(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0000756
(43) 공개일자 2025년01월03일

(51) 국제특허분류(Int. Cl.)
H04L 43/08 (2022.01) *G06N 3/0442* (2023.01)
G06N 3/0455 (2023.01) *H04L 43/16* (2022.01)
(52) CPC특허분류
H04L 43/08 (2022.05)
G06N 3/0442 (2023.01)
(21) 출원번호 10-2023-0082922
(22) 출원일자 2023년06월27일
심사청구일자 2023년06월27일

(71) 출원인
주식회사 엘지유플러스
서울특별시 용산구 한강대로 32(한강로3가)
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
최용우
서울특별시 용산구 한강대로 32(한강로3가, LG유플러스빌딩)
이규복
서울특별시 용산구 한강대로 32(한강로3가, LG유플러스빌딩)
(뒷면에 계속)
(74) 대리인
특허법인(유한)케이비케이

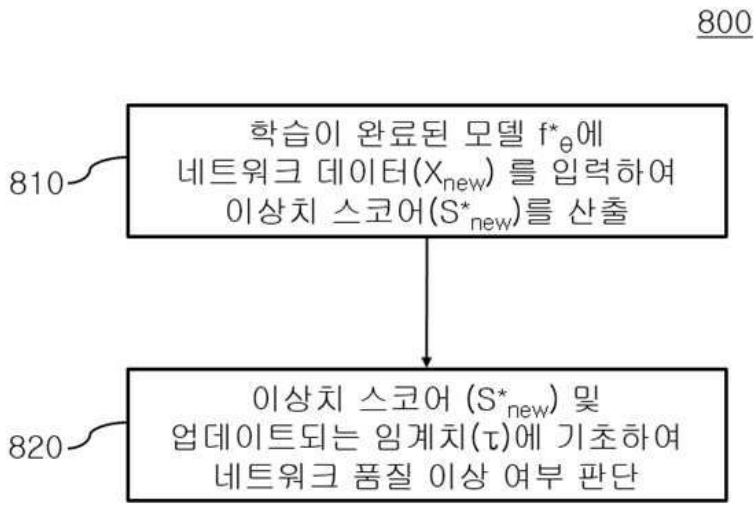
전체 청구항 수 : 총 20 항

(54) 발명의 명칭 **네트워크 품질 모니터링 방법 및 이를 위한 장치**

(57) 요 약

본 발명의 일 실시 예에 따른 장치가 네트워크 품질을 모니터링하는 방법은, AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출; 상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단; 상기 임계치는, 상기 AI 학습 모델의 학습에 사용된 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트되는 것을 포함할 수 있다.

대 표 도 - 도8



(52) CPC특허분류
G06N 3/0455 (2023.01)
H04L 43/16 (2022.05)
(72) 발명자
오준수
서울특별시 용산구 한강대로 32(한강로3가, LG유플러스빌딩)
김성범
서울특별시 송파구 올림픽로 99, 122동 1802호 (잠실동, 잠실엘스)
임새린
서울특별시 종로구 난계로27길 15, 한라운종가 607호(숭인동)
허종국
서울특별시 성북구 고려대로7마길 6, 501호(안암동1가, 해마루)
이정민
서울특별시 동대문구 약령시로 8 교우빌딩 603호(제기동)
김태연
서울특별시 성북구 서경로 31, 106동 706호(정릉동, 푸른마을동아아파트)
유이경
경기도 성남시 분당구 성남대로 449, C동 2006호(정자동,로얄팰리스)

명 세 서

청구범위

청구항 1

장치가 네트워크의 품질을 모니터링 하는 방법에 있어서,

AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출 및;

상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단하는 것을 포함하고;

상기 임계치는, 상기 AI 학습 모델의 학습에 사용된 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트되는, 방법.

청구항 2

제1 항에 있어서,

상기 이상치 스코어는 상기 제2 데이터 및 상기 제2 데이터가 입력된 상기 AI 학습 모델로부터 출력되는 제3 데이터에 기초하여 산출되고,

상기 불확실성 정보는 상기 이상치 스코어의 표준편차로 산출되는 것을 특징으로 하는, 방법.

청구항 3

제2 항에 있어서,

상기 제2 데이터가 상기 AI 학습 모델의 학습 과정의 타당성과 관련된 검증 데이터인 것에 기초하여 제1 불확실성 정보를 산출; 및

상기 산출된 제1 불확실성 정보의 평균 및 표준편차를 산출하는 것을 더 포함하는, 방법.

청구항 4

제3 항에 있어서,

상기 제2 데이터가 네트워크 데이터인 것에 기초하여 제2 불확실성 정보를 산출하는 것을 더 포함하는, 방법.

청구항 5

제4 항에 있어서,

상기 임계치는 임계치 초기 값(τ_{init}) 및 제3 불확실성 정보에 기초하여 산출되고,

상기 제3 불확실성 정보는 상기 제1 불확실성 정보의 평균(μ_{un}), 상기 제1 불확실성 정보의 표준편차(σ_{un}), 상기 제2 불확실성 정보(U_t) 및 정규화 함수에 기초하여 산출되고,

상기 정규화 함수는 수식1로 정의되는, 방법.

(수식1) $$F = \frac{u_t - \mu_{u_n}}{\sigma_{u_n}}$$

(u_t 는 모니터링 시점(t시점)에 네트워크 데이터에 기초하여 산출된 제2 불확실성 정보, μ_{un}은 검증 데이터에 기초하여 산출된 제1 불확실성 정보의 평균, σ_{un}은 검증 데이터에 기초하여 산출된 제1 불확실성 정보의 표준편차를 의미함)

청구항 6

제5 항에 있어서,

상기 임계치는 상기 임계치 초기 값(τ_{init})과 상기 제3 불확실성 정보의 스케일을 맞춰주는 제1 하이퍼 파라미터(α) 및 상기 제1 불확실성 정보에 대한 유의 수준으로서 상기 네트워크 데이터를 정상으로 인정하는 범위와 관련된 제2 하이퍼 파라미터(β)에 기초하여 조정되는, 방법.

청구항 7

제5 항에 있어서,

상기 임계치 초기 값(τ_{init})은 상기 제1 불확실성 정보에 사용자가 설정한 상수 K를 곱한 것을 특징으로 하는, 방법.

청구항 8

제5 항에 있어서,

상기 임계치는 상기 임계치가 작아지는 현상을 막기 위해 상기 임계치 초기 값(τ_{init})의 A배를 넘지 않는 것을 특징으로 하고,

사용자가 설정한 상기 A는 0에서 1사이의 실수 중 하나인 것을 특징으로 하는, 방법.

청구항 9

제6 항에 있어서,

상기 임계치는 수식 2를 통해 결정되는, 방법.

$$\tau = max(\tau_{init} - \alpha \cdot (\frac{u_t - \mu_{u_n}}{\sigma_{u_n}} - \beta),\ \frac{1}{2}k \cdot \sigma_{e_n}\ )$$

(수식2)

(τ는 임계치, τ_{init}, $K*\sigma_{en}$은 임계치 초기 값, μ_{un}은 제1 불확실성 정보의 평균, σ_{un}은 제1 불확실성 정보의 표준편차, u_t는 모니터링 시점의 제2 불확실성 정보, $\frac{u_t - \mu_{u_n}}{\sigma_{u_n}}$ 는 정규화된 불확실성 정보, α는 임계치 초기 값(τ_{init}) 및 정규화된 불확실성 정보의 스케일을 맞춰주는 하이퍼 파라미터, β는 상기 제1 불확실성 정보에 대한 유의 수준으로서 상기 네트워크 데이터를 정상으로 인정하는 범위와 관련된 하이퍼 파라미터를 의미함)

청구항 10

제1 항에 있어서,

상기 초기화된 AI 학습 모델에 상기 제1 데이터를 입력;

상기 제1 데이터가 입력된 상기 AI 학습 모델을 통해 제4 데이터를 출력; 및

상기 AI 학습 모델을 저장하는 것을 포함하는, 방법.

청구항 11

제10 항에 있어서,

상기 입력된 제1 데이터 및 상기 출력된 제4 데이터에 기초하여 손실(Loss)을 산출하는 것을 더 포함하고,

상기 손실(Loss)은 수식3 (Mean Squared Error, MSE)를 통해 결정되는, 방법.

(수식3)

$$MSE = \frac{1}{n}\sum_{i=1}^{n}|Xi - Yi|^2$$

(X_i는 AI 학습 모델에 입력된 제1 데이터이고, Y_i는 출력된 제4 데이터, n은 입력된 제1 데이터의 개수)

청구항 12

제1 항에 있어서,

상기 AI 학습 모델은 MC-dropout(Monte Carlo dropout)을 수행하고,

상기 이상치 스코어 및 상기 불확실성 정보는 상기 MC-dropout의 수행 결과에 기초하여 산출되는, 방법.

청구항 13

제1 항에 있어서,

상기 AI 학습 모델은 적어도 하나의 오토인코더를 포함하고,

상기 적어도 하나의 오토인코더는 입력 레이어, 히든 레이어 및 출력 레이어를 포함하되,

상기 입력 레이어, 상기 히든 레이어 및 상기 출력 레이어는 각각 적어도 하나의 노드를 포함하는 것을 특징으로 하는, 방법.

청구항 14

제13 항에 있어서,

상기 히든 레이어의 노드 개수는 상기 입력 레이어 및 상기 출력 레이어의 노드 개수보다 적은 것을 특징으로 하는, 방법.

청구항 15

제13 항에 있어서,

상기 제2 데이터가 시계열 특성을 가진 시퀀스 데이터라는 것에 기반하여 상기 적어도 하나의 오토인코더는 적어도 하나의 LSTM(Long Short Term Memory)를 포함하는, 방법.

청구항 16

제1 항에 기재된 방법을 수행하기 위한 프로그램 코드를 기록한 컴퓨터로 읽을 수 있는, 기록 매체.

청구항 17

네트워크 품질을 모니터링 하는 장치에 있어서,

메모리; 및

AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출하고; 상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단하는 적어도 하나의 프로세서를 포함하고,

상기 임계치는, 상기 AI 학습 모델이 학습한 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트되는, 모니터링 장치.

청구항 18

제17 항에 있어서,

상기 적어도 하나의 프로세서가,

상기 이상치 스코어를 상기 제2 데이터 및 상기 제2 데이터가 입력된 상기 AI 학습 모델로부터 출력되는 제3 데이터에 기초하여 산출하고,

상기 불확실성 정보를 상기 이상치 스코어의 표준편차로 산출하는 것을 특징으로 하는, 모니터링 장치.

청구항 19

제17 항에 있어서,

상기 AI 학습 모델은 적어도 하나의 오토인코더를 포함하고,

상기 적어도 하나의 오토인코더는 입력 레이어, 히든 레이어 및 출력 레이어를 포함하되,

상기 입력 레이어, 상기 히든 레이어 및 상기 출력 레이어는 각각 적어도 하나의 노드를 포함하는 것을 특징으로 하는, 모니터링 장치.

청구항 20

제19 항에 있어서,

상기 제2 데이터가 시계열 특성을 가진 시퀀스 데이터라는 것에 기반하여 상기 적어도 하나의 오토인코더는 적어도 하나의 LSTM(Long Short Term Memory)를 포함하는, 모니터링 장치.

발명의 설명

기 술 분 야

[0001] 본 발명은 네트워크 모니터링에 대한 것으로, 상세하게는 네트워크의 이상 징후를 판단하는 기술에 관한 것이다.

배 경 기 술

[0002] 네트워크 품질 모니터링이란 네트워크의 가용성, 가동시간, 성능 등을 모니터링 하는 프로세스이다.

[0003] 종래에는 시그니처 기반의 네트워크 품질 모니터링 방법이 사용되어 왔다. 하지만 이러한 방법은 이미 알려진 패턴의 품질 이상에 대해서만 대응할 수 있다는 문제가 있다. 최근에는 이를 개선하기 위하여 머신 러닝 기반의 모니터링 방법이 제시되고 있다.

[0004] 머신러닝(Machine Learning)은 AI(Artificial intelligence)의 한 분야로 데이터를 바탕으로 컴퓨터가 학습할 수 있도록 하는 알고리즘 및 기술을 개발하는 분야이며, 이미지 처리, 영상 인식, 음성 인식, 인터넷 검색 등의 다양한 분야의 핵심 기술로 예측(prediction) 및 이상 탐지(anomaly detection) 등에 탁월한 성과를 나타낸다.

[0005] 종래 머신 러닝에 기반한 네트워크 품질 모니터링 방법은 시계열 특징을 가지는 네트워크 데이터의 특성을 반영하기 어렵고, 사용자가 임계치를 일일이 설정하여 이상 여부를 판단해야 하는 불편함이 있었다.

발명의 내용

해결하려는 과제

[0006] 본 발명이 이루고자 하는 기술적 과제는 보다 효율적으로 네트워크 품질 모니터링을 수행하는 방법 및 이를 위한 장치를 제공하는 것을 포함한다.

[0007] 본 발명은 상술된 기술적 과제에 한정되지 않으며, 다른 기술적 과제들이 본 명세서에 개시된 실시 예들로부터 유추될 수 있다.

과제의 해결 수단

[0008] 본 개시의 일측면에 따른 장치가 네트워크의 품질을 모니터링 하는 방법은 AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출; 상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단하는 것을 포함하고 상기 임계치는, 상기 AI 학습 모델의 학습에 사용된 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트되는 것을 포함할 수 있다.

[0009] 실시 예로, 상기 이상치 스코어는 상기 제2 데이터 및 상기 제2 데이터가 입력된 상기 AI 학습 모델로부터 출력되는 제3 데이터에 기초하여 산출되고, 상기 불확실성 정보는 상기 이상치 스코어의 표준편차로 산출되는 것을 특징으로 할 수 있다.

[0010] 실시 예로, 상기 제2 데이터가 상기 AI 학습 모델의 학습 과정의 타당성과 관련된 검증 데이터인 것에 기초하여 제1 불확실성 정보를 산출; 및 상기 산출된 제1 불확실성 정보의 평균 및 표준편차를 산출하는 것을 더 포함 할 수 있다.

[0011] 실시 예로, 상기 제2 데이터가 네트워크 데이터인 것에 기초하여 제2 불확실성 정보를 산출하는 것을 더 포함할 수 있다.

[0012] 실시 예로, 상기 임계치는 임계치 초기 값(τ_{init}) 및 제3 불확실성 정보에 기초하여 산출되고, 상기 제3 불확실성 정보는 상기 제1 불확실성 정보의 평균(μ_{un}), 상기 제1 불확실성 정보의 표준편차(σ_{un}), 상기 제2 불확실성 정보(U_t) 및 정규화 함수에 기초하여 산출되고, 상기 정규화 함수는 수식1로 정의 될 수 있다.

[0013] (수식1) $$F = \frac{u_t - \mu_{u_n}}{\sigma_{u_n}}$$

[0014] (u_t 는 모니터링 시점(t시점)에 네트워크 데이터에 기초하여 산출된 제2 불확실성 정보, μ_{un}은 검증 데이터에 기초하여 산출된 제1 불확실성 정보의 평균, σ_{un}은 검증 데이터에 기초하여 산출된 제1 불확실성 정보의 표준편차를 의미함)

[0015] 실시 예로, 상기 임계치는 상기 임계치 초기 값(τ_{init})과 상기 제3 불확실성 정보의 스케일을 맞춰주는 제1 하이퍼 파라미터(α) 및 상기 제1 불확실성 정보에 대한 유의 수준으로서 상기 네트워크 데이터를 정상으로 인정하는 범위와 관련된 제2 하이퍼 파라미터(β)에 기초하여 조정 될 수 있다.

[0016] 실시 예로, 상기 임계치 초기 값(τ_{init})은 상기 제1 불확실성 정보에 사용자가 설정한 상수 K를 곱한 것을 특징으로 할 수 있다.

[0017] 실시 예로, 상기 임계치는 상기 임계치가 작아지는 현상을 막기 위해 상기 임계치 초기 값(τ_{init})의 A배를 넘지 않는 것을 특징으로 하고, 사용자가 설정한 상기 A는 0에서 1사이의 실수 중 하나인 것을 특징으로 할 수 있다.

[0018] 실시 예로, 상기 임계치는 수식 2를 통해 결정 될 수 있다.

[0019] (수식2) $$\tau = max(\tau_{init} - \alpha \cdot (\frac{u_t - \mu_{u_n}}{\sigma_{u_n}} - \beta),\ \frac{1}{2}k \cdot \sigma_{e_n}\ )$$

[0020] (τ는 임계치, τ_{init}은 임계치 초기 값, μ_{un}은 제1 불확실성 정보의 평균, σ_{un}은 제1 불확실성 정보의 표준편차, u_t는 제2 불확실성 정보, $K*\sigma_{en}$은 임계치 초기 값, $\frac{u_t - \mu_{u_n}}{\sigma_{u_n}}$ 는 정규화된 불확실성 정보, α는 임계치 초기 값(τ_{init}) 및 정규화된 불확실성 정보의 스케일을 맞춰주는 하이퍼 파라미터, β는 상기 제1 불확실성 정보에 대한 유의 수준으로서 상기 네트워크 데이터를 정상으로 인정하는 범위와 관련된 하이퍼 파라미터를 의미함)

[0021] 실시 예로, 상기 초기화된 AI 학습 모델에 상기 학습 데이터를 입력; 상기 제1 데이터가 입력된 상기 AI 학습 모델을 통해 제4 데이터를 출력; 및 상기 AI 학습 모델을 저장하는 것을 포함 할 수 있다.

[0022] 실시 예로, 상기 입력된 제1 데이터 및 상기 출력된 데이터에 기초하여 손실(Loss)을 산출하는 것을 더 포함하고, 상기 손실(Loss)은 수식3 (Mean Squared Error, MSE)를 통해 결정될 수 있다.

$$MSE = \frac{1}{n}\sum_{i=1}^{n} |Xi - Yi|^2$$

[0023] (수식3)

[0024] (X_i는 입력된 제1 데이터이고, Y_i는 출력된 제4 데이터, n은 입력된 제1 데이터의 개수)

[0025] 실시 예로, 상기 AI 학습 모델은 MC-dropout(Monte Carlo dropout)을 수행하고, 상기 이상치 스코어 및 상기 불확실성 정보는 상기 MC-dropout의 수행 결과에 기초하여 산출될 수 있다.

[0026] 실시 예로, 상기 AI 학습 모델은 적어도 하나의 오토인코더를 포함하고, 상기 적어도 하나의 오토인코더는 입력 레이어, 히든 레이어 및 출력 레이어를 포함하되, 상기 입력 레이어, 상기 히든 레이어 및 상기 출력 레이어는 각각 적어도 하나의 노드를 포함할 수 있다.

[0027] 실시 예로, 상기 히든 레이어의 노드 개수는 상기 입력 레이어 및 상기 출력 레이어의 노드 개수보다 적은 것을 특징으로 할 수 있다.

[0028] 실시 예로, 상기 제2 데이터가 시계열 특성을 가진 시퀀스 데이터라는 것에 기반하여 상기 오토인코더는 적어도 하나의 LSTM(Long Short Term Memory)를 포함할 수 있다.

[0029] 본 발명의 또 다른 일 측면에 따라서 상술된 네트워크의 품질을 모니터링 하는 방법을 수행하기 위한 프로그램 코드를 기록한 컴퓨터로 읽을 수 있는 기록 매체가 제공될 수 있다.

[0030] 본 발명의 또 다른 일 측면에 따라서 모니터링 장치는 메모리; 및 AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출 하고; 상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단하는 적어도 하나의 프로세서를 포함하고, 상기 임계치는, 상기 AI 학습 모델이 학습한 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트될 수 있다.

[0031] 실시 예로, 상기 적어도 하나의 프로세서가 상기 이상치 스코어를 상기 제2 데이터 및 상기 제2 데이터가 입력된 상기 AI 학습 모델로부터 출력되는 제3 데이터에 기초하여 산출하고, 상기 불확실성 정보를 상기 이상치 스코어의 표준편차로 산출하는 것을 특징으로 할 수 있다.

[0032] 실시 예로, 상기 AI 학습 모델은 적어도 하나의 오토인코더를 포함하고, 상기 오토인코더는 입력 레이어, 히든 레이어 및 출력 레이어를 포함하되, 상기 입력 레이어, 상기 히든 레이어 및 상기 출력 레이어는 각각 적어도 하나의 노드를 포함할 수 있다.

[0033] 실시 예로, 상기 제2 데이터가 시계열 특성을 가진 시퀀스 데이터라는 것에 기반하여 상기 오토인코더는 적어도 하나의 LSTM(Long Short Term Memory)를 포함할 수 있다.

발명의 효과

[0034] 본 발명의 일 실시 예에 따르면, 네트워크 품질 모니터링 과정에서 임계치의 업데이트로 인하여, 사용자가 임계치를 일일이 설정해 줄 필요가 없으므로 네트워크 품질 모니터링이 보다 효율적이고 원활하게 수행될 수 있다. 이에 따라 네트워크 서비스 품질 (Quality of Service, QoS)도 향상될 수 있다.

[0035] 본 발명의 기술적 효과는 상술된 효과에 한정되지 않으며, 다른 기술적 효과들이 본 명세서에 개시된 실시 예로부터 유추될 수 있다.

도면의 간단한 설명

[0036] 본 명세서에 첨부되는 도면은 본 발명에 대한 이해를 제공하기 위한 것으로서 본 발명의 다양한 실시형태들을 나타내고 명세서의 기재와 함께 본 발명의 원리를 설명하기 위한 것이다.

도 1은 데이터 패킷의 흐름을 설명하기 위한 도면이다.

도 2은 오토인코더의 개념을 설명하기 위한 도면이다.

도 3은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질 모니터링의 전체적인 순서를 개략적으로 도시한 도면이다.

도 4은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 학습모델의 학습 단계의 순서를 개략적으로 도시한 도

면이다.

도 5은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 임계치(threshold) 생성에 필요한 불확실성 정보 산출 과정을 개략적으로 도시한 도면이다.

도 6은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 실제 네트워크 데이터의 이상 여부를 판단하는 모니터링의 순서를 도시한 도면이다.

도 7는 본 개시의 기술적 사상에 의한 일 실시 예에 따른 MC-dropout을 이용한 불확실성 및 이상치를 계산하는 과정을 개략적으로 도시한 도면이다.

도 8은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질의 이상 여부를 확인하는 순서를 개략적으로 도시한 도면이다.

도 9은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질 모니터링을 위한 장치의 구성을 간략히 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0037] 본 명세의 예시적인 구현들을 첨부된 도면을 참조하여 상세하게 설명한다. 첨부된 도면과 함께 이하에 서술될 상세한 설명은 본 명세의 예시적인 구현들을 설명하고자 하는 것이며, 본 명세에 따라 실시될 수 있는 유일한 구현 형태들을 나타내고자 하는 것이 아니다. 이하의 상세한 설명은 본 명세의 완전한 이해를 제공하기 위해서 구체적 세부사항들을 포함한다. 그러나 통상의 기술자에게 본 명세가 이러한 구체적 세부사항 없이도 실시될 수 있음이 명백할 것이다.

[0038] 본 개시의 다양한 예에서, “/” 및 “,”는 “및/또는”을 나타내는 것으로 해석되어야 한다. 예를 들어, “A/B”는 “A 및/또는 B”를 의미할 수 있다. 나아가, “A, B”는 “A 및/또는 B”를 의미할 수 있다. 나아가, “A/B/C”는 “A, B 및/또는 C 중 적어도 어느 하나”를 의미할 수 있다. 나아가, “A, B, C”는 “A, B 및/또는 C 중 적어도 어느 하나”를 의미할 수 있다.

[0039] 이하, 본 개시의 실시 예들을 차례로 상세히 설명한다.

[0040] 도 1은 데이터 패킷의 흐름을 설명하기 위한 도면이다.

[0041] 일 예로, 사용자가 특정 웹사이트에 접속하는 과정에서 데이터 패킷의 흐름을 확인 할 수 있다.

[0042] 데이터 패킷은 패킷 송신 시스템을 통해 스위치, 라우터를 거쳐 서버로 전달 될 수 있다.

[0043] 사용자가 컴퓨터를 이용하여 웹 브라우저에 특정 웹사이트에 접속하기 위한 도메인주소를 입력하여 서버에 통신을 요청할 수 있다. DNS 서버에서 도메인 주소의 IP주소를 받아옴으로써, 유저의 컴퓨터와 웹 서버간의 커넥션(connection)이 확립된다.

[0044] 커넥션이 확립되면 웹 서버는 데이터 패킷 송신 시스템을 통해 웹 페이지를 요청하는 데이터를 송신한다. 데이터는 응용 프로그램 계층(Layer 7)부터 물리계층(Layer 1)을 거치면서 데이터에 각 계층마다 사용되는 헤더가 붙는 캡슐화가 수행된다. 특히 네트워크 계층(Layer 3)에서 데이터에 붙는 헤더에는 출발지와 목적지 IP주소가 기록되고 이렇게 구성된 데이터를 데이터 패킷이라고 한다.

[0045] 데이터 패킷이 스위치에 도착하면 물리계층(Layer 1)부터 데이터링크 계층(Layer 2)순으로 역캡슐화가 이루어지고, 다음 목적지인 라우터로 데이터 패킷으로 전송된다.

[0046] 라우터는 전기신호로 도착한 데이터를 우선 데이터링크 계층(Layer 2) 헤더까지 역캡슐화한다. 목적지 MAC주소와 자신의 MAC주소가 같으면 네트워크 계층(Layer 3)의 헤더까지 역캡슐화를 수행하고 자신의 라우팅 테이블과 목적지 IP주소를 비교한다. 자신의 라우팅 테이블에서 목적지 IP까지의 경로를 알 수 있으면 라우팅을 진행하고 데이터를 다시 캡슐화해서 다음 경로인 서버로 보낸다.

[0047] 서버에 데이터 패킷이 도착하면 해당 서버는 데이터에 문제가 없는지 확인하고 웹 페이지의 데이터를 사용자에게 송신한다.

[0048] 도 2은 오토인코더의 개념 및 구조를 나타낸다.

[0049] 신경망 구조라고도 불리는, 오토인코더(200)는 노드라고 지칭되는 상호 연결된 계산 단위들의 집합으로 구성될

수 있고, 노드의 집합을 뉴런이라고 지칭할 수 있다. 오토인코더(200)는 적어도 한 개의 노드를 포함하고, 일반적으로 복수개의 노드로 구성된다. 노드들은 하나 이상의 링크에 의해 서로 연결될 수 있다.

[0050] 오토인코더(200)는 비지도학습(unsupervised learning) 모델로서 입력 데이터를 낮은 차원의 잠재 표현(latent representation) 또는 코딩(coding)이라 부르는 밀집표현으로 학습하는 네트워크 함수 일수 있다.

[0051] 도 2을 참조하면, 입력 노드(240)로부터의 거리에 기초하여 하나의 레이어(layer)를 구성할 수 있다.

[0052] 본 명세서에서 설명하는 오토인코더(200)는 입력 레이어(210)와 출력 레이어(230) 외에 적어도 하나의 히든 레이어(220)를 포함하는 딥뉴럴 네트워크(Deep Neural Network, DNN)를 포함할 수 있다. 딥뉴럴 네트워크는 컨볼루셔널 뉴럴 네트워크 (Convolutional Neural Network, CNN), 리커런트 뉴럴 네트워크 (Recurrent Neural Network, RNN), 생성적 적대 신경망(Generative Adversarial Networks, GAN) 등을 포함할 수 있다.

[0053] 오토인코더(200)의 입력 레이어(210)를 구성하는 노드(240)의 개수 및 출력 레이어(230)를 구성하는 노드(260)의 개수는 동일할 수 있다.

[0054] 오토 인코더(200)의 구조는 노드의 개수, 노드간의 링크 관계 및 각 링크에 부여된 가중치로 정의될 수 있다.

[0055] 오토 인코더(200)를 구성하는 히든 레이어(220)의 노드(250) 개수는 입력 레이어(210) 또는 출력 레이어(230)의 노드 개수보다 적을 수 있다.

[0056] 오토인코더(200)는 입력 레이어(210)에 입력되는 데이터를 히든 레이어(220)를 통해 압축한 결과를 잠재 변수(latent vector)로 출력하고, 출력된 잠재 변수를 다시 히든 레이어(220)를 거쳐 출력 레이어(230)를 통해 복원하는 기능을 수행할 수 있다.

[0057] 즉, 오토인코더는 입력 데이터와 목표값이 주어진 라벨링된 데이터를 가지고 학습하는 것이 아니라 입력 데이터만 주어진 상태에서 학습을 수행하여 인코딩 후 다시 디코딩 했을 때의 출력 데이터가 입력 데이터와 같은 결과를 출력하는 것을 목표로 한다.

[0058] 오토인코더의 일 예로써, 순환 신경망 (Recurrent Neural Network, RNN)이 사용될 수 있다.

[0059] RNN은 입력과 출력을 시퀀스 단위로 처리하는 모델이다. RNN은 제1 히든 레이어에서 활성화 함수를 통해 나온 결과를 출력하여, 제2 히든 레이어의 입력으로 보내는 특징을 가지고 있다. RNN에서 이러한 역할을 하는 노드를 셀(Cell)이라고 한다. 셀은 일종의 메모리 역할을 하는 것으로서, 일정 시점에서 이전 히든 레이어에서 출력된 결과를 해당 히든 레이어의 입력으로 다시 사용하는 재귀적 역할을 하는 것을 포함한다. 그래서 RNN은 시계열적 특성을 가진다.

[0060] 다만, RNN은 이전 히든 레이어의 결과 데이터에 의존하기 때문에, 오토인코더의 개수가 많아 학습의 판단 시점(time step)이 길어질수록 초반 입력 데이터의 의미가 떨어질 수가 있다. 또한 히든레이어를 통하는 과정에서 정보의 손실이 발생 할 수 있다.

[0061] 따라서, 이러한 RNN은 비교적 짧은 시퀀스 데이터에 대해서만 효과를 보이는 단점이 있다. 이러한 문제를 해결하기 위하여 긴 시퀀스 데이터에 대해서도 효과적인 학습이 가능하도록 RNN의 변형 모델인 LSTM(Long Short Term Memory) Auto Encoder가 사용될 수 있다.

[0062] LSTM Auto Encoder이란 시계열적인 특성을 가지는 시퀀스 데이터를 적용할 때 주로 사용하는 학습 모델이다. 다시 말해 입력 데이터가 순차적으로 들어오게 된다. LSTM Auto Encoder는 기존 RNN이 가진 문제점을 해결하기 위해 오토인코더가 가지는 히든 레이어(hidden layer)의 구조에 인풋 게이트(input gate), 포겟 게이트(forget gate), 아웃풋 게이트(output gate)를 더 포함 할 수 있다.

[0063] LSTM Auto Encoder는 기억할 부분, 삭제할 부분, 그리고 읽어 들일 부분을 선택적으로 학습할 수 있다. 포겟 게이트를 지나면서 일부를 정보를 잃을 수 있고, 인풋 게이트로부터 입력 데이터의 일부를 추가할 수 있다. 타임스텝마다 일부의 데이터를 삭제하고 추가하는 과정을 거치게 된다. 과정을 다 거친 후 결과 값이 아웃풋 게이트로 전달된다.

[0064] RNN의 단점을 보완하기 위한 또 다른 예로 Auto Encoder는 Attention 레이어를 가질 수 있다. Attention 레이어는 LSTM 오토인코더에서 사용될 수 있다.

[0065] Attention 레이어는 Auto Encoder의 디코더에 배치 될 수 있다.

[0066] Attention 레이어는 디코더에서 데이터를 출력하는 매 시점마다 인코더에 입력된 전체 데이터를 한번씩 참고한

다. Attention 레이어는 인코더에 입력된 데이터 각각을 동일한 비중으로 참고하는 것이 아니라, 디코더에서 출력되어야 하는 데이터와 연관성이 있는 입력 데이터에 더 집중한다는 차이가 있다. 따라서 출력되어야 하는 데이터와 가장 연관성 높은 입력 데이터에 비중 또는 가중치를 두고 참고하여 출력 데이터의 정확성을 높이는 장점이 있다.

[0067] 일 예로, 영문데이터가 입력되어 국문데이터가 출력되는 Attention 레이어가 적용된 오토인코더에서 I LOVE YOU라는 영문데이터가 순차적으로 입력되었을 때 나는 너를 사랑해 라는 국문 데이터가 출력되어야 한다. 첫번째 국문데이터 출력 시 가장 먼저 I LOVE YOU에서 I 부분을 비중 있게 참고하여 나는 이라는 데이터를 출력한다. 두번째로는 너를 이라는 국문데이터가 나와야 하므로 YOU 부분을 비중 있게 참고하고 마지막으로 사랑해라는 국문데이터가 나와야 하므로 LOVE 부분을 비중 있게 참고한다.

[0068] Attention 레이어는 i)Attention 스코어(Attention Score)를 산출하고, ii)이에 기초하여 Attention 가중치(Attention Weight)를 산출하며, iii) Attention 값(Attention Value)을 산출함으로써 데이터를 출력한다.

[0069] 데이터 출력에 필요한 Attention 값을 산출하는데 각 인코더의 Hidden state 값, 각 디코더의 Hidden state 값이 필요하다.

[0070] Attention 스코어(Attention Score)는 상기 연관성을 수치화한 것이다. Attention 스코어는 현재 디코딩 시점에서의 출력 데이터를 예측하기 위해서 인코더에 입력된 각각의 데이터가 출력되어야 하는 데이터와 얼마나 유사한지를 나타내는 스칼라 값이다. Attention 스코어는 RNN의 각 인코더에 존재하는 Hidden state 값에 기초하여 산출된다.

[0071] Attention 스코어를 산출하면, 이들을 확률 값으로 정규화한다. 변환 과정에서 softmax 함수가 사용될 수 있다. 이를 Attention 분포(Attention Distribution)라고 하고, 각각의 확률 값을 Attention 가중치라고 한다. Attention 가중치의 총합은 1이 된다.

[0072] 상기 인코더의 Hidden state 값, Attention 가중치 및 디코더의 Hidden state 값에 기초하여 각 입력 데이터에 대한 Attention 값(Attention Value)들을 산출한다. 상기 Attention 값에 기초하여 출력 데이터를 예측하고, 예측된 데이터를 출력한다. 상기 각 Attention 값은 출력 데이터 산출 시점에 따라 달라질 수 있다. 오토인코더에 Attention 레이어를 사용함으로써 출력되는 데이터의 정확성이 높아질 수 있다.

[0073] 모니터링의 대상이 되는 네트워크 데이터는 시계열 특성을 가진 데이터일 수 있다. 바람직하게는, 상기 LSTM 오코인코더 또는 Attention 레이어를 사용하여 모니터링이 수행될 수 있다.

[0074] 도 3은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질 모니터링의 전체적인 순서를 개략적으로 도시한 도면이다.

[0075] 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질 모니터링 방법은 연산 능력을 구비한 개인용 컴퓨터 (Personal Computer), 워크스테이션 (work station), 서버용 컴퓨터 장치 등에서 수행되거나 이를 위한 별도의 장치 등에서 수행될 수 있다.

[0076] 먼저, 네트워크 모니터링 모델 학습을 수행한다. 상기 학습 모델은 오코인코더 기반의 학습 모델일 수 있다. 구체적으로 적어도 하나의 데이터에 대한 모델 학습을 수행한다. (310) 상기 모델 학습은 입력 레이어(210)에서 입력된 입력 데이터를 인코딩하여 압축한 결과를 디코더로 보내 디코딩하여 출력 데이터를 출력한다. 오토인코더의 목표는 입력 데이터와 같은 출력 데이터를 출력하는 것이다. 하지만 항상 입력 데이터와 출력 데이터가 같을 수는 없다. 따라서 입력 데이터와 출력 데이터의 오차를 줄일 수 있는 Loss 함수가 사용 될 수 있다. Loss 함수는 MSE(Mean Square Error)가 사용 될 수 있다. 즉, 모델 학습은 Loss를 최소화하는 방향으로 학습을 수행한 후, 학습이 완료되면 학습 모델을 저장한다.

[0077] 학습이 완료된 학습 모델이 저장되면 임계치 생성에 필요한 불확실성 정보를 산출한다. (320) 불확실성 정보는 학습이 완료된 모델에 검증 데이터를 입력하고 난 후 출력되는 데이터에 기초하여 산출한다. 산출된 불확실성 정보에 기초하여 불확실성 정보의 평균과 표준편차를 계산한다. 불확실성 정보 산출과정에서 MC-dropout기법이 제안될 수 있다.

[0078] 불확실성 정보 산출이 완료되면, 네트워크의 품질 모니터링을 수행한다. (3 30) 이 과정에서 모니터링의 대상이 되는 네트워크 데이터, 초기 임계치, 학습 모델, 임계치 생성을 위한 불확실성 정보 등이 필요하다. 모니터링 과정에서 산출된 이상치 스코어 및 업데이트된 임계치에 기초하여 네트워크 품질의 이상 여부를 판단할 수

있다.

[0079] 도 4는 본 개시의 기술적 사상에 의한 일 실시 예에 따른 학습 모델의 학습 단계의 순서를 개략적으로 도시한 도면이다.

[0080] 구체적으로 다음 과정을 통해 적어도 하나의 데이터에 대한 학습을 수행한다.

[0081] ⅰ) 학습 모델(f_θ)를 초기화한다. (410)

[0082] ⅱ) 입력 레이어(210)를 통해 적어도 하나의 학습 데이터를 입력하고, 히든 레이어(220)를 통해 데이터를 인코딩한다. (420)

[0083] ⅲ) 인코딩된 데이터를 다시 디코딩하여 출력 레이어(230)를 통해 출력한다. (420)

[0084] ⅳ) 학습이 완료되면 완료된 모델 (f^*_θ)을 저장한다. (430) 완료된 모델(f^*_θ)은 임계치 생성에 필요한 불확실성 정보 및 이상치 스코어 산출 등에 이용될 수 있다.

[0085] 학습 모델(f_θ)에 이용되는 데이터는 학습 데이터 일 수 있다. 학습 데이터는 정상 데이터로만 구성될 수 있다. 일 예로, 학습 모델(f_θ)은 오코인코더를 포함하는 학습 모델일 수 있다.

[0086] 학습 데이터는 정상 데이터로만 구성된 데이터 셋(D_{train})일 수 있다. 적어도 하나의 학습 데이터가 입력되면 학습 모델(f_θ)을 통한 학습을 수행한다. 학습을 수행하여 입력 데이터를 인코딩 한 후 다시 디코딩 했을 때의 출력 데이터가 입력 데이터와 같은 결과를 출력하는 것을 목표로 한다. 다만 항상 출력 데이터가 입력 데이터와 같을 수는 없으므로 최적의 학습결과를 도출하기 위해서 입력 데이터와 출력 데이터의 차이인 손실(Loss)을 최소화하는 방법으로 학습을 수행할 수 있다. 손실함수는 Mean Square Error(MSE)가 사용될 수 있다. 손실함수 MSE의 수식은 $MSE = \frac{1}{n}\sum_{i=1}^{n}|Xi - Yi|^2$ 이다. X_i는 학습 모델(f_θ)에 입력되는 적어도 하나의 학습 데이터이고, Y_i는 출력 데이터, N은 학습 데이터의 개수를 의미한다.

[0087] 도 5는 본 개시의 기술적 사상에 의한 일 실시 예에 따른 임계치 생성에 필요한 불확실성 정보 산출과정을 개략적으로 도시한 도면이다. 이 과정에서는 임계치를 생성할 때 필요한 정보를 산출한다.

[0088] 불확실성이란 학습 모델의 예측결과를 얼마나 신뢰할 수 있는지를 나타내는 지표이다. 다시 말해, AI 학습 모델의 학습에 사용된 데이터의 패턴과 이상치 스코어 산출을 위하여 AI 학습 모델에 입력되는 검증 데이터 및 모니터링의 대상이 되는 네트워크 데이터의 패턴의 유사도를 나타내는 지표로서, 불확실성 정보는 상기 불확실성을 표준편차로 수치화 한 것이다. 모델의 학습 결과는 확률적인 예측 결과를 제공한다는 점에서, 상기 예측 결과가 얼마나 신뢰성 있는지에 대한 정규화 과정이 필요할 수 있다. 따라서 불확실성이 크면 학습 모델의 신뢰도는 낮다고 할 수 있고, 불확실성이 작다면 학습 모델의 신뢰도는 높다고 할 수 있다.

[0089] 또한, 모니터링 대상이 되는 네트워크 데이터가 모델이 학습한 패턴과 유사한 패턴을 보이면 불확실성을 낮게 하고, 모델이 학습한 패턴과 다른 패턴을 보이면 불확실성을 높게 할 수 있다. 따라서 불확실성이 작으면 임계치를 높여 네트워크 품질이 정상으로 판단되도록 할 수 있고, 불확실성이 크면 임계치를 낮춰 네트워크 품질이 이상으로 판단되도록 할 수 있다.

[0090] 상기 불확실성 정보는 동적으로 업데이트되는 임계치의 산출에 이용될 수 있다.

[0091] 도 5에 도시된 바와 같이 불확실성 정보 산출은 다음과 같은 과정을 통해 수행된다.

[0092] ⅰ) 상기 학습과정(400)을 통해 학습이 완료된 학습 모델(f^*_θ)에 검증 데이터(D_{valid})를 입력한다. (510)

[0093] ⅱ) 입력된 검증 데이터(D_{valid})에 기초하여, 히든레이어로 데이터를 인코딩한다. (520)

[0094] ⅲ) 인코딩된 데이터를 다시 디코딩하여 출력한다. (520)

[0095] ⅳ) 상기 입력 데이터 및 출력 데이터에 기초하여 불확실성 정보를 산출한다. (520)

[0096] 검증 데이터(D_{valid})는 AI 학습 모델을 통해 평가되는 데이터가 상기 AI 학습 모델의 학습 과정이 타당했는지와

관련된다. 상기 검증 데이터(D_{valid})는 정상 데이터로 구성될 수도 있다. 또한 상기 검증 데이터(D_{valid})는 시계열 특성을 가진 시퀀스 데이터로 구성될 수도 있다.

[0097] 이상치란 정상 범위에 있지 아니한 데이터를 의미하고, 이상치 스코어는 이상치 여부에 대해 수치화 한 것으로서, AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된다.

[0098] 이상치 스코어는 AI 학습 모델을 통해 평가되는 데이터 및 출력 데이터의 차로 정의 될 수 있다. AI 학습 모델을 통해 평가되는 데이터는 검증 데이터 또는 네트워크 데이터가 될 수 있다. 입력 데이터가 2개 이상인 경우 또는 MC-dropout을 한 경우에는 각각의 차이의 평균값이 이상치 스코어가 될 수 있다.

[0099] 불확실성 정보는 상기 AI 학습 모델을 통해 평가되는 데이터 및 출력 데이터들의 차이에 기초한 표준편차로 정의될 수 있다.

[0100] 다시 말해, 정상 데이터로만 구성된 검증 데이터(D_{valid})를 상기 과정을 통해 학습이 완료된 모델(f^*_Θ)에 입력하고, 결과를 출력한다. (510) 이상치 스코어는 출력 데이터와 입력 데이터의 차이 또는 이들의 평균을 의미한다. 또한 이상치 코어들의 표준편차를 불확실성 정보라고 한다. 상기 불확실성 정보를 이용하여 불확실성 정보의 평균(μ_{un})과 불확실성 정보의 표준편차(σ_{un}) 등을 계산할 수 있다. (520) 상기 불확실성 정보의 평균 (μ_{un})과 불확실성 정보의 표준편차(σ_{un})는 임계치 산출에 이용된다. 상기 출력 데이터는 MC-dropout을 통해 출력된 데이터일 수 있다.

[0101] 상기 이상치 스코어 및 불확실성 정보는 네트워크 데이터 모니터링 과정에서도 산출될 수 있다.

[0102] 도 6은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 실제 네트워크 품질을 모니터링 하는 순서를 개략적으로 도시한 도면이다.

[0103] 도 6을 참조하면, 도 5의 불확실성 정보의 산출이 완료되면 네트워크 품질 모니터링 과정이 수행된다. 모니터링 단계에서는 모니터링의 대상이 되는 네트워크 데이터(X_{new})와 초기 임계치(τ_{init})과 불확실성 정보의 평균 및 표준편차(μ_{un} , σ_{un}) 등이 필요하다.

[0104] 모니터링의 대상이 되는 네트워크 데이터(X_{new})를 학습이 완료된 오토인코더(f^*_Θ)에 입력하여 출력 데이터를 산출한다. (610) 모니터링의 대상이 되는 네트워크 데이터(X_{new})에 기초한 이상치 스코어와 임계치 산출에 필요한 추가적인 불확실성 정보를 산출한다. 추가적인 불확실성 정보 산출 과정에서 MC-dropout 기법이 사용될 수 있다.

[0105] 학습 모델을 통해 데이터가 출력되면 모니터링의 대상이 되는 각 입력 데이터(X_{new})와 출력 데이터 $(\hat{\chi}_i)$의 차이에 기초하여 이상치 스코어를 산출할 수 있다. 이상치 스코어가 2개 이상이 산출되는 경우 이들의 평균(S^*_{new})(640) 및 표준편차(U_{new})(630)를 계산한다. 다시 말해 상기 평균(S^*_{new})을 이상치 스코어라고 한다. 상기 표준편차(U_{new})를 모니터링의 대상이 되는 데이터에 기반한 불확실성 정보라고 한다.

[0106] 상기 표준편차 (U_{new})는 업데이트 되는 임계치 산출에 활용된다. 상기 이상치 스코어(S^*_{new})는 임계치와 함께 네트워크 품질을 판단할 때 활용된다. 상기 불확실성 정보 (U_{new}) 와 이상치 스코어(S^*_{new})의 산출 수식은 다음과 같다.

[0107] (불확실성 정보와 이상치 스코어 산출 수식)

[0108] $S_i = |Xi - Yi|$ (i는 1부터 N까지)

[0109] $S^*_{new} = \frac{1}{N}\sum_{i=1}^{N} Si$,

[0110] $U_{new} = \sqrt{VAR(Si)}$

[0111] 산출된 이상치 스코어(S^{*}_{new}) 및 업데이트 된 임계치에 기초하여 네트워크 품질을 판단할 수 있다. (660)

[0112] 네트워크 품질 판단의 일 예로, 상기 이상치 스코어(S^{*}_{new})가 상기 업데이트 된 임계치보다 작거나 같다고 하면 네트워크 품질은 정상으로 판단하고, 상기 이상치 스코어(S^{*}_{new})가 상기 임계치보다 크다고 하면 네트워크 품질에 이상이 있는 것으로 판단할 수 있다.

[0113] 상기 업데이트되는 임계치는 아래 수식에 의해 산출될 수 있다.

[0114] (임계치 계산 수식)

[0115] $$\tau = max(\tau_{init} - \alpha \cdot (\frac{u_t - \mu_{u_n}}{\sigma_{u_n}} - \beta),\ \frac{1}{2}k \cdot \sigma_{e_n}\ )$$

[0116] 네트워크 품질은 임계치(τ)와 이상치 스코어(S^{*}_{new})에 기초하여 판단된다.

[0117] 업데이트 되는 임계치(τ)는 임계치의 초기 값(τ_{init}) 와 정규화 함수에 의해 정규화된 불확실성 정보에 기초하여 산출될 수 있다. 임계치의 초기 값(τ_{init})은 검증 데이터에 기초하여 산출된 불확실성 정보에 사용자가 설정한 상수 K를 곱한 값으로 설정 될 수 있다. 업데이트 되는 임계치가 과도하게 크거나, 작아지는 것을 방지하기 위해 파라미터를 활용 할 수 있다. 일 예로, 임계치가 과도하게 작아지는 현상을 방지하기 위해 업데이트 되는 임계치는 임계치의 초기 값의 A배수가 넘지 않도록 설정될 수 있다. 바람직하게는 A는 0에서 1사이의 실수 중 하나가 되도록 설정 될 수 있다.

[0118] 업데이트 되는 임계치는 임계치의 초기 값과 정규화 함수에 의해 정규화된 불확실성 정보의 차로 결정될 수 있다.

[0119] 정규화된 불확실성 정보는 u_t, μ_{un}, σ_{un}에 기초하여 결정될 수 있다.

[0120] 정규화 함수는 아래의 수식으로 정의될 수 있다.

[0121] (정규화 함수)

[0122] $$F = \frac{u_t - \mu_{u_n}}{\sigma_{u_n}}$$

[0123] u_t는 모니터링 시점(t시점)에 모니터링의 대상이 되는 네트워크 데이터에 기초하여 산출된 불확실성 정보로서 모니터링의 대상이 되는 네트워크 데이터에 기초하여 산출된 이상치 스코어들의 표준편차를 의미한다. μ_{un}은 검증 데이터에 기초하여 산출된 불확실성 정보의 평균, σ_{un}은 검증 데이터에 기초하여 산출된 불확실성 정보의 표준편차를 의미한다. 임계치가 과도하게 크거나 작게 업데이트 되는 것을 방지하기 위해 사용자에 의해 설정될 수 있는 하이퍼 파라미터(α, β)로 임계치를 조정할 수 있다.

[0124] α는 임계치의 초기 값(τ_{init})과 정규화된 불확실성 $\frac{u_t - \mu_{u_n}}{\sigma_{u_n}} - \beta$ 의 스케일을 맞춰주는 하이퍼 파라미터, β는 상기 제1 불확실성 정보에 대한 유의 수준으로서 상기 네트워크 데이터를 정상으로 인정하는 범위와 관련된 하이퍼 파라미터를 의미한다. .

[0125] α 및 β는 사용자가 설정할 수 있다.

[0126] $K * \sigma_{en}$ 는 임계치의 초기 값과 같다.

[0127] 다시 말해, 임계치는 임계치의 초기 값과 정규화된 불확실성 정보의 차이에 기초하되, 임계치의 초기 값의 일정

비율로 하한선이 결정될 수 있다.

[0128] 도 7은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 MC-dropout을 이용한 불확실성 정보 및 이상치 스코어를 계산하는 과정을 개략적으로 도시한 도면이다.

[0129] MC-Dropout은 불확실성 정보 산출과정에서 학습 모델의 임의의 노드를 제외시키는 방식이다. MC-Dropout의 횟수는 사용자가 지정한 임의의 횟수일 수 있다. 다시 말해, 하나의 입력 데이터에 대해 하나의 출력 데이터를 산출하는 것이 아니라, 사용자가 지정한 횟수만큼 출력 데이터가 산출 된다.

[0130] 예를 들어, 10개의 노드가 있다고 했을 때, 학습 모델을 통하여 하나의 입력 데이터(X_{new})에 대해서 하나의 출력 데이터$(\hat{\chi}_i)$을 발생시키는 것이 아니라,사용자가 10회 MC-dropout을 하는 것으로 설정하면, 회차 별로 임의의 노드를 계산에 참여시키지 않는 형태로 10회의 MC-dropout을 반복하여 10개의 출력 데이터 $(\hat{\chi}_1 \sim \hat{\chi}_{10})$를 각각 발생시킨다. 각 dropout별 출력데이터$(\hat{\chi}_i)$와 입력 데이터(X_{new})의 차이(S_i)의 평균 (S^*_{new})과 표준편차(U_{new})를 계산할 수 있다. 상기 평균(S^*_{new})은 이상치 스코어를 의미하고, 표준편차(U_{new})는 불확실성 정보를 의미한다. 이러한 불확실성 정보를 산출하는 과정을 불확실성 정량화라고도 한다.

[0131] 수식으로 표현하면 다음과 같다.

[0132] $S_i = |X_{new} - \hat{\chi}_i|$ (X_{new}는 학습 모델에 입력되는 입력 데이터, $\hat{\chi}_i$는 MC-dropout별 출력 데이터)

[0133] $S^*_{new} = \frac{1}{N}\sum_{i=1}^{N} Si$ (N은 MC-dropout의 횟수)

[0134] $U_{new} = \sqrt{VAR(Si)}$

[0135] 도 8은 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질의 이상 여부를 확인하는 순서를 개략적으로 도시한 도면이다.

[0136] 도 8을 참조하면 장치가 네트워크의 품질을 모니터링은, i) AI(Artificial Intelligence) 학습 모델을 통해 평가된 상기 네트워크의 품질에 관련된 이상치 스코어를 산출하는 과정과 ii) 상기 이상치 스코어 및 임계치에 기초하여 상기 네트워크의 품질 이상 여부를 판단으로 수행된다. 상기 임계치는, 상기 AI 학습 모델의 학습에 사용된 제1 데이터와 상기 이상치 스코어 산출을 위하여 상기 AI 학습 모델에 입력된 제2 데이터 간의 유사도와 관련된 불확실성 정보에 기초하여 동적으로 업데이트 될 수 있다.

[0137] 도 9는 본 개시의 기술적 사상에 의한 일 실시 예에 따른 네트워크 품질 모니터링을 위한 장치의 구성을 간략히 도시한 블록도이다.

[0138] 통신부(920)는 네트워크 품질 모니터링을 위한 입력 데이터를 수신할 수 있다. 통신부(920)는 유무선 통신부를 포함 할 수 있다. 통신부(920)는 근거리 통신망(Local Area Network; LAN), 광역 통신망(Wide Area Network; WAN), 부가가치 통신망(Value Added Network; VAN), 이동 통신망 (mobile radio communication network), 위성 통신망 및 이들의 상호 조합을 통하여 통신을 하게 하는 하나 이상의 구성요소를 포함할 수 있다. 또한, 통신부(920)는 셀룰러 통신, 무선랜(예를 들어, 와이-파이(Wi-Fi)) 등을 이용하여 무선으로 데이터 또는 신호를 송수신할 수 있다. 입력부(930)는 다양한 사용자 명령을 수신할 수 있다. 입력부(930)는 하나 이상의 입력 장치를 포함하거나 연결할 수 있다.

[0139] 예를 들어, 입력부(930)는 키보드 등의 인터페이스와 연결될 수 있고, USB 포트 등의 인터페이스를 포함할 수도 있다. 또한, 입력부(930)는 터치스크린 등의 다양한 입력 장치를 포함 하거나 이들과 결합되어 외부의 사용자 명령을 수신할 수 있다.

[0140] 메모리(940)는 프로세서(910)의 동작을 위한 프로그램을 저장할 수 있고, 입/출력되는 데이터들을 임시 또는 영구 저장할 수 있다. 메모리(940)는 램(RAM), SRAM, 롬(ROM), EEPROM, PROM, 자기 메모리, 자기 디스크, 광디스크, 하드디스크(hard disk) 타입, 멀티미디어 카드 마이크로(multimedia card micro) 타입, 플래시 메모리

(flash memory) 타입, 카드 타입의 메모리(예를 들어 SD 또는 XD 메모리 등) 중 적어도 하나의 타입의 저장매체를 포함할 수 있다.

[0141] 또한, 메모리(940)는 다양한 함수 및 알고리즘을 저장할 수 있으며, 장치(900)를 구동하고 제어하기 위한 다양한 데이터, 어플리케이션, 소프트웨어, 명령, 코드 등을 저장할 수 있다.

[0142] 프로세서(910)는 장치(900)의 전반적인 동작을 제어할 수 있다. 프로세서(910)는 메모리(940)에 저장되는 하나 이상의 프로그램들을 실행할 수 있다. 프로세서(910)는 중앙 처리 장치(Central Processing Unit, CPU), 그래픽 처리 장치(Graphics Processing Unit, GPU) 또는 본 개시의 기술적 사상에 따른 방법들이 수행되는 전용의 프로세서를 의미할 수 있다.

[0143] 일 실시 예에서, 프로세서(910)는 네트워크 품질 모니터링을 위하여, 오토인코더를 통해 데이터에 대하여 AI 모델 학습을 수행하도록 제어할 수 있다.

[0144] 일 실시 예에서, 프로세서(910)는 학습 모델에 입력되는 데이터 및 학습 모델에 의하여 출력되는 데이터에 기초하여 이상치 스코어를 산출할 수 있으며, 산출된 이상치 스코어와 임계치에 기초하여 네트워크 품질을 판단하도록 제어할 수 있다.

[0145] 본 개시의 기술적 사상에 의한 다양한 실시 예에 따르면, 입력 데이터에 최대한 가깝도록 출력된 출력 데이터 중 니즈에 맞는 출력 데이터를 활용할 수 있으므로, 본 네트워크 품질 모니터링 방법의 활용 가능성이 넓어질 수 있다.

[0146] 일 실시 예에 따른 네트워크 품질 모니터링 방법은 다양한 컴퓨터 수단을 통하여 수행될 수 있는 프로그램 코드로 구현되어 컴퓨터 판독 가능 매체에 기록될 수 있다. 상기 컴퓨터 판독 가능 매체는 프로그램 명령, 데이터 파일, 데이터 구조 등을 단독으로 또는 조합하여 포함할 수 있다. 상기 매체에 기록되는 프로그램 명령은 본 개시를 위하여 특별히 설계되고 구성된 것들이거나 컴퓨터 소프트웨어 통상의 기술자에게 공지되어 사용 가능한 것일 수도 있다. 컴퓨터 판독 가능 기록 매체의 예에는 하드 디스크, 플로피 디스크 및 자기 테이프와 같은 자기 매체(magnetic media), CD-ROM, DVD와 같은 광기록 매체(optical media), 플롭티컬 디스크(floptical disk)와 같은 자기-광매체(magneto-optical media), 및 롬(ROM), 램(RAM), 플래시 메모리 등과 같은 프로그램 명령을 저장하고 수행하도록 특별히 구성된 하드웨어 장치가 포함된다. 프로그램 명령의 예에는 기계어 코드뿐만 아니라 컴퓨터에 의해서 실행될 수 있는 고급 언어 코드를 포함한다.

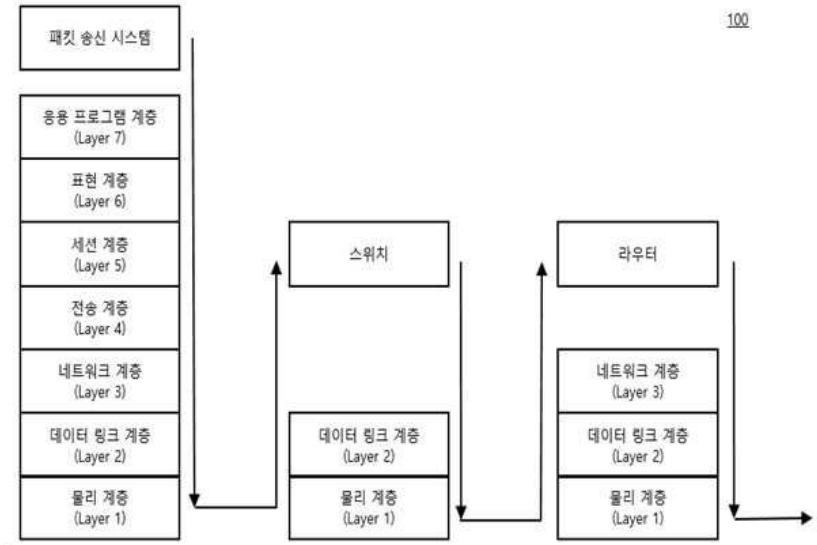
[0147] 또한, 개시된 실시 예들에 따른 네트워크 품질 모니터링 방법은 컴퓨터 프로그램 제품(computer program product)에 포함되어 제공될 수 있다.

[0148] 컴퓨터 프로그램 제품은 S/W 프로그램, S/W 프로그램이 저장된 컴퓨터로 읽을 수 있는 저장 매체를 포함할 수 있다. 예를 들어, 컴퓨터 프로그램 제품은 전자 장치의 제조사 또는 전자 마켓을 통해 전자적으로 배포되는 S/W 프로그램 형태의 상품을 포함할 수 있다. 이 경우, 저장 매체는 서버 또는 프로그램을 저장하는 중계 서버의 저장매체가 될 수 있다.

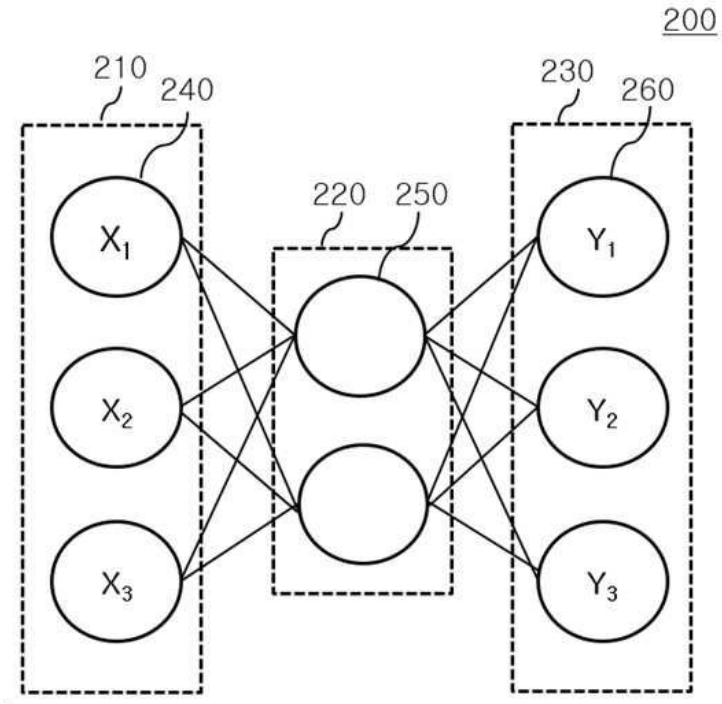
[0149] 이상에서 실시 예들에 대하여 상세하게 설명하였지만 본 개시의 권리범위는 이에 한정되는 것은 아니고 다음의 청구범위에서 정의하고 있는 본 개시의 기본 개념을 이용한 통상의 기술자의 여러 변형 및 개량 형태 또한 본 개시의 권리범위에 속한다.

도면

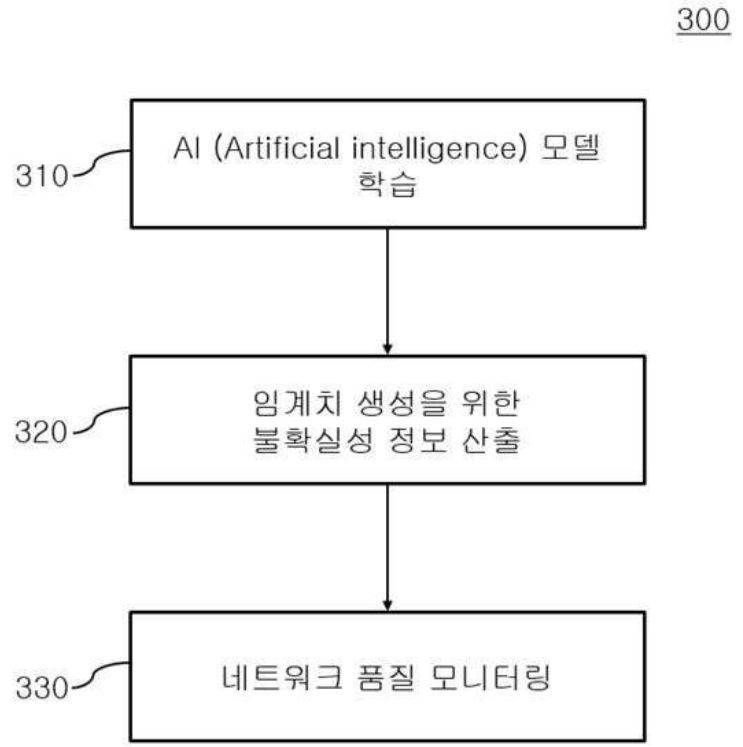
도면1


100
패킷 송신 시스템
응용 프로그램 계층
(Layer 7)
표현 계층
(Layer 6)
세션 계층
(Layer 5)
전송 계층
(Layer 4)
네트워크 계층
(Layer 3)
데이터 링크 계층
(Layer 2)
물리 계층
(Layer 1)
스위치
데이터 링크 계층
(Layer 2)
물리 계층
(Layer 1)
라우터
네트워크 계층
(Layer 3)
데이터 링크 계층
(Layer 2)
물리 계층
(Layer 1)

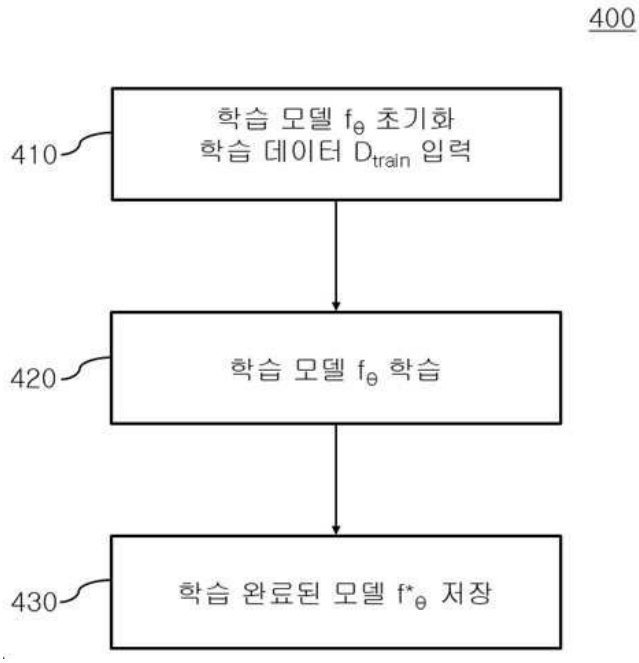
도면2


200
210
240
220
250
230
260
X1
X2
X3
Y1
Y2
Y3

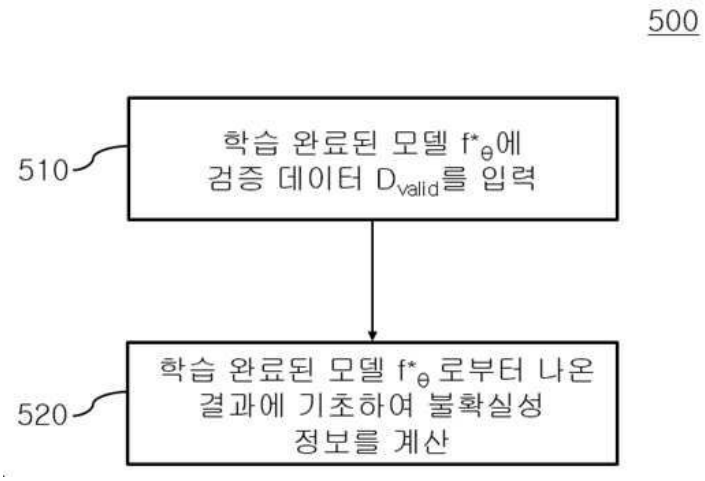
도면3


300
AI (Artificial intelligence) 모델 학습
310
임계치 생성을 위한 불확실성 정보 산출
320
네트워크 품질 모니터링
330

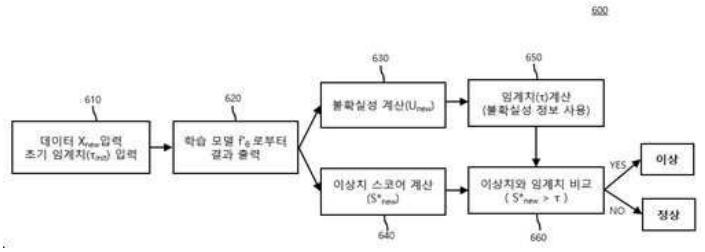
도면4


400
학습 모델 f_θ 초기화
학습 데이터 D_{train} 입력
410
학습 모델 f_θ 학습
420
학습 완료된 모델 f^*_θ 저장
430

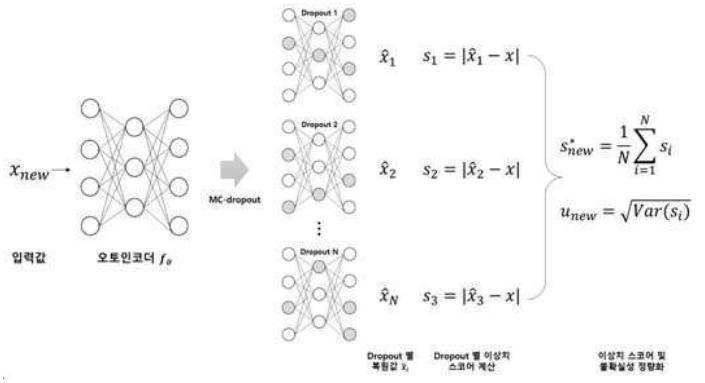
도면5


500
510
학습 완료된 모델 f^*_θ에
검증 데이터 D_{valid}를 입력
520
학습 완료된 모델 f^*_θ로부터 나온
결과에 기초하여 불확실성
정보를 계산

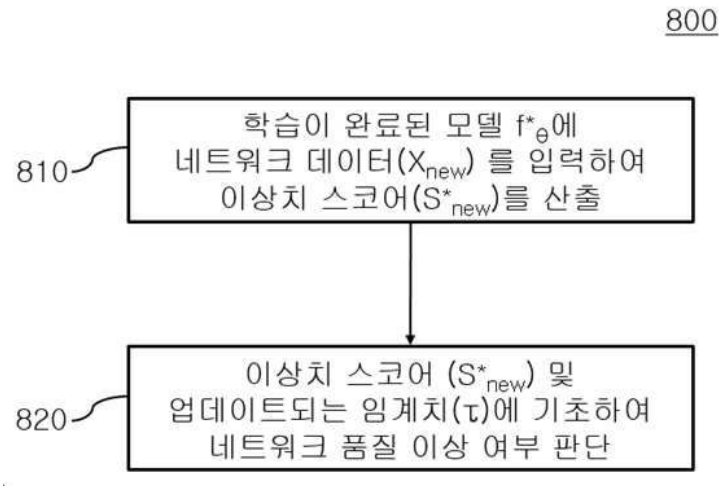
도면6


600
610
데이터 X_{new}입력
초기 임계치(τ_{init}) 입력
620
학습 모델 f^*_θ로부터
결과 출력
630
불확실성 계산(U_{new})
640
이상치 스코어 계산
(S^*_{new})
650
임계치(τ)계산
(불확실성 정보 사용)
660
이상치와 임계치 비교
($S^*_{new} > \tau$)
YES
NO
이상
정상

도면7


x_{new}
입력값
오토인코더 f_θ
MC-dropout
Dropout 1
Dropout 2
Dropout N
$\hat{x}_1$ $s_1 = |\hat{x}_1 - x|$
$\hat{x}_2$ $s_2 = |\hat{x}_2 - x|$
$\hat{x}_N$ $s_3 = |\hat{x}_3 - x|$
$s^*_{new} = \frac{1}{N}\sum_{i=1}^{N} s_i$
$u_{new} = \sqrt{Var(s_i)}$
Dropout 별 복원값 $\hat{x}_i$
Dropout 별 이상치 스코어 계산
이상치 스코어 및 불확실성 정량화

도면8


800
학습이 완료된 모델 f^*_θ에
네트워크 데이터(X_{new}) 를 입력하여
이상치 스코어(S^*_{new})를 산출
810
이상치 스코어 (S^*_{new}) 및
업데이트되는 임계치(τ)에 기초하여
네트워크 품질 이상 여부 판단
820

도면9


900
프로세서
(910)
통신부(920)
입력부(930)
메모리(940)