

(12) 특허협력조약에 의하여 공개된 국제출원

(19) 세계지식재산권기구

국제사무국

(43) 국제공개일

2022년 7월 7일 (07.07.2022)



(10) 국제공개번호

WO 2022/145642 A1

(51) 국제특허분류:

H01F 27/40 (2006.01)

H01F 27/12 (2006.01)

G06N 3/08 (2006.01)

G01N 33/28 (2006.01)

(21) 국제출원번호:

PCT/KR2021/013531

(22) 국제출원일:

2021년 10월 1일 (01.10.2021)

(25) 출원언어:

한국어

(26) 공개언어:

한국어

(30) 우선권정보:

10-2020-0187981 2020년 12월 30일 (30.12.2020) KR

10-2021-0124138 2021년 9월 16일 (16.09.2021) KR

(71) 출원인: 서울대학교산학협력단 (SEOUL NATIONAL UNIVERSITY R&DB FOUNDATION) [KR/KR]; 08826 서울시 관악구 관악로 1, Seoul (KR).

(72) 발명자: 김선의 (KIM, Sun Uwe); 08826 서울시 관악구 관악로 1, 313동 214호, Seoul (KR). 윤병동 (YOUN, Byung Dong); 08826 서울시 관악구 관악로 1, 301동 1514호, Seoul (KR). 조수호 (JO, Soo Ho); 08826 서울시 관악구 관악로 1, 313동 324-2호, Seoul (KR). 박종민 (PARK, Jong Min); 08826 서울시 관악구 관악로 1, 313동 214호, Seoul (KR). 김원곤 (KIM, Won Gon); 08826 서울시 관악구 관악로 1, 301동 215호, Seoul (KR).

(74) 대리인: 특허법인 우인 (WOON PATENT & LAW FIRM); 06246 서울시 강남구 역삼로 157, 2층 (역삼동, 중평빌딩), Seoul (KR).


(81) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 국내 권리의 보호를 위하여): AE, AG, AL, AM, AO, AT, AU, AZ, BA, BB, BG, BH, BN, BR, BW, BY, BZ, CA, CH, CL, CN, CO, CR, CU, CZ, DE, DJ, DK, DM, DO, DZ, EC, EE, EG, ES, FI, GB, GD, GE, GH, GM, GT, HN, HR, HU, ID, IL, IN, IR, IS, IT, JO, JP, KE, KG, KH, KN, KP, KW, KZ, LA, LC, LK, LR, LS, LU, LY, MA, MD, ME, MG, MK, MN, MW, MX, MY, MZ, NA, NG, NI, NO, NZ, OM, PA, PE, PG, PH, PL, PT, QA, RO, RS, RU, RW, SA, SC, SD, SE, SG, SK, SL, ST, SV, SY, TH, TJ, TM, TN, TR, TT, TZ, UA, UG, US, UZ, VC, VN, WS, ZA, ZM, ZW.

(84) 지정국 (별도의 표시가 없는 한, 가능한 모든 종류의 국내 권리의 보호를 위하여): ARIPO (BW, GH, GM, KE, LR, LS, MW, MZ, NA, RW, SD, SL, ST, SZ, TZ, UG, ZM, ZW), 유라시아 (AM, AZ, BY, KG, KZ, RU, TJ, TM), 유럽 (AL, AT, BE, BG, CH, CY, CZ, DE, DK, EE, ES, FI, FR, GB, GR, HR, HU, IE, IS, IT, LT, LU, LV, MC, MK, MT, NL, NO, PL, PT, RO, RS, SE, SI, SK, SM, TR), OAPI (BF, BJ, CF, CG, CI, CM, GA, GN, GQ, GW, KM, ML, MR, NE, SN, TD, TG).

(54) Title: TRANSFORMER MALFUNCTION DIAGNOSIS DEVICE AND MALFUNCTION DIAGNOSIS METHOD USING SAME

(54) 발명의 명칭: 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법

100



- 10 ... Data scaling unit
- 12 ... Data logging unit
- 14 ... Data normalization unit
- 20 ... Provisionally labeled data acquisition unit
- 22 ... Transformer state classification unit
- 24 ... Gas composition ratio derivation unit
- 28 ... Provisionally labeled data conversion unit
- 28 ... Prelearning preparation unit
- 30 ... Prelearning unit
- 32 ... Loss function definition unit
- 34 ... Hyper parameter selection unit
- 36 ... First optimum parameter acquisition unit
- 40 ... Relearning unit
- 41 ... Relearning preparation unit
- 42 ... Hidden layer fixing unit
- 43 ... Hidden layer learning unit
- 44 ... Second optimum parameter acquisition unit
- 45 ... Verification unit

(57) Abstract: The present invention provides a transformer malfunction diagnosis device and a malfunction diagnosis method using same, wherein a rule-based learning method is combined with a deep-learning-based learning method based on artificial intelligence. The transformer malfunction diagnosis device according to an embodiment of the present invention comprises: a data scaling unit for scaling dissolved gas analysis data acquired from a transformer; a provisionally labeled data acquisition unit for converting unlabeled data, among the scaled dissolved gas analysis data, to provisionally labeled data and acquiring same; a prelearning unit for performing prelearning for the unlabeled data, among the scaled dissolved gas analysis data, and the provisionally labeled data; and a relearning unit for performing relearning for a labeled data through the transfer of parameters optimized by performing the prelearning.

(57) 요약서: 본 발명은 룰 기반 학습 방법과 인공 지능에 기반한 딥 러닝 기반 학습 방법을 조합하는 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법을 제공한다. 본 발명의 일 실시예에 따른 변압기의 고장 진단 장치는, 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링하는 데이터 스케일링부와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 가표지 데이터 획득부와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 사전 학습부 및 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 재 학습부를 포함하는 것을 특징으로 한다.

[다음 쪽 계속]

공개:

— 국제조사보고서와 함께 (조약 제21조(3))

명세서

발명의 명칭: 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법

기술분야

- [1] 본 발명은 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법에 관한 것으로서, 상세하게는 유중 가스 분석 데이터를 이용하는 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법에 관한 것이다.

배경기술

- [2] 일반적으로, 변전소나 전력회사 등에 설치되는 유입 변압기는 전력공급 시스템 중 하나이며, 전력의 수요와 용량이 계속 증가함에 따라 전력공급 시스템의 매우 중요한 구성 요소 중 하나이고, 높은 신뢰성 유지가 요구된다.
- [3] 이러한 유입 변압기는 운전 중에 열화 등으로 전기적 또는 기계적인 성능이 저하되어 이상이 발생하는 경우가 있는데, 이러한 현상을 사전에 감지하여 적절한 조치를 취하지 않으면 중대한 사고가 발생할 수 있으며, 전력 손실 뿐만 아니라 심각한 경제적 사회적 혼란을 초래할 수 있다.
- [4] 유입 변압기 내부에 절연과괴, 국부과열 등의 이상현상이 발생하면, 반드시 열 발생을 수반하며, 이러한 열 발생원에 접촉한 절연유, 절연지, 프레스 보드 등의 절연재료가 열의 영향을 받아 화학반응에 의해 분해되어 가스들이 발생한다. 이때, 대부분의 가스들은 절연유에 용해되며, 유입 변압기의 절연유를 채취하여 가스를 추출 및 분석하면 유입 변압기의 내부에 발생한 결함 및 그 정도를 진단할 수 있다.
- [5] 이러한 유중 가스 분석(Dissolved Gas Analysis, DGA)을 이용한 유입 변압기의 진단 방법은 매우 복잡한 절차와 노력을 필요로 하지만, 유입 변압기 내부의 결함 진단으로서의 적중률이 높기 때문에 전세계적으로 널리 이용되고 있다.
- [6] 최근 상기 유중 가스 분석을 사용하여 유입 변압기의 고장 모드를 진단하는데 딥 러닝(Deep-Learning) 방식이 연구되고 있다. 이와 같은 연구는 이상적으로 학습 가능한 데이터 세트가 많은 비 지도학습(Unsupervised Learning)을 추가하여 기존의 얕은 학습(Shallow learning) 방식보다 더 정확한 성능을 발휘할 수 있다.
- [7] 하지만 상기 딥 러닝 방식을 이용하는 경우, 상기 유입 변압기의 고장 진단 방법은 방대한 양의 비표지 데이터(Unlabeled Data) 및 희박한 표지 데이터(labeled Data)만 있는 경우에는 다소 신뢰할 수 없는 낮은 진단 성능을 보이고 있다. 이러한 문제를 개선하기 위하여 딥 러닝 방식을 이용하면서 비표지 데이터를 비 지도학습으로 해결하려는 노력이 있지만 여전히 많은 한계와 도전할 부분이 있으며, 이러한 문제를 해결하기 위해 딥 러닝 분야에서는 최근 어렵고 복잡한 모델을 만들기보다는 기존의 방식을 사용하여 딥 러닝 모델의 정확도를 개선하는데 초점을 맞추고 있다.

발명의 상세한 설명

기술적 과제

- [8] 본 발명은 룰 기반 학습 방법과 인공지능에 기반한 딥 러닝 기반 학습 방법을 조합하는 변압기의 고장 진단 장치 및 이를 이용한 고장 진단 방법을 제공하는데 그 목적이 있다.

기술적 해결방법

- [9] 본 발명의 일 실시예에 따른 변압기의 고장 진단 장치는, 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링하는 데이터 스케일링부와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 가표지 데이터 획득부와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 사전 학습부 및 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 재 학습부를 포함하는 것을 특징으로 한다.
- [10] 바람직하게는, 상기 데이터 스케일링부는 상기 유중 가스 분석 데이터를 로그화하는 데이터 로그화부 및 상기 로그화된 유중 가스 분석 데이터를 정규화하는 데이터 정규화부를 포함하는 것을 특징으로 한다.
- [11] 바람직하게는, 상기 가표지 데이터 획득부는 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여 상기 변압기의 정상 상태와 고장 상태를 분류하는 변압기 상태 분류부와, 세 개의 가연성 가스를 선택하여 각각의 가연성 가스의 농도로부터 가스 조성비를 도출하는 가스 조성비 도출부와, 상기 도출된 가스 조성비를 듀발 삼각형 방법에 적용하여 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하는 가표지 데이터 변환부 및 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터를 준비하는 사전 학습 준비부를 포함하는 것을 특징으로 한다.
- [12] 바람직하게는, 상기 세 개의 가연성 가스는, C_2H_2 , C_2H_4 , CH_4 인 것을 특징으로 한다.
- [13] 바람직하게는, 상기 사전 학습부는 딥 뉴럴 네트워크의 손실함수 $L_{DNN}(\theta) = \alpha L_{su}(\hat{Y}_s, \hat{Y}_{end}) + (1 - \alpha) L_{un}(\hat{X}_s^*, \hat{X}_{end}^*)$ 를 정의하는 손실함수 정의부와, 상기 손실함수의 우측항에서의 첫 번째 항(L_{su})과 두 번째 항(L_{un})을 조절하는 하이퍼 파라미터 α 를 선택하는 하이퍼 파라미터 선택부 및 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 제 1 최적 파라미터 획득부를 포함하는 것을 특징으로 한다.
- [14] 바람직하게는, 상기 손실함수에서 L_{su} 는 듀발 삼각형 방법을 통해 획득된

가표지 데이터 $\tilde{Y}_s$ 와 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 가표지 데이터 $\hat{Y}_{end}$ 간의 차이를 나타내는 것을 특징으로 한다.

- [15] 바람직하게는, 상기 손실함수에서 L_{un} 는 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 X_s^* 와 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 유중 가스 분석 데이터 X_{end}^* 간의 차이를 나타내는 것을 특징으로 한다.
- [16] 바람직하게는, 상기 재 학습부는 상기 표지 데이터의 학습을 준비하는 재 학습 준비부와, 상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 은닉층 고정부와, 상기 고정된 은닉층을 제외한 마지막 은닉층에 대해서만 학습을 수행하는 은닉층 학습부 및 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 제 2 최적 파라미터 획득부를 포함하는 것을 특징으로 한다.
- [17] 바람직하게는, 상기 은닉층 고정부는 상기 마지막 은닉층을 제외한 나머지 은닉층을 고정시키는 것을 특징으로 한다.
- [18] 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법은, 상기 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링하는 단계와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 단계와, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 단계 및 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 단계를 포함하는 것을 특징으로 한다.
- [19] 바람직하게는, 상기 유중 가스 분석 데이터를 스케일링하는 단계는, 상기 유중 가스 분석 데이터를 로그화하는 단계 및 상기 로그화된 유중 가스 분석 데이터를 정규화하는 단계를 포함하는 것을 특징으로 한다.
- [20] 바람직하게는, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 단계는, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여 상기 변압기의 정상 상태와 고장 상태를 분류하는 단계와, 세 개의 가연성 가스를 선택하여 각각의 가연성 가스의 농도로부터 가스 조성비를 도출하는 단계와, 상기 도출된 가스 조성비를 듀발 삼각형 방법에 적용하여 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하는 단계 및 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터를 준비하는 단계를 포함하는 것을 특징으로 한다.
- [21]

C_2H_2, C_2H_4, CH_4 인 것을 특징으로 한다.

- [22] 바람직하게는, 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 단계는, 딥 뉴럴 네트워크의 손실함수 $L_{DNN}(\theta) = \alpha L_{su}(\tilde{Y}_s, \hat{Y}_{end}) + (1 - \alpha)L_{un}(X_s^*, \hat{X}_{end}^*)$ 를 정의하는 단계와, 상기 손실함수의 우측항에서의 첫 번째 항(L_{su})과 두 번째 항(L_{un})을 조절하는 하이퍼 파라미터 α 를 선택하는 단계 및 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하는 것을 특징으로 한다.
- [23] 바람직하게는, 상기 손실함수에서, L_{su} 는 듀발 삼각형 방법을 통해 획득된 가표지 데이터 $\tilde{Y}_s$ 와 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 가표지 데이터 $\hat{Y}_{end}$ 간의 차이를 나타내는 것을 특징으로 한다.
- [24] 바람직하게는, 상기 손실함수에서, L_{un} 는 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 X_s^* 와 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 유중 가스 분석 데이터 $\hat{X}_{end}^*$ 간의 차이를 나타내는 것을 특징으로 한다.
- [25] 바람직하게는, 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 단계는, 상기 표지 데이터의 학습을 준비하는 단계와, 상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 단계와, 상기 고정된 은닉층을 제외한 마지막 은닉층에 대해서만 학습을 수행하는 단계 및 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하는 것을 특징으로 한다.
- [26] 바람직하게는, 상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 단계에서, 상기 마지막 은닉층을 제외한 나머지 은닉층을 고정시키는 것을 특징으로 한다.
- 발명의 효과**
- [27] 본 발명의 실시예에 따르면, 표지 데이터가 없는 데이터의 고장 상태를 진단하는 룰 기반 학습 방법의 장점과 인공지능에 기반한 딥 러닝 기반 학습 방법의 장점을 융합함으로써, 다수의 유중 가스 분석 데이터가 있으나 소수의 표지 데이터 밖에 없는 상황에서도 변압기의 고장 진단을 정확하게 수행할 수 있다.
- [28] 또한, 변압기의 고장 진단시 인공지능에 기반한 딥 러닝 기반 학습 방법에만

의존하지 않고 룰 기반 학습 방법을 통해 전문가의 지식을 융합할 수 있으므로 어렵고 복잡한 모델을 개발하지 않고도 딥 러닝 기반 학습 방법의 정확도를 개선할 수 있다.

도면의 간단한 설명

- [29] 도 1은 듀발 삼각형 방법을 이용한 고장 진단 방법을 나타낸 도면이다.
- [30] 도 2는 본 발명의 일 실시예에 따른 변압기의 고장 진단 장치를 나타낸 도면이다.
- [31] 도 3은 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법을 전체적으로 나타낸 도면이다.
- [32] 도 4는 듀발 삼각형 방법을 이용하여 스케일링된 유중 가스 분석 데이터를 가표지 데이터로 변환하는 과정을 나타낸 도면이다.
- [33] 도 5는 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법을 나타낸 흐름도이다.
- [34] 도 6은 종래의 변압기의 고장 진단 방법과 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법의 진단 정확도를 비교하여 나타낸 도면이다.

발명의 실시를 위한 최선의 형태

- [35] 이하, 본 발명의 바람직한 실시예를 첨부된 도면들을 참조하여 상세히 설명한다. 우선 각 도면의 구성 요소들에 참조 부호를 부가함에 있어서, 동일한 구성 요소들에 대해서는 비록 다른 도면상에 표시되더라도 가능한 한 동일한 부호를 가지도록 하고 있음에 유의해야 한다. 또한, 본 발명을 설명함에 있어, 관련된 공지 구성 또는 기능에 대한 구체적인 설명이 본 발명의 요지를 흐릴 수 있다고 판단되는 경우에는 그 상세한 설명은 생략한다. 또한, 이하에서 본 발명의 바람직한 실시예를 설명할 것이나, 본 발명의 기술적 사상은 이에 한정하거나 제한되지 않고 당업자에 의해 변형되어 다양하게 실시될 수 있음은 물론이다.
- [36] 도 1은 듀발 삼각형 방법을 이용한 고장 진단 방법을 나타낸 도면이다.
- [37] 유중 가스 분석(DGA) 데이터를 이용한 유입식 변압기의 고장 유형(예시적으로, 열, 전기 및 부분 방전 등)을 진단하는 변압기의 고장 진단 방법은 크게 룰 기반 학습(Rule-Based Learning) 방법과 인공 지능 기반 학습(AI-Based Learning) 방법의 두 가지 방법으로 구분될 수 있다.
- [38] 먼저 룰 기반 학습이란 주어진 입력에 대해서 결과값을 도출하는 방법으로서, 확고한 규칙(rule)에 따라 학습 및 예측을 하는 방법을 의미한다. 또한 룰 기반 학습은 전술한 유중 가스 분석(DGA) 데이터를 활용하여 전문가의 물리적 지식과 경험을 통해 이루어진 특징(handcrafted feature)을 기반으로 이루어질 수 있다.
- [39] 도 1을 참조하면, 룰 기반 학습 방법 중 하나인 듀발 삼각형(Duval's Triangle) 방법에서는 세 가지 가연성 가스인 C_2H_2 , C_2H_4 , CH_4 의 농도로부터 가스

조성비(gas ratio)를 도출할 수 있다.

- [40] 이 때, 세 가지 가연성 가스인 C_2H_2 , C_2H_4 , CH_4 의 농도로부터

도출되는 각각의 가스 조성비는 하기 수학적 식 1과 같이 표현할 수 있다.

- [41] [수식1]

$$R_i = \text{Gas}_i / \sum_{i=1}^3 \text{Gas}_i, \text{ where } \text{Gas}_i \in \{C_2H_2, C_2H_4, CH_4\}$$

- [42] 상기 듀발 삼각형 방법에서는 상기 수학적 식 1을 통해 도출된 가스 조성비(예 : R1, R2, R3)를 이용하여 예시적으로 변압기의 고장 유형(Fault identification)을 부분 방전(Partial Discharge, PD), 낮은 수준의 전기적 고장(Discharge of low-energy arcing, D1), 높은 수준의 전기적 고장(Discharge of high-energy arcing, D2), 낮은 수준의 열적 고장(T1, 온도 300°C 미만의 경우), 중간 수준의 열적 고장(T2, 온도 300°C 초과 700°C 미만의 경우), 높은 수준의 열적 고장(T3, 온도 700°C 초과) 및 전기적 고장과 열적 고장(Thermal and discharge faults, DT)의 7가지로 나타낼 수 있다.

- [43] 전술한 바와 같은 고장 유형을 기반으로 한 고장 진단 결과는 도 1에 도시된 바와 같이 상기 수학적 식 1을 통해 도출된 가스 조성비(R1, R2, R3)의 측면에서 듀발 삼각형의 좌표평면에 직관적으로 묘사될 수 있다.

- [44] 그러나, 이와 같은 듀발 삼각형 방법의 경우 사람의 경험에 기반한 특징(features based on human experience)을 이용한 것으로서, 충분한 수학적 공식(mathematical formulation)과 통계적 접근법(statistical approach)에 근거한 인공지능 기반 학습의 고장 진단 능력보다는 떨어질 수 있다.

- [45] 상세하게는, 도 1에 나타난 듀발 삼각형 방법의 경우 학습 데이터(training data) 또는 최적화 프로세스에 대한 요구가 없기 때문에 계산 작업이 많이 요구되지 않으며, 표지가 지정되지 않은(unlabeled) 유증 가스 분석 데이터의 오류 상태를 용이하게 식별할 수 있는 장점이 있다. 그러나, 듀발 삼각형 방법의 경우 수학적 공식이 다수 결합되어 있으며, 전체적인 모델에 있어서 사람의 경험적 방법을 기반으로 하므로 인공지능 기반 학습 방법에 비해 상대적으로 정확도가 낮고 불완전한 진단 결과를 나타낼 수 있다.

- [46] 한편, 인공지능 기반(AI-based) 학습 방법은 딥 러닝(deep-learning) 기반 학습 방법을 포함하며, 딥 러닝 기반 학습 방법의 변압기의 고장 진단 방법에서는 예시적으로 딥 뉴럴 네트워크(Deep Neural Network, DNN)를 이용할 수 있다.

- [47] 딥 뉴럴 네트워크(DNN)는 복수의 노드(node) 및 노드 내에서 입력 반응(input response) 및 출력 반응(output response)을 연관짓는 활성화 함수(activation function)로 구성되는 여러 개의 층이 쌓인 은닉층(hidden layer)이 있는 신경망(neural network)을 의미할 수 있다. 바람직하게는, 상기 딥 뉴럴 네트워크(DNN)에서 은닉층들이 쌓인 깊이가 깊을수록 상기 입력 반응과 출력

반응은 좀 더 고차원적인 특징을 추출할 수 있다.

[48] 딥 뉴럴 네트워크(DNN)에서 학습 데이터(training data)의 샘플(sample)은

$$\{(\mathbf{x}^{(1)}, \mathbf{y}^{(1)}), \dots, (\mathbf{x}^{(p)}, \mathbf{y}^{(p)})\}$$

와 같이 나타낼 수 있다. 이 때, p 는 유중 가스 분석 데이터의 샘플 수를 나타내며,

$$\mathbf{x}^{(m)}$$

은 입력 유중 가스 분석 데이터(입력 반응)를 나타내고,

$$\mathbf{y}^{(m)}$$

은 상기 딥 뉴럴 네트워크(DNN)가 학습할 수 있도록 원-핫 인코딩(one-hot encoded)된 정보(출력 반응)를 나타낼 수 있다. 이 때, 상기 원-핫 인코딩 방법은 딥 러닝 기반 학습 방법에서 딥 러닝을 위해 텍스트(문자)를 유의미한 숫자(또는 벡터)로 변환하는 것을 의미한다.

[49] 활성화 함수(f)는 소프트맥스 함수(softmax function)일 수 있으며, 하기 수학식 2와 같이 상기

$$\mathbf{x}^{(m)}$$

를 파라미터

$$\theta$$

(예시적으로 하기 수학식 2에서와 같이 $\mathbf{W}$ 와 $\mathbf{b}$ 를 포함)를 이용하여 활성화된 유중 가스 분석 데이터인

$$\mathbf{z}^{(m)}$$

으로 선형화하고, 선형화된

$$\mathbf{z}^{(m)}$$

을 은닉 유닛(hidden unit)인

$$\mathbf{h}^{(m)}$$

으로 변환할 수 있다.

[50] [수식2]

$$\mathbf{h}^{(m)} = f(\mathbf{z}^{(m)}) = f(\mathbf{W}\mathbf{x}^{(m)} + \mathbf{b})$$

[51] 상기 수학식 2에서 $\mathbf{W}$ 는 선형 경계의 방향성 또는 형태를 나타내는 가중치이며, $\mathbf{b}$ 는 선형 경계의 절편을 나타내는 바이어스 벡터(bias vector)를 의미할 수 있다.

[52] 한편, 딥 뉴럴 네트워크(DNN)에서는 하기 수학식 3과 같이

$$\mathbf{x}^{(m)}$$

와

$$\mathbf{y}^{(m)}$$

가 서로 연관될 수 있다.

[53] [수식3]

$$\hat{\mathbf{y}}_{\text{end}}^{(m)} = q_{\text{sm}} \left(\mathbf{W}_N f_{N-1} \left(\cdots f_{N-1} \left(\mathbf{W}_1 \mathbf{x}^{(m)} + \mathbf{b}_1 \right) \cdots \right) + \mathbf{b}_N \right)$$

[54] 상기 수학식 3에서

$$q_{\text{sm}}$$

은 딥 뉴럴 네트워크(DNN)의 은닉층 중 마지막 층에 놓이는 소프트맥스 함수(softmax function)를 의미할 수 있으며, 상기 수학식 2에서의

$$\mathbf{h}^{(m)}$$

은

$$\mathbf{y}^{(m)}$$

의 확률 정보를 포함하는 원-핫 인코딩된 벡터

$$\hat{\mathbf{y}}^{(m)}$$

로 변환될 수 있다. 이 때, 상기 수학식 3에서

$$\hat{\mathbf{y}}_{\text{end}}^{(m)}$$

은 딥 뉴럴 네트워크(DNN)가 N개의 은닉층을 가질 때 마지막 은닉층에서의 인코딩된 벡터 값을 의미할 수 있다.

[55] 한편, 상기 수학식 3에서

$$q_{\text{sm}}$$

은 하기 수학식 4와 같이 나타날 수 있다.

[56] [수식4]

$$q_{\text{sm}}\left(\mathbf{z}_n^{(m)}\right)=\exp\left(\mathbf{z}_n^{(m)}\right) / \sum_{n=1}^C \exp\left(\mathbf{z}_n^{(m)}\right)$$

[57]

$$\hat{\mathbf{y}}_{\text{end}}^{(m)}$$

과

$$\hat{\mathbf{y}}^{(m)}$$

을 연관짓기 위하여 파라미터

$$\boldsymbol{\theta}$$

는, 손실함수(loss function)를 최소화함으로써 최적화될 필요가 있는데, 이러한 손실함수는 하기 수학식 5와 같이 나타낼 수 있다.

[58] [수식5]

$$L\left(\mathbf{y}, \hat{\mathbf{y}}_{\text{end}}\right)=-\frac{1}{p} \sum_{m=1}^p \mathbf{y}^{(m)} \log \left(\hat{\mathbf{y}}_{\text{end}}^{(m)}\right)$$

[59] 상기 수학식 5에서 손실함수 L은,

$$\mathbf{y}$$

와

$$\hat{\mathbf{y}}_{\text{end}}$$

간의 차이를 의미할 수 있다.

[60] 또한, 수학식 5를 최적화하기 위해 하기 수학식 6과 같이

역전파(Backpropagation) 방법을 사용하여 최적의 파라미터들을 획득할 수 있다.

바람직하게는 상기 역전파 방법은 MGD 알고리즘(Mini-Batch Gradient Descent Algorithm)에 의해 수행될 수 있다.

[61] [수식6]

$$\theta_{nj}^N \leftarrow \theta_{nj}^N - \eta \frac{\partial L^{(m)}}{\partial \theta_{nj}^N} \left(\frac{\partial L^{(m)}}{\partial \theta_{nj}^N} = \delta_n^L \frac{\partial z_n^{(m)}}{\partial \theta_{nj}^N} = \delta_n^L h_j^{(m)} \right)$$

[62] 상기 수학식 6에서,

$$\boldsymbol{\theta}^N$$

은 최적화된 파라미터를 의미하며,

η

은 학습률(learning rate)을 의미할 수 있다. 또한,

 θ^N

은 딥 뉴럴 네트워크(DNN)의 은닉층 중 마지막 은닉층에서의 파라미터를 의미할 수 있다.

- [63] 이와 같은 과정을 통해 딥 뉴럴 네트워크(DNN)에서는 입력 유증 가스 분석 데이터와 출력 정보를 연관지을 수 있다.
- [64] 그러나, 전술한 딥 뉴럴 네트워크(DNN)를 포함하는 딥 러닝 방식의 경우 학습 데이터(training data)와 테스트 데이터(test data)가 동일한 분포에서 추출된다는 일반적인 가정하에서 잘 작동하나, 실제 변압기 고장 진단 환경에서는 데이터 수집 관점에서 막대한 유지 보수 비용으로 인해 고장 데이터 또는 표지 데이터(labeled data)가 매우 부족하여 딥 러닝 방식이 잘 작동하지 않는 문제가 있다.
- [65] 이러한 문제를 해결하기 위하여 전이 학습(transfer learning)을 이용할 수 있으며, 전이 학습은 주어진 데이터가 충분하지 않은 상황에서도 적용할 수 있어 변압기의 고장 진단 관련 분야에서 최근 각광받고 있다.
- [66] 바람직하게는, 상기 전이 학습은 소스 데이터(source data)인 비표지 데이터(unlabeled data)로부터 얻은 정보(예를 들어 최적화된 파라미터 등)를 타겟 데이터(target data)인 표지 데이터로 전송하는 것을 의미할 수 있다. 이 때, 상기 비표지 데이터에서의 학습 모델을 사전 학습(Pre-trained) 모델, 상기 표지 데이터에서의 학습 모델을 재 학습(re-trained) 모델이라고 정의할 수 있다.
- [67] 또한, 전이 학습은 사전 학습된 모델을 재사용하여 상기 표지 데이터가 포함된 타겟 도메인(target domain)에서 고장 진단 성능을 크게 향상시킬 수 있으며, 상기 표지 데이터의 크기에 따라 완전 고정(freezing), 부분 고정(partial freezing), 미세 조정(fine-tuning) 및 선택적 파라미터 고정 방법(selective parameter freezing) 등이 있고, 바람직하게는 상기 비표지 데이터의 양이 상기 표지 데이터에 비해 매우 많을 경우 주로 완전 고정 방식이 이용될 수 있다.
- [68] 이하에서는, 전술한 룰 기반 학습 방법과 인공지능 기반 학습 방법을 조합하여 변압기의 고장 진단을 수행하는 것에 대해 상세히 설명하도록 한다.
- [69] 도 2는 본 발명의 일 실시예에 따른 변압기의 고장 진단 장치(100)를 나타낸 도면이고, 도 3은 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법을 전체적으로 나타낸 도면이다.
- [70] 도 2를 참조하면, 고장 진단 장치(100)는 데이터 스케일링부(10), 가표지 데이터 획득부(20), 사전 학습부(30) 및 재 학습부(40)를 포함한다.
- [71] 본 발명의 실시예에서, 데이터 스케일링부(10) 및 가표지 데이터 획득부(20)는 룰 기반 학습 방법에 따라 변압기의 고장 진단을 수행할 수 있으며, 사전 학습부(30) 및 재 학습부(40)는 인공지능 기반 학습 방법에 따라 변압기의 고장

진단을 수행할 수 있다.

- [72] 도 2 및 도 3을 참조하면 데이터 스케일링부(10)는, 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링(scaling)할 수 있다. 바람직하게는 유중 가스 분석 데이터는 전술한 비표지 데이터와 표지 데이터를 포함하며, 도 3에서 변압기로부터 획득되는 유중 가스 분석 데이터는

X

와 같이 표기될 수 있고, 스케일링된(스케일 변환된) 유중 가스 분석 데이터는

X^*

와 같이 표기될 수 있다.

- [73] 바람직하게는, 데이터 스케일링부(10)는 데이터 로그화부(12) 및 데이터 정규화부(14)로 구성될 수 있다.

- [74] 먼저 데이터 로그화부(12)는 도 3에 도시된 바와 같이 유중 가스 분석 데이터를 로그(log)화할 수 있다. 일반적으로 유중 가스 분석 데이터의 물리적 단위는 ppm일 수 있는데, 데이터 로그화부(12)를 통해 유중 가스 분석 데이터를 로그화하는 것은 변압기의 고장 발생시 유중 가스 분석 데이터의 값이 튀는(overshooting) 것을 최소화하기 위함이다.

- [75] 다음으로 데이터 정규화부(14)는, 상기 로그화된 유중 가스 분석 데이터를 정규화할 수 있다(예시적으로 [0, 1]의 범위 내에서 정규화할 수 있다).

- [76] 이에 따라, 사전 학습부(30) 및 재 학습부(40)에 의해 이루어지는 인공 지능 기반 학습시 파라미터의 최적화가 안정적으로 이루어질 수 있으며, 인공 지능 기반 학습에 의한 연산이 빠르게 이루어질 수 있다.

- [77] 상기 데이터 스케일링부(10)를 통한 유중 가스 분석 데이터의 로그화 및 정규화 과정은 예시적으로 하기 수학식 7과 같이 나타낼 수 있다. 하기 수학식 7은 예시적으로 유중 가스 분석 데이터 중 비표지 데이터를 로그화 및 정규화하는 과정을 나타낸 것이다.

- [78] [수식7]

$$X \rightarrow \log(X) \rightarrow \text{MimMax}(\log(X)) \rightarrow X_s^*$$

- [79] 도 4는 듀발 삼각형 방법을 이용하여 스케일링된 유중 가스 분석 데이터

X^*

를 가표지 데이터(pseudo label data)로 변환하는 과정을 나타낸 도면이다.

바람직하게는, 스케일링된 유중 가스 분석 데이터 중 비표지 데이터가 가표지 데이터로 변환되는 과정은 듀발 삼각형 방법의 얇은 지도 학습(shallow supervision learning)을 통해 이루어질 수 있다.

- [80] 도 2 내지 도 4를 참조하면, 가표지 데이터 획득부(20)는 듀발 삼각형 방법을 이용하여 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지

데이터(pseudo label data)로 변환하여 획득할 수 있다.

[81] 바람직하게는, 가표지 데이터 획득부(20)는 변압기 상태 분류부(22), 가스 조성비 도출부(24), 가표지 데이터 획득부(26) 및 사전 학습 준비부(28)로 구성될 수 있다.

[82] 먼저, 변압기 상태 분류부(22)는, 물 기반 학습 방법에 따라 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여 변압기의 정상 상태와 고장 상태를 분류(classification)할 수 있다.

[83] 이 때, 변압기의 정상 상태와 고장 상태는 하기 표 1에 나타난 각 가연성 가스의 정상 기준값(normal threshold)을 기반으로 분류될 수 있다.

[84] [표1]

가스	H_2	C_2H_2	C_2H_4	C_2H_6	CH_4
기준값(ppm)	60~150	3~50	60~280	50~90	40~110

[85] 다음으로, 가스 조성비 도출부(24)는, 전술한 수학적 식 1과 같이 세 가지 가연성 가스 C_2H_2 , C_2H_4 , CH_4 를 선택하여 C_2H_2 , C_2H_4 , CH_4 의

농도로부터 가스 조성비를 도출할 수 있다.

[86] 다음으로, 가표지 데이터 변환부(26)는, 도출된 가스 조성비의 샘플 데이터를 도 1 및 도 3에 나타난 바와 같이 듀발 삼각형 방법에 적용하여 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터(pseudo label data)로 변환할 수 있다. 예시적으로 듀발 삼각형 방법을 통해 변환된 가표지 데이터는 [1,0,0,0,0]과 같이 획득될 수 있다.

[87] 마지막으로, 사전 학습 준비부(28)는, 도 3 및 도 4에 나타난 바와 같이 전술한 사전 학습부(30)가 학습할 학습 데이터(training data)로 이용될 $\mathbf{X}_s^*$ 와 $\tilde{\mathbf{Y}}_s$ 를

준비할 수 있다. 이 때, 상기 $\mathbf{X}_s^*$ 와 $\tilde{\mathbf{Y}}_s$ 는 각각 스케일링된 유중 가스 분석

데이터 중 비표지 데이터 및 이에 대응되는 가표지 데이터를 의미할 수 있다.

[88] 도 2 및 도 3을 참조하면, 사전 학습부(30)는 보조적인 비지도 기반(auxiliary unsupervised-based)의 정규화(regularization) 과정을 통해 딥 뉴럴 네트워크(DNN)를 사전 학습할 수 있다. 이 때, 사전 학습부(30)를 통해 이루어지는 학습 과정은 지도 학습(supervised learning)에서의 손실함수 L_{su} 를

최소화할 수 있도록 파라미터를 업데이트하는 것으로 간주될 수 있다.

[89] 바람직하게는, 사전 학습부(30)는 손실함수 정의부(32), 하이퍼 파라미터 선택부(34) 및 제 1 최적 파라미터 획득부(36)로 구성될 수 있다.

- [90] 먼저, 손실함수 정의부(32)는, 전술한 수학식 5에 나타난 손실함수를 하기 수학식 8과 같이 변환하여 정의할 수 있다. 이 때, $L_{\text{DNN}}(\theta)$ 는 상기 딥 뉴럴

네트워크(DNN)를 학습하는 과정에서 고려되는 손실함수일 수 있으며, 하기 수학식 8과 같이 정의될 수 있다.

- [91] [수식8]

$$L_{\text{DNN}}(\theta) = \alpha L_{\text{su}}(\tilde{\mathbf{Y}}_s, \hat{\mathbf{Y}}_{\text{end}}) + (1 - \alpha) L_{\text{un}}(\mathbf{X}_s^*, \hat{\mathbf{X}}_{\text{end}}^*)$$

- [92] 이 때, 상기 수학식 8에서

L_{su}

는 가표지 데이터 획득부(20)를 통한 지도 학습에서 듀발 삼각형 방법을 통해 획득된 가표지 데이터

$\tilde{\mathbf{Y}}_s$

와 딥 뉴럴 네트워크(DNN)의 은닉층 중 마지막 층에서의 추정된(estimated) 가표지 데이터

$\hat{\mathbf{Y}}_{\text{end}}$

간의 차이를 나타내는 손실함수일 수 있다.

- [93] 또한,

L_{un}

는 비 지도 학습(unsupervised learning)에서 스케일링된 유중 가스 분석 데이터 중 비표지 데이터

$\mathbf{X}_s^*$

와 딥 뉴럴 네트워크(DNN)의 은닉층 중 마지막 층에서의 추정된(estimated) 유중 가스 분석 데이터

$\hat{\mathbf{X}}_{\text{end}}^*$

간의 차이를 나타내는 손실함수일 수 있다. 바람직하게는,

L_{un}

은 지도 학습(supervised learning)의 과적합(overfitting) 문제를 최소화하기 위한 정규화(regularization) 과정으로서 수행될 수 있다.

- [94] 또한,

α

는

L_{su}

와

 L_{un}

사이의 가중치인, 하이퍼 파라미터(hyper parameter)를 의미하며, 바람직하게는 0 ~ 1 사이의 값으로 이루어질 수 있다.

- [95] 상기 수학식 8의 우측항에서 첫 번째 항은 수학식 5에서의 손실함수와 마찬가지로 지도 학습(supervised learning)의 목적으로서 포함될 수 있으나, 두 번째 항의 경우에는 입력값 X(유중 가스 분석 데이터 중 비표지 데이터)를 재 학습하는 것을 의미할 수 있다. 이에 따라 사전 학습부(30)는 가표지 데이터 획득부(20)에서 잘못 획득된 가표지 데이터

 $\tilde{Y}_s$

를 이용하는 경우에도 입력값 X(유중 가스 분석 데이터 중 비표지 데이터)의 재 학습을 통해 이를 보완할 수 있다.

- [96] 다음으로, 하이퍼 파라미터 선택부(34)는, 상기 수학식 8의 우측항에서의 첫 번째 항(

 L_{su}

)과 두 번째 항(

 L_{un}

)을 조절하는 하이퍼 파라미터

 α

를 선택할 수 있다.

- [97] 마지막으로, 제 1 최적 파라미터 획득부(36)는, 상기 수학식 8을 최적화하기 위해 하기 수학식 9와 같이 역전파 방법을 사용하여 최적의 파라미터들을 획득할 수 있다.

- [98] [수식9]

$$\theta_{nj} \leftarrow \theta_{nj} - \eta \frac{\partial L_{DNN}^{(m)}}{\partial \theta_{nj}},$$

$$\left(\frac{\partial L_{DNN}^{(m)}}{\partial \theta_{nj}} = \alpha \delta_n^{su} h_j^{(m)} + (1 - \alpha) \delta_n^{un} h_j^{(m)} \right)$$

- [99] 상기 수학식 9에서,

 δ_n^{su}

및

$$\delta_n^{\text{su}}$$

은 각각 하기 수식 10과 같이 나타낼 수 있다.

[100] [수식 10]

$$\delta_n^{\text{su}} \equiv \frac{\partial L_{\text{su}}^{(m)}}{\partial z_n^{(m)}} = f_{\text{su}}' \left(z_n^{(m)} \right) \frac{\partial L_{\text{su}}^{(m)}}{\partial \hat{Y}_{\text{end}}^{(m)}},$$

$$\delta_n^{\text{un}} \equiv \frac{\partial L_{\text{un}}^{(m)}}{\partial z_n^{(m)}} = f_{\text{un}}' \left(z_n^{(m)} \right) \frac{\partial L_{\text{un}}^{(m)}}{\partial \hat{X}_{\text{end}}^{*(m)}}$$

[101] 도 2 및 도 3을 참조하면, 재 학습부(40)는 사전 학습부(30)에서 사전 학습된 데이터에 대해 딥 뉴럴 네트워크(DNN)의 파라미터 전이(parameter transfer)를 통해 재 학습을 수행할 수 있다.

[102] 바람직하게는, 재 학습부(40)는 재 학습 준비부(41), 은닉층 고정부(42), 은닉층 학습부(43), 제 2 최적 파라미터 획득부(44) 및 검증부(45)로 구성될 수 있다.

[103] 먼저 재 학습 준비부(41)는, 표지 데이터

$$\mathbf{X}_t^*$$

와

$$\mathbf{Y}_t$$

의 학습을 준비할 수 있다.

[104] 바람직하게는,

$$\mathbf{X}_t^*$$

와

$$\mathbf{Y}_t$$

는 각각 스케일링된 유증 가스 분석 데이터 중 표지 데이터 및 이에 대응되는 실제 고장 상태를 나타내는 값을 의미할 수 있다.

[105] 다음으로, 은닉층 고정부(42)는, 딥 뉴럴 네트워크(DNN)의 일부 은닉층을 고정(freezing)할 수 있다.

[106] 전술한 바와 같이 전이 학습은 비표지 데이터의 양이 표지 데이터에 비해 매우 많을 경우 완전 고정 방식이 이용될 수 있다.

[107] 상기 은닉층 고정부(42)에서는 표지 데이터의 양이 비표지 데이터의 양보다 매우 적다고 가정하고, 완전 고정 방식에 따라 전이 학습을 수행할 수 있다. 이

경우, 은닉층 고정부(42)를 통해 마지막 은닉층을 제외한 나머지 모든 은닉층에서의 파라미터가 고정될(frozen) 수 있다.

[108] 이 때, 은닉층 고정부(42)에 의해 고정되는 파라미터는 상기 사전 학습부(30)를 통해 최적화된 파라미터 중 비 지도 학습을 통해 최적화된 파라미터일 수 있다.

[109] 은닉층 고정부(42)는 하기 수학식 11과 같이 마지막 은닉층을 제외한 나머지 은닉층을 고정시킬 수 있으며, 고정되지 않는 마지막 은닉층에 관한 파라미터는 상기 사전 학습부(30)를 통해 최적화된 파라미터 중 지도 학습을 통해 최적화된 파라미터일 수 있다.

[110] [수식11]

$$\frac{\partial L_{DNN}}{\partial \theta^m} = \begin{cases} \frac{\partial L_{DNN}}{\partial \theta^m}, & m=N \text{ \& Supervised task (Re-training)} \\ 0, & \text{otherwise (Freezing)} \end{cases}$$

[111] 상기 수학식 11에서, m은 N번째 은닉층을 나타내며, N은 전체 은닉층의 수를 의미한다.

[112] 다음으로, 은닉층 학습부(43)는, 전술한 수학식 8에 따라 학습을 수행하되 고정된 은닉층은 학습하지 않고, 마지막 은닉층에 대해서만 학습(재 학습)을 수행할 수 있다.

[113] 다음으로, 제 2 최적 파라미터 획득부(44)는 전술한 수학식 8 내지 10을 다시 이용하여 지도 학습(supervised learning)에서의 파라미터들을 다시 최적화함에 따라 최적의 파라미터를 획득할 수 있다. 이 때, 전술한 수학식 8에서의 손실함수는

$$\mathbf{X}_t^*$$

및

$$\mathbf{Y}_t$$

로 구성될 수 있다.

[114] 마지막으로, 검증부(45)는 전술한 방법을 통해 도출된 학습 모델에 표지 데이터(

$$\mathbf{X}_t^*$$

,

$$\mathbf{Y}_t$$

)를 가지고 테스트하여 그 정확도를 검증할 수 있다.

[115] 도 5는 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법을 나타낸 흐름도이다.

[116] 도 5를 참조하면, 본 발명의 일 실시예에 따른 변압기 고장 진단 방법은 아래와

같다.

[117] 먼저, 변압기로부터 획득되는 유중 가스 분석 데이터

$$X$$

를 스케일링 한다(S1 단계).

[118] 상기 S1 단계는, 유중 가스 분석 데이터를 로그화하는 단계 및 로그화된 유중 가스 분석 데이터를 정규화하는 단계를 포함하며, S1 단계는 전술한 데이터 스케일링부(10)에 의해 수행될 수 있다.

[119] 다음으로, 상기 S1 단계에서 스케일링된 유중 가스 분석 데이터

$$X^*$$

중 비표지 데이터

$$X_s^*$$

를 가표지 데이터

$$\tilde{Y}_s$$

로 변환하여 획득한다(S2 단계).

[120] 상기 S2 단계는, 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여 상기 변압기의 정상 상태와 고장 상태를 분류하는 단계와, 세 개의 가연성 가스를 선택하여 각각의 가연성 가스의 농도로부터 가스 조성비를 도출하는 단계와, 도출된 가스 조성비를 듀발 삼각형 방법에 적용하여 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하는 단계 및 스케일링된 유중 가스 분석 데이터 중 비표지 데이터

$$X_s^*$$

및 가표지 데이터

$$\tilde{Y}_s$$

를 준비하는 단계를 포함하며, S2 단계는 전술한 가표지 데이터 획득부(20)에 의해 수행될 수 있다. 바람직하게는, 가표지 데이터 획득부(20)에 의해 선택되는 세 개의 가연성 가스는

$$C_2H_2$$

,

$$C_2H_4$$

,

$$CH_4$$

일 수 있다.

[121] 다음으로, 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 가표지 데이터에 대해 사전 학습을 수행한다(S3 단계).

[122] 상기 S3 단계는, 딥 뉴럴 네트워크(DNN)의 손실함수

$$L_{\text{DNN}}(\theta) = \alpha L_{\text{su}}(\tilde{\mathbf{Y}}_s, \hat{\mathbf{Y}}_{\text{end}}) + (1 - \alpha) L_{\text{un}}(\mathbf{X}_s^*, \hat{\mathbf{X}}_{\text{end}}^*)$$

를 정의하는 단계와, 손실함수의 우측항에서의 첫 번째 항(L_{su})과 두 번째 항(L_{un})을 조절하는 하이퍼 파라미터 α

L_{su}

)과 두 번째 항(L_{un})을 조절하는 하이퍼 파라미터 α

L_{un}

)을 조절하는 하이퍼 파라미터 α

α

를 선택하는 단계 및 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하며, S3 단계는 전술한 사전 학습부(30)에 의해 수행될 수 있다.

[123] 바람직하게는, 상기 사전 학습을 수행하는 단계는 복수 회(예 : 200회) 수행될 수 있다.

[124] 마지막으로, 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행한다(S4 단계).

[125] 상기 S4 단계는, 표지 데이터($\mathbf{X}_t^*$ 와 $\mathbf{Y}_t$)의 학습을 준비하는 단계와, 딥 뉴럴 네트워크(DNN)의 일부 은닉층을 고정하는 단계와, 고정된 은닉층을 제외하고 마지막 은닉층에 대해서만 학습을 수행하는 단계 및 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하며, S4 단계는 전술한 재 학습부(40)에 의해 수행될 수 있다.

$\mathbf{X}_t^*$

와

$\mathbf{Y}_t$

)의 학습을 준비하는 단계와, 딥 뉴럴 네트워크(DNN)의 일부 은닉층을 고정하는 단계와, 고정된 은닉층을 제외하고 마지막 은닉층에 대해서만 학습을 수행하는 단계 및 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하며, S4 단계는 전술한 재 학습부(40)에 의해 수행될 수 있다.

[126] 이 때, 딥 뉴럴 네트워크(DNN)의 일부 은닉층을 고정하는 단계에서, 마지막 은닉층을 제외한 나머지 은닉층은 모두 고정될 수 있으며, 상기 재 학습을 수행하는 단계는 복수 회(예 : 20회) 수행될 수 있다.

[127] 도 6은 종래의 변압기의 고장 진단 방법과 본 발명의 일 실시예에 따른 변압기의 고장 진단 방법의 진단 정확도를 비교하여 나타낸 도면이다.

[128] 도 6을 참조하면, 본 발명의 실시예에 따른 변압기의 고장 진단 방법을 표지가 지정된(labeled) 학습 데이터(training data)의 양과 관련하여 종래의 변압기의

고장 진단 방법과 비교한 변압기 고장 진단의 정확도 결과를 요약하여 나타낸 결과를 표로 확인할 수 있다.

- [129] 이 때, 도 6에서 첫 번째 학습 관점(learning approach)은 표지가 지정된 데이터로만 학습하는 지도 학습(supervised learning)의 경우를 나타내며, 두 번째 학습 관점은 표지가 지정된 표지 데이터와 비표지 데이터를 모두 학습하는 반지도 학습(semi-supervised learning)의 경우를 나타내고, 세 번째 학습 관점은 룰 기반 방법과 인공지능 기반 방법을 이용하는 변압기의 고장 진단 방법(rule-based knowledge learning)을 나타낸다.
- [130] 또한, 도 6에서 L-SVM은 선형 서포트 벡터 머신(linear support vector machine)을 의미하고, R-SVM은 방사형 기저 함수(radial basis function)를 가지는 서포트 벡터 머신(support vector machine)을 의미하며, KNN은 K-최근접 이웃 알고리즘(K-nearest neighbors algorithm)을 의미하고, 1-NN은 하나의 은닉층을 가지는 뉴럴 네트워크(neural network)를 의미하며, DeA는 딥 오토인코더(deep autoencoder)를 의미한다. 전술한, L-SVM, R-SVM, KNN, 1-NN 및 DeA은 대표적인 인공지능 기반 분석 방법이므로 이에 대한 자세한 설명은 생략하도록 한다.
- [131] 한편, 도 6의 세 번째 학습 관점에서 딥 뉴럴 네트워크(DNN)를 이용한 진단 방법은

$$DNN_{FT}^{Non}$$

,

$$DNN_{PF}^{Non}$$

,

$$DNN_{FT}^{Aux}$$

및 BDD로 나타낼 수 있다. 이 때, "Non"은 전술한 사전 학습부(30)를 통한 보조적인 비 지도 학습이 이루어지지 않는 것을 의미하며, "Aux"는 사전 학습부(30)를 통한 보조적인 비 지도 학습이 이루어지는 것을 의미한다. 또한, "PF"는 전술한 재 학습부(40)를 통한 파라미터 고정(parameter freezing)이 이루어지는 것을 의미하며, "FT"는 미세 조정(fine tuning)이 이루어지는 것을 의미하고, "BDD"는 듀발 삼각형 방법과 딥 뉴럴 네트워크 방법을 조합(bridging duval's triangle method and deep neural network)하는 본 발명의 실시예에 따른 변압기의 고장 진단 방법을 나타낸다.

- [132] 도 6을 참조하면, 모든 진단 방법에서 표지가 지정된 학습 데이터의 양이 증가함에 따라 변압기의 고장 진단 정확도가 증가하는 것을 확인할 수 있다.
- [133] 이 때, 본 발명의 실시예와 같이 룰 기반 방법과 딥 러닝 기반 방법을 조합한 본 발명의 실시예에 따른 변압기의 고장 진단 방법(BDD)이 표지가 지정된 학습

데이터의 양에 관계없이 다른 진단 방법에 비해 가장 높은 고장 진단 정확도를 달성하는 것을 확인할 수 있다.

[134] 특히, 본 발명의 실시예에 따른 변압기의 고장 진단 방법의 경우 희박한 표지 데이터(labeled data)가 존재하는 조건에서도 가장 높은 고장 진단 성능을 달성하였음을 확인할 수 있다.

[135] 예시적으로, 본 발명의 실시예에 따른 변압기의 고장 진단 방법의 경우 표지가 지정된 학습 데이터가 5%만 존재하는 경우에도 다른 진단 방법에 비해 가장 높은 고장 진단 정확도(86.4%)를 달성하는 것을 확인할 수 있다.

[136] 또한, 본 발명의 실시예에 따른 변압기의 고장 진단 방법의 경우 표지가 지정된 학습 데이터가 30%만 존재하는 경우에도 다른 진단 방법에 비해 가장 높은 고장 진단 정확도(95.4%)를 가장 빠르게 달성할 수 있다.

[137] 본 발명의 실시예에 따르면, 표지 데이터가 없는 데이터의 고장 상태를 진단하는 룰 기반 학습 방법의 장점과 인공지능에 기반한 딥 러닝 기반 학습 방법의 장점을 융합함으로써, 다수의 유중 가스 분석 데이터가 있으나 소수의 표지 데이터 밖에 없는 상황에서도 변압기의 고장 진단을 정확하게 수행할 수 있다.

[138] 또한, 변압기의 고장 진단시 인공지능에 기반한 딥 러닝 기반 학습 방법에만 의존하지 않고 룰 기반 학습 방법을 통해 전문가의 지식을 융합할 수 있으므로 어렵고 복잡한 모델을 개발하지 않고도 딥 러닝 기반 학습 방법의 정확도를 개선할 수 있다.

[139] 이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위 내에서 다양한 수정, 변경 및 치환이 가능할 것이다. 따라서, 본 발명에 개시된 실시예 및 첨부된 도면들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시예 및 첨부된 도면에 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.

청구범위

- [청구항 1] 변압기의 고장 진단 장치에 있어서,
 상기 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링하는
 데이터 스케일링부;
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지
 데이터로 변환하여 획득하는 가표지 데이터 획득부;
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지
 데이터에 대해 사전 학습을 수행하는 사전 학습부; 및
 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지
 데이터에 대해 재 학습을 수행하는 재 학습부;를 포함하는 것을 특징으로
 하는 변압기의 고장 진단 장치.
- [청구항 2] 제 1항에 있어서,
 상기 데이터 스케일링부는,
 상기 유중 가스 분석 데이터를 로그화하는 데이터 로그화부 및
 상기 로그화된 유중 가스 분석 데이터를 정규화하는 데이터 정규화부를
 포함하는 것을 특징으로 하는 변압기의 고장 진단 장치.
- [청구항 3] 제 1항에 있어서,
 상기 가표지 데이터 획득부는,
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여
 상기 변압기의 정상 상태와 고장 상태를 분류하는 변압기 상태 분류부와,
 세 개의 가연성 가스를 선택하여 각각의 가연성 가스의 농도로부터 가스
 조성비를 도출하는 가스 조성비 도출부와,
 상기 도출된 가스 조성비를 듀발 삼각형 방법에 적용하여 상기
 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로
 변환하는 가표지 데이터 변환부 및
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지
 데이터를 준비하는 사전 학습 준비부를 포함하는 것을 특징으로 하는
 변압기의 고장 진단 장치.
- [청구항 4] 제 3항에 있어서,
 상기 세 개의 가연성 가스는, C_2H_2 , C_2H_4 , CH_4 인 것을 특징으로
 하는 변압기의 고장 진단 장치.
- [청구항 5] 제 1항에 있어서,
 상기 사전 학습부는,
 딥 뉴럴 네트워크의 손실함수

$$L_{DNN}(\theta) = \alpha L_{su}(\tilde{Y}_s, \hat{Y}_{end}) + (1 - \alpha) L_{un}(\mathbf{X}_s^*, \hat{\mathbf{X}}_{end}^*)$$

정의하는 손실함수 정의부와,
 상기 손실함수의 우측항에서의 첫 번째 항(L_{su})과 두 번째 항(L_{un})을
 조절하는 하이퍼 파라미터 α 를 선택하는 하이퍼 파라미터 선택부 및
 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의
 파라미터를 획득하는 제 1 최적 파라미터 획득부를 포함하는 것을
 특징으로 하는 변압기의 고장 진단 장치.

[청구항 6] 제 5항에 있어서,
 상기 손실함수에서,
 L_{su} 는 듀발 삼각형 방법을 통해 획득된 가표지 데이터 $\tilde{Y}_s$ 와 상기 딥
 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 가표지 데이터
 Y_{end} 간의 차이를 나타내는 것을 특징으로 하는 변압기의 고장 진단
 장치.

[청구항 7] 제 5항에 있어서,
 상기 손실함수에서,
 L_{un} 는 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 X_s^* 와
 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 유중 가스
 분석 데이터 X_{end}^* 간의 차이를 나타내는 것을 특징으로 하는 변압기의
 고장 진단 장치.

[청구항 8] 제 5항에 있어서,
 상기 재 학습부는,
 상기 표지 데이터의 학습을 준비하는 재 학습 준비부와,
 상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 은닉층 고정부와,
 상기 고정된 은닉층을 제외한 마지막 은닉층에 대해서만 학습을
 수행하는 은닉층 학습부 및
 상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의
 파라미터를 획득하는 제 2 최적 파라미터 획득부를 포함하는 것을
 특징으로 하는 변압기의 고장 진단 장치.

[청구항 9] 제 8항에 있어서,
 상기 은닉층 고정부는,
 상기 마지막 은닉층을 제외한 나머지 은닉층을 고정시키는 것을
 특징으로 하는 변압기의 고장 진단 장치.

[청구항 10] 변압기의 고장 진단 방법에 있어서,
 상기 변압기로부터 획득되는 유중 가스 분석 데이터를 스케일링하는
 단계;

상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 단계;
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 단계; 및
 상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 단계;를 포함하는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 11] 제 10항에 있어서,
 상기 유중 가스 분석 데이터를 스케일링하는 단계는,
 상기 유중 가스 분석 데이터를 로그화하는 단계 및
 상기 로그화된 유중 가스 분석 데이터를 정규화하는 단계를 포함하는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 12] 제 10항에 있어서,
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하여 획득하는 단계는,
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 이용하여 상기 변압기의 정상 상태와 고장 상태를 분류하는 단계와,
 세 개의 가연성 가스를 선택하여 각각의 가연성 가스의 농도로부터 가스 조성비를 도출하는 단계와,
 상기 도출된 가스 조성비를 듀발 삼각형 방법에 적용하여 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터를 가표지 데이터로 변환하는 단계 및
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터를 준비하는 단계를 포함하는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 13] 제 12항에 있어서,
 상기 세 개의 가연성 가스는, C_2H_2 , C_2H_4 , CH_4 인 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 14] 제 10항에 있어서,
 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 및 상기 가표지 데이터에 대해 사전 학습을 수행하는 단계는,
 딥 뉴럴 네트워크의 손실함수

$$L_{DNN}(\theta) = \alpha L_{su}(\tilde{Y}_s, \hat{Y}_{end}) + (1 - \alpha) L_{un}(\mathbf{X}_s^*, \hat{\mathbf{X}}_{end}^*)$$

를 정의하는 단계와,
 상기 손실함수의 우측항에서의 첫 번째 항(L_{su})과 두 번째 항(L_{un})을

조절하는 하이퍼 파라미터 α 를 선택하는 단계 및

상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 15] 제 14항에 있어서,
상기 손실함수에서,
 L_{su} 는 듀발 삼각형 방법을 통해 획득된 가표지 데이터 $\tilde{Y}_s$ 와 상기 딥


뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 가표지 데이터 Y_{end} 간의 차이를 나타내는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 16] 제 14항에 있어서,
상기 손실함수에서,
 L_{un} 는 상기 스케일링된 유중 가스 분석 데이터 중 비표지 데이터 X_s^* 와 상기 딥 뉴럴 네트워크의 은닉층 중 마지막 층에서의 추정된 유중 가스 분석 데이터 X_{end}^* 간의 차이를 나타내는 것을 특징으로 하는 변압기의 고장 진단 방법.

[청구항 17] 제 14항에 있어서,
상기 사전 학습 수행에 의해 최적화된 파라미터의 전이를 통해 표지 데이터에 대해 재 학습을 수행하는 단계는,
상기 표지 데이터의 학습을 준비하는 단계와,
상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 단계와,
상기 고정된 은닉층을 제외한 마지막 은닉층에 대해서만 학습을 수행하는 단계 및
상기 손실함수를 최적화하도록 역전파 방법을 사용하여 최적의 파라미터를 획득하는 단계를 포함하는 것을 특징으로 하는 변압기의 고장 진단 방법.


[청구항 18] 제 17항에 있어서,
상기 딥 뉴럴 네트워크의 일부 은닉층을 고정하는 단계에서,
상기 마지막 은닉층을 제외한 나머지 은닉층을 고정시키는 것을 특징으로 하는 변압기의 고장 진단 방법.

[도 1]




[도2]

100




[도3]


1. Scaling of industrial DGA data



2. Pseudo labeling by Weak supervision



Parameter transfer (Freezing)




$$\frac{\partial L_{DNN}}{\partial \theta_m} := \begin{cases} \frac{\partial L_{DNN}}{\partial \theta_m}, m=k \text{ (Retraining)} \\ 0, m < k \text{ (Freezing)} \end{cases}$$

$$L_{DNN}(\theta) = \alpha L_{su}(y, \hat{y}) + (1 - \alpha) L_{un}(x, \hat{x})$$
$$\frac{\partial L_{DNN}^{(m)}}{\partial \theta_j} = \alpha \delta_n^{su} h_j^{(m)} + (1 - \alpha) \delta_n^{un} h_j^{(m)}$$


4. Retraining under parameter transferred with DNN

3. Pretraining by DNN with pseudo labeled and input DGA

[도4]



[도5]



[도6]

TABLE 4 EVALUATION OF THE FAULT DIAGNOSIS ACCURACY

Learning approaches	Methods	Ratio (%) of labeled training data					Unlabeled
		5	10	30	60	80	
Supervised learning	L-SVM	50.0	54.5	63.6	68.2	68.2	X
	R-SVM	40.9	40.9	45.5	50.0	54.5	
	KNN	40.9	40.9	59.1	72.7	72.7	
	1-NN	50.0	40.9	50.0	50.0	59.1	
	DeA	13.6	18.2	22.7	77.2	86.4	
	DNN	50.0	63.6	68.2	81.8	90.9	
Semi-supervised learning	L-SVM	40.9	45.5	63.6	63.6	59.1	O
	R-SVM	50.0	63.6	72.7	77.3	68.2	
	KNN	45.5	50.0	59.1	63.6	68.2	
	1-NN	40.9	63.6	63.6	63.6	72.7	
	DeA	50.0	54.5	68.1	77.2	86.4	
	DNN	50.0	63.6	72.7	77.3	86.4	
Rule-based knowledge learning	L-SVM	45.5	45.5	45.5	50.0	50.0	Δ
	R-SVM	63.6	72.7	77.3	81.8	81.8	
	KNN	54.5	54.5	59.1	63.6	63.6	
	1-NN	59.1	63.6	63.6	77.3	72.7	
	DeA	63.6	68.2	77.3	81.8	81.8	
	DNN_{FT}^{Non}	77.2	77.2	81.8	81.8	81.8	
	DNN_{PF}^{Non}	77.3	81.8	86.4	86.4	90.9	
	DNN_{FT}^{Aux}	81.8	81.8	81.8	86.4	86.4	
BDD		86.4	90.9	95.4	95.4	95.4	

INTERNATIONAL SEARCH REPORT

International application No.

PCT/KR2021/013531

A. CLASSIFICATION OF SUBJECT MATTER H01F 27/40(2006.01)i; H01F 27/12(2006.01)i; G06N 3/08(2006.01)i; G01N 33/28(2006.01)i According to International Patent Classification (IPC) or to both national classification and IPC		
B. FIELDS SEARCHED Minimum documentation searched (classification system followed by classification symbols) H01F 27/40(2006.01); G01N 33/00(2006.01); G01N 33/28(2006.01); G06F 15/18(2006.01); G06K 9/62(2006.01); G06N 3/08(2006.01) Documentation searched other than minimum documentation to the extent that such documents are included in the fields searched Korean utility models and applications for utility models: IPC as above Japanese utility models and applications for utility models: IPC as above Electronic data base consulted during the international search (name of data base and, where practicable, search terms used) eKOMPASS (KIPO internal) & keywords: 변압기(transformer), 진단(diagnosis), 유중 가스(dissolved gas), 학습(learning), 파라미터 전이(parameter transfer)		
C. DOCUMENTS CONSIDERED TO BE RELEVANT		
Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	KIM, Sunuwe et al. A Semi-Supervised Autoencoder With anAuxiliary Task (SAAT) for Power Transformer Fault Diagnosis Using Dissolved Gas Analysis. IEEE Access. 09 October 2020. <DOI: 10.1109/ACCESS.2020.3027830>. See pages 178295-178308; and figure 2.	1-18
A	CN 106596900 A (ELECTRIC POWER RESEARCH INSTITUTE, GUZHOU POWER GRID CO., LTD.) 26 April 2017 (2017-04-26) See claims 1-2.	1-18
A	KR 10-2128460 B1 (KOREA ELECTRIC POWER CORPORATION et al.) 30 June 2020 (2020-06-30) See paragraphs [0023]-[0052]; and figure 1.	1-18
A	KR 10-2019-0034963 A (KOREA ELECTRIC POWER CORPORATION) 03 April 2019 (2019-04-03) See claims 1-17; and figures 1-2.	1-18
☒ Further documents are listed in the continuation of Box C. ☒ See patent family annex.		
* Special categories of cited documents: "A" document defining the general state of the art which is not considered to be of particular relevance "D" document cited by the applicant in the international application "E" earlier application or patent but published on or after the international filing date "L" document which may throw doubts on priority claim(s) or which is cited to establish the publication date of another citation or other special reason (as specified) "O" document referring to an oral disclosure, use, exhibition or other means "P" document published prior to the international filing date but later than the priority date claimed "T" later document published after the international filing date or priority date and not in conflict with the application but cited to understand the principle or theory underlying the invention "X" document of particular relevance; the claimed invention cannot be considered novel or cannot be considered to involve an inventive step when the document is taken alone "Y" document of particular relevance; the claimed invention cannot be considered to involve an inventive step when the document is combined with one or more other such documents, such combination being obvious to a person skilled in the art "&" document member of the same patent family		
Date of the actual completion of the international search 10 January 2022		Date of mailing of the international search report 10 January 2022
Name and mailing address of the ISA/KR Korean Intellectual Property Office Government Complex-Daejeon Building 4, 189 Cheongsaro, Seo-gu, Daejeon 35208 Facsimile No. +82-42-481-8578		Authorized officer Telephone No.

INTERNATIONAL SEARCH REPORT

International application No.

PCT/KR2021/013531

C. DOCUMENTS CONSIDERED TO BE RELEVANT

Category*	Citation of document, with indication, where appropriate, of the relevant passages	Relevant to claim No.
A	US 8751421 B2 (THE TRUSTEES OF COLUMBIA UNIVERSITY IN THE CITY OF NEW YORK et al.) 10 June 2014 (2014-06-10) See claims 1-22; and figures 5 and 9.	1-18

INTERNATIONAL SEARCH REPORT
Information on patent family members

International application No.

PCT/KR2021/013531

Patent document cited in search report			Publication date (day/month/year)	Patent family member(s)		Publication date (day/month/year)
CN	106596900	A	26 April 2017	None		
KR	10-2128460	B1	30 June 2020	KR 10-2020-0039368	A	16 April 2020
KR	10-2019-0034963	A	03 April 2019	None		
US	8751421	B2	10 June 2014	CA	2805747	A1 19 January 2012
				CN	103154845	A 12 June 2013
				EP	2593844	A1 22 May 2013
				EP	2593844	A4 31 May 2017
				JP	2013-538543	A 10 October 2013
				MX	2013000577	A 05 June 2013
				US	2013-0232094	A1 05 September 2013
				WO	2012-009724	A1 19 January 2012

A. 발명이 속하는 기술분류(국제특허분류(IPC)) H01F 27/40(2006.01)i; H01F 27/12(2006.01)i; G06N 3/08(2006.01)i; G01N 33/28(2006.01)i		
B. 조사된 분야 조사된 최소문헌(국제특허분류를 기재) H01F 27/40(2006.01); G01N 33/00(2006.01); G01N 33/28(2006.01); G06F 15/18(2006.01); G06K 9/62(2006.01); G06N 3/08(2006.01) 조사된 기술분야에 속하는 최소문헌 이외의 문헌 한국등록실용신안공보 및 한국공개실용신안공보: 조사된 최소문헌란에 기재된 IPC 일본등록실용신안공보 및 일본공개실용신안공보: 조사된 최소문헌란에 기재된 IPC 국제조사에 이용된 전산 데이터베이스(데이터베이스의 명칭 및 검색어(해당하는 경우)) eKOMPASS(특허청 내부 검색시스템) & 키워드: 변압기(transformer), 진단(diagnosis), 유증 가스(dissolved gas), 학습(learning), 파라미터 전이(parameter transfer)		
C. 관련 문헌		
카테고리*	인용문헌명 및 관련 구절(해당하는 경우)의 기재	관련 청구항
A	SUNUWE KIM 등, A Semi-Supervised Autoencoder With anAuxiliary Task (SAAT) for Power Transformer Fault Diagnosis Using Dissolved Gas Analysis. IEEE Access, 2020.10.09, <DOI: 10.1109/ACCESS.2020.3027830>. 페이지 178295-178308; 및 도면 2	1-18
A	CN 106596900 A (ELECTRIC POWER RESEARCH INSTITUTE, GUIZHOU POWER GRID CO., LTD.) 2017.04.26 청구항 1-2	1-18
A	KR 10-2128460 B1 (한국전력공사 등) 2020.06.30 단락 [0023]-[0052]; 및 도면 1	1-18
A	KR 10-2019-0034963 A (한국전력공사) 2019.04.03 청구항 1-17; 및 도면 1-2	1-18
A	US 8751421 B2 (THE TRUSTEES OF COLUMBIA UNIVERSITY IN THE CITY OF NEW YORK 등) 2014.06.10 청구항 1-22; 및 도면 5, 9	1-18
☐ 추가 문헌이 C(계속)에 기재되어 있습니다. ☒ 대응특허에 관한 별지를 참조하십시오.		
* 인용된 문헌의 특별 카테고리: “A” 특별히 관련이 없는 것으로 보이는 일반적인 기술수준을 정의한 문헌 “D” 본 국제출원에서 출원인이 인용한 문헌 “E” 국제출원일보다 빠른 출원일 또는 우선일을 가지나 국제출원일 이후에 공개된 선출원 또는 특허 문헌 “L” 우선권 주장에 의문을 제기하는 문헌 또는 다른 인용문헌의 공개일 또는 다른 특별한 이유(이유를 명시)를 밝히기 위하여 인용된 문헌 “O” 구두 개시, 사용, 전시 또는 기타 수단을 언급하고 있는 문헌 “P” 우선일 이후에 공개되었으나 국제출원일 이전에 공개된 문헌 “T” 국제출원일 또는 우선일 후에 공개된 문헌으로, 출원과 상충하지 않으며 발명의 기초가 되는 원리나 이론을 이해하기 위해 인용된 문헌 “X” 특별한 관련이 있는 문헌. 해당 문헌 하나만으로 청구된 발명의 신규성 또는 진보성이 없는 것으로 본다. “Y” 특별한 관련이 있는 문헌. 해당 문헌이 하나 이상의 다른 문헌과 조합하는 경우로 그 조합이 당업자에게 자명한 경우 청구된 발명은 진보성이 없는 것으로 본다. “&” 동일한 대응특허문헌에 속하는 문헌		
국제조사의 실제 완료일 2022년01월10일(10.01.2022)		국제조사보고서 발송일 2022년01월10일(10.01.2022)
ISA/KR의 명칭 및 우편주소 대한민국 특허청 (35208) 대전광역시 서구 청사로 189, 4동 (둔산동, 정부대전청사) 팩스 번호 +82-42-481-8578		심사관 박혜련 전화번호 +82-42-481-3463

국제조사보고서에서 인용된 특허문헌	공개일	대응특허문헌	공개일
CN 106596900 A	2017/04/26	없음	
KR 10-2128460 B1	2020/06/30	KR 10-2020-0039368 A	2020/04/16
KR 10-2019-0034963 A	2019/04/03	없음	
US 8751421 B2	2014/06/10	CA 2805747 A1	2012/01/19
		CN 103154845 A	2013/06/12
		EP 2593844 A1	2013/05/22
		EP 2593844 A4	2017/05/31
		JP 2013-538543 A	2013/10/10
		MX 2013000577 A	2013/06/05
		US 2013-0232094 A1	2013/09/05
		WO 2012-009724 A1	2012/01/19