



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0019980
(43) 공개일자 2025년02월11일

(51) 국제특허분류(Int. Cl.)
H04W 24/08 (2009.01) H04B 17/391 (2015.01)
H04W 16/18 (2009.01)
(52) CPC특허분류
H04W 24/08 (2013.01)
H04B 17/3912 (2023.05)
(21) 출원번호 10-2023-0101264
(22) 출원일자 2023년08월02일
심사청구일자 2023년08월02일

(71) 출원인
울산대학교 산학협력단
울산광역시 남구 대학로 93(무거동)
(72) 발명자
구인수
울산광역시 울주군 범서읍 구영로 75-7, 306동
1703호
황태웅
울산광역시 남구 봉월로102번길 9-13, 404호 (신정동)
(뒷면에 계속)
(74) 대리인
특허법인태백

전체 청구항 수 : 총 8 항


(54) 발명의 명칭 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법

(57) 요약

본 발명은 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법에 관한 것이다. 본 발명에 따르면, 초기 데이터 세트를 구성하는 N개의 데이터에 대해 클러스터링을 수행하여 K개의 클러스터를 생성하는 단계(N, K는 자연수이다); 상기 K개의 클러스터 각각에 대해 수신신호 세기 값을 예측하는 예측모델을 학습하는 단계; 학습 완료된 상기 예측모델을 통해 예측한 수신신호 세기 값을 기초로 전파환경맵을 생성하는 단계; 및 기 설정된 시간 경과 후에 수집된 측정 데이터를 이용하여 상기 전파환경맵을 업데이트하는 단계를 포함한다.

이와 같이 본 발명에 따르면, 관심영역을 복수의 클러스터로 구분하여 전파환경맵을 구축하고 구축된 전파환경맵을 업데이트함으로써 동적 무선 통신 환경에서 전파음역구역의 식별과 망품질 분석을 가능하게 한다.

대표도 - 도1



(52) CPC특허분류

H04B 17/3913 (2023.05)

H04W 16/18 (2013.01)

(72) 발명자

카마나 아코스타 마리

울산광역시 남구 대학로 93 (무거동)

가르시아 모레타 카를

울산광역시 남구 대학로 93 (무거동)

이 발명을 지원한 국가연구개발사업

과제고유번호

1711159923

과제번호

2022-0-00805-001

부처명

과학기술정보통신부

과제관리(전문)기관명

정보통신기획평가원

연구사업명

ICTR&D혁신바우처지원사업(예타)

연구과제명

건조 선박 음영 구역 작업자의 안전통신망 구축을 위한유무선 통신기술 개발

기 여 율

1/1

과제수행기관명

주식회사 에이티솔루션

연구기간

2022.04.01 ~ 2023.03.31

명세서

청구범위

청구항 1

초기 데이터 세트를 구성하는 N 개의 데이터에 대해 클러스터링을 수행하여 K 개의 클러스터를 생성하는 단계(N , K 는 자연수이다);

상기 K 개의 클러스터 각각에 대해 수신신호 세기 값을 예측하는 예측모델을 학습하는 단계;

학습 완료된 상기 예측모델을 통해 예측한 수신신호 세기 값을 기초로 전파환경맵을 생성하는 단계; 및

기 설정된 시간 경과 후에 수집된 측정 데이터를 이용하여 상기 전파환경맵을 업데이트하는 단계를 포함하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 2

제 1항에 있어서,

상기 초기 데이터 세트는 N 개의 과거 측정값을 포함하며,

각 과거 측정값은 2차원 좌표 상에서의 위치와 각 위치에서 측정된 수신신호 세기 값을 포함하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 3

제 1항에 있어서,

상기 K 개의 클러스터를 생성하는 단계는,

K -평균 알고리즘을 적용하여 클러스터링을 수행하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 4

제 1항에 있어서,

상기 예측모델을 학습하는 단계는,

K 개의 클러스터 각각에 대해 할당된 데이터 세트를 이용하여 랜덤 포레스트 알고리즘에 의하여 해당 클러스터에 포함된 임의의 좌표에 대하여 수신신호 세기 값을 예측하도록 학습시키는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 5

제 1항에 있어서,

상기 전파환경맵을 생성하는 단계는,

관심 영역 전체를 커버하는 그리드를 생성하는 단계;

상기 그리드에 포함된 각 좌표 데이터를 상기 K 개의 클러스터 중 하나로 할당하는 단계;

상기 각 좌표 데이터에 대해 수신신호 세기 값을 예측하는 단계; 및

상기 예측된 수신신호 세기 값을 이용하여 전파환경맵을 구축하는 단계를 포함하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 6

제 5항에 있어서,

상기 수신신호 세기 값을 예측하는 단계는,

상기 각 좌표 데이터가 할당된 클러스터에 대하여 학습된 예측 모델을 통하여 상기 수신신호 세기 값을 예측하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 7

제 1항에 있어서,

상기 전파환경맵을 업데이트하는 단계는,

상기 전파환경맵 구축 시점으로부터 임의의 시간이 경과한 후 수집된 새로운 측정값을 이용하여 기 정해진 조건을 만족하는 클러스터에 대해 예측 모델을 교체하고 이를 기초로 전파환경맵을 업데이트하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

청구항 8

제 7항에 있어서,

상기 전파환경맵을 업데이트하는 단계는,

상기 새로운 측정값을 상기 K개의 클러스터 중 하나로 할당하는 단계;

각 클러스터에 할당된 데이터의 개수가 기 정해진 최소 데이터 수 이상이면 상기 새로운 측정값을 이용하여 예측 모델을 학습시켜서 기존의 예측 모델을 교체하는 단계; 및

교체된 예측 모델을 통해 예측한 수신신호 세기 값을 기초로 상기 전파환경맵을 업데이트하는 단계를 포함하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법.

발명의 설명

기술 분야

[0001] 본 발명은 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법에 관한 것으로서, 더욱 상세하게 설명하면 관심영역을 복수의 클러스터로 구분하여 전파환경맵을 구축하고 구축된 전파환경맵을 업데이트함으로써 동적 무선 통신 환경에서 전파음역구역의 식별과 망품질 분석을 가능하게 하는 기술에 관한 것이다.

배경 기술

[0002] 전파가 송수신 되는 모든 현장에서 복잡한 레이아웃, 다양한 구조물 및 음향 문제를 일으킬 수 있는 기계 등으로 인하여 전파 음역구역 발생 및 망품질이 저하되는 현상이 발생하는 경우가 많다.

[0003] 이에, 액세스 포인트 및 안테나 그리고 네트워크 인프라의 이상적인 배치를 결정하여 신호 적용 범위를 최대화하고 신호 감쇠를 최소화하는 데 있어, 전파가 송수신 되는 현장에서 전파환경맵의 구축은 필수적이다.

[0004] 본 발명의 배경이 되는 기술은 미국등록특허 US 11483719(2022.10.25 등록)에 개시되어 있다.

발명의 내용

해결하려는 과제

[0005] 이와 같이 본 발명에 따르면, 관심영역을 복수의 클러스터로 구분하여 전파환경맵을 구축하고 구축된 전파환경맵을 업데이트함으로써 동적 무선 통신 환경에서 전파음역구역의 식별과 망품질 분석을 가능하게 하는 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법을 제공하기 위한 것이다.

과제의 해결 수단

[0006] 이러한 기술적 과제를 이루기 위한 본 발명의 실시예에 따르면 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 업데이트 구축 및 방법에 있어서, 초기 데이터 세트를 구성하는 N개의 데이터에 대해 클러스터링을 수행하여 K개의 클러스터를 생성하는 단계(N, K는 자연수이다); 상기 K개의 클러스터 각각에 대해 수신신호 세기 값을 예측하는 예측모델을 학습하는 단계; 학습 완료된 상기 예측모델을 통해 예측한 수신신호 세기 값을 기초로

전파환경맵을 생성하는 단계; 및 기 설정된 시간 경과 후에 수집된 측정 데이터를 이용하여 상기 전파환경맵을 업데이트하는 단계를 포함한다.

발명의 효과

[0007] 이와 같이 본 발명에 따르면, 관심영역을 복수의 클러스터로 구분하여 전파환경맵을 구축하고 구축된 전파환경맵을 업데이트함으로써 동적 무선 통신 환경에서 전파음역구역의 식별과 망품질 분석을 가능하게 한다.

[0008] 특히, K-평균 알고리즘을 이용하여 관심 영역에 대하여 K개의 클러스터를 생성하고, 랜덤 포레스트 알고리즘을 이용하여 각 클러스터에서의 무선 신호의 품질을 예측하여 전파환경맵을 구축할 수 있다. 더 나아가 시간 흐름에 따라 변화하는 환경을 고려하여 전파환경맵을 업데이트함으로써 동적 무선 통신 환경에서 전파음역구역의 식별과 망품질 분석을 가능하게 한다.

도면의 간단한 설명

[0009] 도 1은 본 발명의 실시예에 따른 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법의 흐름도이다.

도 2는 본 발명의 실시예에 따른 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법의 흐름을 개략적으로 도시한 도면이다.

도 3은 예측모델 학습과정에서 사용되는 의사 결정 트리의 구조를 도시하는 도면이다.

도 4는 본 발명의 실시예에 대한 성능 평가를 위한 실험 환경의 예를 도시하는 도면이다.

도 5는 본 발명의 실시예와 다양한 예측 모델 및 종래 기술에 대한 성능 평가 결과를 도시하는 도면이다.

발명을 실시하기 위한 구체적인 내용

[0010] 이하 첨부된 도면을 참조하여 본 발명에 따른 바람직한 실시예를 상세히 설명하기로 한다. 이 과정에서 도면에 도시된 선들의 두께나 구성요소의 크기 등은 설명의 명료성과 편의상 과장되게 도시되어 있을 수 있다.

[0011] 또한 후술되는 용어들은 본 발명에서의 기능을 고려하여 정의된 용어들로써, 이는 사용자, 운용자의 의도 또는 관계에 따라 달라질 수 있다. 그러므로 이러한 용어들에 대한 정의는 본 명세서 전반에 걸친 내용을 토대로 내려져야 할 것이다.

[0012] 도 1은 본 발명의 실시예에 따른 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법의 흐름도이고, 도 2는 도 1의 흐름도를 개략적으로 도시한 도면이다.

[0013] 도 1 및 도 2를 참조하면, 전파환경맵 업데이트 방법은 클러스터 생성 과정(S110), 예측 모델 학습 과정(S120), 전파환경맵 구축 과정(S130) 및 전파환경맵 업데이트 과정(S140)을 포함한다.

[0014] 구체적으로, 클러스터 생성 과정(S110)은 먼저 다음과 같은 초기 데이터 세트 D_H 를 입력 받는다(S111).

[0015] $D_H = \{z_1, \dots, z_n, \dots, z_N\}$,

[0016] 여기서, N은 초기 데이터 세트를 구성하는 데이터(즉, 과거 측정값)의 개수이고, z_n 은 다음과 같이 표현된다.

[0017] $z_n = \{x_n, y_n, R_n\}$

[0018] 이때, x_n, y_n 은 2차원 좌표 상에서의 위치를 나타내고, R_n 은 해당 위치에서 측정된 수신신호 세기 값(Received Signal Strength Indicator, RSSI)을 나타낸다.

[0019] 이후, 입력된 초기 데이터 세트에 대해 클러스터링을 수행한다(S112).

[0020] 일 실시예에 따르면, K-평균 알고리즘(K-means algorithm)에 의해 클러스터링을 수행할 수 있다. 다시 말해, 초기 데이터 세트에 대해 K-평균 알고리즘을 적용하여 초기 데이터 세트에 포함된 각 데이터가 K개의 클러스터 중에서 가장 가까운 중심을 갖는 클러스터로 할당되도록 한다.

[0021] 다음으로, 예측 모델 학습 과정(S120)은 K개의 클러스터 각각에 대해 수신신호 세기 값을 예측하는 예측 모델을 학습한다. 일 실시예에 따르면, 예측 모델은 랜덤 포레스트(Random Forest, RF) 알고리즘을 기반으로 구축될 수

있다.

[0022] 구체적으로 설명하면, k 번째 클러스터에 할당된 데이터 세트 D_k 는 다음과 같이 표현된다.

[0023] $D_k = \{z_{1k}, \dots, z_{mk}, \dots, z_{Mk}\},$

[0024] 여기서, k 는 1부터 K 까지의 자연수이고, z_{mk} 은 다음과 같이 표현된다.

[0025] $z_{mk} = \{x_{mk}, y_{mk}, R_{mk}\}$

[0026] 각 클러스터에 할당된 데이터 세트 D_k 를 이용하여 각각의 예측 모델이 해당 클러스터에 포함된 임의의 좌표에 대한 수신신호 세기 값을 예측하도록 학습시킨다.

[0027] 다음으로, 전파환경맵 구축 과정(S130)은 먼저 전체 관심 영역을 커버하는 그리드 G 를 생성한다(S131).

[0028] $G = \{f_1, \dots, f_h, \dots, f_H\}$ (h, H 는 자연수),

[0029] 여기서, H 는 해당 그리드에 포함된 좌표 데이터의 개수이고, f_h 는 다음과 같이 표현된다.

[0030] $f_h = \{x_h, y_h\}$

[0031] 이후, 그리드에 포함된 각 좌표 데이터를 K 개의 클러스터 중 어느 하나로 할당한 다음(S132), 각 좌표 데이터에 대해 할당된 클러스터에 대해 학습된 예측 모델을 통해서 수신신호 세기 값을 예측하고, 각 좌표 데이터와 이에 대해 예측된 수신신호 세기 값을 이용하여 전파환경맵(REM)을 구축한다(S133).

[0032] 다음으로, 전파환경맵 업데이트 과정(S140)은 전파환경맵 구축 시점으로부터 임의의 시간이 경과한 후($t_0 \rightarrow t_1$) 수집된 새로운 측정값을 이용하여 기 정해진 조건을 만족하는 클러스터에 대해 예측 모델을 교체하고 이를 기초로 전파환경맵을 업데이트 한다.

[0033] 구체적으로, t_0 시점에 입력 받은 초기 데이터 세트를 이용하여 전파환경맵(REM)을 구축한 후, t_1 시점에 새롭게 측정된 데이터 세트 D_{t1} 은 다음과 같이 표현된다(S141).

[0034] $D_{t1} = \{z_{1t1}, \dots, z_{nt1}, \dots, z_{Nt1}\},$

[0035] 여기서 N_{t1} 은 t_1 시점에 수집된 측정값들의 수이고, z_{nt1} 은 다음과 같이 표현된다.

[0036] $z_{nt1} = \{x_{nt1}, y_{nt1}, R_{nt1}\}$

[0037] 각 데이터를 K 개의 클러스터 중 하나로 할당하면(S142), k 번째 클러스터에 할당된 데이터 세트 D_{kt1} 은 다음과 같이 표현된다.

[0038] $D_{kt1} = \{z_1, \dots, z_{mk,t1}, \dots, z_{Mk,t1}\}$

[0039] 다음으로, k 번째 클러스터에 할당된 데이터 세트 D_{kt1} 가 다음의 조건을 만족하면 기존의 k 번째 클러스터의 예측 모델을 새롭게 측정된 데이터로 업데이트한다(S143).

[0040] $|D_{kt1}| \geq N_{\min},$

[0041] 여기서, $N_{\min}$ 은 예측 모델 업데이트를 위한 최소 데이터 수를 나타내는 것으로 기 정해진 값일 수 있다.

[0042] 구체적으로 설명하면, 상기 조건을 만족할 경우 k 번째 클러스터에 대해 새롭게 측정된 데이터를 이용하여 기존 예측 모델을 업데이트 시켜서 기존 예측 모델을 새롭게 학습된 예측 모델로 교체하고, 교체된 예측 모델을 통해 예측한 수신신호 세기 값을 기초로 전파환경맵을 업데이트 한다(S144). 반면, 상기 조건을 만족하지 못할 경우 해당 클러스터에 대한 기존 예측 모델이 유지된다.

[0043] 도 1 및 도 2를 참조하여 상술한 전파음역구역 식별 및 망품질 분석을 위한 전파환경맵 구축 및 업데이트 방법은 예측 모델의 학습 및 이를 이용한 예측과 전파환경맵의 구축 및 업데이트를 수행 가능한 프로세싱 장치에 의해 수행될 수 있다

[0044] 도 3은 예측모델 학습과정에서 사용되는 의사 결정 트리의 구조를 도시하는 도면으로, 루트 노드(Root node), 분할 노드(Split node), 리프 노드(Leaf node)를 포함한다.

[0045] 구체적으로 설명하면, 예측모델의 학습을 위한 데이터세트 D_{RF} 는 다음과 같다.

$$[0046] D_{RF} = \{z_1, \dots, z_m, \dots, z_M\}$$

[0047] 여기서, M 은 학습시키는 데이터의 수이고, z_m 은 다음과 같이 표현된다.

$$[0048] z_m = \{x_m, y_m, R_m\}$$

[0049] 이때, x_m , y_m 은 2차원 좌표 상에서의 위치를 나타내고, R_m 은 해당 위치에서 측정된 수신신호 세기 값을 나타낸다

[0050] 다음으로, 예측모델 알고리즘은 배깅(Bootstrap aggregating, Bagging)을 통하여 D_{RF} 로부터 데이터세트 $D_{RF,w}$ 를 생성하고, 각 의사 결정 트리 회귀자는 $D_{RF,w}$ 에 대응하여 학습된다.

[0051] 각 의사 결정 트리 회귀자에서 데이터세트 $D_{RF,w}$ 는 각 분할 노드에서 분할 규칙을 선택하여 최종적으로 리프 노드에 도달할 때까지 사용된다.

[0052] w 번째 의사 결정 트리 회귀자의 b 번째 분할 노드에서 학습하고자 하는 데이터의 하위 집합으로 $D_{RF,w}^b$ 를 사용한다고 가정하면, b 번째 분할 노드에서 사용되는 복수의 후보 분할 규칙은 다음의 수학적 식 1과 같이 정의되며, 그 중 최적의 분할 규칙을 $D_{RF,w}^b$ 를 통하여 결정한다.

수학적 식 1

$$s_{f,\alpha}^{b,w}(z_i) = \begin{cases} 1, & \text{if } f_{z_i} > \alpha \\ 0, & \text{otherwise,} \end{cases}$$

[0053]

[0054] 여기서, f_{z_i} 는 학습 과정 동안 데이터 z_i 에서의 특징 $f \in \{x_i, y_i\}$ 의 값이며, α 는 임계값을 나타낸다(이때, $z_i \in D_{RF,w}^b$). 다음으로, 각 분할 노드에서 학습되는 과정동안 평균 제곱 오차(MSE)가 가장 적은 경우를 최적의 분할 규칙으로 선택한다.

[0055] 구체적으로 설명하면, 상기 분할규칙은 $D_{RF,w}^b$ 을 다음과 같이 두 개의 그룹으로 나눈다.

[0056] 1) $DR_{RF,w}^b$, 각 분할 규칙을 만족하는 학습 데이터를 포함하는 그룹

[0057] 2) $DL_{RF,w}^b$, 상기 1)에 해당되지 않는 학습 데이터를 포함하는 그룹

[0058] 이후, 아래의 수학적 식 2에 따라 각 후보 분할규칙의 평균 제곱 오차를 계산하여 가장 낮은 평균 제곱 오차 값을 가지는 분할 규칙을 최적이라고 판단한다.

수학적 식 2

$$MSE(s_{f,\alpha}^{b,w}) = \frac{1}{|DR_{RF,w}^b|} \sum_{i \in DR_{RF,w}^b} (R_i - \hat{R}_b^{DR})^2 + \frac{1}{|DL_{RF,w}^b|} \sum_{i \in DL_{RF,w}^b} (R_i - \hat{R}_b^{DL})^2.$$

[0059]

- [0060] 이때, $|DR_{RF,w}^b|$ 와 $|DL_{RF,w}^b|$ 는 각각 $DR_{RF,w}^b$ 와 $DL_{RF,w}^b$ 의 데이터 수를 나타낸다. 또한, R_i 는 i 번째 데이터의 실제 목표 값이며, $\hat{R}_b^{DR}$ 과 $\hat{R}_b^{DL}$ 은 데이터세트 $DR_{RF,w}^b$ 와 $DL_{RF,w}^b$ 의 학습중인 데이터의 평균 수신 세기 신호 값을 기반으로 예측된다.
- [0061] 상술한 과정을 통해 최적의 분할 규칙을 결정한 후, 해당 과정은 최종적으로 리프 노드에 도달할 때까지 반복되며, 이 과정은 각 노드를 분할하기 위하여 필요한 최소한의 학습 데이터 수 m_{min} 에 의하여 결정된다.
- [0062] 이때, 리프 노드에서의 값이 의사 결정 트리 회귀자에서 데이터에 대한 예측 수신신호 세기 값을 결정하며, 최종 예측 모델의 예측 값은 각 의사 결정 트리 회귀 분석기에 의해 예측된 수신신호 세기 값의 평균과 같다.
- [0063] 도 4는 본 발명의 실시예에 대한 성능 평가를 위한 실험 환경의 예를 도시하는 도면이다.
- [0064] 도 4를 참조하면, 실험에 사용된 장비에는 센서, 내비게이션 시스템 및 의사 결정 알고리즘이 장착되며, 사람의 개입 없이 작동하고 작업을 완료할 수 있는 모바일 로봇이 포함되었다.
- [0065] 해당 모바일 로봇은 임베디드 컨트롤러, LiDAR(Light Detection and Ranging) 센서, 관성 측정 장치(IMU) 센서, 인코더, 단일 보드 컴퓨터(SBC) 및 로봇 운영 체제(ROS)를 포함한다.
- [0066] 라즈베리 파이(Raspberry Pi)는 Linux 환경에서 알고리즘을 구성하고 ROS를 사용하여 서로 다른 프로세스 간의 통신을 가능하게 하는 SBC를 구동한다.
- [0067] OpenCR을 활용한 임베디드 컨트롤러는 다양한 센서를 통해 이동 로봇의 움직임을 제어하는 역할을 한다.
- [0068] LiDAR 센서는 레이저 빔을 사용하여 주변 물체까지의 거리를 계산한다. LiDAR 센서는 360도 수평 시야에서 레이저 빔을 스캔함으로써 로봇 주변의 2D 포인트 클라우드 맵을 생성할 수 있다. 이 맵은 장애물 감지, 매핑 및 위치 파악에 활용될 수 있다.
- [0069] 또한 모바일 로봇은 시작 위치와 관련하여 로봇의 위치와 방향을 추정하기 위해 인코더와 IMU의 센서 데이터를 사용하는 오도메트리 기술을 활용한다. 오도메트리 데이터는 LiDAR 데이터와 결합되어 위치 지점의 좌표가 2D 데카르트 좌표계로 표시되는 보다 정확하고 강력한 위치 파악 시스템을 제공한다.
- [0070] 여기서 수신신호 세기 값은 송수신기 사이의 링크 품질 추정을 위해 사용된다. 수신신호 세기 값은 수신된 무선 신호에 존재하는 전력을 측정한 것으로 WIFI 및 블루투스 그리고 셀룰러 네트워크와 같은 무선 시스템에서 수신된 신호의 강도를 결정하기 위하여 사용된다.
- [0071] 도 5는 본 발명의 실시예와 다양한 예측 모델 및 종래 기술에 대한 성능 평가 결과를 도시하는 도면이다.
- [0072] 구체적으로 설명하면, 도 5는 RF 모델, SVR(support vector regression) 모델, MLP(multilayer perceptron) 모델 및 AdaBoost 회귀 모델에 대하여 클러스터를 사용한 경우와 클러스터링을 하지 않은 경우에 대해 각각 평균 절대 비 오차(Mean Absolute Percentage Error, MAPE), 평균 제곱근 편차(Root Mean Squared Error, RMSE) 및 결정계수(R^2 score)를 나타낸 것으로, 시간 경과와 클러스터의 유무에 따른 예측 결과의 오류를 평가하였다.
- [0073] 이때, 본 발명의 실시예에서 제안한 바와 같이 클러스터를 사용한 기술은 시간의 경과에 따라 오차가 줄어들어 알 수 있다.
- [0074] 반면, 클러스터를 사용하지 않은 종래 기술의 경우 시간의 경과와 무관하게 오차가 줄어들지 않았고, 획득한 오차는 새로운 데이터가 수집될 때마다 크게 상이함을 알 수 있다.
- [0075] 또한, 본 발명의 실시예에서 제안하는 RF 기반 방식이 비교 방식 중 가장 적은 오류를 달성하였고, AdaBoost 알고리즘이 두 번째로 좋은 방식임을 확인하였다.


부호의 설명

- [0076] S110: 클러스터 생성 단계
S120: 예측모델 학습 과정
S130: 전파환경맵 구축 과정


S140: 전파환경맵 업데이트 과정

도면


도면1




도면2



도면3



도면4



도면5

MAPE	4 Clusters			Without Clustering		
Model for Prediction	t ₁	t ₂	t ₃	t ₁	t ₂	t ₃
RF	6.10%	5.03%	1.92%	10.52%	6.60%	12.40%
SVR	7.90%	6.01%	4.90%	15.89%	8.74%	15.54%
MLP	12.98%	5.76%	4.55%	27.27%	18.56%	7.97%
AdaBoost	6.40%	5.49%	3.82%	13.37%	6.78%	9.03%
RMSE	4 Clusters			Without Clustering		
Model for Prediction	t ₁	t ₂	t ₃	t ₁	t ₂	t ₃
RF	3.731	3.401	2.069	6.100	4.019	8.167
SVR	4.952	3.823	3.439	8.996	5.174	9.514
MLP	9.959	3.538	3.018	15.811	11.235	5.193
AdaBoost	3.952	3.422	2.527	7.513	3.960	6.064
R2 Score	4 Clusters			Without Clustering		
Model for prediction	t ₁	t ₂	t ₃	t ₁	t ₂	t ₃
RF	0.646	0.735	0.842	0.055	0.630	-1.463
SVR	0.563	0.598	0.440	-1.056	0.387	-2.342
MLP	-1.520	0.714	0.664	-5.351	-1.888	0.004
AdaBoost	0.603	0.732	0.764	-0.434	0.641	-0.358