



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2018-0116922
(43) 공개일자 2018년10월26일

(51) 국제특허분류(Int. Cl.)
G06Q 10/04 (2012.01) E21D 9/06 (2006.01)
G06N 3/08 (2006.01)
(52) CPC특허분류
G06Q 10/04 (2013.01)
E21D 9/06 (2013.01)
(21) 출원번호 10-2017-0049843
(22) 출원일자 2017년04월18일
심사청구일자 2017년04월18일

(71) 출원인
인하대학교 산학협력단
인천광역시 남구 인하로 100, 인하대학교 (용현동)
(72) 발명자
송기일
인천광역시 연수구 아트센터대로97번길 75, 1303동 902호 (송도동, 더샵 하버뷰13단지)
이항로
인천광역시 서구 원적로96번길 21, 2층 (가좌동)
(74) 대리인
특허법인태백

전체 청구항 수 : 총 10 항


(54) 발명의 명칭 쉘드 TBM의 순굴진속도 예측 장치 및 그 방법

(57) 요약

본 발명은 쉘드 TBM의 순굴진속도 예측 장치 및 그 방법에 관한 것이다. 본 발명에 따르면, 기 시공된 복수의 현장 각각에 대응하여, 상기 현장에 대해 예측된 복수의 지반 인자 및 쉘드 TBM의 현장 관입 지수를 저장한 데이터 베이스와, 상기 복수의 지반 인자에 대응하는 좌표점을 입력 벡터 공간에 투영하여 상기 현장 각각의 좌표점을

(뒷면에 계속)

대표도 - 도2



복수의 군집으로 퍼지 클러스터링하는 클러스터링부와, 상기 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망의 입력 노드와 출력 노드에 각각 상기 복수의 지반 인자와 상기 현장 관입 지수를 적용하여, 상기 신경망을 학습시키는 신경망 학습부, 및 시공 대상 현장에 대해 획득한 복수의 지반 인자를 상기 학습된 신경망에 입력시켜 상기 시공 대상 현장에 대한 현장 관입 지수를 예측하는 예측부를 포함하는 쉘드 TBM의 순굴진속도 예측 장치를 제공한다.

본 발명에 의하면, 과거 시공 현장에서 획득된 지반 인자들 및 쉘드 TBM의 현장 관입 지수를 적응형 뉴로 퍼지 신경망에서 훈련시켜 구축한 ANFIS 훈련 모델을 이용하여, 시공대상 현장의 지반 데이터만으로 현장 관입 지수를 쉽게 예측하고, 나아가 이를 토대로 쉘드 TBM의 순굴진속도를 신뢰성 있게 예측할 수 있어, 시공대상 현장에 필요한 공사비 및 공사 시간의 예측 오차를 크게 줄일 수 있다.

(52) CPC특허분류

G06N 3/08 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호 54061-1

부처명 국토부

연구관리전문기관 국토교통과학기술진흥원

연구사업명 건설기술연구사업

연구과제명 소단면 쉘드 TBM 복합지반(토사/암반지반) 실굴진율 예측 모델 및 프로그램(2차년도)

기 여 율 1/1

주관기관 한국과학기술원

연구기간 2016.05.30 ~ 2017.05.29

명세서

청구범위

청구항 1

기 시공된 복수의 현장 각각에 대해, 상기 현장에 대응하여 계측된 복수의 지반 인자 및 쉘드 TBM의 현장 관입 지수를 저장한 데이터베이스;

상기 복수의 지반 인자에 대응하는 좌표점을 입력 벡터 공간에 투영하여 상기 현장 각각의 좌표점을 복수의 군집으로 퍼지 클러스터링하는 클러스터링부;

상기 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망(ANFIS)의 입력 노드와 출력 노드에 각각 상기 복수의 지반 인자와 상기 현장 관입 지수를 적용하여, 상기 신경망을 학습시키는 신경망 학습부; 및

시공 대상 현장에 대해 획득한 복수의 지반 인자를 상기 학습된 신경망에 입력시켜 상기 시공 대상 현장에 대한 현장 관입 지수를 예측하는 예측부를 포함하는 쉘드 TBM의 순굴진속도 예측 장치.

청구항 2

청구항 1에 있어서,

상기 예측부는,

상기 예측한 현장 관입 지수 및 상기 쉘드 TBM의 기계 인자를 기초로 상기 쉘드 TBM의 순굴진속도를 예측하는 쉘드 TBM의 순굴진속도 예측 장치.

청구항 3

청구항 2에 있어서,

상기 예측부는,

아래의 수학식을 이용하여 상기 순굴진속도를 연산하는 쉘드 TBM의 순굴진속도 예측 장치:

$$\text{순굴진속도} = \frac{F_n \times RPM}{FPI}$$

여기서, F_n 은 상기 쉘드 TBM의 커터 당 추력, RPM은 상기 쉘드 TBM의 분당 회전수, FPI는 상기 예측한 현장 관입 지수를 나타낸다.

청구항 4

청구항 1에 있어서,

상기 복수의 지반 인자는,

상기 지반에 대한 일축압축강도, 탄성계수, 탄성과 속도, 암반 등급, 암질지수, 루전값, 흡수율 중 적어도 두 개의 인자를 포함하는 쉘드 TBM의 순굴진속도 예측 장치.

청구항 5

청구항 1에 있어서,

상기 현장에 대응하여 저장된 현장 관입 지수(FPI)는 아래의 수학식으로 결정되는 쉘드 TBM의 순굴진속도 예측 장치:

$$FPI = \frac{F_n}{P_e}$$

여기서, F_n 은 상기 쉴드 TBM의 커터 당 추력, P_e 는 상기 현장에서 예측된 상기 TBM의 커터헤드 1회전당 관입 깊이를 나타낸다.

청구항 6

기 시공된 복수의 현장 각각에 대해, 상기 현장에 대응하여 예측된 복수의 지반 인자 및 쉴드 TBM의 현장 관입 지수를 데이터베이스에 저장하는 단계;

상기 복수의 지반 인자에 대응하는 좌표점을 입력 벡터 공간에 투영하여 상기 현장 각각의 좌표점을 복수의 군집으로 퍼지 클러스터링하는 단계;

상기 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망(ANFIS)의 입력 노드와 출력 노드에 각각 상기 복수의 지반 인자와 상기 현장 관입 지수를 적용하여, 상기 신경망을 학습시키는 단계; 및
시공 대상 현장에 대해 획득한 복수의 지반 인자를 상기 학습된 신경망에 입력시켜 상기 시공 대상 현장에 대한 현장 관입 지수를 예측하는 단계를 포함하는 쉴드 TBM의 순굴진속도 예측 방법.

청구항 7

청구항 6에 있어서,

상기 예측한 현장 관입 지수 및 상기 쉴드 TBM의 기계 인자를 기초로 상기 쉴드 TBM의 순굴진속도를 예측하는 단계를 더 포함하는 쉴드 TBM의 순굴진속도 예측 방법.

청구항 8

청구항 7에 있어서,

상기 순굴진속도를 예측하는 단계는,

아래의 수학적식을 이용하여 상기 순굴진속도를 연산하는 쉴드 TBM의 순굴진속도 예측 방법:

$$\text{순굴진속도} = \frac{F_n \times RPM}{FPI}$$

여기서, F_n 은 상기 쉴드 TBM의 커터 당 추력, RPM은 상기 쉴드 TBM의 분당 회전수, FPI는 상기 예측한 현장 관입 지수를 나타낸다.

청구항 9

청구항 6에 있어서,

상기 복수의 지반 인자는,

상기 지반에 대한 일축압축강도, 탄성계수, 탄성과 속도, 암반 등급, 암질지수, 루진값, 흡수율 중 적어도 두 개의 인자를 포함하는 쉴드 TBM의 순굴진속도 예측 방법.

청구항 10

청구항 6에 있어서,

상기 현장에 대응하여 저장된 현장 관입 지수(FPI)는 아래의 수학적식으로 결정되는 쉴드 TBM의 순굴진속도 예측 방법:

$$FPI = \frac{F_n}{P_e}$$

여기서, F_n 은 상기 쉴드 TBM의 커터 당 추력, P_e 는 상기 현장에서 계측된 상기 TBM의 커터헤드 1회전당 관입 깊이를 나타낸다.

발명의 설명

기술 분야

[0001] 본 발명은 쉴드 TBM의 순굴진속도 예측 장치 및 그 방법에 관한 것으로서, 보다 상세하게는 시공대상 현장에 사용되는 쉴드 TBM(Shield Tunnel Boring Machine)의 순굴진속도를 신뢰성 있게 예측할 수 있는 쉴드 TBM의 순굴진속도 예측 장치 및 그 방법에 관한 것이다.

배경 기술

[0002] 국내에서는 전기 공급을 위한 선로의 지중화를 위해 터널식 전력구를 많이 건설하는 추세이다. 전력구 터널은 기계식 터널 굴착기 즉, 쉴드 TBM(Shield Tunnel Boring Machine)에 의해 주로 건설된다.

[0003] 신뢰성 있는 공사비 또는 공사 기간을 예측하기 위해서는 설계 단계에서 쉴드 TBM의 성능을 정확하게 예측하는 것이 매우 중요하다. 쉴드 TBM의 성능 중에서 대표적으로 순굴진속도(PR;Penetration Rate)가 있다. 이러한 순굴진속도는 시간당 지반을 굴착하는 거리로 정의될 수 있다. 순굴진속도에 쉴드 TBM의 가동률을 곱하면 최종적으로 공사기간과 그에 따른 공사비가 산정되기 때문에, 순굴진속도는 매우 중요한 요소라 할 수 있다.

[0004] 그런데, 현재 국내에서는 시추 샘플의 일축압축강도(USC;Uniaxial Compressive Strength) 즉, 암반의 강도에 따라 전력구 터널에 사용되는 쉴드 TBM의 순굴진속도를 예측하고 있는 실정이다. 일축 압축 강도만으로 순굴진속도를 예측한다는 것은 암반에 존재하는 다양한 특성을 반영하지 못함을 의미하며 이는 예측 오차를 증가시키는 원인이 된다.

[0005] 또한, 국내에서 회귀 분석 등의 통계 기법을 이용하여 쉴드 TBM의 순굴진속도를 예측한 사례가 존재하지만 통계 분석의 복잡도가 높고 요소 간의 상관관계가 크지 않아 예측 능력에 한계가 따르는 문제점이 있다.

[0006] 본 발명의 배경이 되는 기술은 한국등록특허 제0769499호(2007.10.24 공고)에 개시되어 있다.

발명의 내용

해결하려는 과제

[0007] 본 발명은, 시공대상 현장에 사용되는 쉴드 TBM의 순굴진속도를 신뢰성 있게 예측할 수 있는 쉴드 TBM의 순굴진속도 예측 장치 및 그 방법을 제공하는데 목적이 있다.

과제의 해결 수단

[0008] 본 발명은, 기 시공된 복수의 현장 각각에 대해, 상기 현장에 대응하여 계측된 복수의 지반 인자 및 쉴드 TBM의 현장 관입 지수를 저장한 데이터베이스와, 상기 복수의 지반 인자에 대응하는 좌표점을 입력 벡터 공간에 투영하여 상기 현장 각각의 좌표점을 복수의 군집으로 퍼지 클러스터링하는 클러스터링부와, 상기 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망(ANFIS)의 입력 노드와 출력 노드에 각각 상기 복수의 지반 인자와 상기 현장 관입 지수를 적용하여, 상기 신경망을 학습시키는 신경망 학습부, 및 시공 대상 현장에 대해 획득한 복수의 지반 인자를 상기 학습된 신경망에 입력시켜 상기 시공 대상 현장에 대한 현장 관입 지수를 예측하는 예측부를 포함하는 쉴드 TBM의 순굴진속도 예측 장치를 제공한다.

[0009] 또한, 상기 예측부는, 상기 예측한 현장 관입 지수 및 상기 쉴드 TBM의 기계 인자를 기초로 상기 쉴드 TBM의 순굴진속도를 예측할 수 있다.

[0010] 또한, 상기 예측부는, 아래의 수학적식을 이용하여 상기 순굴진속도를 연산할 수 있다.

$$\text{순굴진속도} = \frac{F_n \times RPM}{FPI}$$

[0011]

[0012] 여기서, F_n 은 상기 쉴드 TBM의 커터 당 추력, RPM은 상기 쉴드 TBM의 분당 회전수, FPI는 상기 예측한 현장 관

입 지수를 나타낸다.

[0013] 또한, 상기 복수의 지반 인자는, 상기 지반에 대한 일축압축강도, 탄성계수, 탄성과 속도, 암반 등급, 암질지수, 루전값, 흡수율 중 적어도 두 개의 인자를 포함할 수 있다.

[0014] 또한, 상기 현장에 대응하여 저장된 현장 관입 지수(FPI)는 아래의 수학적식으로 결정될 수 있다.

$$FPI = \frac{F_n}{P_e}$$

[0015] 여기서, F_n 은 상기 쉘드 TBM의 커터 당 추력, P_e 는 상기 현장에서 계측된 상기 TBM의 커터헤드 1회전당 관입 깊이를 나타낸다.

[0017] 그리고, 본 발명은, 기 시공된 복수의 현장 각각에 대해, 상기 현장에 대응하여 계측된 복수의 지반 인자 및 쉘드 TBM의 현장 관입 지수를 데이터베이스에 저장하는 단계와, 상기 복수의 지반 인자에 대응하는 좌표점을 입력 벡터 공간에 투영하여 상기 현장 각각의 좌표점을 복수의 군집으로 퍼지 클러스터링하는 단계와, 상기 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망(ANFIS)의 입력 노드와 출력 노드에 각각 상기 복수의 지반 인자와 상기 현장 관입 지수를 적용하여, 상기 신경망을 학습시키는 단계, 및 시공 대상 현장에 대해 획득한 복수의 지반 인자를 상기 학습된 신경망에 입력시켜 상기 시공 대상 현장에 대한 현장 관입 지수를 예측하는 단계를 포함하는 쉘드 TBM의 순굴진속도 예측 방법을 제공한다.

발명의 효과

[0018] 본 발명에 의하면, 과거 시공 현장에서 획득된 지반 인자들 및 쉘드 TBM의 현장 관입 지수를 적응형 뉴로 퍼지 신경망에서 훈련시켜 구축한 ANFIS 훈련 모델을 이용하여, 시공대상 현장의 지반 데이터만으로 현장 관입 지수를 쉽게 예측하고, 나아가 이를 토대로 쉘드 TBM의 순굴진속도를 신뢰성 있게 예측할 수 있어, 시공대상 현장에 필요한 공사비 및 공사 시간의 예측 오차를 크게 줄일 수 있는 이점이 있다.

도면의 간단한 설명

[0019] 도 1은 본 발명의 실시예에 따른 쉘드 TBM의 순굴진속도 예측 장치의 구성을 나타낸 도면이다.

도 2는 도 1의 장치를 이용한 순굴진속도 예측 방법을 나타낸 도면이다.

도 3은 본 발명의 실시예에서 퍼지 클러스터링의 원리를 설명하는 도면이다.

도 4는 본 발명의 실시예에서 ANFIS 훈련 과정을 설명하는 도면이다.

도 5는 본 발명의 실시예에서 현장 관입 지수 및 순굴진속도를 예측하는 개념을 설명하는 도면이다.

도 6은 본 발명의 실시예에 따른 순굴진속도 예측 방법을 요약 설명하는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0020] 그러면 첨부한 도면을 참고로 하여 본 발명의 실시예에 대하여 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자가 용이하게 실시할 수 있도록 상세히 설명한다.

[0021] 본 발명은 쉘드 TBM의 순굴진속도 예측 장치 및 그 방법에 관한 것으로, 터널 굴착기의 하나인 쉘드 TBM(Shield Tunnel Boring Machine) 장비(이하, 쉘드 TBM)의 순굴진속도(PR:Penetration Rate)를 신뢰성 있게 예측할 수 있는 기법을 제시한다.

[0022] 순굴진속도는 쉘드 TBM이 시간당 지반을 굴착하는 거리로 정의된다. 특히 순굴진속도는 공사 기간과 공사 비용의 산정에 필수적인 설계 인자이며, 보다 신뢰성 있게 예측될수록 공사 시간과 공사 비용을 크게 절감할 수 있으므로 매우 중요한 요소라 볼 수 있다.

[0023] 본 발명의 실시예는 과거 시공 현장 별로 축적된 지반 인자(지반 데이터)들과 쉘드 TBM의 현장 관입 지수를 적응형 뉴로 퍼지 신경망(ANFIS:Adaptive Neuro Fuzzy Inference System)에서 학습시켜 ANFIS 훈련 모델을 얻고, ANFIS 훈련 모델을 이용하여 현재 시공 대상이 되는 현장에 대한 지반 데이터의 입력만으로 그에 대응하는 현장 관입 지수를 용이하게 도출할 수 있다.

- [0024] 쉘드 TBM의 전단에는 지반을 절삭하도록 회전하면서 전진하는 원판 형상의 커터헤드(cutter head)를 포함하고 있다. 커터헤드는 복수의 커터들을 포함하며 커터헤드의 회전 시 커터들에 의해 지반(암반)이 절삭되면서 터널이 굴착된다.
- [0025] 현장 관입 지수(FPI;Field Penetration Index)는 커터헤드의 관입 깊이와 관련한 요소이다. 본 발명의 실시예에서, 초기에 신경망 학습(훈련 모델 구축)에 사용된 현장 관입 지수의 경우 과거 현장 시공 시에 실제 측정을 통하여 얻은 값에 해당하며, 추후 시공 대상 현장을 대상으로 도출한 현장 관입 지수의 경우 훈련 모델을 통해 예측한 값에 해당한다.
- [0026] 시공 예정의 현장에 대한 쉘드 TBM의 현장 관입 지수(FPI)를 예측하게 되면 이를 토대로 쉘드 TBM의 순굴진속도(PR)까지 예측이 가능해진다. 즉, 예측한 현장 관입 지수와 기 알고 있는 쉘드 TBM의 기계 인자를 조합하여 연산하면 쉘드 TBM의 순굴진속도를 예측할 수 있다. 이에 대해서는 추후 상세히 설명할 것이다.
- [0027] 이상과 같이 본 발명의 실시예는 현재의 시공대상 현장에 대한 지반 인자들(지반 데이터)만으로 시공대상 현장에 대한 쉘드 TBM의 현장 관입 지수를 1차적으로 예측하며, 예측한 현장 관입 지수를 기초로 쉘드 TBM의 순굴진속도를 2차적으로 예측함으로써 공사기간 및 비용의 예측 오차를 현저히 줄일 수 있다.
- [0028] 이하에서는 본 발명의 실시예에 따른 쉘드 TBM의 순굴진속도 예측 장치에 관하여 상세히 설명한다.
- [0029] 도 1은 본 발명의 실시예에 따른 쉘드 TBM의 순굴진속도 예측 장치의 구성을 나타낸 도면이고, 도 2는 도 1의 장치를 이용한 순굴진속도 예측 방법을 나타낸 도면이다.
- [0030] 도 1 및 도 2를 참조하면, 본 발명의 실시예에 따른 쉘드 TBM의 순굴진속도 예측 장치(100)는 데이터베이스(110), 클러스터링부(120), 신경망 학습부(130), 예측부(140)를 포함한다.
- [0031] 먼저, 데이터베이스(110)는 기 시공된 복수의 현장 각각에 대해, 현장에 대응하여 계측된 복수의 지반 인자 및 쉘드 TBM의 현장 관입 지수를 저장하고 관리한다(S210).
- [0032] 데이터베이스(110)는 과거 시공된 현장에서 얻은 지반 인자들과 TBM의 현장 관입 지수에 관한 데이터를 현장 별로 저장 및 관리하고 있으며, 추후 이들 데이터는 적응형 뉴로 퍼지 신경망(ANFIS)의 훈련용 데이터로 활용된다. 지반 인자들은 신경망의 입력 벡터로 사용되고 현장 관입 지수는 입력 벡터에 대한 신경망의 출력 값으로 사용된다. 여기서 물론, 새로운 현장의 시공이 완료되면 지속적으로 현장 데이터가 데이터베이스(110)에 추가 및 업데이트될 수 있다.
- [0033] 현장의 지반 인자로는 지반의 일축압축강도(USC;Uniaxial Compressive Strength), 탄성계수(Elastic modulus), 탄성과 속도(탄성과 p파 속도; Elastic p-wave), 암반 등급(RMR;Rock Mass Rating), 암질지수(RQD;Rock Quality Designation), 루전값(Lugeon value), 흡수율(Absorption ratio) 등이 있다.
- [0034] 본 발명의 실시예에서 신경망의 훈련 데이터로 사용되는 지반 인자는 상술한 7가지 인자들 중 적어도 2개의 인자를 포함할 수 있다. 즉, 2개 혹은 그 이상의 지반 인자들을 신경망의 입력에 사용할 수 있다.
- [0035] 이하의 본 발명의 실시예는 설명의 편의상 2개의 지반 인자를 활용하는 것을 예시한다. 물론 지반 인자들의 종류가 다양할수록 훈련의 복잡도가 증가하는 대신 신경망의 출력(현장 관입 지수) 값에 대한 예측 정확도를 높일 수 있다.
- [0036] 지반 인자들 중 일축압축강도는 암반의 강도를 나타내는 인자이며, 탄성계수는 암반의 탄성정도를 나타내는 인자로서, 값이 작을수록 변형 정도가 크고 값이 클수록 변형이 어렵다. 탄성과 p파 속도는 암반의 p파 전달 속도를 의미한다.
- [0037] 암반등급은 암반상태를 종합적으로 나타내는 인자로서 0~100까지 나타내며 값이 클수록 암반상태가 좋고 굴진(굴착)이 어려운 것을 의미한다. 암질지수는 암반의 절리(비슷한 말로는 균열) 상태를 나타내는 인자로 0~100까지 나타내며 값이 클수록 암반상태가 좋은 것을 나타낸다.
- [0038] 루전값은 암반의 물 투수율을 표현하는 단위로, 루전값이 클수록 물의 투수율이 높은 것을 의미한다. 흡수율은 암반의 물 흡수 정도를 표현하는 인자로, 값이 클수록 흡수 정도가 높은 것을 의미한다.
- [0039] 물론, 데이터베이스(110)는 크게 지반 인자 및 TBM 기계 인자를 관리하며, 지반 인자로는 앞서 설명한 요소들을 관리하고, 기계 인자로는 현장 관입 지수(FPI) 외에도 총 추력, 커터당 추력(F_n), RPM, 커터 개수 등을 관리할 수 있다.

[0040] 이와 같은 TBM 기계 인자들은 기 시공 현장에서 측정 가능한 인자들에 해당한다. TBM 기계 인자 중에서, 총 추력은 쉘드 TBM의 전체 추진력, 커터당 추력(F_n)은 총 추력을 커터 개수로 나누어 계산한 값, 그리고 RPM은 쉘드 TBM(상세하게는 커터헤드)의 분당 회전수를 나타낸다.

[0041] 또한, 현장에 대응하여 저장된 현장 관입 지수(FPI)는 아래의 수학적 식 1에 의해 결정된다.

수학적 식 1

$$FPI = \frac{F_n}{P_e}$$

[0042]

[0043] 여기서, F_n 은 쉘드 TBM의 커터 당 추력, P_e 는 현장에서 계측된 쉘드 TBM의 커터헤드 1회전당 관입 깊이를 나타낸다. 이러한 FPI는 $kN/cutter/mm/rev$ 로 표현된다.

[0044] 물론, 앞서 설명한 바와 같이, 데이터베이스(110)의 자료 중 실제 훈련(학습)에 사용되는 자료는 다수의 지반 인자들 중 선택된 적어도 두 개의 인자와, TBM 기계 인자 중 현장 관입 지수만 해당된다.

[0045] 다음, 데이터베이스(110)에 구축된 데이터를 기초로, 클러스터링부(120)는 현장 각각 별로 복수의 지반 인자에 대응하는 하나의 좌표점(자료점)을 입력 벡터 공간에 투영한 후, 현장 각각에 대한 좌표점을 복수의 군집으로 퍼지 클러스터링(Fuzzy Clustering)한다(S220).

[0046] 이에 따라, 입력 벡터 공간 내에는 현장 하나당 하나의 좌표점이 해당 위치에 투영되며, 각각의 좌표점은 퍼지 클러스터링 기법을 통하여 다수의 군집(다수의 클러스터)으로 클러스터링된다.

[0047] 퍼지 클러스터링은 기 공지된 방식이나 그 원리를 간단히 설명하면 다음과 같다. 퍼지 클러스터링은 소속 함수(멤버십 함수)를 이용하여 각 데이터(좌표)를 모든 클러스터에 연관되도록 정의하는 기법이다.

[0048] 퍼지 클러스터링은 소프트 클러스터링이라 불리며 하드 클러스터링과는 구분된다. 하드 클러스터링은 각 데이터가 정확하게 하나의 클러스터(군집)에 속하며 이때 가중치는 1이 되며 나머지 속하지 않는 클러스터에 대한 가중치는 0이 된다.

[0049] 하지만, 소프트 클러스터링 즉, 퍼지 클러스터링은 각 데이터가 특정한 클러스터에 속하지 않고 각 클러스터의 중심점을 기준으로 데이터가 클러스터에 얼마만큼 소속되어 있는지를 가중치로서 표현하는 기법이며 이때 가중치의 총 합은 1이 된다.

[0050] 도 3은 본 발명의 실시예에서 퍼지 클러스터링의 원리를 설명하는 도면이다. 이하에서는 설명의 편의를 위해 2개의 지반 인자(ex, 일축압축강도, 암반등급)를 입력 벡터 공간에 투영하여 퍼지 클러스터링을 수행하는 것을 예시로 한다.

[0051] 2개의 지반 인자(x_1 , x_2)를 이용하는 경우에는 도 3에 도시된 것과 같이 2차원의 입력 벡터 공간에서 퍼지 클러스터링이 이루어진다.

[0052] 이때, x_1 은 일축압축강도, x_2 는 암반등급인 것으로 가정하며, 2차원 벡터 공간의 가로축은 x_1 값, 세로축은 x_2 값을 나타낸다. 각각의 현장 별로, 현장의 일축압축강도(x_1) 및 암반 등급(x_2)이 만나는 좌표점을 투영하게 되면, N개 현장에 대응하는 N개의 좌표점이 찍히게 된다.

[0053] 도 3은 퍼지 클러스터링을 이용하여 각각의 좌표점을 2개의 군집(그룹 1, 그룹 2)으로 분류한 것을 예시한다. 각 군집은 완전히 독립된 군집이 아닌 가중치에 따라서 서로를 어느 정도 공유하게 된다.

[0054] 군집을 나누는 원리는 다음과 같다. 나누고자 하는 군집의 개수를 설정하고 각 군집의 중심을 초기 설정한다. 도 3의 경우 군집의 개수를 2로 설정한 것이다.

[0055] 다음의 수학적 식 2는 퍼지 클러스터링을 위해 사용되는 수식으로서 기존에 공지된 것에 해당한다.

수학식 2

$$\arg \min SSE = \sum_{k=1}^K \sum_{i=1}^n W_{ik}^p d(x_i, c_k)^2$$

[0056]

[0057]

여기서, K는 군집(클러스터)의 개수, n은 관측치(좌표점)의 개수, x_i 는 i번째 관측치, c_k 는 k번째 클러스터의 중심, $d(a,b)^2$ 는 a와 b 간 거리의 제곱을 나타낸다. W_{ik} 는 k번째 군집에서 i번째 관측치의 가중치로서 i번째 관측치가 속하는 소속 정도로 0과 1 사이의 실수이고, p는 퍼지화 계수로서 1에 가까울수록 군집 간 공유 정도가 거의 없고 1보다 커질 경우 각 군집 간 공유 정도는 점점 증가한다.

[0058]

수학식 2의 원리를 요약하면, 군집 내 관측치(좌표점)들 간의 유사성을 최대화하기 위하여, i번째 관측치와 k번

째 군집의 중심과의 거리의 제곱합($\sum_{i=1}^n d(x_i, c_k)^2$)을 최소화하고, 이와 동시에 군집 간 비유사성을 최대화하기 위하여, 군집의 중심 간 거리의 합을 최대화하는 반복적인 최적화 연산을 통해 군집을 나누게 된다.

[0059]

각 군집의 무게중심은 해당 군집에 속한 정도를 비중으로 두어 모든 점들의 평균을 계산한 값이 된다. 그리고 각각의 관측치가 특정 군집에 속할 가능성인 가중치를 고려한 것을 알 수 있다. 또한 클러스터의 중심으로부터 먼 데이터는 잡음으로 생각하여 소속도를 감소시키고 반대로 중심으로부터 가까운 데이터는 소속도를 증가시킨다.

[0060]

이러한 퍼지 클러스터링의 결과, 도 3의 상측과 우측 그림과 같이 x1에 대한 소속 함수와, x2에 대한 소속 함수를 각각 얻을 수 있다. 이때, 두 개의 군집으로 분류한 경우이므로 각각의 소속 함수는 두 개의 퍼지 집합을 가진다. 도 3의 소속 함수를 보면, 모두 두 개의 집합으로 이루어져 있으며 두 집합이 일부 겹쳐져 있는 것을 볼 수 있다. 두 집합의 좌측은 넘버 1, 우측은 넘버 2로 하면, x1의 소속 함수는 A1(좌), A2(우)의 두 퍼지 집합을 가지고, x2의 소속 함수는 B1(좌), B2(우)의 두 퍼지 집합을 가진다.

[0061]

이상과 같은 퍼지 클러스터링 단계는 다음 단계인 ANFIS 훈련 단계에서 사용되는 소속 함수(멤버십 함수)와 If_then_규칙을 설정하는데 그 목적이 있다.

[0062]

퍼지 클러스터링이 완료되면, 신경망 학습부(130)는 퍼지 클러스터링에 의한 소속 함수를 기초로 구축되는 적응형 뉴로 퍼지 신경망(ANFIS)의 입력 노드와 출력 노드에 각각 복수의 지반 인자와 현장 관입 지수를 적용하여, 신경망을 학습시킨다(S230).

[0063]

도 4는 본 발명의 실시예에서 ANFIS 훈련 과정을 설명하는 도면이다. ANFIS 훈련단계에서는 도 4와 같이 퍼지화층, 규칙층, 정규화층, 역퍼지화층 그리고 합계뉴런층을 포함한 5단계로 세분화할 수 있다.

[0064]

퍼지화층의 입력 x1, x2에는 과거 시공 현장에서 획득된 두 개의 지반 데이터(일축압축강도, 암반등급)를 입력하며, 그에 대응하여 현장에서 측정된 현장 관입 지수를 합계뉴런층의 출력 y에 적용하여 학습하는 과정을 거친다.

[0065]

먼저, 기존의 지반 데이터(x1,x2)가 입력되면 퍼지화층에서는 퍼지 클러스터링단계에서 초기 설정되었던 각 소속 함수에 할당한다. 여기서, 소속 함수는 ANFIS를 처음 제안한 로저 장(Roger Jang)의 모델에서는 수학식 3과 같이 종형 활성화 함수를 취한다.

수학식 3

$$y_i = \frac{1}{1 + \left(\frac{x_i - a_i}{c_i} \right)^{2b_i}}$$

[0066]

[0067] 여기서, a_i , b_i , c_i 은 각각 종형 활성화 함수의 중심, 폭 그리고 기울기를 제어하는 전제매개변수(premise parameter)이다.

[0068] 종형 활성화 함수의 출력값은 각 규칙층으로 전달된다. 규칙층에서는 퍼지화층에서 입력을 받아 규칙의 수행 강도를 출력하게 된다. 여기서 규칙이란, If_then_형식을 의미하며, If절은 주로 규칙전건부, then절은 규칙후건부로 불린다. ANFIS의 규칙층의 각 뉴런은 스게노형 퍼지 규칙전건부 하나에 대응한다. 예를 들어 도 4와 같이 μ_1 은 멤버십함수 A1과 B1의 출력값을 할당받게 되며, 수학식 4와 같이 각 출력값을 곱하여 규칙의 강도인 μ_1 을 출력하게 된다.

수학식 4

$$\mu_{A1} \times \mu_{B1} = \mu_1$$

[0069]

[0070] 정규화층은 규칙층의 출력값인 수행강도를 정규화한다. 이를테면 도 4와 같이 μ_1 은 규칙층에 있는 모든 출력값을 받아 규칙 μ_1 의 수행강도를 수학식 5와 같이 계산하여 정규화 수행강도 $\bar{\mu}_1$ 을 출력한다.

수학식 5

$$\frac{\mu_1}{\mu_1 + \mu_2 + \mu_3 + \mu_4} = \bar{\mu}_1$$

[0071]

[0072] 역퍼지화층은 정규화층의 각각의 출력값과 초기에 입력했던 지반데이터 x1과 x2를 받아, 규칙후건부의 함수식에 적용된다. 여기서, 스게노형 퍼지규칙은 규칙후건부가 함수식으로 주어짐으로써 퍼지 규칙을 체계적으로 생성하는 방법으로 ANFIS에서는 스게노형 퍼지규칙이 사용된다. 첫 번째 역퍼지화 뉴런을 예를 들면 수학식 6에서와 같이 스게노형 규칙후건부인 함수(1차선형함수로 설정)에 지반데이터 값을 넣어 계산한 후 정규화층으로부터 받은 정규화 규칙강도와 곱셈연산의 결과값 y_1 으로 출력하게 된다.

수학식 6

$$\bar{\mu}_1 [k_{10} + k_{11}x_1 + k_{12}x_2] = y_1$$

[0073]

[0074] 여기서, k_{10} , k_{11} , k_{12} 는 각각 첫 번째 역퍼지화 뉴런의 규칙후건부 함수의 계수를 의미하며, 이는 결론매개변수(consequent parameter)라고 불린다. 첫 번째 뉴런 이외의 역퍼지화층의 모든 뉴런도 동일하게 적용된다.

[0075] 합계뉴런층은 수학식 7과 같이 역퍼지화 모든 뉴런의 출력값을 더하여 Y 를 출력하게 된다. 도 4의 경우에는 n 값은 4가 된다.

수학식 7

$$\sum_{i=1}^n y_i = Y$$

[0076]

[0077]

ANFIS의 최종 출력한 Y 값과 현장에 계측된 출력값과의 차이 즉, 오차가 발생하면 역방향으로 인공신경망에서 작동되는 기울기 하강법(gradient descent method) 알고리즘을 이용하여 퍼지화층에 있는 전체매개변수를 재조정하게 된다. 재조정이 완료되면 다시 순방향으로 ANFIS를 작동하게 되며 역퍼지화층의 결론매개변수를 최소제곱추정(least square estimator)으로 재계산하게 된다. 이와 같은 방법으로 오차가 허용범위 안에 들 때까지 반복하여 ANFIS 훈련은 최종적으로 마치게 된다.

[0078]

이후에는 상술한 바와 같이 학습된 신경망을 이용하여 시공 예정인 현장 즉, 시공 대상 현장에 대한 지반 인자만 입력하면 현장 관입 지수를 예측할 수 있게 된다.

[0079]

즉, 예측부(140)는 시공 대상 현장에 대해 획득한 복수의 지반 인자를 학습된 신경망에 입력시켜, 시공 대상 현장에 대한 현장 관입 지수(FPI)를 예측한다(S240). 예를 들어, 예측하고자 하는 특정 현장 구간의 지반 데이터(일축압축강도, 암반 등급)만 입력하면, 훈련된 ANFIS 모델을 이용하여 현장 설계 단계에서 특정 현장 구간의 현장 관입 지수(FPI)를 빠르고 쉽게 예측할 수 있다.

[0080]

물론, 현장에서 사용될 쉘드 TBM의 최적 추력과 RPM이 산정되면, 이를 이용하여 최종적으로 순굴진속도를 예측할 수 있다.

[0081]

도 5는 본 발명의 실시예에서 현장 관입 지수 및 순굴진속도를 예측하는 개념을 설명하는 도면이다. 도 5에 나타난 것과 같이, 예측부(140)는 초기에 현장 관입 지수를 먼저 예측한 다음, 예측한 현장 관입 지수(FPI)와 쉘드 TBM의 기계 인자(F_n , RPM)를 이용하여 쉘드 TBM의 순굴진속도(net penetration rate)를 예측해낸다(S250). 그 구체적인 연산식은 수학식 8과 같다.

수학식 8

$$\text{순굴진속도} = \frac{F_n \times RPM}{FPI}$$

[0082]

[0083]

여기서, F_n 은 쉘드 TBM의 커터 당 추력, RPM은 쉘드 TBM의 분당 회전수, FPI는 예측한 현장 관입 지수를 나타낸다.

[0084]

도 6은 본 발명의 실시예에 따른 순굴진속도 예측 방법을 요약 설명하는 도면이다. 본 발명은 크게 3가지 단계로 구분되는데, 단계 1은 과거 시공된 현장의 지반 데이터를 퍼지 클러스터링하는 단계이고, 단계 2는 퍼지 클러스터링의 결과를 기초로 해당 현장의 지반 데이터를 입력으로 하고 그에 대응하는 현장 관입 지수를 출력으로 하는 적응적 뉴로 퍼지 신경망을 훈련시키는 단계이다.

[0085]

또한, 단계 3은 ANFIS 훈련 모델을 이용하여 시공 대상 현장에 대한 지반 데이터에 대응하는 결과값 즉, 쉘드 TBM의 현장 관입 지수를 도출하며, 나아가 도출한 현장 관입 지수를 토대로 쉘드 TBM의 순굴진속도까지 도출해낼 수 있다.

[0086]

이상과 같은 본 발명에 따른 쉘드 TBM의 순굴진속도 예측 장치 및 그 방법에 의하면, 과거 시공 현장에서 획득된 지반 인자들 및 쉘드 TBM의 현장 관입 지수를 적응형 뉴로 퍼지 신경망에서 훈련시켜 구축한 ANFIS 훈련 모델을 이용하여, 시공대상 현장의 지반 데이터만으로 현장 관입 지수를 쉽게 예측하고, 나아가 이를 토대로 쉘드 TBM의 순굴진속도를 신뢰성 있게 예측할 수 있어, 시공대상 현장에 필요한 공사비 및 공사 시간의 예측 오차를 크게 줄일 수 있는 이점이 있다.

[0087]

본 발명은 도면에 도시된 실시예를 참고로 설명되었으나 이는 예시적인 것에 불과하며, 본 기술 분야의 통상의 지식을 가진 자라면 이로부터 다양한 변형 및 균등한 다른 실시예가 가능하다는 점을 이해할 것이다. 따라서,


본 발명의 진정한 기술적 보호 범위는 첨부된 특허청구범위의 기술적 사상에 의하여 정해져야 할 것이다.

부호의 설명


100: 쉴드 TBM의 순굴진속도 예측 장치
110: 데이터베이스 120: 클러스터링부
130: 신경망 학습부 140: 예측부

도면


도면1




도면2




도면3



도면4



도면5



도면6

