 왜냐하면 시그모이드 함수와 비교하여 회귀성능이 좋았기 때문이다. 도 17은 본 발명의 일 실시예에 따른 NOx 감소 시스템의 ANN 모

델 구조를 나타낸다.

[0106] 본 발명의 일 실시예에 따른 학습/테스트 세트는 총 63 세트의 실험 데이터를 사용하여 모델을 학습하고 테스트했다. 보다 구체적으로, 학습에 53 세트, 신경망 테스트에 10 세트가 사용되었다. 모델을 학습하기 전에 입력 및 출력 데이터를 정규화하여 -1과 1 사이가 되도록 하고 베이지안 정규화 (BR) 알고리즘을 사용하여 모델을 학습한다.

[0107] 본 발명의 일 실시예에 따른 모델의 정확도 측면에서 결과는 0.9985의 R 값 (상관 계수), 0.9668의 MSE 및 4.4433의 MAPE를 도출하였다. 도 18은 SCV 시스템의 NO 감소에 대한 실험 값과 예측 값의 분포를 나타낸다. 도 19는 모든 실험 결과의 오차 막대를 나타낸다.

[0108] C.2 감도 분석

[0109] 입력 변수와 모델링 출력 간의 '원인과 결과'관계를 분석하기 위해 감도 분석이 수행되었다. 따라서 시스템 성능에 대한 독립 변수의 기여도를 평가했다. 민감도 분석을 위해 다양한 알고리즘을 사용할 수 있다. 본 발명에서는 MLP에서 입력 변수의 상대적 중요성은 수학식 (11) 및 수학식 (12)에 도시 된 바와 같이 수정된 Garson 알고리즘 및 연결 가중치 접근법을 통해 평가되었다.

수학식 11

[0110] $$RI_x = \frac{\sum_{y=1}^{m} |w_{xy} w_{yz}| / \sum_{x=1}^{n} |w_{xy}|}{\sum_{x=1}^{n} \sum_{y=1}^{m} (|w_{xy} w_{yz}| / \sum_{x=1}^{n} |w_{xy}|)}$$

수학식 12

[0111] $$RI_x = \sum_{y=1}^{m} w_{xy} w_{yz}$$

[0112] 여기서, 는 입력 변수 x의 상대적 중요성, n은 입력 뉴런 수, m은 숨겨진 뉴런의 수, 는 입력 뉴런 x와 숨겨진 뉴런 y 사이의 연결 무게, 는 숨겨진 뉴런 y와 출력 뉴런 z 사이의 연결 무게를 나타낸다.

[0113] 결과는 모든 연결 중량이 양수 또는 음수 값을 나타내고 반작용 영향이 발생했음을 나타낸다. 이를 피하기 위해 모든 연결 가중치는 수정된 Garson 알고리즘에서 절대값으로 계산되었다.

[0114] [표 2]

[0115] 수정 된 Garson 알고리즘 및 연결 가중치 접근법을 통한 입력의 상대적 중요성.

[0116]

	Modified Garson's algorithm		Connection Weight Approach	
	Relative importance	Rank	Relative importance	Rank
O_2	0.382	1	-1.038	1
pH	0.262	2	0.743	2
H_2O_2	0.200	3	0.465	3
T	0.159	4	-0.193	4

[0117] 표 2에 나타난 바와 같이, 상대적 중요도 변수의 순위가 매겨졌다. 상기 방법의 결과에 기초하여, O_2 농도 및 pH는 NO 환원에 가장 큰 영향을 미쳤으며, 이어서 H_2O_2 농도 및 수온이 뒤를 이었다. 연결 가중치 접근법의 관점에서, 상대 중요도의 절대 값이 높을수록 변수가 시스템 성능에 더 큰 영향을 미쳤다는 것을 암시했다.

[0118] 도 20은 ANN 모델에 의한 예측 결과에서 NO 환원에 대한 pH 및 과량의 O_2 농도의 영향을 나타낸다.

[0119] 가장 중요한 두 가지 입력 변수(O_2 농도 및 pH)는 15 ℃ 고정 온도 및 0 %에 해당하는 H_2O_2 농도에서 도 20과 같이 3 차원 그래프로 표시된다. 이것은 ANN 모델에 의해 얻어진 예측 결과가 실험 결과와 잘 맞는다는 것을 나타냈다. 또한 ANN 모델이 비선형 시스템을 잘 나타낸다는 것을 보여준다.

[0120] **C.3 GA 최적화**

[0121] **GA와 ANN의 통합**

[0122] ANN 모델링을 통해 입력 변수와 NO 감소 간의 관계를 비선형 입력-출력 매핑으로 간주되는 함수(수학식 13)로 획득할 수 있다.

수학식 13

[0123]
$$\text{NO reduction} = \text{ANN}(O_2\ concentration, Temperature, pH, H_2O_2\ concentration)$$

[0124] 본 발명의 일 실시예에 따르면, 복잡한 SCV 시스템은 ANN 모델로 표시되었으며, 입력 값의 변화에 대응하여 해당 출력을 신속하게 추정한다. GA 최적화 알고리즘은 입력 변수의 변화에 따라 출력을 계산하기 위해 많은 반복이 필요하기 때문에, ANN 모델은 최적화를 위한 계산 속도 측면에서 상당히 유용하다. 따라서 ANN과 GA의 통합 시스템을 채택하면 다양한 조건에서 비교적 빠른 방식으로 최적의 작동 조건을 검색 할 수 있다.

[0125] SCV 시스템의 최적화 목표는 하한과 상한 사이의 공정 변수의 최적 지점을 검색하여 NO 감소를 최대화하는 것과 관련이 있다. 각 변수의 하한과 상한은 표 3에 나와 있다.

[0126] [표 3]

[0127] 입력 변수의 상한 및 하한

[0128]

	Lower bound	Upper bound
O_2(%)	8	13
T(℃)	10	28
pH	3	11
H_2O_2(%)	0	0.2

[0129] 참고로, 하한과 상한의 값은 현장에서 식별된 작동 제한에 따라 선택되었다. GA는 최적화된 최소값을 결정하도록 설계되었으므로 NO 감소의 최대 값을 얻기 위해 ANN 모델 기능에 '-1'을 곱했다. GA 피트니스 함수는 다음과 같이 수학식 14로 표시된다.

수학식 14

[0130]
$$\text{GA fitness function} = -\text{ANN}(O_2\ concentration, Temperature, pH, H_2O_2\ concentration)$$

[0131] 도 21은 최적의 피트니스 함수 값을 나타낸다. GA의 파라미터는 시행 착오 방법을 통해 표 4에 나타낸 바와 같이 설정되었다.

[0132] [표 4]

[0133] GA의 세부 사항

Mutation function	Adaptive Feasible
Cross-over fraction	0.8
Population size	50
Function tolerance	1e-6

[0134]

[0135] 최고의 피트니스 함수 값의 변화가 1 x 10^{-6}의 수렴 기준보다 작거나 같은 경우에만 GA가 종료되었다. ANN 모델과 GA 최적화를 결합한 결과 수렴률이 매우 높은 것으로 관찰되었다. 최대 NO 감소를 달성하는 최적 작동 조건은 표 5에 제시되어 있다. 최적화 결과에 따르면, 입력 변수의 최적 값이 SCV 시스템에 적용된 경우 NO 감소의 최대량은 26.68 %로 예측되었다.

[0136] [표 5]

[0137] 입력 변수의 최적 조건 및 최대 NO 감소

	O_2 (%)	T (℃)	pH	H_2O_2 (%)	Predicted NO reduction (%)
Best value	9.23	28	5	0.13	26.68

[0138]

[0139] **실험적 검증**

[0140] NO 감소의 최대 값을 달성하는 공정 변수를 검증하기 위해 추가 실험이 수행되었다. 최적 조건에서 추가 실험으로부터 얻은 NO 감소는 26.75% 였다. 따라서, 최적의 조건에서 실험적 NO 감소와 예측된 NO 감소의 차이는 0.07 %이고, 오차는 다음과 같이 수학식 15에 의해 계산된 바와 같이 0.26 %이다.

수학식 15

[0141]
$$\text{Error (\%)} = \frac{Experimental\ NO\ reduction\ (\%) - Predicted\ NO\ reduction\ (\%)}{Experimental\ NO\ reduction\ (\%)} \times 100$$

[0142] 도 22는 ANN 예측 모델에서 얻은 NO 감소 값을 최적 조건에서 실험한 검증 결과를 나타낸다.

[0143] **고정 온도의 적용**

[0144] 다른 변수와 달리 수온을 제어하는 것은 비용이 많이 들지만 다른 변수와 비교할 때 크게 효과적이지 않다. 따라서 ANN 모델과 GA 최적화를 통합한 통합 모델은 고정 온도 세트에서 세 가지 변수만 최적화하여 최대 NO 감소를 달성했다. 표 6은 세 가지 변수의 최적 값과 각 온도에서 NO 감소의 최대 값을 보여준다.

[0145] [표 6]

[0146] 각 온도에서의 최적 값

T (℃)	10	13	15	17	19	21	23	25	28
O_2 (%)	9.68	9.60	9.55	9.49	9.44	9.39	9.34	9.30	9.23
pH	4.75	4.80	4.84	4.86	4.88	4.89	4.91	4.93	4.95
H_2O_2 (%)	0.077	0.084	0.089	0.095	0.101	0.108	0.114	0.121	0.132
NO reduction (%)	23.22	23.75	24.13	24.51	24.90	25.29	25.69	26.09	26.68

[0147]

[0148] 수온이 상승하면 과량의 O_2와 H_2SO_4의 양이 감소하고 효율적으로 작동하기 위해 더 많은 H_2O_2가 필요하다. H_2SO_4는 전술한 바와 같이 산성 조건을 생성하는 첨가제였다. 실험 표준 조건에서 수행되었을 때, NO 감소는 16.67 %에 해당했다 (수온은 15 ℃). 첨가제가 표 6에 나타낸 바와 같이 물에 첨가되면 최종 NO 감소는 24.13 %에 도달 하였다.

[0149] **D.결론**

[0150] 본 발명의 일 실시예에 따른 SCV의 구조는 대기에서 배기 가스를 방출하기 전에 NO를 NO_2 로 전환 및 NO_2의 탱크 내에서 물로의 흡수를 증가 시키도록 변형되었다. 개선된 SCV 셋업의 파일럿 스케일을 준비하고, 공정 변수 (즉, 과량의 O2 농도, 온도, 물의 pH 및 H2O2 농도)를 변경함으로써 실험을 수행 하였다.

[0151] 실험 데이터에 기초하여, 4 개의 공정 변수의 변화에 반응하여 NO 감소를 예측하는 대리 모델이 ANN 알고리즘을 통해 개발되었다. 개발된 ANN 모델의 구조는 3 계층 피드 포워드 신경망을 나타내었으며 베이지안 정규화 (BR) 알고리즘을 통해 학습되었다. 모델의 성능과 관련하여 R 값은 0.9985, MSE는 0.9668, MAPE는 4.4433을 나타냈다. 민감도 분석은 O_2의 농도가 NO 환원에 가장 효과적이며, 이어서 물의 pH, H_2O_2의 농도 및 수온에 효과적임을 나타냈다. ANN 모델은 GA와 통합되었으며 NO 제거를 최대화하기 위해 최적의 작동 조건을 검색했다. 마지막으로, 최적화 결과를 검증하기 위해 추가 실험을 수행하였고, 모델 예측과 실험 결과 사이의 오차는 0.26 % 였다.

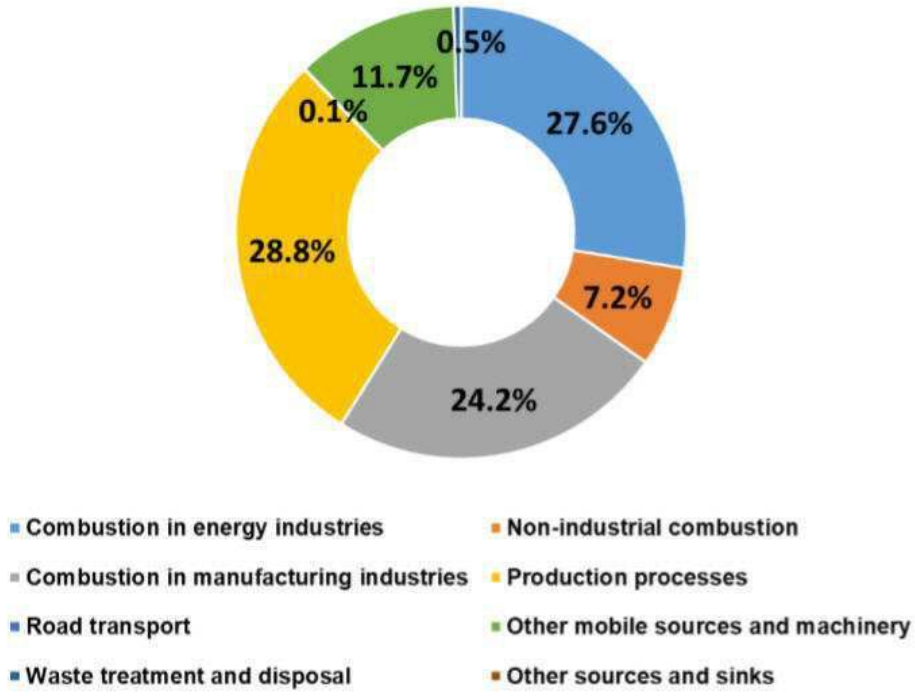
[0152] 수정된 공정은 유용한 현장 응용을 제공하며, 모델링 결과는 최적의 공정 변수(예: 초과 O_2 농도, 온도, 물의 pH 및 H_2O_2 농도)로 최적화된 작동 조건을 크게 수정하지 않고 기존 SCV에 적용할 가능성이 높다. 또는 현장 SCV의 실시간 데이터를 통합된 ANN-GA 모델에 공급할 수 있으며 최적의 작동 조건을 검색 할 수 있다. 또한 개발된 통합 모델을 이용하여 NOx 환경 규제를 만족시키는 효율적인 운영 전략을 신속하게 개발할 수 있으며, 이 방법론을 다른 프로세스에도 쉽게 적용할 수 있다.

[0153] 본 발명의 일 실시예에 따른 질소산화물 저감 시스템 및 그 방법은 ANN-GA 통합 모델을 효과적으로 사용하여 SCV에서 연도 가스의 NOx 감소를 극대화하기 위해 최적의 작동 조건을 검색할 수 있다. ANN-GA 모델은 여러 공정 변수로 복잡한 다른 배출 감소 시스템에 쉽게 적용 할 수 있다. 또한 수학적으로 모델링하기 어렵고 시스템의 매개 변수를 최적화하기 위해 상당한 계산 부하가 필요한 시스템의 모델링 및 최적화에서 우수한 성능을 보여준다. 본 발명의 일 실시예에 따라 ANN-GA 모델을 사용하면 공정의 경제성을 평가하는 데 유용하다. 예를 들어, 개발된 ANN-GA 모델을 사용하여 필요한 최소량의 H_2O_2를 쉽게 추정 할 수 있다.

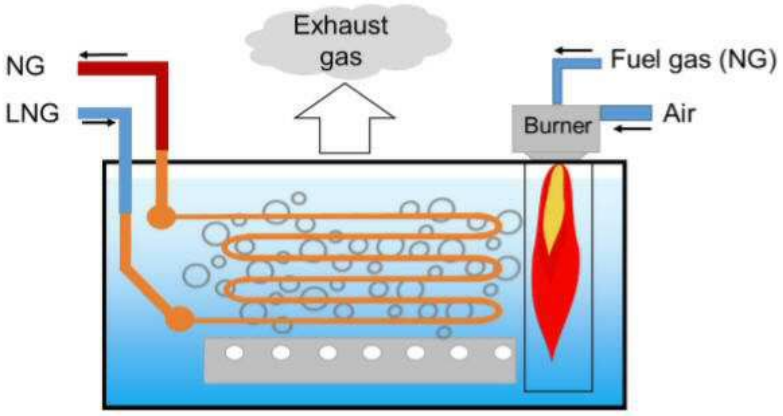
[0154] 이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 사람이라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 다양한 수정 및 변형이 가능할 것이다. 따라서, 본 발명에 개시된 실시예들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다. 본 발명의 보호 범위는 아래의 청구범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 발명의 권리범위에 포함되는 것으로 해석되어야 할 것이다.

도면

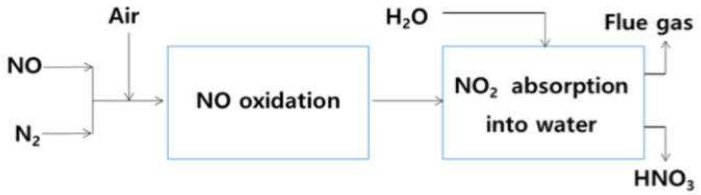
도면1



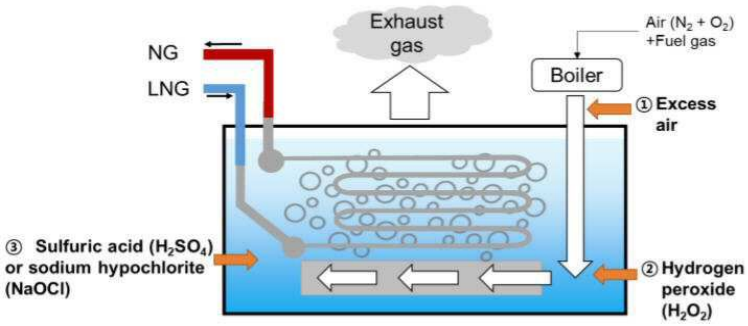
도면2



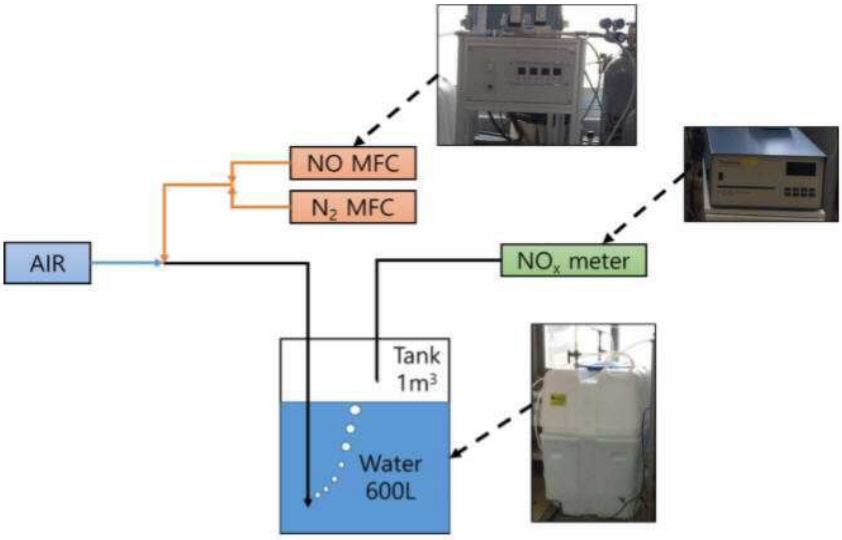
도면3



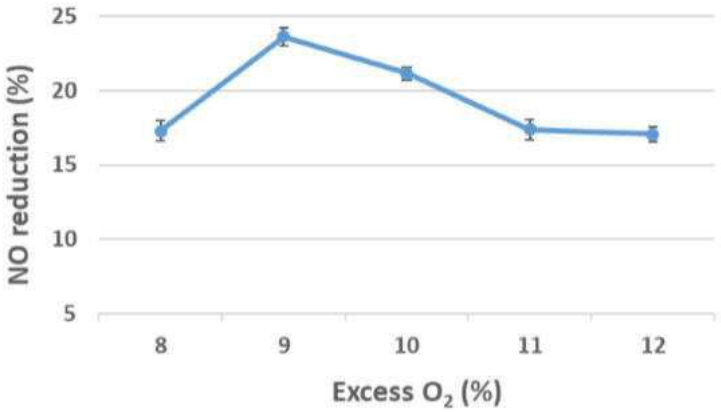
도면4


Exhaust gas
Air (N_2 + O_2) +Fuel gas
NG
LNG
Boiler
① Excess air
③ Sulfuric acid (H_2SO_4) or sodium hypochlorite (NaOCl)
② Hydrogen peroxide (H_2O_2)

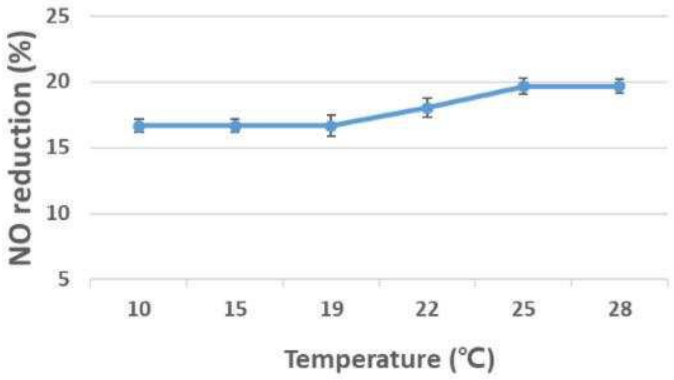
도면5


NO MFC
N_2 MFC
AIR
NO_x meter
Tank 1m³
Water 600L

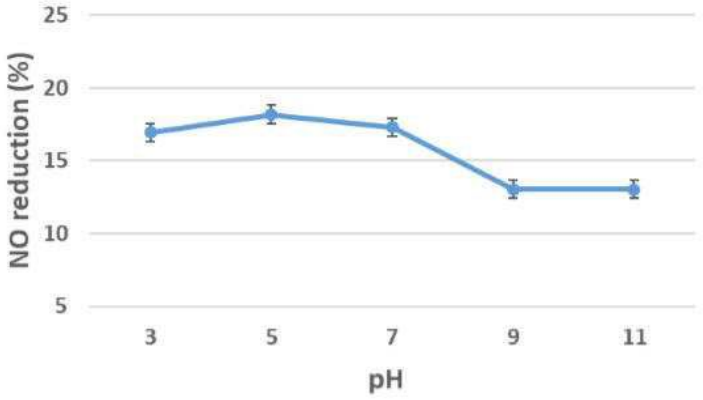
도면6


NO reduction (%)
25
20
15
10
5
8
9
10
11
12
Excess O_2 (%)

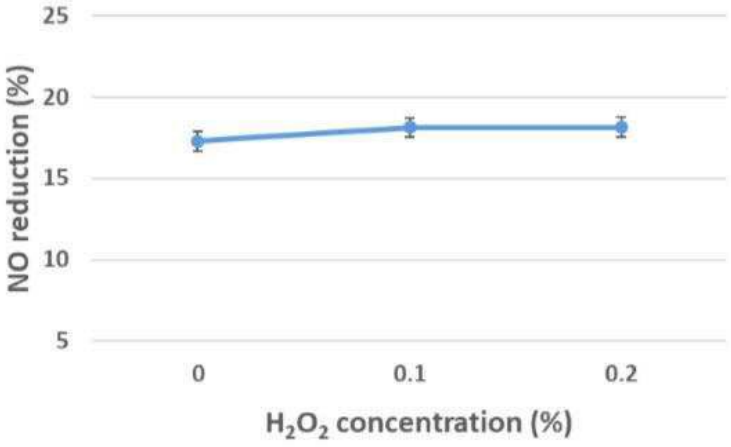
도면7


NO reduction (%)
25
20
15
10
5
10
15
19
22
25
28
Temperature (℃)

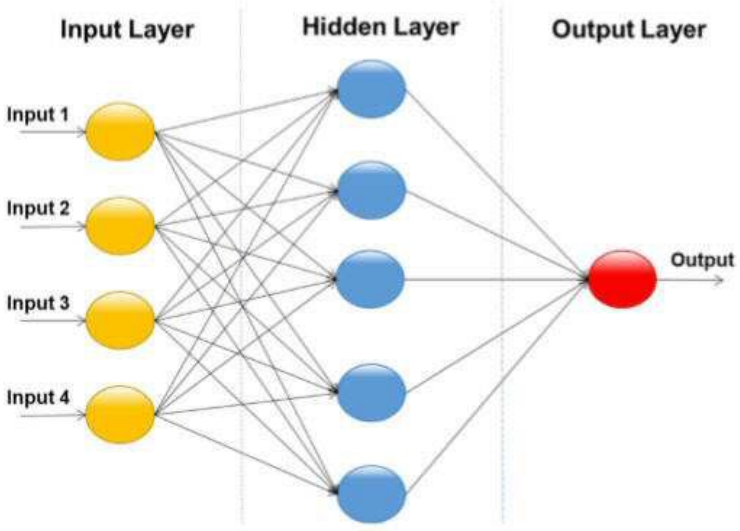
도면8


NO reduction (%)
25
20
15
10
5
3
5
7
9
11
pH

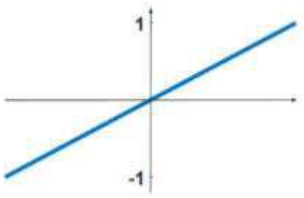
도면9


NO reduction (%)
25
20
15
10
5
0
0.1
0.2
H2O2 concentration (%)

도면10

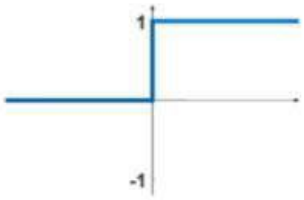


도면11



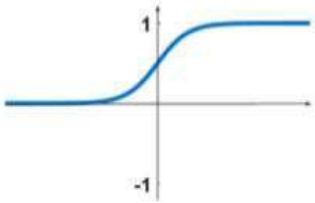
$$f(x)=x$$

도면12



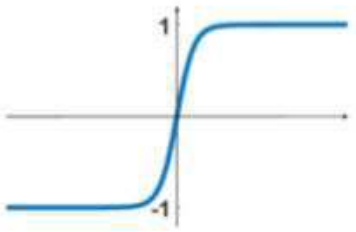
$$f(x)=\begin{cases}0 & for\ x<0\\ 1 & for\ x\geq 0\end{cases}$$

도면13



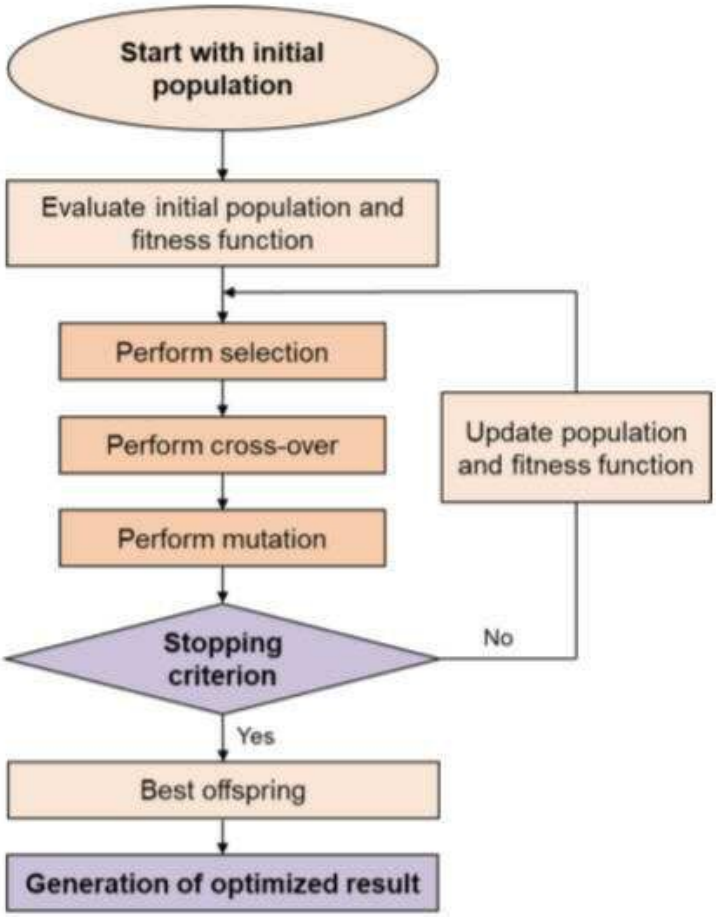
$$f(x)=\sigma(x)=\frac{1}{1+e^{-x}}$$

도면14

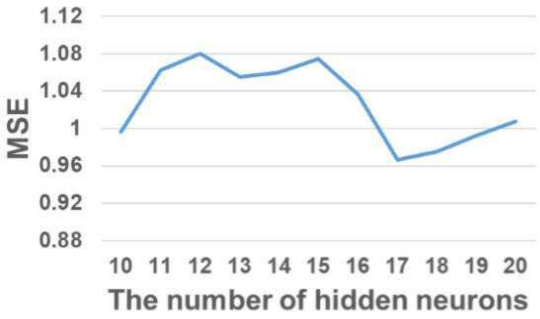


$$f(x) = tanh(x) = \frac{(e^{x}-e^{-x})}{(e^{x}+e^{-x})}$$

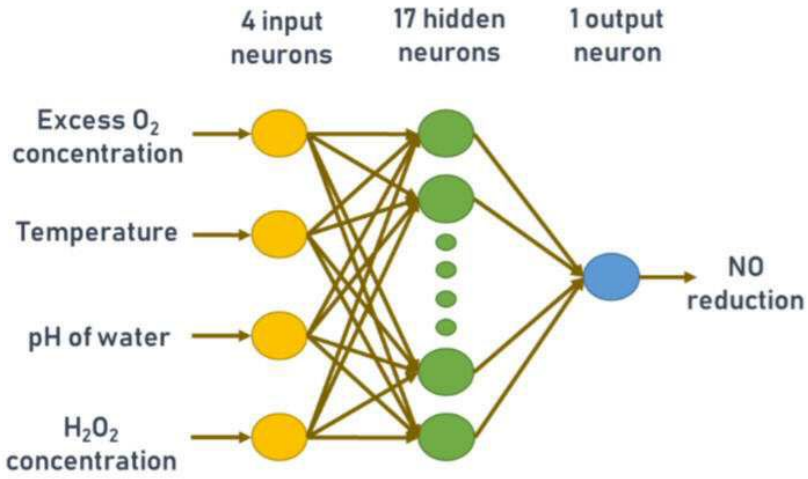
도면15



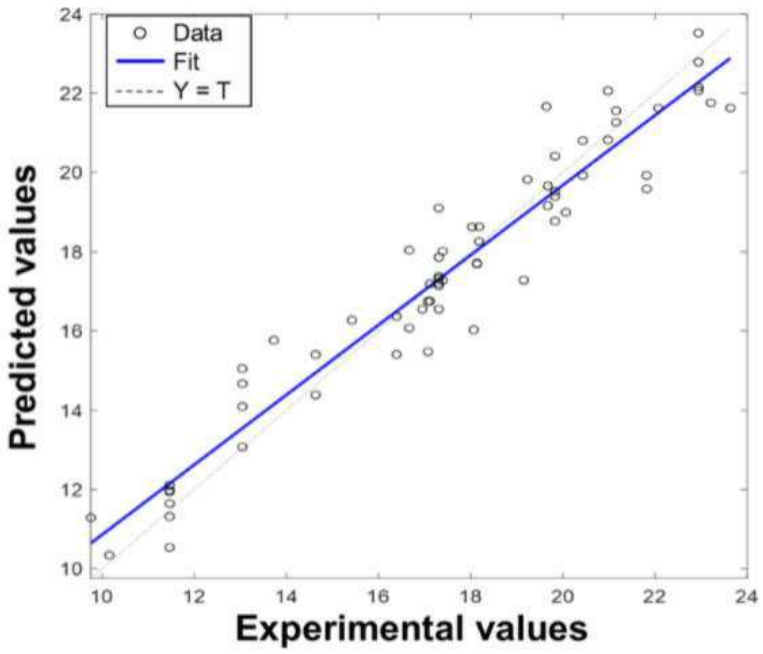
도면16



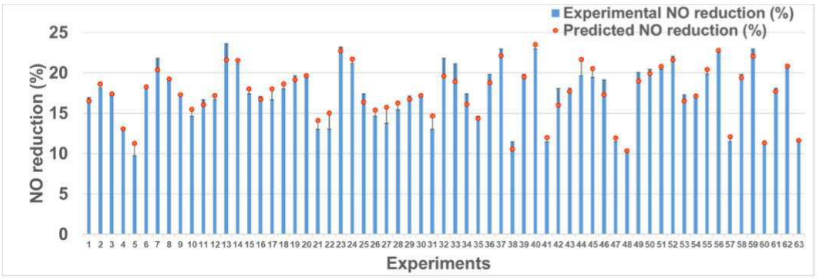
도면17



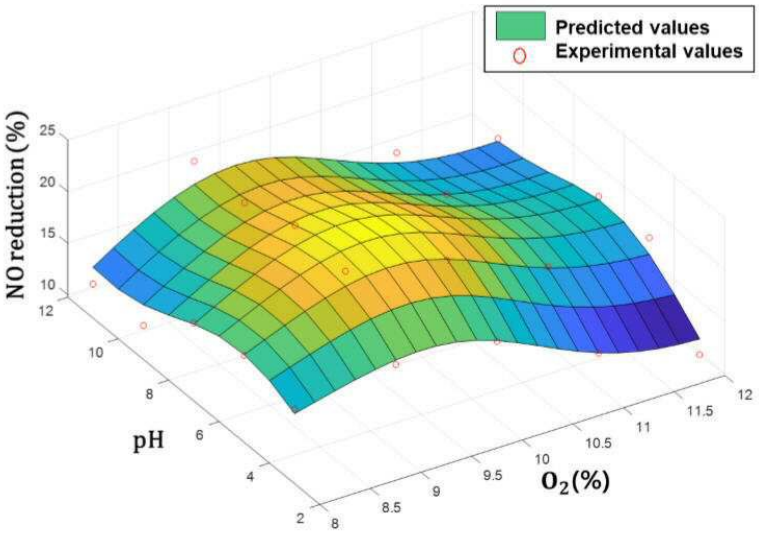
도면18



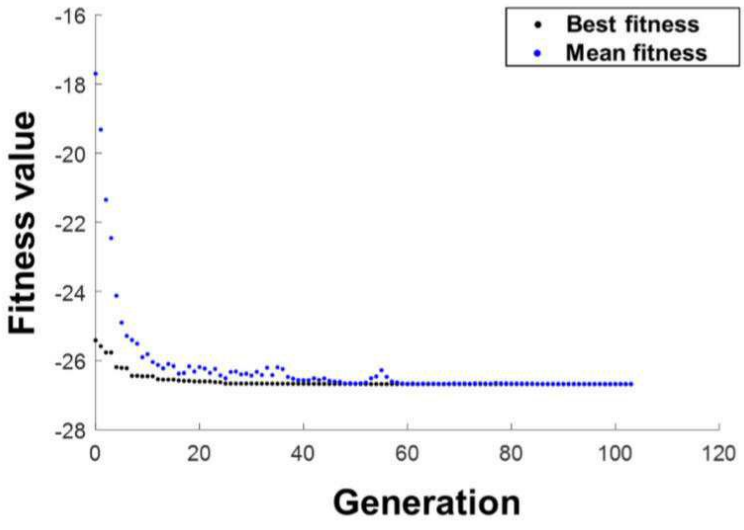
도면19



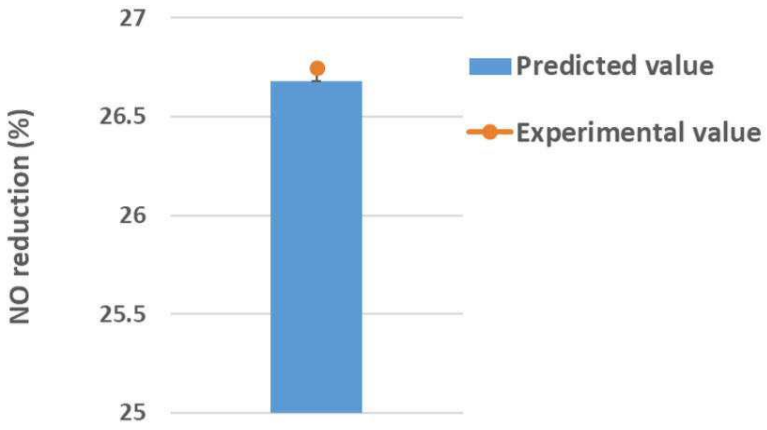
도면20



도면21



도면22


27
26.5
26
25.5
25
NO reduction (%)
Predicted value
Experimental value