(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2022-0095097
(43) 공개일자 2022년07월06일

(51) 국제특허분류(Int. Cl.)
G06N 3/04 (2006.01) *G06N 3/08* (2006.01)
G06N 3/12 (2006.01) *G06N 5/04* (2006.01)
(52) CPC특허분류
G06N 3/0436 (2013.01)
G06N 3/08 (2013.01)
(21) 출원번호 10-2021-0135546
(22) 출원일자 2021년10월13일
심사청구일자 2021년10월13일
(30) 우선권주장
1020200186122 2020년12월29일 대한민국(KR)

(71) 출원인
세종대학교산학협력단
서울특별시 광진구 능동로 209 (군자동, 세종대학교)
(72) 발명자
최수미
서울특별시 광진구 능동로 209, 세종대학교 대양AI센터 720호(군자동)
아볼가셈
서울특별시 광진구 능동로 209, 세종대학교 대양AI센터 433호(군자동)
소메이에
서울특별시 광진구 능동로 209, 세종대학교 대양AI센터 715호(군자동)
(74) 대리인
송인호, 윤형근, 최관락

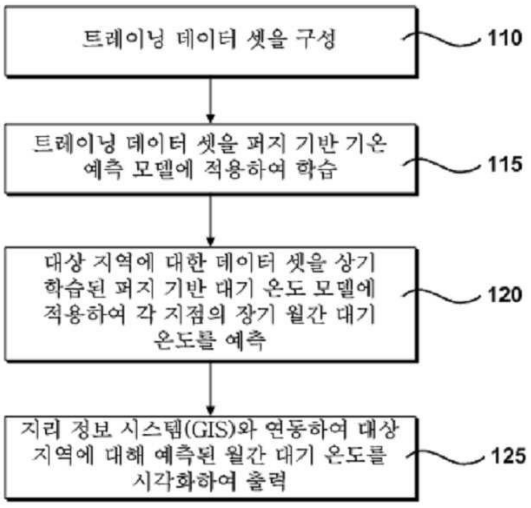
전체 청구항 수 : 총 7 항

(54) 발명의 명칭 **장기간 기온 모델링 방법 및 그 장치**

(57) 요 약

장기간 기온 모델링 방법 및 그 장치가 개시된다. 장기간 기온 모델링 방법은, (a) 트레이닝 데이터 셋을 수집하는 단계-상기 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함함; (b) 상기 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키는 단계; (c) 대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측하는 단계; 및 (d) 지리 정보와 연동하여 상기 예측된 대기 온도를 시각화하여 출력하는 단계를 포함한다.

대 표 도 - 도1



(52) CPC특허분류
G06N 3/126 (2013.01)
G06N 5/04 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1711116243
과제번호	2016-0-00312-005
부처명	과학기술정보통신부
과제관리(전문)기관명	정보통신기획평가원
연구사업명	정보통신방송혁신인재양성(R&D)
연구과제명	모바일 플랫폼 기반 엔터테인먼트 VR 기술 연구
기 여 율	1/1
과제수행기관명	세종대학교 산학협력단
연구기간	2020.01.01 ~ 2020.12.31

명 세 서

청구범위

청구항 1

(a) 트레이닝 데이터 셋을 수집하는 단계-상기 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함함;

(b) 상기 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키는 단계;

(c) 대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측하는 단계; 및

(d) 지리 정보와 연동하여 상기 예측된 대기 온도를 시각화하여 출력하는 단계를 포함하는 장기 대기 온도 모델링 방법.

청구항 2

제1 항에 있어서,

상기 퍼지 기반 대기 온도 모델은 유전 알고리즘(GA: genetic algorithm)을 이용하여 상기 퍼지 기반 대기 온도 모델의 각 입력에 대한 소속 함수(membership function)을 최적화하는 것을 특징으로 하는 장기 대기 온도 모델링 방법.

청구항 3

제1 항에 있어서,

상기 (c) 단계에서,

상기 대상 지역 중 관측소가 위치되지 않은 일부 지역은 지리 정보 시스템(GIS)와 연동된 공간 모델과 연동하여 공간 정보를 보간하여 상기 학습된 퍼지 기반 대기 온도 모델을 통해 월간 대기 온도가 예측되는 것을 특징으로 하는 장기 대기 온도 모델링 방법.

청구항 4

제1 항 내지 제3 항 중 어느 하나의 항에 따른 방법을 수행하기 위한 프로그램 코드를 기록한 컴퓨터로 판독 가능한 기록매체 제품.

청구항 5

트레이닝 데이터 셋을 수집하는 수집부-상기 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함함;

상기 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키는 학습부;

대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측하는 대기 온도 추정부; 및

지리 정보와 연동하여 상기 예측된 대기 온도를 시각화하여 출력하도록 제어하는 프로세서를 포함하는 장기 대기 온도 모델링 장치.

청구항 6

제5 항에 있어서,

상기 퍼지 기반 대기 온도 모델은 유전 알고리즘(GA: genetic algorithm)을 이용하여 상기 퍼지 기반 대기 온도 모델의 각 입력에 대한 소속 함수(membership function)을 최적화하는 것을 특징으로 하는 장기 대기 온도 모델링 장치.

청구항 7

제5 항에 있어서,

상기 대기 온도 추정부는,

상기 대상 지역 중 관측소가 위치되지 않은 일부 지역은 지리 정보 시스템(GIS)와 연동된 공간 모델과 연동하여 공간 정보를 보간한 후 상기 보간된 공간 정보를 추가적으로 상기 학습된 퍼지 기반 대기 온도 모델을 통해 월간 대기 온도가 예측되는 것을 특징으로 하는 장기 대기 온도 모델링 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 장기간 기온 모델링 방법 및 그 장치에 관한 것이다.

배 경 기 술

[0003] 지역 기후는 잠재적인 수확량에 큰 영향을 미치기 때문에 작물의 효율성에 매우 중요하다. 강수량, 일사량 및 기온은 작물 수확량 및 생장 등에 영향을 미치는 요인이다. 작물의 성장에 이상적인 온도 범위가 매우 중요한 결정 요인이다. 온도는 각 지역에서 작물의 생존과 성장을 결정하는 매우 중요한 요인이다.

[0004] 종래에는 매시간 기온을 예측하기 위해 귀납적 신경망 방법을 사용하였다. Smith, McClendon & Hoogenboom(2005)은 계절성과 관련된 데이터를 사용하고, 인공 신경망(ANN) 모델의 매개변수를 변경하여 온도 예측을 위한 인공 신경망을 개발하였으나, 지리 정보를 적용하지 않아 지역의 온도를 정확하게 예측/모델링하는 데는 한계가 있었다.

발명의 내용

해결하려는 과제

[0006] 본 발명은 장기간 기온 모델링 방법 및 그 장치를 제공하기 위한 것이다.

[0007] 또한, 본 발명은 지리 정보를 기반으로 공간 정보 보간을 통해 기온을 예측할 수 있는 장기간 기온 모델링 방법 및 그 장치를 제공하기 위한 것이다.

과제의 해결 수단

[0009] 본 발명의 일 측면에 따르면, 장기간 기온 모델링 방법이 제공된다.

[0010] 본 발명의 일 실시예에 따르면, (a) 트레이닝 데이터 셋을 수집하는 단계-상기 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함함; (b) 상기 트레이닝 데이터 셋을

이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키는 단계; (c) 대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측하는 단계; 및 (d) 지리 정보와 연동하여 상기 예측된 대기 온도를 시각화하여 출력하는 단계를 포함하는 장기 대기 온도 모델링 방법이 제공될 수 있다.

[0011] 상기 퍼지 기반 대기 온도 모델은 유전 알고리즘(GA: genetic algorithm)을 이용하여 상기 퍼지 기반 대기 온도 모델의 각 입력에 대한 소속 함수(membership function)을 최적화할 수 있다.

[0012] 상기 (c) 단계에서, 상기 대상 지역 중 관측소가 위치되지 않은 일부 지역은 지리 정보 시스템(GIS)와 연동된 공간 모델과 연동하여 공간 정보를 보간하여 상기 학습된 퍼지 기반 대기 온도 모델을 통해 월간 대기 온도가 예측될 수 있다.

[0014] 본 발명의 다른 측면에 따르면, 장기간 기온 예측 장치가 제공된다.

[0015] 본 발명의 일 실시예에 따르면, 트레이닝 데이터 셋을 수집하는 수집부-상기 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함함; 상기 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키는 학습부; 대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측하는 대기 온도 추정부; 및 지리 정보와 연동하여 상기 예측된 대기 온도를 시각화하여 출력하도록 제어하는 프로세서를 포함하는 장기 대기 온도 모델링 장치가 제공될 수 있다.

[0016] 상기 대기 온도 추정부는, 상기 대상 지역 중 관측소가 위치되지 않은 일부 지역은 지리 정보 시스템(GIS)와 연동된 공간 모델과 연동하여 공간 정보를 보간한 후 상기 보간된 공간 정보를 추가적으로 상기 학습된 퍼지 기반 대기 온도 모델을 통해 월간 대기 온도가 예측될 수 있다.

발명의 효과

[0018] 본 발명의 일 실시예에 따른 장기간 기온 모델링 방법 및 그 장치를 제공함으로써, 월간 대기 온도를 예측할 수 있다.

[0019] 또한, 본 발명은 지리 정보를 기반으로 공간 정보 보간을 통해 기온을 예측할 수도 있다.

도면의 간단한 설명

[0021] 도 1은 본 발명의 일 실시예에 따른 장기간 대기 온도 모델링 방법을 나타낸 순서도.

도 2는 본 발명의 일 실시예에 따른 관측소에서 기록한 기온, 경도, 위도 및 해발 고도를 예시한 도면.

도 3은 본 발명의 일 실시예에 따른 터키의 기상 관측소 분포를 예시한 도면.

도 4는 적응형 신경 퍼지 추론 시스템을 개략적으로 도시한 도면.

도 5는 본 발명의 일 실시예에 따른 대상 지역의 대기 온도 예측 결과를 시각화하여 출력한 도면.

도 6 내지 도 8은 종래와 본 발명의 일 실시예에 따른 대기 온도 예측 결과를 비교한 도면.

도 9는 본 발명의 일 실시예에 따른 장기간 대기 온도 모델링 장치의 내부 구성을 개략적으로 도시한 도면.

발명을 실시하기 위한 구체적인 내용

[0022] 본 명세서에서 사용되는 단수의 표현은 문맥상 명백하게 다르게 뜻하지 않는 한, 복수의 표현을 포함한다. 본 명세서에서, "구성된다" 또는 "포함한다" 등의 용어는 명세서상에 기재된 여러 구성 요소들, 또는 여러 단계들을 반드시 모두 포함하는 것으로 해석되지 않아야 하며, 그 중 일부 구성 요소들 또는 일부 단계들은 포함되지 않을 수도 있고, 또는 추가적인 구성 요소 또는 단계들을 더 포함할 수 있는 것으로 해석되어야 한다. 또한, 명세서에 기재된 "...부", "모듈" 등의 용어는 적어도 하나의 기능이나 동작을 처리하는 단위를 의미하며, 이는 하드웨어 또는 소프트웨어로 구현되거나 하드웨어와 소프트웨어의 결합으로 구현될 수 있다.

[0023] 이하, 첨부된 도면들을 참조하여 본 발명의 실시예를 상세히 설명한다.

[0025] 도 1은 본 발명의 일 실시예에 따른 장기간 대기 온도 모델링 방법을 나타낸 순서도이고, 도 2는 관측소에서 기록한 기온, 경도, 위도 및 해발 고도를 예시한 도면이고, 도 3은 터키의 기상 관측소 분포를 예시한 도면이고, 도 4는 적응형 신경 퍼지 추론 시스템을 개략적으로 도시한 도면이고, 도 5는 본 발명의 일 실시예에 따른 대상 지역의 대기 온도 예측 결과를 시각화하여 출력한 도면이고, 도 6 내지 도 8은 종래와 본 발명의 일 실시예에 따른 대기 온도 예측 결과를 비교한 도면이다.

[0026] 단계 110에서 장기 대기 온도 모델링 장치(100)는 트레이닝 데이터 셋을 구성한다. 여기서, 트레이닝 데이터 셋은 경도, 위도, 고도 및 월(month of year)일 수 있으며, 기온이 포함될 수도 있다.

[0027] 이를 위해, 본 발명의 일 실시예에서는 터키 기상청의 관측소에서 수집한 월별 평균 기온을 사용하는 것을 가정하기로 한다. 본 발명의 일 실시예에서는 1970년부터 약40년 동안의 관측소의 데이터 중 일부를 트레이닝 데이터 셋으로 구성할 수 있다. 각 관측소에서 기록한 기온, 경도, 위도 및 해발 고도는 도 2에 도시된 바와 같다.

[0028] 온도는 1월에는 11.5도이며, 7월은 약 32도까지 장기적으로는 다양하였으며, 이러한 큰 변동은 이 지역을 둘러싸고 있는 바다, 흑해와 지중해 연안의 높은 산, 동부 아나톨리아 지역의 산악 지역 때문이다. 도 3은 터키의 기상 관측소 분포를 예시한 도면이다.

[0029] 이와 같이, 트레이닝 데이터 셋이 구성되면, 단계 115에서 장기 대기 온도 모델링 장치(100)는 트레이닝 데이터 셋을 퍼지 기반 기온 예측 모델에 적용하여 학습시킨다.

[0030] 본 발명의 일 실시예에 따른 퍼지 기반 기온 예측 모델은 퍼지 기술을 기반으로 하며, 각 입력에 대한 소속 함수(membership function)는 유전자 알고리즘(GA: genetic algorithm)을 사용하여 최적화될 수 있다.

[0031] 도 3는 퍼지 시스템의 일반적인 퍼지화를 도시한 도면이다. 퍼지 시스템은 추론 엔진, 퍼지 룰 베이스 및 역 퍼지화를 포함한다.

[0032] 추론 엔진은 데이터의 입력을 취하여 데이터를 출력한다. 추론 엔진은 퍼지 연관 메모리로 불리는 연관 맵을 사용하여 입력이 퍼지 시스템 학습에 의해 동등한 출력 세트로 변환된다.

[0033] 가우시안 소속 함수(Gaussian member function)을 사용하는 몇몇 서브세트는 입력 및 출력 파라미터로부터 형성될 수 있다. ck 퍼지 규칙이 이용되며, c와 k는 서브 셋과 입력 번호를 각각 나타낸다.

[0034] 가우시안 소속 함수를 사용하는 여러 서브 셋은 입력 및 출력 매개 변수로 구성될 수 있다. 서브 셋의 수에 따라 효율성이 증가하고 룰 베이스 가중치가 증가하여 구성이 더 복잡해진다. 하나의 입력 x와 k 서브 셋의 경우 룰 베이스는 yn 을 산출할 수 있다(여기서, n=1, 2, ?, $k2$)

[0035] 예를 들어, 하나의 입력 변수(x)를 가정하는 경우, x는 "low", "medium", "high" 및 "very high"와 같이 4가지 규칙이 가능하며, 그에 대한 규칙의 예시는 다음과 같다.

[0036] R1: IF x is "low", THEN y_1

[0037] R2: IF x is "medium", THEN y_2

[0038] R3: IF x is "high", THEN y_3

[0039] R4: IF x is "very high"", THEN y_4

[0040] 즉, 출력은 4가지 규칙의 출력에 대한 가중 평균인 단일 가중치 y일 수 있다. 이를 수학식으로 나타내면 수학식 1과 같다.

수학식 1

[0041] $$y = \frac{\sum_{n=1}^{4} w_n \cdot y_n}{\sum_{n=1}^{4} w_n}$$

[0042] 여기서, 소속함수 등급 W_n은 각 규칙을 트리거한 후 동등한 yn 이 할당되도록 각 x에 대해 조사될 수 있다. 따라서, 규칙 베이스를 형성한 후 퍼지 시스템의 입력으로 사용되는 매개 변수 서브 셋의 모든 분류는 출력 값(y)을 계산하는데 사용될 수 있다.

[0043] 기본적인 퍼지 규칙은 다음과 같이 입력 및 출력으로 사용되는 데이터 세트를 사용하여 계산될 수 있다.

[0044] 1. 가장 적은 수의 입력 사용

[0045] 2. 각 입력에 특정 소속 함수를 할당

[0046] 3. 모든 퍼지 서브셋에서 x의 소속함수 (W_n) 값을 계산

[0047] 4. 가중치 세트 W_n 을 가지고 동시에 출력 yn 을 계산

[0048] 5. 모든 다른 데이터 포인트를 갱신

[0049] 6. 수학식 1을 사용하여 가중 평균을 계산

[0050] 서브셋의 변경은 퍼지 모델의 기능에 직접적인 영향을 미치므로, 퍼지 서브 셋을 형성하는 것은 어려운 문제이다. 따라서, 모델링 효율성을 극대화하기 위해 소속 함수를 최적으로 정의하는 것이 가장 중요하며, 본 발명의 일 실시예에서는 유전자 알고리즘(GA: genetic algorithm)을 사용하여 최적의 소속 함수를 최적화할 수 있다.

[0051] 유전자 알고리즘(GA)은 자연 선택에 대한 다윈주의적 개념을 모방한다. 유전자 알고리즘(GA)는 먼저 가능한 솔루션 세트를 생성하고 이전보다 실제 솔루션을 더 잘 평가하는 새로운 솔루션 모집단을 형성하기 위해 생존에 대한 최상의 접근 방식을 찾으려고 한다. 더 나은 솔루션 세트를 만드는 문제는 유전자 알고리즘(GA)의 기본 원칙이다.

[0052] 예를 들어, 유전자 알고리즘을 이용하여 퍼지 소속 함수를 형성하기 위한 최상의 퍼지 경계(퍼지 부분집합)을 찾고, 퍼지 함수의 가장 좋은 유형을 찾는 과정을 반복하여 소속 함수를 최적화할 수 있다. 즉, 경계를 기반으로 하는 퍼지 소속 함수와 기존 출력 관련 입력 데이터를 사용하여 생성된 출력 간의 차이를 줄이도록 유전자 알고리즘을 사용하여 최적의 퍼지 경계를 찾을 수 있다.

[0053] 적응형 신경 퍼지 추론 모델은 최종 결과값이 계급값이 아닌 연속형 변수값을 취하게 되므로 산출된 결과값을 이용하여 절절한 계급값을 할당하는 과정이 필요하다.

[0054] 일반적으로 퍼지 신경망을 구현하기 위해서는 네트워크 설계 구조가 필요하다. 네트워크 구조 설계라함은 추론에 필요한 퍼지 규칙의 구조와 형태를 결정하고 퍼지 추론 방법을 선택하는 것을 포함한다. 퍼지 규칙은 퍼지 용어로 기술되기 때문에 각 퍼지 용어에 대한 소속함수(membership function) 형태뿐 아니라 입력 변수들로 구성된 다차원의 입력 공간을 몇 개의 세부 공간으로 분할할 것인지도 결정하여야 한다.

[0055] 퍼지공간에 대한 분할이 이루어지면 각 퍼지 공간에 대응하는 퍼지 규칙이 필요하게 되며, 이렇게 정해진 퍼지 규칙의 개수와 규칙의 형태는 분류 성능을 결정하는 중요한 요인이 된다. 초기 퍼지 규칙이 구성되면 이를 이용하는 퍼지 추론 방법이 결정되어야 한다. 이는 AND, OR 등의 연산과 같은 퍼지 연산 방법과 디퍼지화 방법을 포함한다.

[0056] 분류 모형의 네트워크 구조 설계가 완료되면 각 네트워크 노드에서 사용되는 파라미터를 분류오차가 최소화되도

록 조정하는 학습과정을 거친다. 각 네트워크 노드에서 사용되는 파라미터는 퍼지규칙의 조건부에 기술된 각 퍼지용어의 소속함수를 결 정하기 위한 파라미터와 규칙의 결과부에 나타나는 선형함수의 파라미터를 의미한다

[0057] 퍼지추론 과정은 입력변수로 구성된 다차원의 입력공간을 세부영역으로 구분하여 각 세부영역에서 추론의 결과값을 산출하도록 하는 "분할 후 정복(Divide and Conquer)" 방식으로 이루어진다. 즉, 퍼지규칙의 조건부는 입력공간을 세분영역으로 분할하게 되며, 퍼지규칙의 결론부는 각 영역에서의 추론결과를 기술하게 된다. 따라서 퍼지규칙 의 구조를 설계한다는 것은 입력공간을 어떻게 분할하는가와 밀접히 관계되어 있다. ANFIS에서 입력변수들로 구성된 다차원공간을 분할하는 방법으로 그리드분할(Grid Partitioning)과 차감클러스터링(Subtractive Clustering)방법을 주로 사용한다.

[0058] 그리드 분할(Grid partitioning) 방법은 입력공간을 중복이 생기지 않도록 격자구조로 공간을 분할 하는 것이다. 일반적으로 그리드 분할법을 적용하면 분할된 퍼지영역이 동질적으로 존재하기 때문에 퍼지규칙의 해석용이성(Interpretability)이 높아진다(Bersini and Bontempi, 1997).

[0059] 이 방법은 입력변수의 수가 작을 때(입력공간의 차원이 낮을 때) 주로 사용되는 방법이다. 예를 들면, 입력변수가 10개이고, 각 입력변수가 2개의 소속함수로 구 분이 되는 경우, 2 10 = 1024개의 세분영역이 생기게 되며, 각 영역마다 1개의 규칙씩 총 1024개의 퍼지 규칙이 만들어지게 되어 매우 복잡한 시스템이 된다.

[0060] 이 경우 다른 공간분할 방법을 사용하는 것이 효과적이다. 차감 클러스터링(Subtractive Clustering) 방법은 다차원의 입력데이터를 분석하여 이를 군집화 함으로써 입력공간을 몇 개의 세분된 퍼지공간으로 구분하는 방법이다.

[0061] 그리드 분할의 경우, 입력변수가 증가함에 따라 규칙이 기하급수적으로 증가 하는데 이러한 단점을 해결하기 위해 차감 클러스터링이 사용된다. 또한 차감 클러스터링은 퍼지 군 집의 개수를 지정하지 않더라도 입력데이터의 공 간을 적절한 갯수로 분할한다(Chiu, 1994). 차감 클러스터링에서는 군집의 반경을 지정 하게 되는데 이는 데이터 공간을 단위 하이퍼큐브로 간주할 때 군집 중심으로부터의 영향범위를 나타내며 0에서 1사이의 값을 가진다. 너무 작은 군집반경을 지정 하면 작은 군집이 많이 생기게 되고 따라서 퍼지규칙의 수가 많아진다. 반대로 군집반경을 크게 설정 하면 군집의 수가 작아져서 규칙의 수도 작아지게 된다.

[0062] 입력공간의 분할이 이루어지고 나면 소속함수의 형태를 정의해야 한다. 소속함수의 형태로 주로 사용되는 것은 삼각형(Triangular)함수, 사다리꼴 (Trapezoidal)함수, 가우시안(Gaussian)함수, 종형 (bell)함수, 시그모이달(sigmoidal)함수 등이 있다. 이중 가우시안함수와 종형함수는 부드러운 곡선 형태를 취하며 작은 수의 파라미터와 간략한 표현법에 의해 퍼지집합을 묘사하기 때문에 가장 폭넓게 사용되고 있다. 한편 시그모이달함수는 오른편과 왼편이 개방된 형태의 함수로써 "매우 크다", "매우 높다" 등의 극단적인 퍼지집합을 표현하는데 자주 사용된다.

[0063] 도 4를 참조하여 세개의 입력과 한 개의 출력을 가지며, 두개의 Takagi-Sugenro if-then 퍼지 규칙으로 구성된 퍼지 추론 모델에 대해 설명하기로 한다.

[0064] Rule 1: $\text{If x is A1, y is B1, and z is C1, then } f_1 = p_1x + q_1y + r_1z + s_1$

[0065] Rule 2: $\text{If x is A2, y is B2, and z is C2, then } f_2 = p_2x + q_2y + r_2z + s_2$

[0066] 여기서, f_1 과 f_2 는 Rule 1과 Rule 2의 출력 함수를 나타낸다.

[0067] 도 4에는 적응형 신경 퍼지 추론 모델(ANFIS) 구조가 도시되어 있다. 노드의 출력 함수는 다음과 같다.

[0068] $O_{l,i} = \phi A_i(x)$ 는 레이어 1의 사각형 노드 i의 노드 함수로 파라미터를 포함하는 적응형 노드이며, x는 입력 노드를 나타내고, A_i 는 해당 노드 함수를 위한 언어 레이블(예를 들어, "small" 또는 "big" 을 나타낸다.

[0069] 입력 x가 정량자(quantifier) A_i fmf 만족하면, $O_{l,i}$ 는 퍼지 세트 A(예를 들어,

$A_1, A_2, B_1, B_2, C_1, C_2$)의 소속 함수이며, 이 소속도(degree)를 나타낸다.

[0070] $\phi A_i(x)$는 최소 및 최대 레벨으로 각각 0과 1 사이의 범위를 갖는 가우시안 함수이며 수학식 2와 같이 나타낼 수 있다.

수학식 2

$$\phi A_i(x) = \exp\left(-\left(\frac{x-a_i}{b_i}\right)^2\right)$$

[0071]

[0072] 여기서, $\{a_i, b_i\}$는 파라미터 세트이며, 이러한 레이어 파라미터는 가정된 것을 간주될 수 있다.

[0073] 레이어 2의 원형 노드는 인덱스 Π를 가지며, 파라미터 없이 주어진 연산만을 수행하는 일반 노드로 예를 들어, 입력의 곱셈을 수행할 수 있다. 예를 들어, $w_i = \phi A_i(x)\phi B_i(y)\phi C_i(z),\ i = 1, 2$이다.

[0074] 각 노드의 출력은 룰의 노출 수준을 보여준다. 레이어 3의 원형 노드는 라벨 N을 취한다. 모든 룰의 레벨 합계에 대한 i번째 룰의 인상 수준 비율은 i번째 노드에 의해 계산되며, 이를 수학식으로 나타내면 수학식 3과 같다.

수학식 3

$$w_i = \frac{w_i}{w_1 + w_2},\quad i = 1, 2.$$

[0075]

[0076] 레이어 4의 사각형 노드의 함수는 $O_{4,i} = \bar{w}_i f_i = \bar{w}_i\left(p_i x + q_i y + r_i z + s_i\right)$이다. 여기서, $\bar{w}_i$는 레이어 3의 출력을 나타내고, 파라미터 시리즈는 $\{p_i, q_i, r_i, s_i\}$이다. 레이어 파라미터는 결과 파라미터로 불리운다.

[0077] "Σ,"로 레이블된 레이어 5의 단일 원형 노드는 들어오는 모든 신호를 합산하고 결과를 최종 출력으로 반환한다. 이를 수학식으로 나타내면 수학식 4와 같다.

수학식 4

$$O_{5,i} = \sum_{i=1} \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i}$$

[0078]

[0079] 적응형 신경 퍼지 추론 모델(ANFIS) 네트워크는 1차 Sugeno FIS와 유사하게 동작한다. 선형 또는 고정 값 함수

는 적응형 신경 퍼지 추론 모델(ANFIS)에서 출력을 생성하는데 사용된다.

[0080] 적응형 신경 퍼지 추론 모델(ANFIS)에서 입력변수들로 구성된 다차원공간을 분할하는 방법으로 그리드분할(Grid Partitioning)과 차감클러스터링(Subtractive Clustering)방법이 생성될 수 있다.

[0081] 이전 변수의 독립 분할을 제공하며, 모든 이전 변수의 소속 함수는 사전 지식과 경험에 의해 결정될 수 있다. 컨텍스트의 언어적 용어의 의미를 표현하는 것이 분할을 설계하는 목표이다. 많은 시스템에서 이러한 분할에 액세스 할 수 있는 특징 정보가 없다. 다라서, 이전 변수의 범위는 동일한 모양과 간격을 가진 소속 함수로 쉽게 나눌 수 있다. 소속 함수의 기능은 시스템의 입력 출력 데이터를 사용할 수 있는 경우 적절하게 배치할 수 있다. 룰 베이스는 이전 퍼지 세트 조합을 완벽하게 다루는 방식으로 생성되어야 한다. 각 변수의 소속 함수는 다른 변수와는 별도로 구축되며, 이는 변수간 관계를 간과하는 측면에서 단점이다.

[0082] 적응형 신경 퍼지 추론 모델(ANFIS)-SC 모델은 적응형 신경 퍼지 추론 모델(ANFIS)를 차감클러스터링과 병합하여 정의된다. 이 모델에서 가능한 군집 중심을 그리드 포인트가 아닌 각 데이터 포인트이다. ANFIS-SC 방식에서 그리드 포인트의 수는 문제의 차원 수에 관계없이 데이터 포인트의 수와 유사하다.

[0083] 이 접근 방식의 장점 중 하나는 그리드 해상도를 정의 할 필요가 없기 때문에 계산 복잡성과 정확도 사이의 절충이 불필요하다는 것이다. 클러스터 센터를 수락하거나 거부하는 산악 방법의 규모도 차감 클러스터링에서는 확장된다. 반경은 클러스터 수를 정의하는 데 중요하다. 작은 반지름을 선택한 경우 너무 많은 작은 클러스터에 더 많은 규칙이 필요하며 그 반대의 경우도 마찬가지이다. 따라서 데이터 공간 클러스터링에 적합한 인상적인 반경을 선택하는 것이 중요하다. 퍼지 규칙의 수와 퍼지 소속 함수의 추정을 정의하는 것이 다음 단계이다. 결굴 출력 소속 함수의 결과는 유효한 FIS fmf 구축하는 선형 최소 제곱을 사용하여 생성된다.

[0084] C-평균 퍼지 클러스터링은 특징 공간에서 가능한 데이터 포인트를 계산하여 데이터 포인트가 결합되는 유연한 클러스터링 모델의 한 형태이다. 이 모델에서 산(mountain) 클러스터링 접근은 클러스터와 클러스터 센터의 수를 계산하는데 사용될 수 있다. 이 모델은 큰 데이터베이스에는 적합하지 않은 k-평균 알고리즘을 기반으로 한다.

[0085] C-평균 퍼지 클러스터링은 클러스터 내 분산을 최소로 줄이고, 클러스터링 알고리즘을 사용하여 데이터를 컴바인(결합)한다. C-평균 퍼지 클러스터링은 거리 또는 목적 제곱 오차 함수를 최소화할 수 있다.

[0086] 상술한 바와 같이, 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 장치(100)는 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습할 수 있다. 이를 통해 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 장치(100)는 퍼지 기반 대기 온도 모델의 각 입력에 대한 소속 함수를 유전자 알고리즘을 이용하여 최적화할 수 있다.

[0087] 학습이 완료된 이후, 단계 120에서 장기 대기 온도 모델링 장치(100)는 대상 지역에 대한 데이터 셋을 상기 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측한다.

[0088] 본 발명의 일 실시예에 따르면, 지리 정보 시스템(GIS)과 연동된 공간 모델을 포함한다. 공간 모델은 지리 정보 시스템과 연동되어 관측소가 위치되지 않아 공간 정보가 존재하지 않은 일부 지역의 공간 정보를 보간할 수 있다.

[0089] 이와 같이, 보간된 공간 정보가 학습된 퍼지 기반 대기 온도 모델에 입력으로 적용되어 월간 대기 온도 예측에 이용될 수 있다.

[0090] 시간 및 공간 모델링에 지리 정보 시스템(GIS)을 연동하는 것은 모델 시각화를 개선하고 지속 가능성 지표에서 얼마나 멀리 떨어져 있는지 추적하는데 중요한 역할을 한다.

[0091] 지리 정보 시스템(GIS)과 연동된 공간 모델은 퍼지 기반 대기 온도 모델의 입력으로 사용되는데 필요한 공간 정보(지리적 위치)를 생성할 수 있다. 또한, 공간 함수를 사용하면 모델링 현상과 관련된 지도가 생성되어 다른 위치에서 행동을 평가할 수도 있다. 구역 통계와 같은 공간 통계 기능은 현상의 변동과 다른 위치에서 최소 및 최대 평균값을 평가한다. 보간 방법과 같은 지리 공간 함수는 모델 결함(일부 영역의 데이터 손실)을 제거할 수 있다.

[0092] 단계 125에서 장기 대기 온도 모델링 장치(100)는 지리 정보 시스템(GIS)와 연동하여 대상 지역에 대해 예측된 월간 대기 온도를 시각화하여 출력한다. 이에 대한 일 예가 도 5에 예시되어 있다.

[0093] 도 6 내지 도 8은 종래와 본 발명의 일 실시예에 따른 대기 온도 예측 결과를 비교한 도면이다. 도 6 내지 도 8

에서 보여지는 바와 같이, 본 발명의 일 실시예에 따른 퍼지 기반 대기 온도 모델의 추정치가 종래의 다른 모델들(ANFIS-GP, ANFIS-SC 및 ANFIS-FCM 모델)보다 해당 관측 온도에 더 가까운 것을 알 수 있다.

[0095] 도 9는 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 장치의 내부 구성을 개략적으로 도시한 블록도이다.

[0096] 도 9를 참조하면, 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 장치(100)는 통신부(910), 수집부(915), 학습부(920), 대기 온도 추정부(925), 메모리(930) 및 프로세서(935)를 포함하여 구성된다.

[0097] 통신부(910)는 통신망을 통해 다른 장치들과 데이터를 송수신하기 위한 수단이다.

[0098] 수집부(915)는 트레이닝 데이터 셋을 수집하기 위한 수단이다. 여기서, 트레이닝 데이터 셋은 각 관측소에서 관측된 경도, 위도, 고도 및 월(month of year)을 입력 데이터로 포함할 수 있다.

[0099] 학습부(920)는 트레이닝 데이터 셋을 이용하여 퍼지 기반 대기 온도 모델이 대기 온도를 예측하도록 학습시키기 위한 수단이다. 퍼지 기반 대기 온도 모델은 각 입력에 대해 소속 함수를 가지되, 소속 함수는 유전자 알고리즘을 이용하여 최적화될 수 있다.

[0100] 대기 온도 추정부(925)는 대상 지역에 대한 데이터 셋을 학습된 퍼지 기반 대기 온도 모델에 적용하여 각 지점의 장기 월간 대기 온도를 예측할 수 있다.

[0101] 이때, 대기 온도 추정부(925)는 지리 정보 시스템(GIS)와 연동된 공간 모델과 연동되며, 대상 지역 중 관측소가 위치되지 않거나 공간 정보가 없는 일부 지역에 대한 공간 정보를 해당 공간 모델을 통해 보간하여 학습된 퍼지 기반 대기 온도 모델에 적용하여 월간 대기 온도를 예측할 수 있다.

[0102] 메모리(930)는 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 방법을 수행하기 위한 다양한 명령어들을 저장한다.

[0103] 프로세서(935)는 본 발명의 일 실시예에 따른 장기 대기 온도 모델링 장치(100)의 내부 구성 요소들(예를 들어, 통신부(910), 수집부(915), 학습부(920), 대기 온도 추정부(925), 메모리(930) 등)을 제어하기 위한 수단이다.

[0104] 또한, 프로세서는 지리 정보와 연동하여 상기 예측된 대기 온도를 지도상에 시각화하여 출력하도록 제어할 수도 있다.

[0106] 본 발명의 실시 예에 따른 장치 및 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 명령 형태로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 컴퓨터 판독 가능 매체에 기록되는 프로그램 명령은 본 발명을 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 분야 통상의 기술자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기매체(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.

[0107] 상술한 하드웨어 장치는 본 발명의 동작을 수행하기 위해 하나 이상의 소프트웨어 모듈로서 작동하도록 구성될 수 있으며, 그 역도 마찬가지이다.

[0108] 이제까지 본 발명에 대하여 그 실시 예들을 중심으로 살펴보았다. 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 본 발명의 본질적인 특성에서 벗어나지 않는 범위에서 변형된 형태로 구현될 수 있음을 이해할 수 있을 것이다. 그러므로 개시된 실시 예들은 한정적인 관점이 아니라 설명적인 관점에서 고려되어야 한다. 본 발명의 범위는 전술한 설명이 아니라 특허청구범위에 나타나 있으며, 그와 동등한 범위 내에 있는 모든 차이점은 본 발명에 포함된 것으로 해석되어야 할 것이다.

부호의 설명

[0110] 100: 장기 대기 온도 모델링 장치

910: 통신부

915: 수집부

920: 학습부

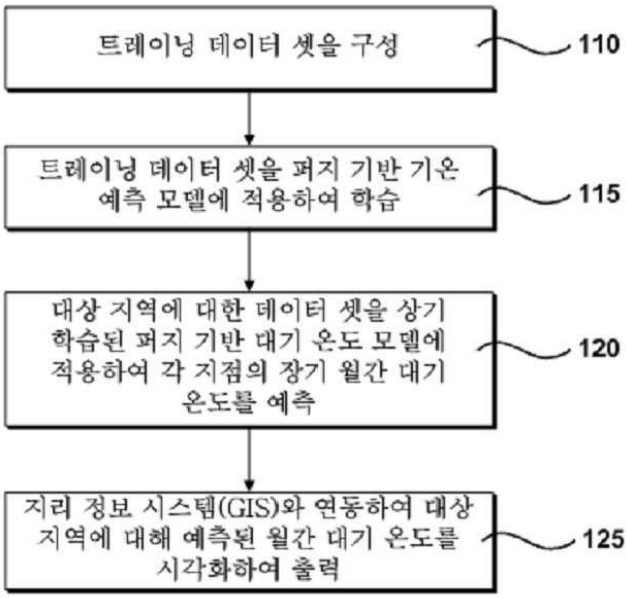
925: 대기 온도 추정부

930: 메모리

935: 프로세서

도면

도면1



도면2

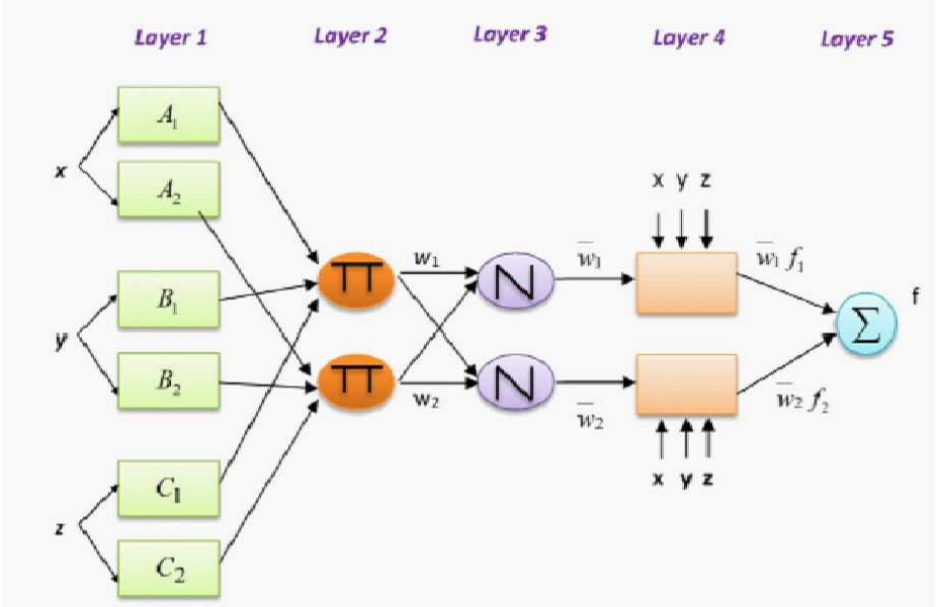
Table 1 Summary of the geographical information of the studied weather stations (*Kisi & Shiri, 2014*).

Station	Lat. (°N)	Long. (°W)	Alt. (m)	*T (°C)	Station	Lat. (°N)	Long. (°W)	Alt. (m)	*T (°C)
Adana	37	35.32	27	19.12	K.maras	37.3	40.77	572	16.81
Adiyaman	37.76	38.27	672	17.24	Karabuk	41.2	32.62	259	13.33
Afyon	38.74	30.55	1,034	11.28	Karaman	37.17	33.22	1,025	11.88
Agri	39.72	43.05	1,632	6.18	Kars	40.59	43.08	400	4.81
Aksaray	38.37	34.03	965	12.02	Kastamonu	41.37	33.77	800	9.73
Amasya	40.65	35.83	412	13.63	Kayseri	38.72	35.49	1,093	10.44
Ankara	39.97	32.86	891	11.98	Kirikkale	39.84	33.52	748	12.57
Antalya	36.9	30.79	54	18.40	Kirklareli	41.74	27.22	232	13.20
Ardahan	41.11	42.7	1,829	3.75	Kirsehir	39.16	34.15	1,007	11.35
Artvin	41.18	41.82	628	12.03	Kilis	36.72	37.12	638	17.10
Aydin	37.84	27.84	56	17.63	Konya	37.99	32.56	1,031	11.58
Balikesir	39.63	27.92	102	14.55	Kutayha	39.42	29.99	969	10.75
Bartin	41.62	32.35	30	12.63	Malatya	38.35	38.31	948	13.74
Batman	37.89	41.12	540	16.51	Manisa	38.61	37.4	71	16.98
Bayburt	40.25	40.43	1,584	6.93	Mardin	37.31	40.73	1,040	16.15
Bilecik	40.14	29.97	539	12.50	Mugla	37.29	28.37	646	15.01
Bingol	38.88	40.49	11.77	11.95	Mus	38.74	41.49	1,320	9.71
Bitlis	38.39	42.12	1,573	9.53	Nigde	37.97	34.69	1,211	11.08
Bolu	40.74	31.6	743	10.53	Osmaniye	37.1	36.25	94	18.24
Burdur	37.72	30.29	967	13.18	Rize	41.04	40.5	9	14.23
Bursa	40.23	29.01	100	14.56	Sakarya	40.77	30.39	31	14.44
Canakkale	40.15	26.41	6	15.01	Samsun	41.35	36.24	4	14.38
Cankiri	40.61	33.61	751	11.18	Siirt	37.93	41.94	896	16.11
Corum	40.54	34.94	776	10.57	Sinop	42.02	35.15	32	14.09
Denizli	37.76	29.09	425	16.21	Sivas	39.74	37.02	1,285	9.08
Elazig	38.67	39.22	990	13.03	S.urfa	37.16	38.79	549	18.38
Erzincan	39.74	39.5	1,218	10.89	Sirnak	37.52	42.45	1,350	14.13
Erzurum	39.95	41.17	17.58	5.40	Tekirdag	40.99	27.49	3	13.96
Eskisehir	39.78	30.58	786	10.84	Tokat	40.3	36.56	608	12.48
Gaziantep	37.07	37.39	855	15.07	Trabzon	41	39.78	39	14.68
Giresun	40.92	38.39	37	14.53	Tunceli	39.1	39.55	978	12.83
Gumushane	40.46	39.47	1219	9.55	Usak	38.67	29.4	919	12.51
Hakkari	37.57	43.75	1,728	10.26	Van	38.49	43.39	1,661	9.24
Hatay	36.36	36.28	82	18.26	Yalova	40.66	29.27	4	14.67
Igdir	39.92	44.06	858	12.08	Yozgat	39.82	34.81	1,298	8.97
Istanbul	40.98	28.82	33	15.01					

도면3


Black Sea
RUSSIA
BULGARIA
GEORGIA
GREECE
IRAN
SYRIA
IRAQ
Mediterranean Sea
Turkey

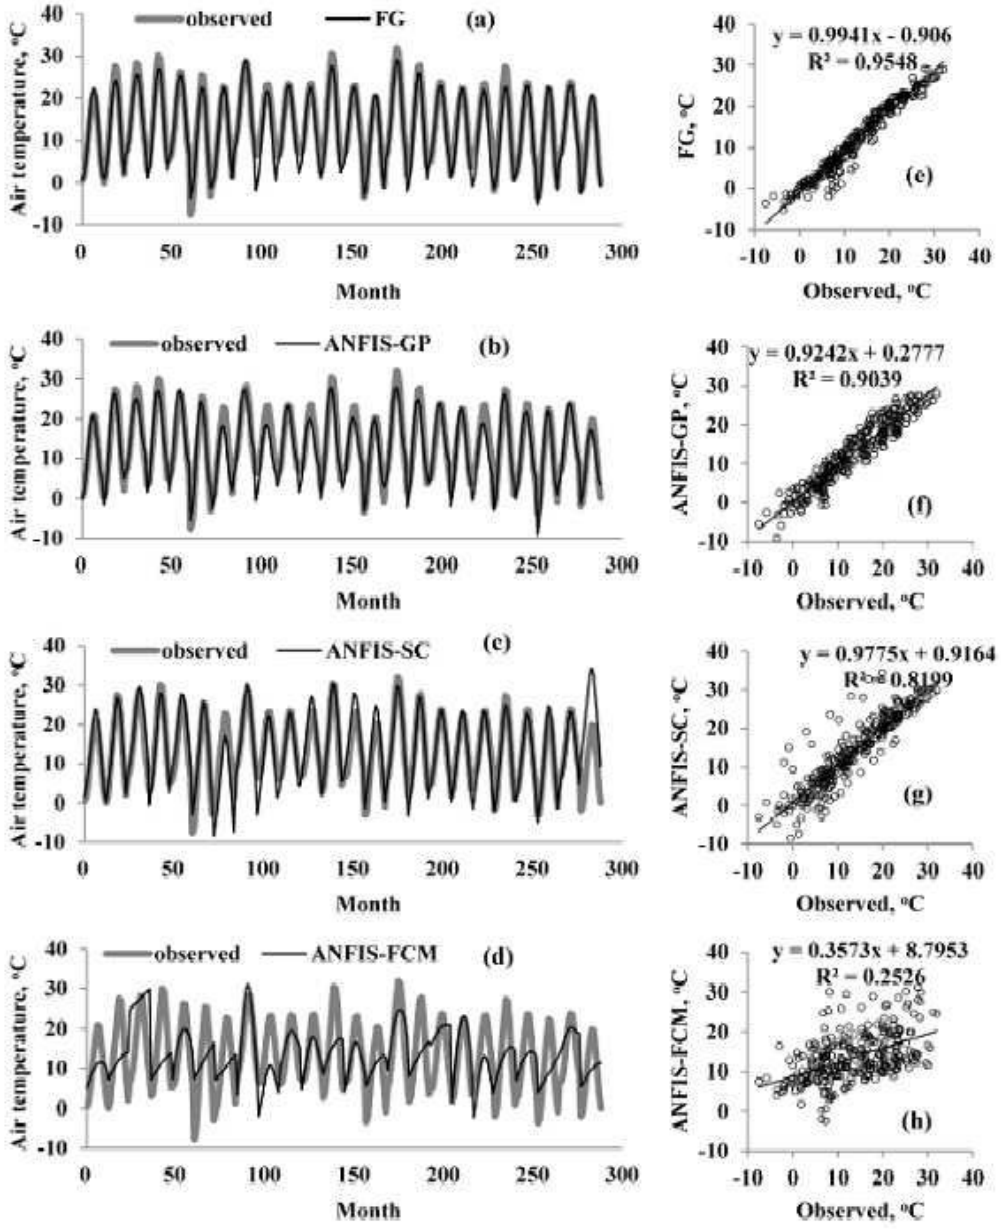
도면4


Layer 1
Layer 2
Layer 3
Layer 4
Layer 5
x
y
z
A1
A2
B1
B2
C1
C2
TT
TT
w1
w2
N
N
x y z
x y z
f

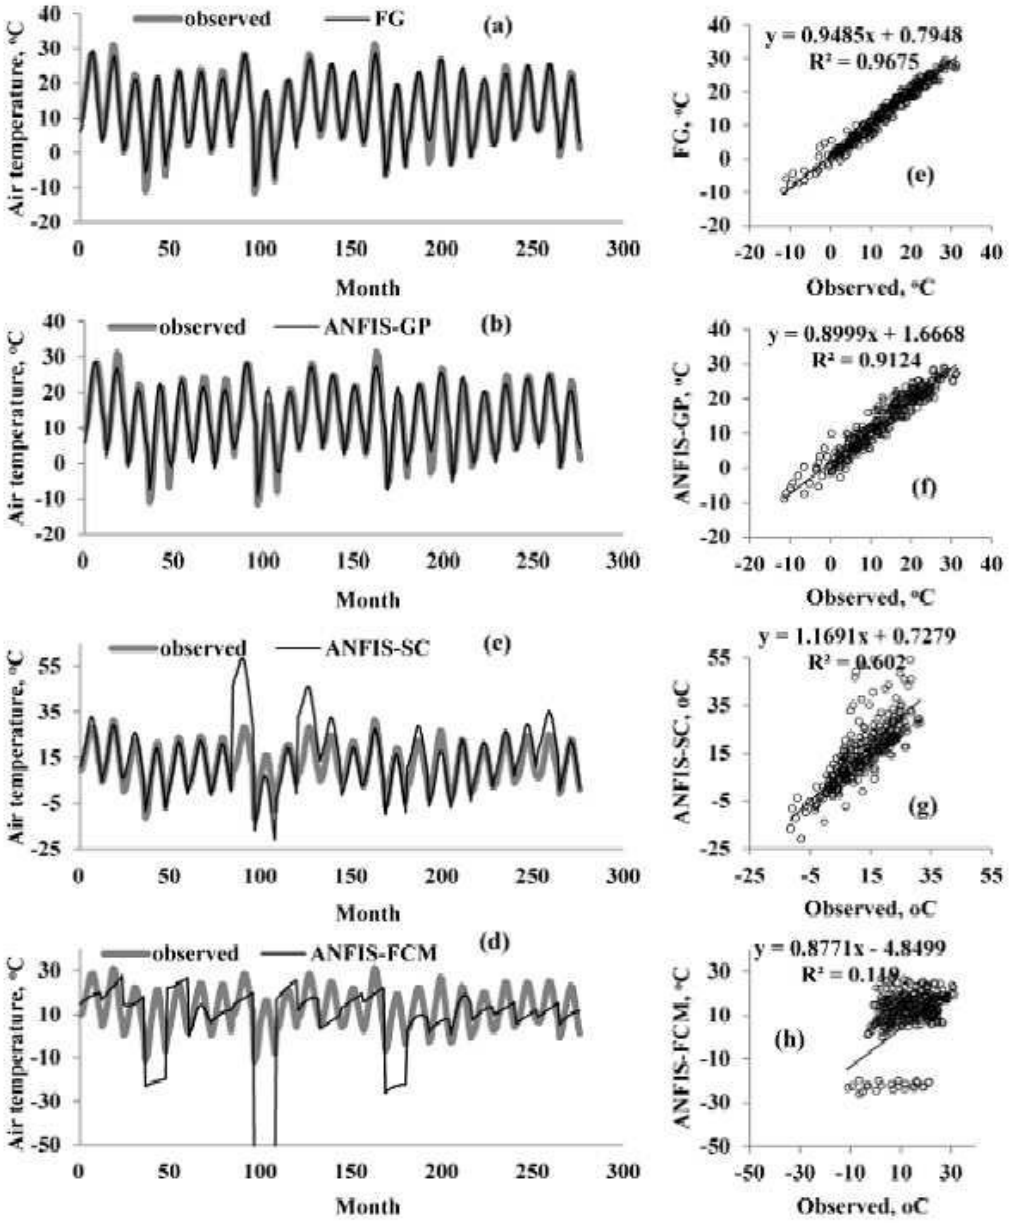
도면5


Legend
M1 FG_Fuzzy_G
temperature
N
W
E

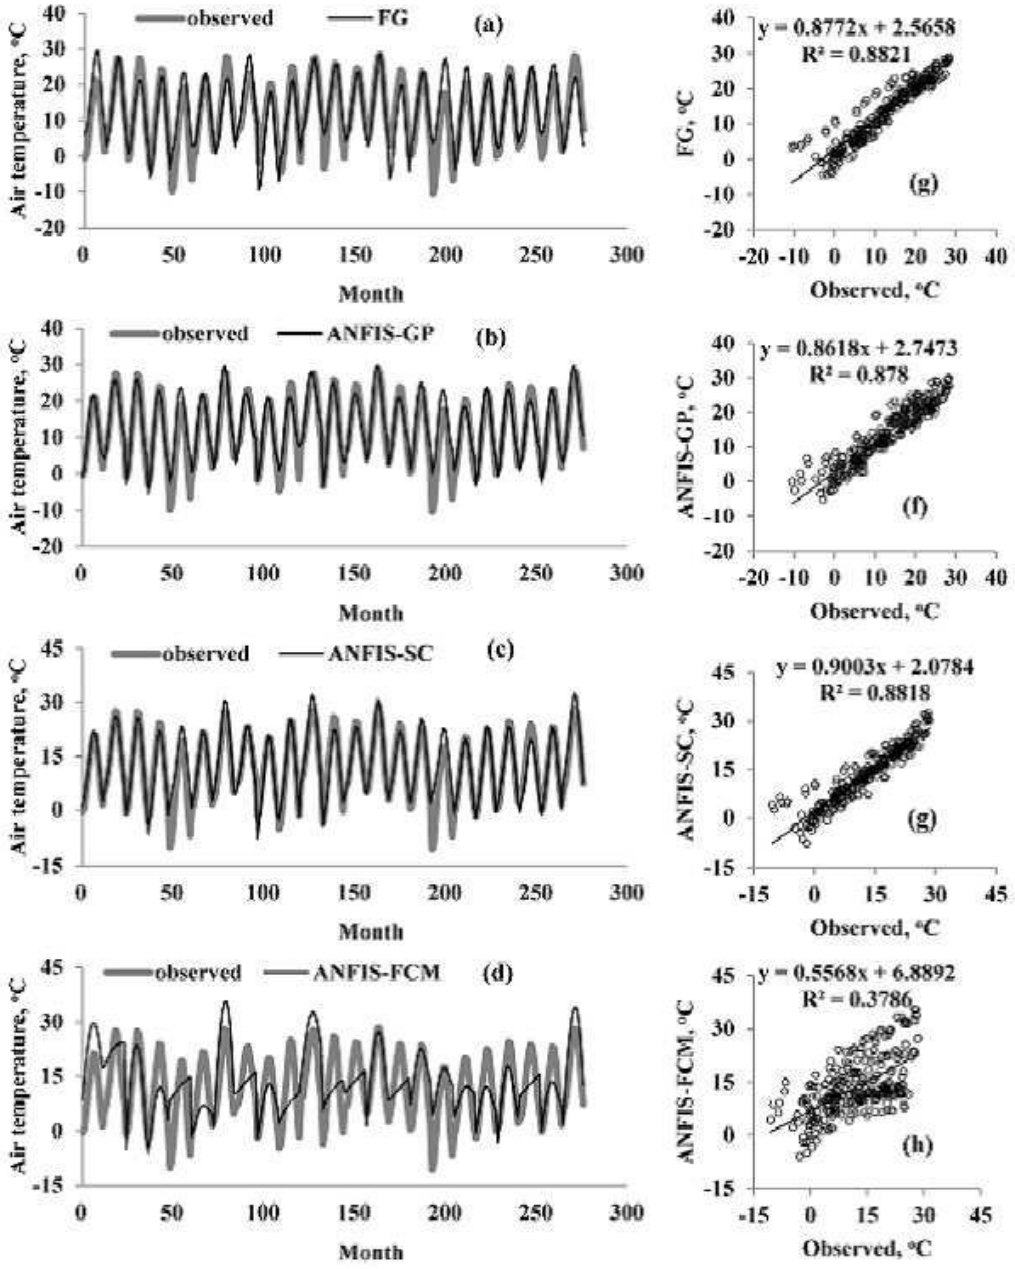
도면6


observed
FG
(a)
Air temperature, °C
Month
y = 0.9941x - 0.906
R² = 0.9548
FG, °C
Observed, °C
(e)
observed
ANFIS-GP
(b)
Air temperature, °C
Month
y = 0.9242x + 0.2777
R² = 0.9039
ANFIS-GP, °C
Observed, °C
(f)
observed
ANFIS-SC
(c)
Air temperature, °C
Month
y = 0.9775x + 0.9164
R² = 0.8199
ANFIS-SC, °C
Observed, °C
(g)
observed
ANFIS-FCM
(d)
Air temperature, °C
Month
y = 0.3573x + 8.7953
R² = 0.2526
ANFIS-FCM, °C
Observed, °C
(h)

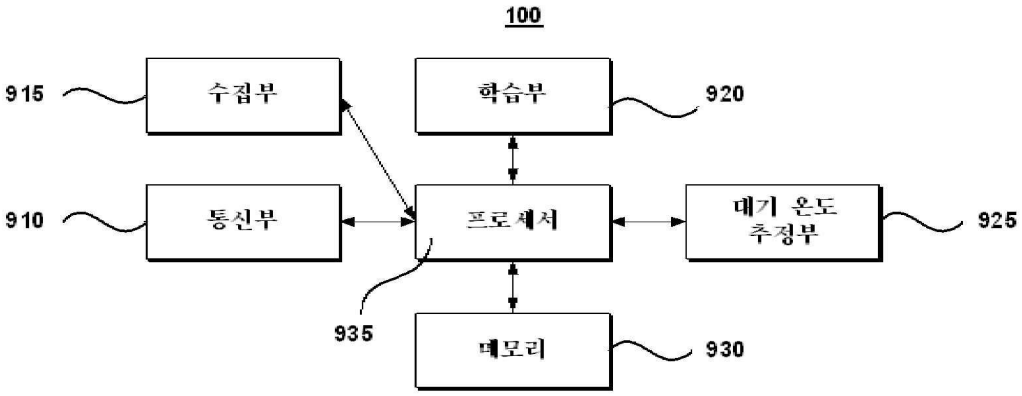
도면7


observed
FG
(a)
Air temperature, °C
Month
y = 0.9485x + 0.7948
R² = 0.9675
(e)
FG, °C
Observed, °C
observed
ANFIS-GP
(b)
y = 0.8999x + 1.6668
R² = 0.9124
(f)
ANFIS-GP, °C
observed
ANFIS-SC
(c)
y = 1.1691x + 0.7279
R² = 0.602
(g)
ANFIS-SC, oC
Observed, oC
observed
ANFIS-FCM
(d)
y = 0.8771x - 4.8499
R² = 0.149
(h)
ANFIS-FCM, °C
Observed, oC

도면8


observed
FG
(a)
Air temperature, °C
Month
y = 0.8772x + 2.5658
R² = 0.8821
FG, °C
Observed, °C
(g)
observed
ANFIS-GP
(b)
y = 0.8618x + 2.7473
R² = 0.878
ANFIS-GP, °C
(f)
observed
ANFIS-SC
(c)
y = 0.9003x + 2.0784
R² = 0.8818
ANFIS-SC, °C
(g)
observed
ANFIS-FCM
(d)
y = 0.5568x + 6.8892
R² = 0.3786
ANFIS-FCM, °C
(h)

도면9


100
915
수집부
학습부
920
910
통신부
프로세서
대기 온도 추정부
925
935
메모리
930