(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2024-0167365
(43) 공개일자 2024년11월26일

(51) 국제특허분류(Int. Cl.)
G06N 3/09 (2023.01) *G06N 3/04* (2023.01)
(52) CPC특허분류
G06N 3/09 (2023.01)
G06N 3/04 (2023.01)
(21) 출원번호 10-2023-0104583
(22) 출원일자 2023년08월10일
심사청구일자 2023년08월10일
(30) 우선권주장
1020230065187 2023년05월19일 대한민국(KR)

(71) 출원인
고려대학교 산학협력단
서울특별시 성북구 안암로 145, 고려대학교 (안암동5가)
(72) 발명자
김미정
서울특별시 종로구 비봉1길 22-4 삼진파크맨션 나동 102호
(74) 대리인
특허법인위솔

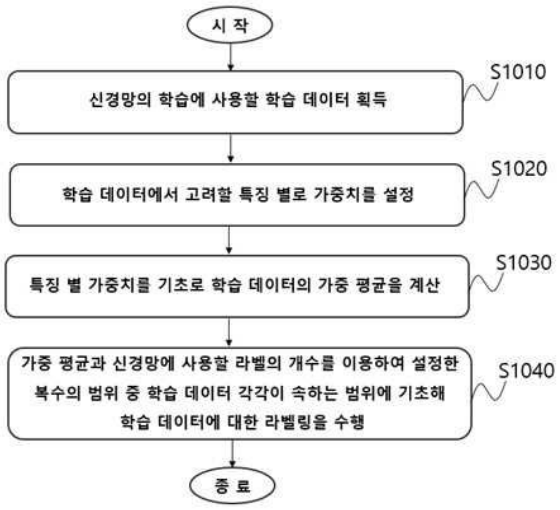
전체 청구항 수 : 총 11 항

(54) 발명의 명칭 **지도 학습 기반의 신경망에 사용될 학습 데이터의 자동 라벨링 방법 및 이를 위한 장치**

(57) 요 약

일 실시 예에 따른 자동 라벨링 장치는 신경망의 학습에 사용할 학습 데이터를 획득하는 동작; 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 특징 별 가중치를 기초로 학습 데이터의 가중 평균을 계산하는 동작; 및 가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 학습 데이터 각각이 속하는 범위에 기초해 학습 데이터에 대한 라벨링을 수행하는 동작; 구축된 친환경 신경망 이용 및/또는 갱신을 통해 새로 발생한 데이터에 대해 라벨링을 수행하는 동작 또는 오퍼레이션을 실행할 수 있다

대 표 도 - 도2



이 발명을 지원한 국가연구개발사업

과제고유번호	1711182753
과제번호	2019R1A2C1002706
부처명	과학기술정보통신부
과제관리(전문)기관명	한국연구재단
연구사업명	개인기초연구(과기정통부)
연구과제명	5세대 네트워크 기술을 위한 데이터 트래픽 모델링및 예측 기술 연구: 머신러닝 및 시계열 분석 접근법
기 여 율	1/1
과제수행기관명	고려대학교
연구기간	2023.03.01 ~ 2024.02.29

명 세 서

청구범위

청구항 1

프로세서 및 메모리를 포함하는 자동 라벨링 장치의 자동 라벨링 방법에 있어서,

신경망의 학습에 사용할 학습 데이터를 획득하는 동작;

상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작;

상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및

상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작;

을 포함하는 방법.

청구항 2

제1항에 있어서,

상기 학습 데이터 중 로우 데이터가 $\{X_i\}_{i=1}^{m}$ (m은 로우 데이터의 개수)이고, 각 로우 데이터의 특징을 n개로 설정하여, i번째 로우 데이터 X_i 에 대한 각 특징값의 표현을 $\boldsymbol{X}_i = (X_{i,1}, \cdots, X_{i,n})$ 로 할 때,

상기 가중치를 설정하는 동작은

하기 수학식 1을 기초로 각 특징 별로 가중치 a_j 를 설정하는 동작을 포함하는,

[수학식 1]

$$X_{i,w} = \sum_{j=1}^{n} a_j X_{i,j},$$

($X_{i,w}$ 는 $\boldsymbol{X}_i$ 에 가중치가 설정된 데이터, a_j 는 $X_{i,j}$ 의 가중치, n은 특징의 개수)

방법.

청구항 3

제2항에 있어서,

상기 가중 평균을 계산하는 동작은

하기 수학식 2를 기초로 상기 학습 데이터의 가중 평균 Ave_w 을 계산하는 동작을 포함하는,

[수학식 2]

$$Ave_w = \frac{1}{m} \sum_{i=1}^{m} X_{i,w}.$$

($X_{i,w}$ 는 $\boldsymbol{X}_i$ 에 가중치가 설정된 데이터, m은 데이터의 개수)

방법.

청구항 4

제3항에 있어서,

상기 라벨링을 수행하는 동작은

상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 하기 수학식 3을 기초로 상기 학습 데이터를 복수의 범위로 분류하여, 상기 학습 데이터 각각에 대한 라벨링을 수행하는 동작을 포함하는,

[수학식 3]

$$Y_i = \begin{cases} k, & \text{if } \dfrac{2k}{L+1} Ave_w \le X_{i,w} < \dfrac{2(k+1)}{L+1} Ave_w, k = 0, \cdots, L, \\ 0, & \text{if } X_{i,w} < 0, \\ L, & \text{if } X_{i,w} \ge 2Ave_w. \end{cases}$$

(k 는 신경망에 사용하는 각각의 라벨값, L 은 라벨의 최대값, Y_i 는 $X_{i,w}$ 가 속하는 범위에 따라 할당된 라벨)

방법.

청구항 5

제1항에 있어서,

상기 라벨링이 된 학습 데이터를 $\{(\boldsymbol{X},Y)\} = \{(\boldsymbol{X}_i,Y_i)\}_{i=1}^{m}$ (X는 학습 데이터, Y는 라벨, i는 학습 데이터를 특정하는 인덱스, m은 학습 데이터의 개수)라고 할 때

상기 라벨링을 수행하는 동작은

상기 데이터 집합 $\{(\boldsymbol{X},Y)\} = \{(\boldsymbol{X}_i,Y_i)\}_{i=1}^{m}$ 에 대해 하기 수학식 1을 기초로 min-max 변환을 수행하여, 학습 집합 $\{(\boldsymbol{x}_i,y_i)\}_{i=1}^{m_1}$ ($m_1 = m \times r$, r은 상기 데이터 집합에서 학습 집합에 사용될 비율, $r \in (0,1)$)을 생성하는 동작을 포함하는,

[수학식 4]

$$\text{min-max}(x_{ij}) = \frac{x_{ij} - \min(\mathbf{x}^i)}{\max(\mathbf{x}^i) - \min(\mathbf{x}^i)}, j = 1, \cdots, n,$$

($\boldsymbol{x}^i$ 는 $\{\boldsymbol{x}_i\}_{i=1}^{m}$ 의 번째 특징으로 이루어진 열벡터)

방법.

청구항 6

제1항에 있어서,

상기 방법은

상기 라벨링이 수행된 학습 데이터를 기초로 상기 신경망을 생성하는 동작을 더 포함하고,

상기 학습 데이터를 제1 학습 데이터로 지칭할 때, 상기 제1 학습 데이터와 다른 제2 학습 데이터가 새롭게 획득되는 경우, 상기 방법은

상기 제2 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작;

상기 특징 별 가중치를 기초로 상기 제2 학습 데이터의 가중 평균을 계산하는 동작;

상기 제2 학습 데이터의 가중 평균과 상기 신경망에 사용할 라벨의 개수를 기초로 설정한 복수의 범위 중 상기 제2 학습 데이터 각각이 속하는 범위에 기초하여, 상기 제2 학습 데이터에 대한 라벨링을 수행하는 동작; 및

상기 라벨링이 수행된 제2 학습 데이터와 상기 신경망을 기초로 상기 제2 학습 데이터에 대한 최종 라벨을 결정하는 동작을 더 포함하는,

방법.

청구항 7

제6항에 있어서,

상기 최종 라벨을 결정하는 동작은

상기 신경망을 통해 상기 제2 학습 데이터에 대해 출력된 제2 라벨을 도출하는 동작; 및

상기 라벨링에 의한 제1 라벨과 상기 출력에 의한 제2 라벨 중 상기 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 상기 제2 학습 데이터의 최종 라벨로 결정하는 동작을 포함하는,

방법.

청구항 8

제6항에 있어서,

상기 최종 라벨을 결정하는 동작은

상기 제1 학습 데이터 및 상기 제2 학습 데이터를 기초로 상기 신경망의 가중치를 갱신하는 동작; 상기 갱신된 신경망을 통해 상기 제2 학습 데이터에 대해 출력된 제2 라벨을 도출하는 동작; 및

상기 라벨링에 의한 제1 라벨과 상기 출력에 의한 제2 라벨 중 상기 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 상기 제2 학습 데이터의 최종 라벨로 결정하는 동작을 포함하는,

방법.

청구항 9

제8항에 있어서,

상기 신경망의 가중치를 갱신하는 동작은

상기 제1 학습 데이터의 개수에서 상기 제2 학습 데이터의 개수 만큼 제외한 개수의 제1 학습 데이터와 상기 제2 학습 데이터를 이용하여 상기 신경망의 가중치를 갱신하는 동작을 포함하는

방법.

청구항 10

명령어를 포함하는 메모리; 및

상기 명령어를 실행하는 프로세서를 포함하고,

상기 프로세서의 동작은,

신경망의 학습에 사용할 학습 데이터를 획득하는 동작;

상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작;

상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및

상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작;

을 포함하는 장치.

청구항 11

컴퓨터 판독 가능 기록매체에 저장되어 있는 컴퓨터 프로그램으로서,

상기 컴퓨터 프로그램은, 프로세서에 의해 실행되면,

신경망의 학습에 사용할 학습 데이터를 획득하는 동작;

상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작;

상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및

상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작;

을 포함하는 방법을 상기 프로세서가 수행하도록 하기 위한 명령어를 포함하는 컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램.

발명의 설명

기 술 분 야

[0001] 본 발명은 지도 학습 기반의 신경망에 사용될 학습 데이터의 자동 라벨링 방법 및 이를 위한 장치에 관한 것이다. 보다 자세하게는 지도 학습 기반의 신경망에 사용될 학습 데이터를 소정의 기준에 따라 자동으로 라벨링함으로써 신경망의 학습에 활용하는 방법 및 이를 위한 장치에 관한 것이다.

배 경 기 술

[0002] 빅데이터는 통신, 생태, 환경, 의학, 경제 등을 아우르는 다양한 분야에서 활용되고 있으며, 딥러닝은 빅데이터를 이용하여 예측 문제를 다루는데 활용되고 있다.

[0003] 신경망의 학습 방법 중 학습에 사용할 학습 데이터가 의미하는 바를 특정하는 라벨을 데이터에 라벨링하고, 라벨링된 학습 데이터를 이용하여 신경망의 가중치를 갱신시키는 학습 방법을 지도 학습이라고 한다. 일반적으로 지도 학습은 라벨링 작업이 필요하지 않은 비지도 학습에 비해 더 정확한 예측이 가능하다는 장점이 있다.

[0004] 다만, 이러한 지도 학습의 장점은 학습 데이터에 정확한 라벨링이 되어 있다는 점이 전제된 것이다. 앞선 전제와 달리 부정확한 라벨이 할당된 학습 데이터를 이용하여 학습된 신경망은 매우 부정확한 성능을 나타내기 때문에, 잘못된 라벨링 작업은 경제적 손실을 포함한 다양한 불이익을 초래할 수 있다.

[0005] 또한, 학습 데이터의 라벨링을 수행하는 기존 방법은 빅데이터를 다루는 전문가의 지식에 지나치게 의존할 뿐만 아니라, 많은 인력과 비용을 필요로 한다는 단점이 존재하다.

[0006] 이에 따라, 지도 학습에 필요한 기존 라벨링 과정의 문제를 극복하고, 정확하면서 신속한 라벨링 과정을 달성하기 위한 새로운 기술이 요구되고 있다.

선행기술문헌

특허문헌

[0007] (특허문헌 0001) 대한민국 공개특허공보 제10-2537695호(2022.06.29)

발명의 내용

해결하려는 과제

[0008] 본 발명이 해결하고자 하는 기술적 과제는 학습 데이터에 대한 라벨을 소정 기준에 따라 자동으로 할당함으로써, 실시간으로 생성되는 데이터에 대한 라벨링을 즉각적으로 수행할 뿐만 아니라, 라벨이 할당된 데이터를 활용하여 실시간으로 해당 데이터와 관련된 새로운 데이터를 기초로 원하는 출력값을 예측하는 신경망을 생성하는 기술을 제공하는 것이다.

[0009] 본 발명의 기술적 과제들은 이상에서 언급한 기술적 과제들로 제한되지 않으며, 언급되지 않은 또 다른 기술적 과제들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

과제의 해결 수단

[0010] 상기 기술적 과제를 달성하기 위한 본 발명의 일 실시 예에 따른 자동 라벨링 장치가 수행하는 방법은 신경망의 학습에 사용할 학습 데이터를 획득하는 동작; 상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및 상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작을 포함할 수 있다.

[0011] 일 실시 예에 따르면, 상기 학습 데이터 중 로우 데이터(raw data)가 $\{X_i\}_{i=1}^{m}$ (m은 로우 데이터의 개수)이고, 각 로우 데이터의 특징을 n개로 설정하여, i번째 로우 데이터 X_i에 대한 각 특징값의 표현을 $X_i = (X_{i,1}, \cdots, X_{i,n})$ 로 할 때, 상기 가중치를 설정하는 동작은 하기 수학식 1을 기초로 각 특징 별로 가중치 a_j 를 설정하는 동작을 포함할 수 있다.

[0012] [수학식 1]

[0013] $$X_{i,w} = \sum_{j=1}^{n} a_j X_{i,j},$$

[0014] ($X_{i,w}$ 는 X_i 에 가중치가 설정된 데이터, a_j 는 $X_{i,j}$ 의 가중치, n은 특징의 개수)

[0015] 일 실시 예에 따르면, 상기 가중 평균을 계산하는 동작은 하기 수학식 2를 기초로 상기 학습 데이터의 가중 평균 Ave_w 을 계산하는 동작을 포함할 수 있다.

[0016] [수학식 2]

[0017] $$Ave_w = \frac{1}{m} \sum_{i=1}^{m} X_{i,w}.$$

[0018] ($X_{i,w}$ 는 X_i 에 가중치가 설정된 데이터, m은 데이터의 개수)

[0019] 일 실시 예에 따르면, 상기 라벨링을 수행하는 동작은 상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 하기 수학식 3을 기초로 상기 학습 데이터를 복수의 범위로 분류하여, 상기 학습 데이터 각각에 대한 라벨링을 수행하는 동작을 포함할 수 있다.

[0020] [수학식 3]

$$Y_i = \begin{cases} k, & \text{if } \dfrac{2k}{L+1} Ave_w \le X_{i,w} < \dfrac{2(k+1)}{L+1} Ave_w, k = 0, \cdots, L, \\ 0, & \text{if } X_{i,w} < 0, \\ L, & \text{if } X_{i,w} \ge 2Ave_w. \end{cases}$$

[0021]

[0022] (k는 신경망에 사용하는 각각의 라벨값, L은 라벨의 최대값, Y_i는 $X_{i,w}$가 속하는 범위에 따라 할당된 라벨)

[0023] 일 실시 예에 따르면, 상기 라벨링이 된 학습 데이터를 $\{(\boldsymbol{X},Y)\} = \{(\boldsymbol{X}_i, Y_i)\}_{i=1}^{m}$(X는 학습 데이터, Y는 라벨, i는 학습 데이터를 특정하는 인덱스, m은 학습 데이터의 개수)라고 할 때, 상기 라벨링을 수행하는 동작은 상기 데이터 집합 $\{(\boldsymbol{X},Y)\} = \{(\boldsymbol{X}_i, Y_i)\}_{i=1}^{m}$에 대해 하기 수학식 4를 기초로 min-max 변환을 수행하여, 학습 집합 $\{(\boldsymbol{x}_i, y_i)\}_{i=1}^{m_1}$($m_1 = m \times r$, r은 상기 데이터 집합에서 학습 집합에 사용될 비율, $r \in (0,1)$)을 생성하는 동작을 포함할 수 있다.

[0024] [수학식 4]

$$\text{min-max}(x_{ij}) = \frac{x_{ij} - \min(\mathbf{x}^i)}{\max(\mathbf{x}^i) - \min(\mathbf{x}^i)}, j = 1, \cdots, n,$$

[0025]

[0026] (x^i는 $\{\boldsymbol{x}_i\}_{i=1}^{m}$의 번째 특징으로 이루어진 열벡터)

[0027] 일 실시 예에 따르면, 상기 방법은 상기 라벨링이 수행된 학습 데이터를 기초로 상기 신경망을 생성하는 동작을 더 포함하고, 상기 학습 데이터를 제1 학습 데이터로 지칭할 때, 상기 제1 학습 데이터와 다른 제2 학습 데이터가 새롭게 획득되는 경우, 상기 방법은 상기 제2 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 상기 특징 별 가중치를 기초로 상기 제2 학습 데이터의 가중 평균을 계산하는 동작; 상기 제2 학습 데이터의 가중 평균과 상기 신경망에 사용할 라벨의 개수를 기초로 설정한 복수의 범위 중 상기 제2 학습 데이터 각각이 속하는 범위에 기초하여, 상기 제2 학습 데이터에 대한 라벨링을 수행하는 동작; 및 상기 라벨링이 수행된 제2 학습 데이터와 상기 신경망을 기초로 상기 제2 학습 데이터에 대한 최종 라벨을 결정하는 동작을 더 포함할 수 있다.

[0028] 일 실시 예에 따르면, 상기 최종 라벨을 결정하는 동작은 상기 신경망을 통해 상기 제2 학습 데이터에 대해 출력된 제2 라벨을 도출하는 동작; 및 상기 라벨링에 의한 제1 라벨과 상기 출력에 의한 제2 라벨 중 상기 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 상기 제2 학습 데이터의 최종 라벨로 결정하는 동작을 포함할 수 있다.

[0029] 일 실시 예에 따르면, 상기 최종 라벨을 결정하는 동작은 상기 제1 학습 데이터 및 상기 제2 학습 데이터를 기초로 상기 신경망의 가중치를 갱신하는 동작; 상기 갱신된 신경망을 통해 상기 제2 학습 데이터에 대해 출력된 제2 라벨을 도출하는 동작; 및 상기 라벨링에 의한 제1 라벨과 상기 출력에 의한 제2 라벨 중 상기 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 상기 제2 학습 데이터의 최종 라벨로 결정하는 동작을 포함할 수 있다.

[0030] 일 실시 예에 따르면, 상기 신경망의 가중치를 갱신하는 동작은 상기 제1 학습 데이터의 개수에서 상기 제2 학습 데이터의 개수 만큼 제외한 개수의 제1 학습 데이터와 상기 제2 학습 데이터를 이용하여 상기 신경망의 가중치를 갱신하는 동작을 포함할 수 있다.

[0031] 상기 기술적 과제를 달성하기 위한 본 발명의 일 실시 예에 따른 자동 라벨링 장치는 명령어를 포함하는 메모리; 및 상기 명령어를 실행하는 프로세서를 포함하고, 상기 프로세서의 동작은 신경망의 학습에 사용할 학

습 데이터를 획득하는 동작; 상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및 상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작을 포함할 수 있다.

[0032] 상기 기술적 과제를 달성하기 위한 본 발명의 일 실시 예에 따른 컴퓨터 판독 가능 기록매체에 저장되어 있는 컴퓨터 프로그램으로서, 상기 컴퓨터 프로그램은 프로세서에 의해 실행되면, 신경망의 학습에 사용할 학습 데이터를 획득하는 동작; 상기 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 상기 특징 별 가중치를 기초로 상기 학습 데이터의 가중 평균을 계산하는 동작; 및 상기 가중 평균과 상기 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 상기 학습 데이터 각각이 속하는 범위에 기초해 상기 학습 데이터에 대한 라벨링을 수행하는 동작을 포함하는 방법을 상기 프로세서가 수행하도록 하기 위한 명령어를 포함할 수 있다.

발명의 효과

[0033] 상기와 같은 본 발명에 따르면, 신경망을 통해 데이터에서 관찰하고자 하는 각 특징에 대하여 가중치를 설정하고, 설정된 특징 별 가중치를 기초로 가중 평균을 계산함으로써, 가중 평균과 신경망에서 출력할 라벨의 개수를 기초로 기준 범위를 설정하여 학습 데이터가 속하는 범위를 분류할 수 있다.

[0034] 이에 따라, 본 발명은 이러한 데이터 분석을 통해 분류한 범주를 기초로 데이터의 특성을 잘 나타내는 중요한 특징을 추출하고, 이를 기반으로 데이터에 자동으로 라벨을 할당할 수 있게 한다.

[0035] 이를 통해, 본 발명은 시간과 자원이 많이 소요되는 기존의 라벨링 과정에 대한 단점을 극복하고, 실시간으로 생성되는 데이터에 대한 라벨링을 즉각적으로 수행할 뿐만 아니라, 라벨이 할당된 데이터를 활용하여 실시간으로 해당 데이터와 관련된 새로운 데이터를 기초로 원하는 출력값을 예측하는 신경망을 생성할 수 있게 한다.

[0036] 나아가, 본 발명의 기술은 다양한 빅데이터의 라벨링 과정에 사용될 수 있다. 예를 들면, 전자, 환경, 의료, 보건 등의 다양한 분야의 빅데이터와 신경망 모델에 적용하여 사용할 수 있다.

[0037] 본 발명의 효과들은 이상에서 언급한 효과들로 제한되지 않으며, 언급되지 않은 또 다른 효과들은 아래의 기재로부터 통상의 기술자에게 명확하게 이해될 수 있을 것이다.

도면의 간단한 설명

[0038] 도 1은 일 실시 예에 따른 자동 라벨링 장치가 포함하는 전체 구성을 예시적으로 도시한 도면이다.

도 2는 일 실시 예에 따라 자동 라벨링 장치가 수행하는 자동 라벨링 방법의 대표적인 단계를 나타낸 순서도이다.

도 3은 일 실시 예에 따라 자동 라벨링 장치가 신경망을 생성하는 단계를 나타낸 순서도이다.

도 4는 일 실시 예에 따라 ELM(Extreme Learning Machine)을 기초로 설계한 신경망의 구조를 예시적으로 도시한 도면이다.

도 5는 제1 실시 예에 따라 자동 라벨링 장치가 제2 학습 데이터에 대한 라벨링을 수행하는 단계를 나타낸 순서도이다.

도 6은 제2 실시 예에 따라 자동 라벨링 장치가 제2 학습 데이터에 대한 라벨링을 수행하는 단계를 나타낸 순서도이다.

도 7은 상술한 도 2, 도 3, 도 5, 도 6의 실시 예에 따른 자동 라벨링 방법의 동작을 연결하여 수학식의 표현과 함께 예시적으로 도시한 도면이다.

발명을 실시하기 위한 구체적인 내용

[0039] 본 발명의 목적과 기술적 구성 및 그에 따른 작용 효과에 관한 자세한 사항은 본 발명의 명세서에 첨부된 도면에 의거한 이하의 상세한 설명에 의해 보다 명확하게 이해될 것이다. 첨부된 도면을 참조하여 본 발명에 따른 실시 예를 상세하게 설명한다.

[0040] 본 명세서에서 개시되는 실시 예들은 본 발명의 범위를 한정하는 것으로 해석되거나 이용되지 않아야 할 것이다. 이 분야의 통상의 기술자에게 본 명세서의 실시 예를 포함한 설명은 다양한 응용을 갖는다는 것이 당연

하다. 따라서, 본 발명의 상세한 설명에 기재된 임의의 실시 예들은 본 발명을 보다 잘 설명하기 위한 예시적인 것이며 본 발명의 범위가 실시 예들로 한정되는 것을 의도하지 않는다.

[0041] 도면에 표시되고 아래에 설명되는 기능 블록들은 가능한 구현의 예들일 뿐이다. 다른 구현들에서는 상세한 설명의 사상 및 범위를 벗어나지 않는 범위에서 다른 기능 블록들이 사용될 수 있다. 또한, 본 발명의 하나 이상의 기능 블록이 개별 블록들로 표시되지만, 본 발명의 기능 블록들 중 하나 이상은 동일 기능을 실행하는 다양한 하드웨어 및 소프트웨어 구성들의 조합일 수 있다.

[0042] 또한, 어떤 구성요소들을 포함한다는 표현은 "개방형"의 표현으로서 해당 구성요소들이 존재하는 것을 단순히 지칭할 뿐이며, 추가적인 구성요소들을 배제하는 것으로 이해되어서는 안 된다.

[0043] 나아가 어떤 구성요소가 다른 구성요소에 "연결되어" 있다거나 "접속되어" 있다고 언급될 때에는, 그 다른 구성요소에 직접적으로 연결 또는 접속되어 있을 수도 있지만, 중간에 다른 구성요소가 존재할 수도 있다고 이해되어야 한다.

[0044] 이하에서는 도면들을 참조하여 본 발명의 세부적인 실시 예들에 대해 살펴보도록 한다.

[0045] 도 1은 일 실시 예에 따른 자동 라벨링 장치(100)(이하, '장치(100)'로 지칭)가 포함하는 전체 구성을 예시적으로 도시한 도면이다.

[0046] 그러나 이는 본 발명의 목적을 달성하기 위한 바람직한 실시 예일 뿐이며, 필요에 따라 일부 구성이 추가되거나 삭제될 수 있고, 어느 한 구성이 수행하는 역할을 다른 구성이 함께 수행할 수도 있음은 물론이다.

[0047] 일 실시 예에 따른 장치(100)는 프로세서(10), 네트워크 인터페이스(20), 메모리(30), 스토리지(40) 및 이들을 연결하는 데이터 버스(50)를 포함할 수 있으며, 기타 본 발명의 목적을 달성함에 있어 요구되는 부가적인 구성들을 더 포함할 수 있음은 물론이라 할 것이다.

[0048] 프로세서(10)는 각 구성의 전반적인 동작을 제어한다. 프로세서(10)는 CPU(Central Processing Unit), MPU(Micro Processer Unit), MCU(Micro Controller Unit) 또는 본 발명이 속하는 기술 분야에서 널리 알려져 있는 형태의 인공지능 프로세서 중 어느 하나일 수 있다. 아울러, 프로세서(10)는 일 실시 예에 따른 장치(100)가 수행하는 동작 또는 오퍼레이션을 수행하기 위한 적어도 하나의 애플리케이션 또는 프로그램에 대한 연산을 수행할 수 있다.

[0049] 네트워크 인터페이스(20)는 일 실시 예에 따른 장치(100)의 유무선 인터넷 통신을 지원하며, 그 밖의 공지의 통신 방식을 지원할 수도 있다. 따라서 네트워크 인터페이스(20)는 그에 따른 통신 모듈을 포함하여 구성될 수 있다.

[0050] 메모리(30)는 각종 정보, 명령 및/또는 정보를 저장하며, 일 실시 예에 따른 장치(100)가 수행하는 동작 또는 오퍼레이션을 수행하기 위해 스토리지(40)로부터 하나 이상의 컴퓨터 프로그램(41)을 로드할 수 있다. 도 1에서는 메모리(30)의 하나로 RAM을 도시하였으나 이와 더불어 다양한 저장 매체를 메모리(30)로 이용할 수 있음은 물론이다.

[0051] 스토리지(40)는 하나 이상의 컴퓨터 프로그램(41)을 비임시적으로 저장할 수 있다. 이러한 스토리지(40)는 ROM(Read Only Memory), EPROM(Erasable Programmable ROM), EEPROM(Electrically Erasable Programmable ROM), 플래시 메모리 등과 같은 비휘발성 메모리, 하드 디스크(HDD), 보조 저장 매치(SSD), 착탈형 디스크, 또는 본 발명이 속하는 기술 분야에서 널리 알려져 있는 임의의 형태의 컴퓨터로 읽을 수 있는 기록 매체 중 어느 하나일 수 있다.

[0052] 컴퓨터 프로그램(41)은 메모리(30)에 로드되어, 하나 이상의 프로세서(10)에 의해, 신경망의 학습에 사용할 학습 데이터를 획득하는 동작; 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 특징 별 가중치를 기초로 학습 데이터의 가중 평균을 계산하는 동작; 및 가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 학습 데이터 각각이 속하는 범위에 기초해 학습 데이터에 대한 라벨링을 수행하는 동작 또는 오퍼레이션을 실행할 수 있다.

[0053] 이상 간단하게 언급한 컴퓨터 프로그램(41)이 수행하는 동작 또는 오퍼레이션은 컴퓨터 프로그램(41)의 일 기능으로 볼 수 있으며, 보다 자세한 설명은 일 실시 예에 따른 장치(100)가 수행하는 방법에 대한 설명에서 후술하도록 한다.

[0054] 데이터 버스(50)는 이상 설명한 프로세서(10), 네트워크 인터페이스(20), 메모리(30) 및 스토리지(40) 사이의

명령 및/또는 정보의 이동 경로가 된다.

[0055] 이상 간단하게 설명한 일 실시 예에 따른 장치(100)는 독립된 디바이스의 형태, 예를 들어 전자 기기나 서버(클라우드 포함)의 형태일 수 있으며, 여기서 전자 기기는 한 장소에 고정 설치되어 사용하는 데스크톱 PC, 서버 디바이스 등과 같은 기기 뿐만 아니라, 스마트폰, 태블릿 PC, 노트북 PC, PDA, PMP 등과 같이 휴대가 용이한 포터블 기기 등이라도 무방한바, 프로세서(10)에 해당하는 CPU 등이 설치되고 네트워크 기능만 보유하고 있는 전자 기기라면 어떠한 것이라도 무방하다 할 것이다. 예를 들어, 일 실시 예에 따른 장치(100)는 독립된 디바이스인 전자 기기 형태 중 "서버"의 형태로 구현될 수 있다. 또한, 일 실시 예에 따른 장치(100)는 독립된 디바이스인 전자 기기 형태 중 서버가 제공하는 애플리케이션 또는 서비스를 이용하기 위해 사용자가 소지하는 "단말"의 형태로 구현될 수 있다.

[0056] 이하, 일 실시 예에 따른 장치(100)가 수행하는 방법에 대하여 도 2 내지 도 7을 참조하여 설명하도록 한다.

[0057] 도 2는 일 실시 예에 따라 장치(100)가 수행하는 자동 라벨링 방법의 대표적인 단계를 나타낸 순서도이다.

[0058] 도 2에 개시된 각 단계는 일 실시 예에 따른 장치(100)를 통해 수행될 수 있고, 구체적으로 각 단계의 동작은 프로세서(10)가 수행하는 동작으로 이해될 수 있다.

[0059] 도 2에 개시된 각 단계는 본 발명의 목적을 달성함에 있어서 바람직한 실시 예일 뿐이며, 필요에 따라 일부 단계가 추가 또는 삭제될 수 있음은 물론이고, 어느 한 단계가 다른 단계에 포함되어 수행될 수도 있다.

[0060] 도 2에 개시된 각 동작의 순서는 이해의 편의를 위해 배치된 순서일 뿐, 이러한 순서가 시계열적인 순서로 한정되는 것이 아니며, 설계자의 선택에 따라 순서가 다르게 변경되어 동작될 수 있다.

[0061] 도 2를 참조하면, S1010 단계에서, 장치(100)는 신경망의 학습에 사용할 학습 데이터를 획득할 수 있다.

[0062] 학습 데이터 중 로우 데이터를 $\{X_i\}_{i=1}^{m}$ (m은 로우 데이터의 개수)로 표현하고, 각 로우 데이터의 특징을 n개로 특정하여 사용한다면, i번째 로우 데이터 X_i 에 대한 각 특징값을 $\boldsymbol{X}_i = (X_{i,1}, \cdots, X_{i,n})$ 로 표현할 수 있다.

[0063] 다음으로, S1020 단계에서, 장치(100)는 학습 데이터에서 고려할 특징 별로 가중치를 설정(가중치가 모두 1인 경우를 포함)할 수 있다. 예를 들어, 가중치는 신경망을 통해 데이터에서 관찰하고자 하는 각 특징의 중요도에 기초하여 설정될 수 있다. 학습 데이터의 특징 별 가중치는 하기 수학식 1을 기초로 설정될 수 있다.

수학식 1

[0064]
$$X_{i,w} = \sum_{j=1}^{n} a_j X_{i,j},$$

[0065] ($X_{i,w}$ 는 X_i 에 가중치가 설정된 데이터, a_j 는 $X_{i,j}$ 의 가중치, n은 특징의 개수)

[0066] 다음으로, S1030 단계에서, 장치(100)는 특징 별 가중치를 기초로 하기 수학식 2와 같이 학습 데이터의 가중 평균 Ave_w 을 계산할 수 있다.

수학식 2

[0067]
$$Ave_w = \frac{1}{m} \sum_{i=1}^{m} X_{i,w}.$$

[0068] ($X_{i,w}$ 는 X_i 에 가중치가 설정된 데이터, m은 데이터의 개수)

[0069] 다음으로, S1040 단계에서, 장치(100)는 가중 평균 Ave_w 과 신경망에 사용할 라벨의 개수 (L+1)를 기초로 소정의 범위를 설정하여 학습 데이터가 속하는 범위를 분류할 수 있다. 예를 들어, 장치(100)는 하기 수학식 3을 기초로 설정한 복수의의 범위 중 학습 데이터 각각이 속하는 범위에 기초해 학습 데이터에 대한 라벨링을 수행할 수 있다.

수학식 3

[0070]
$$Y_i = \begin{cases} k, & \text{if } \frac{2k}{L+1} Ave_w \le X_{i,w} < \frac{2(k+1)}{L+1} Ave_w, k = 0, \cdots, L, \\ 0, & \text{if } X_{i,w} < 0, \\ L, & \text{if } X_{i,w} \ge 2 Ave_w. \end{cases}$$

[0071] (k 는 신경망에 사용할 각각의 라벨값이고 k 는 자연수를 포함함, L 은 라벨의 최대값, Y_i 는 $X_{i,w}$가 속하는 범위에 따라 X_i 에 할당되는 라벨값)

[0072] 도 3은 일 실시 예에 따라 장치(100)가 신경망을 생성하는 단계를 나타낸 순서도이다.

[0073] 도 3을 참조하면, S2010 단계에서, 장치(100)는 라벨링이 수행된 학습 데이터에 대한 전처리를 수행할 수 있다.

[0074] 학습 데이터 X_i 에 할당된 라벨을 Y_i 로 표현하기로 할 때, 라벨이 매핑된 데이터 집합을 $\{(X,Y)\} = \{(X_i,Y_i)\}_{i=1}^{m}$ 로 표기하기로 한다.

[0075] 이때 장치(100)는 로우 데이터 집합 $\{(X,Y)\} = \{(X_i,Y_i)\}_{i=1}^{m}$ 에 대해 하기 수학식 4를 기초로 min-max 변환을 수행하여, 학습 집합 $\{(x_i,y_i)\}_{i=1}^{m_1}$ ($m_1 = m \times r$, r은 데이터 집합 중 학습 집합에 사용될 비율, $r \in (0,1)$) 을 생성하는 동작을 포함할 수 있다.

수학식 4

[0076]
$$\text{min-max}(x_{ij}) = \frac{x_{ij} - \min(\mathbf{x}^i)}{\max(\mathbf{x}^i) - \min(\mathbf{x}^i)}, j = 1, \cdots, n,$$

[0077] (x^i 는 $\{x_i\}_{i=1}^{m}$ 의 i번째 특징으로 이루어진 열벡터)

[0078] 다음으로, S2020 단계에서, 장치(100)는 신경망의 은닉 레이어에 대한 정보를 설정할 수 있다. 장치(100)는 은닉 레이어의 활성화 함수 f, 은닉 레이어의 노드 개수 k_0 및 $\{k_p\}_{p=1}^{P}$ (p는 은닉 레이어를 특정하는 인덱스)를 포함하는 은닉 레이어에 대한 정보를 설정할 수 있다.

[0079] 예를 들어, 장치(100)는 일 실시 예에 따른 신경망을 ELM(Extreme Learning Machine)를 기초로 네트워크를 설

계할 수 있다.

[0080] 도 4는 일 실시 예에 따라 ELM(Extreme Learning Machine)을 기초로 설계한 신경망의 구조를 예시적으로 도시한 도면이다.

[0081] 도 4를 참조하면, ELM은 딥러닝 신경망의 은닉층에서 사용되는 가중치 행렬 및 바이어스 등의 하이퍼파라미터를 조절할 필요가 없이, 여러 유형의 활성화 함수의 기능과 함께 작동할 수 있는 신경망 설계를 사용한다. 즉, ELM은 딥러닝 신경망에서 하이퍼파라미터의 튜닝 시간을 제거하여 빠르게 학습하므로 반복적인 실행으로 인한 시간 소모적인 기존 딥러닝의 단점을 극복한 것이며, 이러한 ELM의 설계에 본 발명의 실시 예를 적용하는 경우, 보다 효과적으로 가중치를 초기 설정할 수 있다.

[0082] 상술한 도 4의 신경망 설계는 이해의 편의를 돕기 위한 예시일 뿐, 본 발명의 실시 예가 반드시 위 예시에 한정되는 것은 아니다.

[0083] 한편, S2020 단계의 활성화 함수 f, 은닉 레이어의 노드 개수 k_0 및 $\{k_p\}_{p=1}^{P}$(p는 은닉 레이어를 특정하는 인덱스)를 기초로 한 신경망의 정보는 아래와 같은 기호로 표현될 수 있다.

[0084] 대문자 P는 최종 은닉 레이어를 특정하는 인덱스이다. 소문자 p는 각 은닉 레이어를 특정하는 인덱스이다. $\boldsymbol{W}^p = (w_{u,v}^p)$는 $(p-1)$ 번째 은닉 레이어에 있는 노드와 p 번째 은닉 레이어에 있는 노드 사이의 가중치 행렬을 의미한다. $\boldsymbol{b}^p = (b_u^p)$ 에서 b_u^p는 p 번째 은닉 레이어에 있는 노드 u에 할당된 바이어스 값을 의미한다.

[0085] 이때 가중치 행렬 $\boldsymbol{W} = (w_{u,v}^p)$ 과 바이어스 행렬 $\boldsymbol{b}^p = (b_u^p)$ 은 하기 수학식 5와 같이 나타낼 수 있다.

수학식 5

$$\boldsymbol{W}^p = \begin{bmatrix} \boldsymbol{w}_1^p & \boldsymbol{w}_2^p & \cdots & \boldsymbol{w}_{k_{p-1}}^p \end{bmatrix}^{\mathrm{T}} = \begin{bmatrix} w_{11}^p & w_{12}^p & \cdots & w_{1k_p}^p \\ \vdots & \vdots & \cdots & \vdots \\ w_{k_{p-1}1}^p & w_{k_{p-1}2}^p & \cdots & w_{k_{p-1}k_p}^p \end{bmatrix}^{\mathrm{T}} = \begin{bmatrix} w_{11}^p & w_{12}^p & \cdots & w_{k_{p-1}1}^p \\ \vdots & \vdots & \cdots & \vdots \\ w_{1k_p}^p & w_{2k_p}^p & \cdots & w_{k_{p-1}k_p}^p \end{bmatrix}_{k_p \times k_{p-1}}$$

$$\boldsymbol{b}^p = \begin{bmatrix} b_1^p \\ \vdots \\ b_{k_{p-1}}^p \end{bmatrix},$$

[0086]

[0087] 수학식 5에서 T는 전치행렬을 나타내고, 활성화 함수 f는 실수에서 정의된 유한한 함수값을 갖는 함수이다.

[0088] 수학식 5에 따르면 H_1 을 하기 수학식 6과 같이 표현할 수 있다.

수학식 6

$$H_1 = f(\boldsymbol{W}^1 \cdot \boldsymbol{x} + \boldsymbol{b}^1) = \begin{bmatrix} f(\boldsymbol{w}_1^1 \cdot \boldsymbol{x}_1 + b_1^1) & f(\boldsymbol{w}_2^1 \cdot \boldsymbol{x}_1 + b_2^1) & \cdots & f(\boldsymbol{w}_{k_1}^1 \cdot \boldsymbol{x}_1 + b_{k_1}^1) \\ \vdots & \vdots & \cdots & \vdots \\ f(\boldsymbol{w}_1^1 \cdot \boldsymbol{x}_m + b_1^1) & f(\boldsymbol{w}_2^1 \cdot \boldsymbol{x}_m + b_2^1) & \cdots & f(\boldsymbol{w}_{k_1}^1 \cdot \boldsymbol{x}_m + b_{k_1}^1) \end{bmatrix}$$
$$= \begin{bmatrix} f(h_{1,1}^1 + b_1^1) & f(h_{1,2}^1 + b_2^1) & \cdots & f(h_{1,k_1}^1 + b_{k_1}^1) \\ \vdots & \vdots & \cdots & \vdots \\ f(h_{m,1}^1 + b_1^1) & f(h_{m,2}^1 + b_2^1) & \cdots & f(h_{m,k_1}^1 + b_{k_1}^1) \end{bmatrix}_{m \times k_1},$$

[0089]

[0090] H_1 를 편의상 $H_1 = \boldsymbol{W}^1 \boldsymbol{x}$ 로 나타내면 $\{H_p\}_{p=1}^{\mathrm{P}}$ 는 하기 수학식 7과 같이 표현할 수 있다.

수학식 7

$$H_1 = \boldsymbol{W}^1 \boldsymbol{x}, H_2 = \boldsymbol{W}^2 (\boldsymbol{W}^1 \boldsymbol{x}) = f(\boldsymbol{W}^2 \cdot H_1 + \boldsymbol{b}^2), \cdots, H_{\mathrm{P}} = \boldsymbol{W}^{\mathrm{P}} (\boldsymbol{W}^{\mathrm{P}-1} \cdots \boldsymbol{W}^1 \boldsymbol{x}) = f(\boldsymbol{W}^{\mathrm{P}} \cdot H_{\mathrm{P}-1} + \boldsymbol{b}^{\mathrm{P}}).$$

[0091]

[0092] ELM의 경우, p 번째 출력 행렬 H_p 는 하기 수학식 8과 같이 표현될 수 있다.

수학식 8

$$H_p = f(\boldsymbol{W}^p \cdot H_{p-1} + \boldsymbol{b}^p)$$
$$= \begin{bmatrix} f(\boldsymbol{w}_1^p \cdot H_{p-1}(1) + b_1^p) & f(\boldsymbol{w}_2^p \cdot H_{p-1}(1) + b_2^p) & \cdots & f(\boldsymbol{w}_{k_p}^p \cdot H_{p-1}(1) + b_{k_p}^p) \\ \vdots & \vdots & \cdots & \vdots \\ f(\boldsymbol{w}_1^p \cdot H_{p-1}(k_{p-1}) + b_1^p) & f(\boldsymbol{w}_2^p \cdot H_{p-1}(k_{p-1}) + b_2^p) & \cdots & f(\boldsymbol{w}_{k_p}^p \cdot H_{p-1}(k_{p-1}) + b_{k_p}^p) \end{bmatrix}$$
$$= \begin{bmatrix} f(h_{1,1}^p + b_1^p) & f(h_{1,2}^p + b_2^p) & \cdots & f(h_{1,k_p}^p + b_{k_p}^p) \\ \vdots & \vdots & \cdots & \vdots \\ f(h_{k_{p-1},1}^p + b_1^p) & f(h_{k_{p-1},2}^p + b_2^p) & \cdots & f(h_{k_{p-1},k_p}^p + b_{k_p}^p) \end{bmatrix}_{k_{p-1} \times k_p},$$

[0093]

[0094] 수학식 8에서 $\boldsymbol{w}_i^p \cdot H_{p-1}(j)$ 는 $\boldsymbol{w}_i^p$ 와 H_{p-1} 의 j번째 행과의 내적이다. 최종 출력 $\boldsymbol{y}^{out}$ 는 출력벡터 $\begin{bmatrix} y_1^{out} & \cdots & y_m^{out} \end{bmatrix}^{\mathrm{T}}$ 로 $H_{\mathrm{P}} \boldsymbol{W}^{out} = \boldsymbol{y}^{out}$ 풀어서 구할 수 있다. 구체적으로, y_i^{out} 는 하기 수학식 9와 같이 구할 수 있다.

수학식 9

$$y_i^{out} = \sum_{j=1}^{k_P} w_j^{out} f\left[\boldsymbol{W}^P \cdot H_{P-1}(i) + b_j^P \right] \equiv \boldsymbol{W}^{out} \cdot H_P(i),\ i = 1, \cdots, m.$$

[0095]

[0096] 수학식 9에서 W^{out} 는 최종 은닉 레이어의 노드와 출력 레이어의 노드 사이의 가중치 행렬이다.

[0097] 이때, S2020 단계에서, 장치(100)는 상기 최종 은닉 레이어와 출력 레이어 사이의 가중치 행렬의 랭크 $r(W^p)$ 가 최대가 되도록, 은닉 레이어의 가중치 행렬 및 바이어스 행렬 $\{W^p, b^p\}_{p=1}^P$ 의 초기값을 설정할 수 있다.

[0098] 예를 들어, 장치(100)는 입력 레이어로부터 출력 레이어로 향하는 방향으로 각 은닉 레이어에 대해, p번째(p는 은닉 레이어를 특정하는 인덱스) 레이어의 출력 함수 H_p 의 랭크 $r(H_p)$ 가 p번째 레이어의 출력 함수의 행의 개수 또는 열의 개수 중의 최소값($\min(k_{p-1}, k_p)$)과 같은지 판별할 수 있다. 이 경우, 장치(100)는 해당 판별에서 $r(H_p) = \min(k_{p-1}, k_p)$ 를 만족하지 않는다면, 기 설정된 횟수만큼 p번째 레이어의 바이어스를 갱신하여 p번째 레이어의 출력 함수 H_p 를 갱신함으로써, 가중치 행렬의 랭크 $r(W^p)$ 가 최대가 되도록 은닉 레이어의 가중치 행렬 및 바이어스 행렬 $\{W^p, b^p\}_{p=1}^P$ 의 초기값을 재설정할 수 있다.

[0099] 다음으로, S2030 단계에서, 장치(100)는 학습 데이터를 이용해 얻은 예측값과 실제값 간의 오차 최소화를 기반으로 얻은 최종 은닉 레이어의 출력 행렬에 대한 랭크에 기초해 최종 가중치 행렬에 적용할 무어-펜로즈 일반화 역행렬을 결정하여 최종 가중치 행렬을 설정할 수 있다.

[0100] S2030 단계의 구체적 예시를 설명하기에 앞서, 설명의 이해에 필요한 수학적 정의에 대해 먼저 설명하기로 한다.

[0101] [정의 1]

[0102] $HG = I_m$ $(GH = I_n)$ 를 만족하는 경우, G를 H의 우(또는 좌)의사 역행렬(right(left) pseudo-inverse)이라 정의한다. 여기서 I_m는 $m \times m$ 단위행렬이다. 우의사 역행렬(right pseudo-inverse)과 좌의사 역행렬(left pseudo-inverse)은 각각 H^{r-} 와 H^{l-} 로 표기한다.

[0103] [정의 2]

[0104] $\mathrm{rank}(H) = r(H) < \min(n, m)$ 라고 할 때,

[0105] [정의 2]-(a).

[0106] $HGH = H$ 및 $GHG = G$ 의 두 등식을 만족하면 G를 H의 일반화 역행렬(generalized inverse)이라 정의한다.

[0107] [정의 2]-(b).

[0108] $HGH = H$, $GHG = G$, $(HG)^{\mathrm{T}} = HG$, $(GH)^{\mathrm{T}} = GH$ 의 네 등식을 만족하면 G를 H의 무어-펜로즈 일반화 역행렬(Moore-Penrose generalized inverse, M-P GI)이라 정의한다. 이때 일반화 역행렬(generalized inverse)은

H^- 로 표기하고, 무어-펜로즈 일반화 역행렬(Moore-Penrose generalized inverse)은 H^+ 로 표기하기로 한다.

[0109] 이어서, S2030 단계에서 최종 가중치 행렬을 설정하는 구체적 예시를 설명한다.

[0110] 먼저, 최종 가중치 행렬 W^{out} 은 $W^{out}=H_P^+ y^{out}$ 에서 하기 수학식 10에 나타나 있는 H_P 의 무어-펜로즈 일반화 역행렬의 극한을 이용하여 구할 수 있다.

[0111] 즉, 최종 가중치 행렬 W^{out} 은 $W^{out}=H_P^+ y^{out}$ 를 통해 도출할 수 있으며, 임의의 $m\times n$ 행렬 H에 대하여 그 행렬의 M-P GI H^+ 는 다음과 같다.

수학식 10

$$H^+=\lim_{\delta\to 0}(H^{\mathrm{T}}H+\delta^2 I_n)^{-1}H^{\mathrm{T}}=\lim_{\delta\to 0}H^{\mathrm{T}}(HH^{\mathrm{T}}+\delta^2 I_m)^{-1}.$$

[0112]

[0113] 여기서, $\mathrm{rank}(H)=r(H)<\min(n,m)$ 라 하면, $G=H^+$ 가 될 수 있는 필요충분조건은 [정의 2]-(b)에 나타난 4개의 등식을 만족하는 것이다. 이때 H^+ 는 항상 존재하고 유일하게 존재한다.

[0114] 이 경우, 최종 은닉 레이어에서 얻은 행렬 H_P 의 랭크에 따라 예측 오차 $E_2=\|y^{out}-y\|_2$ (L_2 norm) 를 확인할 수 있으며, 이는 하기 수학식 11과 같이 최종 레이어의 출력 행렬에 대한 랭크와 학습 데이터에 대한 오차값에 기초해 나타낼 수 있다.

[0115] 즉, 실수에서 정의된 활성화 함수 f가 임의의 유한값을 함수값으로 갖는다고 가정하고, $w_{i,j}^p$와 b_i^p 는 모든 $p=1,\cdots,P$ 에 대해 각각 $\mathbb{R}^{k_{p-1}}$ 와 $\mathbb{R}$ 에서 임의로 선택했다고 하면, 다음 수학식 11 이 성립한다.

수학식 11

$$\begin{cases}
\text{(i) } r(H_P)=k_{P-1}\text{인 경우: } W^{out}=H_P^{r-}y\text{이고 } E_2\equiv 0\\
\text{(ii) } r(H_P)=k_P\text{인 경우}\\
\quad\text{(a) } y\in C(H_P)\text{: } W^{out}=(H_P^{\mathrm{T}}H_P)^{-1}H_P^{\mathrm{T}}y\text{이고 } E_2\equiv 0\\
\quad\text{(b) } y\notin C(H_P)\text{: } W^{apout}=(H_P^{\mathrm{T}}H_P)^{-1}H_P^{\mathrm{T}}y\text{일 때 } E_2\text{는 최소값}\\
\text{(iii) } r(H_P)<\min(k_{P-1},k_P)\text{인 경우}\\
\quad\text{(a) } y\in C(H_P)\text{: } W^{out}\text{의 성분 중에는 자유변수가 있고 } E_2\equiv 0\\
\quad\text{(b) } y\notin C(H_P)\text{: } W^{apout}=(H_P^{\mathrm{T}}H_P)^{+}H_P^{\mathrm{T}}y\text{일 때 } E_2\text{는 최소값}
\end{cases}$$

[0116]

[0117] 여기서, W^{apout} 는 오차가 0이 아닌 경우 가중치 행렬 W^{out} 을 근사한 근사 행렬이고, $C(H_P)$ 는 H_P 의 열

공간(column space)이다. 또한, 수학식 11의 (iii)의 (a)에서 W^{out} 의 성분 중 자유변수의 개수는 $\min(k_{p-1}, k_p) - r(H_p)$. 이다.

[0118] 수학식 11에 따르면, S2030 단계에서, 장치(100)는 최종 레이어의 출력 행렬 H_p 에 대한 랭크 $r(H_p)$ 에 따라 최종 가중치 행렬에 적용할 무어-펜로즈 일반화 역행렬 H_p^{r-}, $(H_p^T H_p)^{-1}$, $(H_p^T H_p)^{+}$ 을 결정하고, 데이터의 예측값과 상기 데이터의 실제값의 L2 norm 오차 E2가 0 인지 또는 0보다 큰 실수인지를 구분한다. 이에 따라 장치(100)는 최종 가중치 행렬 W^{out} (E2가 0인 경우) 또는 W^{apout} (E2가 0이 아닌 경우)을 설정할 수 있다.

[0119] 이하, 도 5 및 도 6에서는 상술한 학습 데이터(이하, '제1 학습 데이터'로 지칭)와는 별도로 새로운 학습 데이터인 '제2 학습 데이터'를 획득한 경우, 장치(100)가 제2 학습 데이터에 대한 라벨을 결정하는 실시 예를 설명한다.

[0120] 도 5는 제1 실시 예에 따라 장치(100)가 제2 학습 데이터에 대한 라벨링을 수행하는 단계를 나타낸 순서도이다. 도 5의 제1 실시 예는 제1 학습 데이터를 사용하여 학습시킨 신경망을 그대로 이용하여 제2 학습 데이터에 대한 최종 라벨을 결정하는 실시 예이다.

[0121] 도 5를 참조하면, S3010 단계에서, 장치(100)는 제2 학습 데이터를 기준으로 상술한 도 2의 S1010 단계 내지 S1040 단계를 적용하여, 제2 학습 데이터에 대한 라벨링을 수행할 수 있다. 이때 제2 학습 데이터에 대해 S1010 단계 내지 S1040 단계를 적용하여 분류된 라벨을 '제1 라벨'로 지칭한다.

[0122] 다음으로, S3020 단계에서, 장치(100)는 제1 학습 데이터를 사용하여 학습시킨 신경망을 통해 제2 학습 데이터에 대한 라벨을 출력시킬 수 있다. 이때 제2 학습 데이터에 대해 신경망이 출력한 라벨을 '제2 라벨'로 지칭한다.

[0123] 다음으로, S3030 단계에서, 장치(100)는 제1 라벨과 제2 라벨 중 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 제2 학습 데이터의 최종 라벨로 결정할 수 있다.

[0124] 도 6은 제2 실시 예에 따라 장치(100)가 제2 학습 데이터에 대한 라벨링을 수행하는 단계를 나타낸 순서도이다. 도 6의 제2 실시 예는 제1 학습 데이터와 제2 학습 데이터를 함께 이용하여 기존의 신경망을 재학습 시킨 후, 재학습시킨 신경망을 이용하여 제2 학습 데이터에 대한 최종 라벨을 결정하는 실시 예이다.

[0125] 도 6을 참조하면, S4010 단계에서, 장치(100)는 제2 학습 데이터를 기준으로 상술한 도 2의 S1010 단계 내지 S1040 단계를 적용하여, 제2 학습 데이터에 대한 라벨링을 수행할 수 있다. 이때 제2 학습 데이터에 대해 S1010 단계 내지 S1040 단계를 적용하여 분류된 라벨을 '제1 라벨'로 지칭한다.

[0126] 다음으로, S3020 단계에서, 장치(100)는 제1 학습 데이터 및 제2 학습 데이터를 이용하여 신경망을 갱신할 수 있다. 예를 들어, 장치(100)는 제1 학습 데이터의 개수에서 제2 학습 데이터의 개수 만큼 제외한 개수의 제1 학습 데이터와, 새로운 제2 학습 데이터를 이용하여 신경망의 가중치를 갱신할 수 있다. 가령, 제1 학습 데이터가 시계열적인 순서로 입력된 것이라면, FIFO(First In, First Out) 방식으로 제1 학습 데이터의 개수 중 제2 학습 데이터의 개수 만큼을 제거하고, 제거된 개수 만큼의 제2 학습 데이터를 추가한 새로운 데이터 집합을 생성하여, 해당 데이터 집합을 이용해 신경망의 가중치를 갱신할 수 있다.

[0127] 다음으로, S3030 단계에서, 장치(100)는 갱신된 신경망을 통해 제2 학습 데이터에 대한 라벨을 출력시킬 수 있다. 이때 제2 학습 데이터에 대해 신경망이 출력한 라벨을 '제2 라벨'로 지칭한다.

[0128] 이후, S3040 단계에서, 장치(100)는 제1 라벨과 제2 라벨 중 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 제2 학습 데이터의 최종 라벨로 결정할 수 있다.

[0129] 다음으로, 도 7을 통해 신경망의 정보를 표현하는 수학식을 사용하여 상술한 도 2, 도 3, 도 5, 도 6의 동작을 연결한 예시를 설명하기로 한다.

[0130] 도 7은 상술한 도 2, 도 3, 도 5, 도 6의 실시 예에 따른 자동 라벨링 방법의 동작을 연결하여 수학식의 표현과 함께 예시적으로 도시한 도면이다.

[0131] 도 7의 모든 STEP은 장치(100)가 수행하는 것으로 이해될 수 있다. 도 7의 STEP 1 내지 STEP 3은 도 2의 동작을 알고리즘의 형태로 분할하여 예시한 것이다. 도 7의 STEP 4 내지 STEP 15는 도 3의 동작을 알고리즘의 형태로 분할하여 예시한 것이다. 도 7의 STEP 16 내지 STEP 19는 도 5 및 도 6의 동작을 알고리즘의 형태로 분할하여 예시한 것이다.

[0132] 도 7을 참조하면, 우선 학습 데이터 $\{X_i\}_{i=1}^{m}$ (m은 로우 데이터의 개수)가 준비될 수 있다.

[0133] STEP 1에서, 학습 데이터의 특징 별 가중치가 $X_{i,w}=\sum_{j=1}^{n}a_jX_{i,j},$ 와 같이 설정될 수 있다.

[0134] STEP 2에서, 특징 별 가중치를 기초로 학습 데이터의 가중 평균 $Ave_w=\frac{1}{m}\sum_{i=1}^{m}X_{i,w}.$ 을 계산할 수 있다.

[0135] STEP 3에서, 가중 평균과 신경망에 사용할 라벨의 개수를 기초로 기준 범위를 설정하여 학습 데이터가 속하는 범위를 분류하고, 학습 데이터 각각이 속하는 범위에 기초해 학습 데이터에 대한 라벨링을 수행한 데이터 집합 $\{(\boldsymbol{X},Y)\}=\{(\boldsymbol{X}_i,Y_i)\}_{i=1}^{m}$ 을 생성할 수 있다.

[0136] STEP 4에서, 데이터 집합 $\{(\boldsymbol{X},Y)\}=\{(\boldsymbol{X}_i,Y_i)\}_{i=1}^{m}$ 에 대해 전처리를 수행할 수 있으며, 전처리가 수행된 데이터를 $\{(\boldsymbol{x}_i,y_i)\}_{i=1}^{m}$ 로 표현할 수 있다.

[0137] STEP 5에서, 전처리된 데이터 집합을 학습 집합(training set)과 테스트 집합(testing set)으로 나눌 수 있다. 신경망의 학습에 사용할 학습 집합은 $\{(\boldsymbol{x}_i,y_i)\}_{i=1}^{m_1}$, 신경망의 테스트에 사용할 테스트 집합은 $\{(\boldsymbol{x}_i,y_i)\}_{i=m_1+1}^{m},\ m_1=m\times r,$ 로 표기할 수 있고, 여기서 r 은 전체 데이터 집합 중 학습 집합의 비율 $r\in(0,1)$ 이다.

[0138] STEP 6에서, 신경망의 활성화 함수 f, 은닉 레이어의 노드 개수 k_0 및 $\{k_p\}_{p=1}^{P}$ (p는 은닉 레이어를 특정하는 인덱스)를 포함하는 네트워크 환경을 설정할 수 있다.

[0139] STEP 7에서, 은닉 레이어의 가중치 행렬과 바이어스 행렬의 초기값을 설정할 수 있다. 이때 $\{\boldsymbol{W}^p,\boldsymbol{b}^p\}_{p=1}^{P}$ 설정은 $r(\boldsymbol{W}^p)$ 가 최대가 되도록 설정할 수 있다. 이와 같이 초기값을 설정함으로써 최적의 $\{\boldsymbol{W}^p,\boldsymbol{b}^p\}_{p=1}^{P}$ 를 구하기 위한 업데이트 횟수를 줄일 수 있다.

[0140] 이후, 신경망 모델의 생성 과정은 STEP 8~10에 해당한다.

[0141] STEP 8에서, 초기 설정 $p=1$ (첫번째 은닉 레이어)부터 다음의 알고리즘을 시작한다. 입력 레이어로부터 출력 레이어로 향하는 방향으로 각 은닉 레이어에 대해, p번째(p는 은닉 레이어를 특정하는 인덱스) 레이어의 출력 함수 H_p 의 랭크 $r(H_p)$ 가 p번째 레이어의 출력 함수의 행의 개수 또는 열의 개수 중의 최소값 ($\min(k_{p-1},k_p)$)과 같은지 판별할 수 있다. 이 경우, 장치(100)는 해당 판별에서 $r(H_p)=\min(k_{p-1},k_p)$ 를 만족하지 않는다면, 기 설정된 횟수만큼 p번째 레이어의 바이어스를 갱신하여 p번째 레이어의 출력 함수 H_p 를 갱신함으로써, 가중치 행렬의 랭크 $r(\boldsymbol{W}^p)$ 가 최대가 되도록 은닉 레이어의 가중치 행렬 및 바이어스

행렬 $\{W^p, b^p\}_{p=1}^{P}$ 의 초기값을 재설정할 수 있다.

[0142] STEP 9에서, p=P라면, 은닉 레이어 중 최종 레이어의 출력 행렬에 대한 랭크와 학습 데이터에 대한 오차값에 기초해 최종 가중치 행렬에 적용할 무어-펜로즈 일반화 역행렬을 결정하여 신경망의 최종 가중치 행렬을 설정할 수 있다. 즉, H_P 을 계산하여, $r(H_p)$ 를 확인하고 그에 따라 H_P^{r-}, $(H_P^T H_P)^{-1}$, $(H_P^T H_P)^{+}$ 중 하나를 선택하여 계산한다.

[0143] STEP 10에서, 최종 가중치 행렬을 W^{out} 또는 W^{apout} 설정한다.

[0144] 이후, 상기 학습 데이터로 학습된 신경망 모델이 상기 학습 데이터에 대해 정확한 라벨을 생성하는지를 검증하는학습된 신경망 모델의 테스트 과정은 STEP 11~13에 해당한다.

[0145] STEP 11에서, y_{tr}^{out} 를 구한다. STEP 10에서 설정한 W^{out} 또는 W^{apout} 을 이용하여, $\boldsymbol{y}_{tr}^{r,out} = \{y_i^{r,out}\}_{i=1}^{m_1}$와 $\boldsymbol{y}_{tr}^{l,out} = \{y_i^{l,out}\}_{i=1}^{m_1}$ 를 도출한다. 여기서, tr은 학습 데이터를 사용했음을 의미하며, 윗 첨자 ^{r} 은 로우 데이터, ^{l} 은 라벨을 의미한다.

[0146] STEP 12에서, STEP 11에서 도출된 $\boldsymbol{y}_{tr}^{r,out} = \{y_i^{r,out}\}_{i=1}^{m_1}$ 와 $\boldsymbol{y}_{tr}^{l,out} = \{y_i^{l,out}\}_{i=1}^{m_1}$ 를 이용하여 예측 오차 $E_{2,tr,r}$ 와 $E_{2,tr,l}$ 을 구할 수 있다. $E_{2,tr,r}$ 와 $E_{2,tr,l}$ 는 각각 $y_{tr}^{r,out}$ 와 $y_{tr}^{l,out}$ 를 사용하여 얻은 오차이다.

[0147] STEP 13에서, 만일 학습을 통해 얻은 라벨의 정확도 $(Acc_{tr,l})$ 가 원하는 정확도로 설정된 Accuracy criterion 보다 작고 하이퍼파라미터가 업데이드가 가능하면 하이퍼파라미터를 업데이트한다. 만일 $(Acc_{tr,l})$가 Accuracy criterion 보다 작고 하이퍼파라미터가 업데이드가 가능하지 않으면 원하는 정확도를 얻기 위해 데이터에 대한 가중치 데이터부터 다시 계산하는 STEP 1부터 반복한다. 만일 $(Acc_{tr,l})$ 가 Accuracy criterion 보다 크면 학습과정은 완료된 것이며 테스트 과정을 수행한다.

[0148] STEP 14에서, STEP 11~13을 거쳐 검증된 W^{out} 및 W^{apout} 가 설정된 신경망에 테스트 집합 $\{(x_i, y_i)\}_{i=m_1+1}^{m}$ 에 적용하여 테스트 오차 $E_{2,te,r}$ 와 $E_{2,te,l}$ 를 계산한다.

[0149] 이후, 새로운 학습 데이터인 제2 학습 데이터가 획득되는 경우, 제2 학습 데이터의 라벨을 결정하는 과정은 STEP 15~19에 해당한다.

[0150] STEP 15에서, 새로운 제2 학습 데이터 $\{X_k^{new}\}_{k=1}^{n_k}$ 가 획득된 것으로 판별되면, 제2 학습 데이터에 대한 최종 라벨을 결정하는 STEP 16~19가 수행된다.

[0151] STEP 16에서, 제2 학습 데이터 $\{X_k^{new}\}_{k=1}^{n_k}$ 에 대해 STEP 1~3과 동일한 과정을 수행하여, $\{X_k^{new}\}_{k=1}^{n_k}$ 에 대한 제1 라벨 $\{Y_k^{base}\}_{k=1}^{n_k}$ 을 도출한다. 이에, 제2 학습 데이터와 제1 라벨이 매핑된 제2 데이터 집합

$\{(X_k^{new}, Y_k^{base})\}_{k=1}^{n_k}$을 생성할 수 있다.

[0152] 이후, 도 7의 Fixed-update는 도 5의 예시에 해당하며, 도 7의 All-update는 도 6의 예시에 해당한다.

[0153] 먼저, 도 7의 Fixed-update 과정인 STEP 17~19를 설명한다.

[0154] STEP 17에서, 제2 데이터 집합 $\{(X_k^{new}, Y_k^{base})\}_{k=1}^{n_k}$을 전처리하여, $\{(x_k^n, y_n^b)\}_{k=1}^{n_k}$를 생성할 수 있다.

[0155] STEP 18에서, STEP 4~13의 과정으로 생성된 신경망을 그대로 이용하여 제2 학습 데이터 $\{X_k^{new}\}_{k=1}^{n_k}$에 대해 출력한 제2 라벨 $\{Y_k^{new}\}_{k=1}^{n_k}$을 획득한다.

[0156] STEP 19에서, 제1 라벨 $\{Y_k^{base}\}_{k=1}^{n_k}$과 제2 라벨 $\{Y_k^{new}\}_{k=1}^{n_k}$ 중 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 제2 학습 데이터의 최종 라벨로 결정한다.

[0157] 다음으로, 도 7의 All-update 과정인 STEP 17~19를 설명한다.

[0158] STEP 17에서, 제1 학습 데이터의 개수 m에서 제2 학습 데이터의 개수 n_r 만큼 제외한 개수의 제1 학습 데이터 $\{(X_i, Y_i)\}_{i=n_r+1}^{m}$와, 새로운 제2 학습 데이터 $\{(X_k^{new}, Y_k^{base})\}_{k=1}^{n_r}$를 이용해 STEP 4~9를 재수행하여 신경망의 가중치를 갱신함으로써 W^{out} 또는 W^{apout}를 재설정한다.

[0159] STEP 18에서, 갱신된 신경망이 제2 학습 데이터 $\{X_k^{new}\}_{k=1}^{n_k}$에 대해 출력한 제2 라벨 $\{Y_k^{new}\}_{k=1}^{n_k}$을 획득한다.

[0160] STEP 19에서, 제1 라벨 $\{Y_k^{base}\}_{k=1}^{n_k}$과 제2 라벨 $\{Y_k^{new}\}_{k=1}^{n_k}$ 중 제2 학습 데이터의 실제값과 오차가 더 적은 라벨을 제2 학습 데이터의 최종 라벨로 결정한다.

[0161] 다음으로는, 네트워크 트래픽 탐지에서 사용하는 두 데이터, CAIDA(CAIDA, 2007)에서 얻은 'DDoS 공격 2007' 데이터 집합과, MIT Lab(MIT Lincoln Lab, 1998)에서 얻은 DARPA의 'DDoS 공격 1998' 데이터 집합을 상술한 알고리즘에 적용하여 실험한 결과를 설명한다.

[0162] CAIDA 데이터 집합에는 '공격자가 희생자로 전송' 한 데이터 및 '희생자가 공격자로 전송' 한 데이터가 포함되어 있는데, 실험에서는 '공격자가 피해자로 전송' 한 데이터를 사용하였다. CAIDA에는 20:50:08-21:56:16 UTC (협정 세계시, 실제 날짜 및 시간: 20070804, 13:49:36-14:54:36)의 네트워크 트래픽이 포함되어 있다. 한편, DARPA에는 19980629, 20:57:14-19980630, 04:59:14의 네트워크 트래픽이 포함되어 있다. 두 데이터 집합에서 공격은 각각 약 21:13 UTC와 04:33에 발생했으며 약 200Kbit/sec~90MB/sec 및 20Kbit/sec~11MB/sec의 빠른 네트워크 로드 증가가 발생하므로 공격은 식별된다. 즉, 식별에 따라 라벨을 할당할 수 있다.

[0163] 두 데이터에서 (the number of source internet protocols, addresses, the number of transmitted packets by IPs, the number of accumulated packets)을 특징 성분으로 추출하였고, 이 두 데이터 집합은 정상 트래픽과 공격 트래픽으로 이루어져 있으므로 l 은 1로 설정하였다.

[0164] 실험은 Python 3.6에서 TensorFlow v.1.7.0을 사용하여 수행되었다. 네트워크 하이퍼파라미터는 초기값은 다음과 같이 설정하였다.

[0165] $$W=\begin{bmatrix}0.1 & 0 & 0\\ 0 & 0.1 & 0\\ 0 & 0 & 0.1\end{bmatrix},$$

[0166] $$B=\begin{bmatrix}0\\ 0\\ 0\end{bmatrix}.$$

[0167] 알고리즘 1에 선별된 데이터 성분의 가중치 a_j 는 1, 즉 모든 성분이 같은 가중치를 갖는다고 가정하였다. 학습에 사용하는 데이터와 테스트에 사용되는 데이터의 비율은 0.7:0.3 으로 설정하였으며, 무어-펜로즈 일반화 역행렬(Moore-Penrose generalized inverse)에서 δ 는 10^{-6} 으로 설정하였다. 활성 함수 f 는 다음과 같이 정의된 ReLU함수로 설정하였다.

[0168] $$f(x)=\begin{cases}x, x \geq 0,\\ 0, x<0.\end{cases}$$

[0169] 이에 따라, 본 발명에서 제안하는 알고리즘으로 얻은 라벨(Auto-label)과 기존 라벨(Conv. label)을 비교한 결과는 다음 표 1과 같다.

표 1

[0170]

		Auto-label			
	Data	CAIDA		DARPA	
	Label	N	A	N	A
Conv. label	N	157	0	156	0
	A	10	227	1	155

[0171] 표 1을 참조하면, 기존 라벨은 데이터가 급증하는 구간을 식별해서 할당한 라벨이다. 표 1에서 'N은 정상, 'A' 은 공격을 의미한다. 표 1를 이용해 얻은 상대 정확도는 기존 라벨이 정확하다는 가정 하에 0.975이다. 상대 정확도 A_{rel} 는 다음과 같이 정의하였다.

[0172] $$A_{rel}=\frac{\sum_{\text{label}}\chi_{\{\text{conv.label=auto-label}\}}}{m}$$

[0173] 또한, 기존 라벨을 가진 데이터 집합(Data-conv)과 본 발명의 알고리즘으로 얻은 라벨을 가진 데이터 집합(Data-auto)에 대해 학습을 했을 경우에 예측에 대한 성능을 비교한 결과는 다음 표 2와 같다.

표 2

[0174]

Data	CAIDA						DARPA					
	Data-conv			Data-auto			Data-conv			Data-auto		
Traffic type	N	A	w-ave	N	A	w-ave	N	A	Ave	N	A	w-ave
Precision	0.98	1	0.99	1	1	1	1	1	1	1	1	1
Recall	1	0.98	0.99	1	1	1	1	1	1	1	1	1
F1-score	0.99	0.99	0.99	1	1	1	1	1	1	1	1	1
Accuracy	0.9907			1			1			1		

[0175] 표 2를 참조하면, 본 발명의 알고리즘으로 라벨링된 데이터로 학습하는 경우, 기존 라벨링 데이터로 학습한 경우에 비하여 성능이 향상되는 것을 확인할 수 있다.

[0176] 이처럼 본 발명에 따르면, 신경망을 통해 데이터에서 관찰하고자 하는 각 특징에 대하여 가중치를 설정하고, 설정된 특징 별 가중치를 기초로 가중 평균을 계산함으로써, 가중 평균과 신경망에서 출력할 라벨의 개수를 기초로 기준 범위를 설정하여 학습 데이터가 속하는 범위를 분류할 수 있다.

[0177] 이에 따라, 본 발명은 이러한 데이터 분석을 통해 분류한 범주를 기초로 데이터의 특성을 잘 나타내는 중요한 특징을 추출하고, 이를 기반으로 데이터에 자동으로 라벨을 할당할 수 있게 한다.

[0178] 이를 통해, 본 발명은 시간과 자원이 많이 소요되는 기존의 라벨링 과정에 대한 단점을 극복하고, 실시간으로 생성되는 데이터에 대한 라벨링을 즉각적으로 수행할 뿐만 아니라, 라벨이 할당된 데이터를 활용하여 실시간으로 해당 데이터와 관련된 새로운 데이터를 기초로 원하는 출력값을 예측하는 신경망을 생성할 수 있게 한다.

[0179] 나아가, 본 발명의 기술은 다양한 빅데이터의 라벨링 과정에 사용될 수 있다. 예를 들면, 전자, 환경, 의료, 보건 등의 다양한 분야의 빅데이터와 신경망 모델에 적용하여 사용할 수 있다.

[0180] 또한, 상술한 실시 예에 따른 방법은 컴퓨터로 판독 가능한 매체에 저장된 컴퓨터 프로그램 또는 컴퓨터로 판독 가능한 기록 매체의 형태로도 구현될 수 있다. 일 실시 예에 따른 컴퓨터 판독 가능 기록매체에 저장되어 있는 컴퓨터 프로그램은 프로세서에 의해 실행되면, 신경망의 학습에 사용할 학습 데이터를 획득하는 동작; 학습 데이터에서 고려할 특징 별로 가중치를 설정하는 동작; 특징 별 가중치를 기초로 학습 데이터의 가중 평균을 계산하는 동작; 및 가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 설정한 복수의 범위 중 학습 데이터 각각이 속하는 범위에 기초해 학습 데이터에 대한 라벨링을 수행하는 동작을 포함하는 방법을 프로세서가 수행하도록 하기 위한 명령어를 포함할 수 있다.

[0181] 또한, 본 문서의 실시 예들의 프로세서는, 저장 매체로부터 저장된 하나 이상의 명령어들 중 적어도 하나의 명령을 호출하고, 그것을 실행할 수 있다. 이것은 기기가 호출된 적어도 하나의 명령어에 따라 적어도 하나의 기능을 수행하도록 운영되는 것을 가능하게 한다. 이러한 하나 이상의 명령어들은 컴파일러에 의해 생성된 코드 또는 인터프리터에 의해 실행될 수 있는 코드를 포함할 수 있다. 프로세서는 범용 프로세서, FPGA(Field Programmable Gate Array), ASIC(Application Specific Integrated Circuit), DSP(Digital Signal Processor) 및/또는 등등 일 수 있다.

[0182] 이상 첨부된 도면을 참조하여 본 발명의 실시 예들을 설명하였지만, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자는 본 발명이 그 기술적 사상이나 필수적인 특징을 변경하지 않고서 다른 구체적인 형태로 실시될 수 있다는 것을 이해할 수 있을 것이다. 그러므로 이상에서 기술한 실시 예들은 모든 면에서 예시적인 것이며 한정적이 아닌 것으로 이해해야만 한다.

부호의 설명

[0183] 10: 프로세서

20: 네트워크 인터페이스

30: 메모리

40: 스토리지

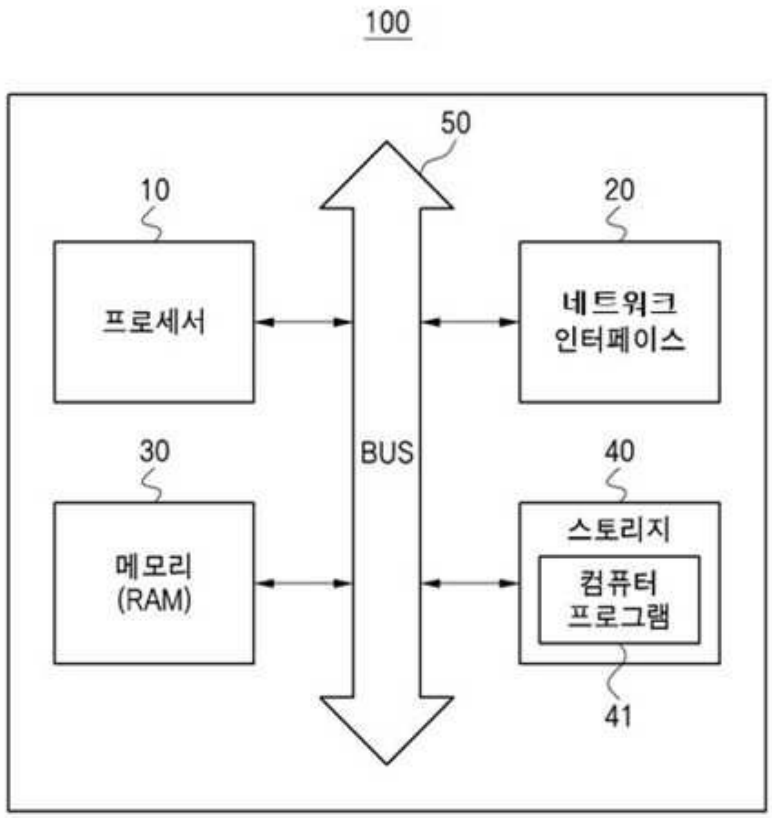
41: 컴퓨터 프로그램

50: 데이터 버스

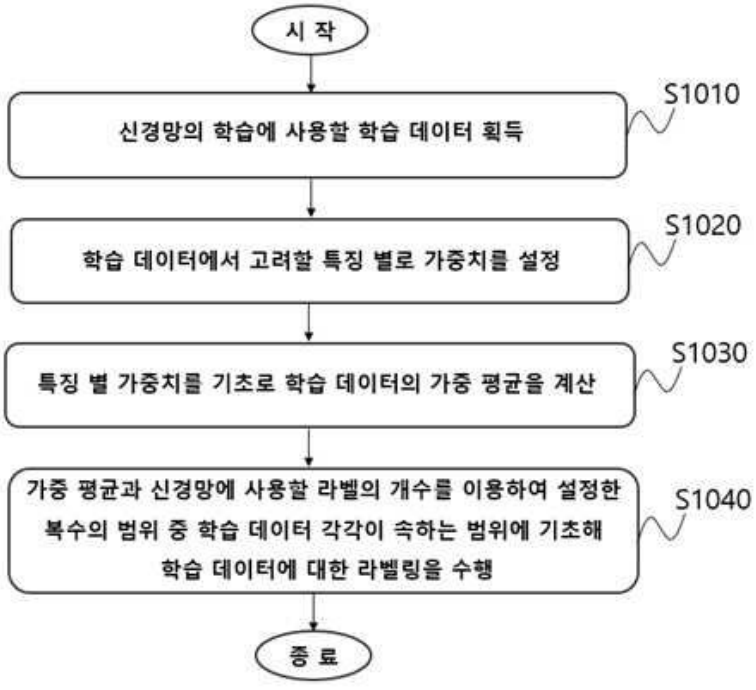
100: 자동 라벨링 장치

도면

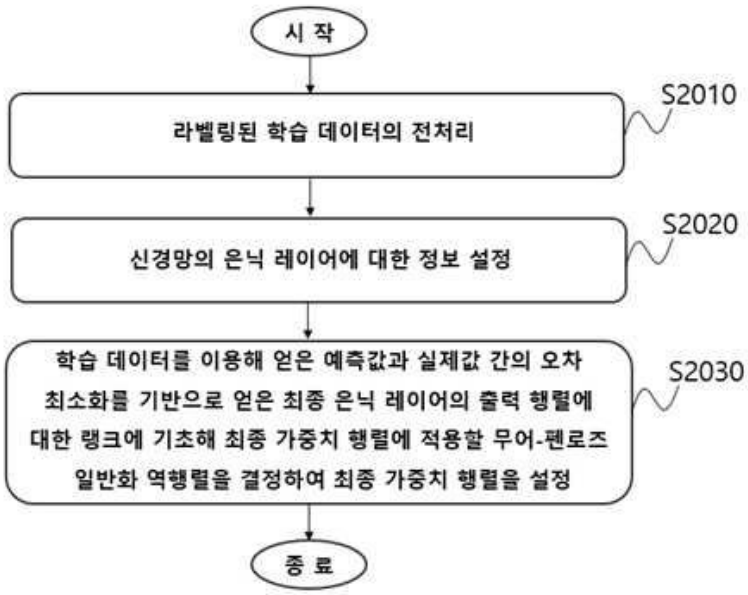
도면1


100
50
10
프로세서
20
네트워크
인터페이스
BUS
30
메모리
(RAM)
40
스토리지
컴퓨터
프로그램
41

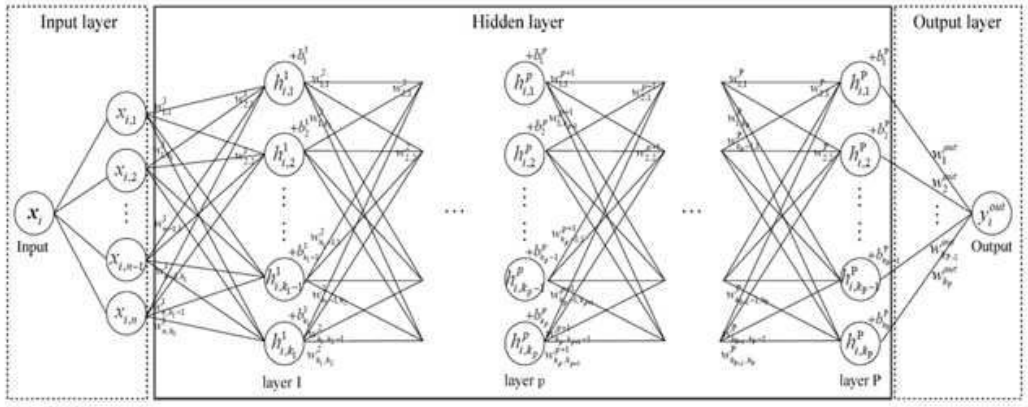
도면2


시 작
신경망의 학습에 사용할 학습 데이터 획득
S1010
학습 데이터에서 고려할 특징 별로 가중치를 설정
S1020
특징 별 가중치를 기초로 학습 데이터의 가중 평균을 계산
S1030
가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 설정한
복수의 범위 중 학습 데이터 각각이 속하는 범위에 기초해
학습 데이터에 대한 라벨링을 수행
S1040
종 료

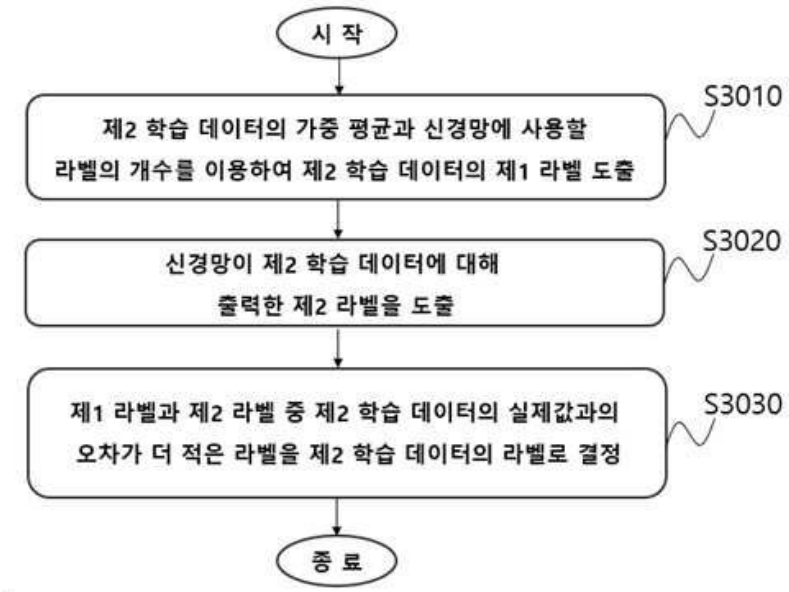
도면3


시 작
라벨링된 학습 데이터의 전처리
S2010
신경망의 은닉 레이어에 대한 정보 설정
S2020
학습 데이터를 이용해 얻은 예측값과 실제값 간의 오차 최소화를 기반으로 얻은 최종 은닉 레이어의 출력 행렬에 대한 랭크에 기초해 최종 가중치 행렬에 적용할 무어-펜로즈 일반화 역행렬을 결정하여 최종 가중치 행렬을 설정
S2030
종 료

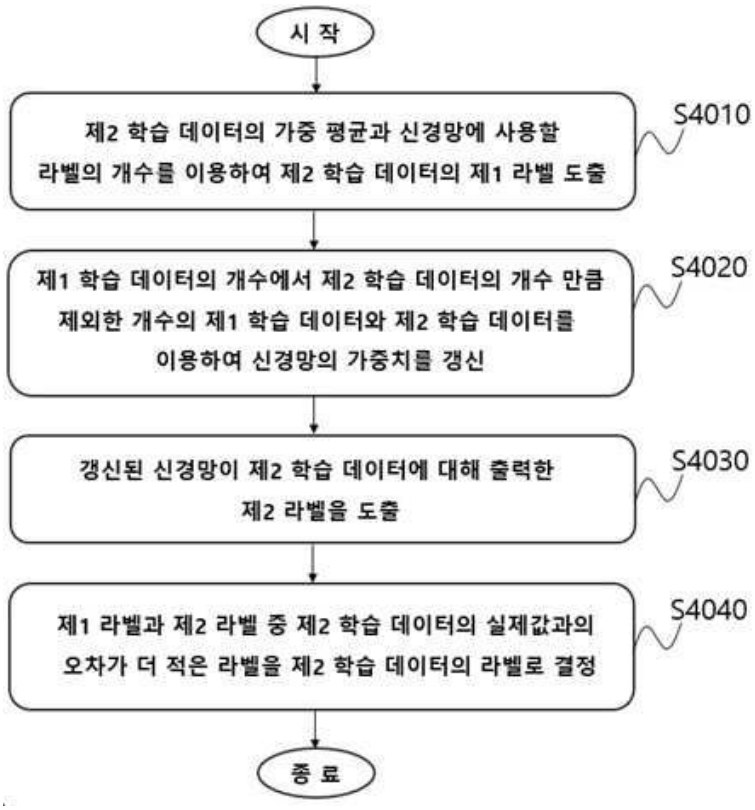
도면4


Input layer
Hidden layer
Output layer
Input
Output
layer 1
layer p
layer P

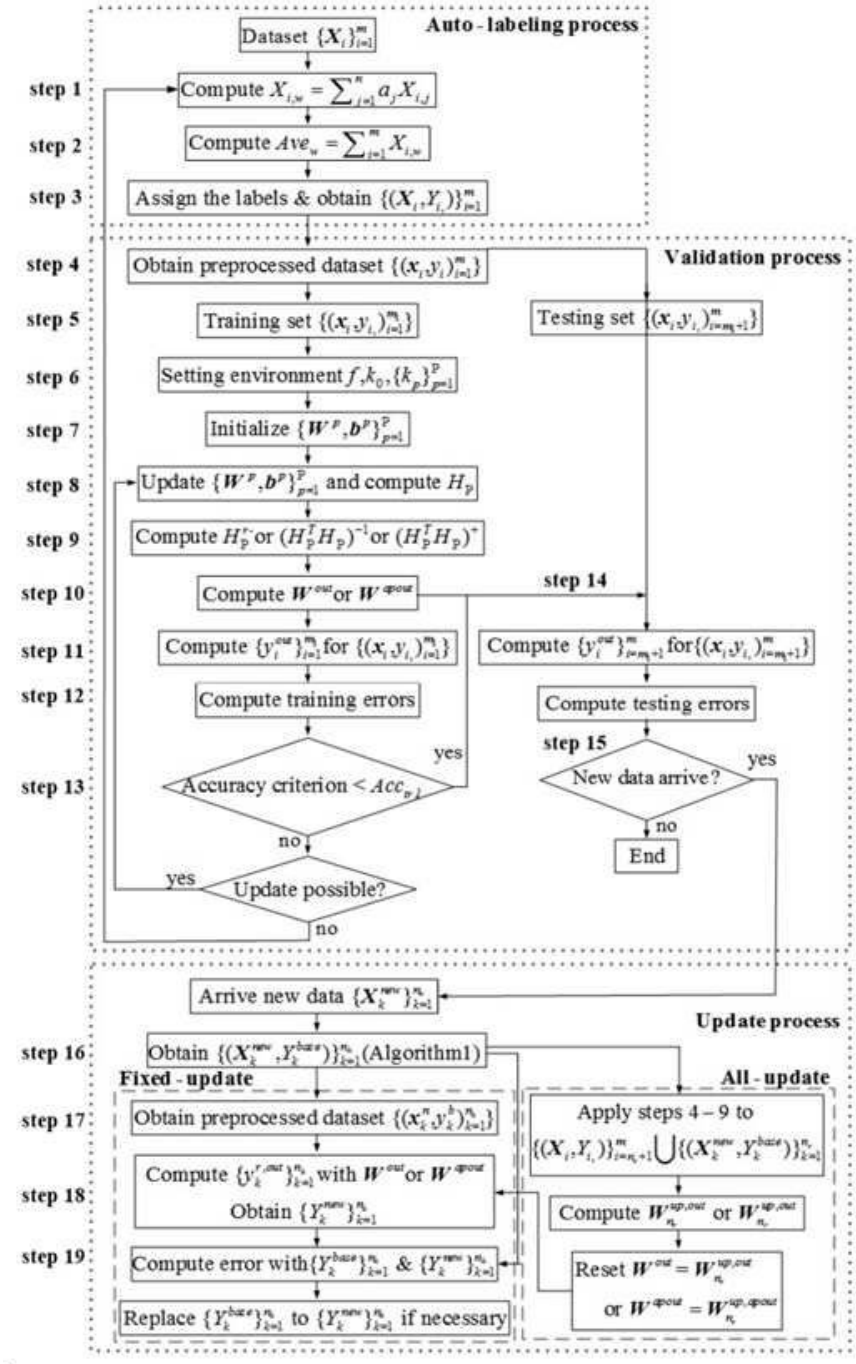
도면5


시 작
제2 학습 데이터의 가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 제2 학습 데이터의 제1 라벨 도출
S3010
신경망이 제2 학습 데이터에 대해 출력한 제2 라벨을 도출
S3020
제1 라벨과 제2 라벨 중 제2 학습 데이터의 실제값과의 오차가 더 적은 라벨을 제2 학습 데이터의 라벨로 결정
S3030
종 료

도면6


시 작
제2 학습 데이터의 가중 평균과 신경망에 사용할 라벨의 개수를 이용하여 제2 학습 데이터의 제1 라벨 도출
S4010
제1 학습 데이터의 개수에서 제2 학습 데이터의 개수 만큼 제외한 개수의 제1 학습 데이터와 제2 학습 데이터를 이용하여 신경망의 가중치를 갱신
S4020
갱신된 신경망이 제2 학습 데이터에 대해 출력한 제2 라벨을 도출
S4030
제1 라벨과 제2 라벨 중 제2 학습 데이터의 실제값과의 오차가 더 적은 라벨을 제2 학습 데이터의 라벨로 결정
S4040
종 료

도면7


Auto - labeling process
Dataset $\{X_i\}_{i=1}^{m}$
step 1
Compute $X_{i,w} = \sum_{j=1}^{n} a_j X_{i,j}$
step 2
Compute $Ave_w = \sum_{i=1}^{m} X_{i,w}$
step 3
Assign the labels & obtain $\{(X_i, Y_i)\}_{i=1}^{m}$
Validation process
step 4
Obtain preprocessed dataset $\{(x_i, y_i)_{i=1}^{m}\}$
step 5
Training set $\{(x_i, y_i)_{i=1}^{m_1}\}$
Testing set $\{(x_i, y_i)_{i=m_1+1}^{m}\}$
step 6
Setting environment $f, k_0, \{k_p\}_{p=1}^{P}$
step 7
Initialize $\{W^p, b^p\}_{p=1}^{P}$
step 8
Update $\{W^p, b^p\}_{p=1}^{P}$ and compute H_p
step 9
Compute H_p^r or $(H_p^T H_p)^{-1}$ or $(H_p^T H_p)^+$
step 10
Compute W^{out} or W^{qpout}
step 14
step 11
Compute $\{y_i^{out}\}_{i=1}^{m_1}$ for $\{(x_i, y_i)_{i=1}^{m_1}\}$
Compute $\{y_i^{out}\}_{i=m_1+1}^{m}$ for $\{(x_i, y_i)_{i=m_1+1}^{m}\}$
step 12
Compute training errors
Compute testing errors
step 15
step 13
Accuracy criterion < Acc_{tr}
yes
New data arrive?
yes
no
End
no
yes
Update possible?
no
Update process
Arrive new data $\{X_k^{new}\}_{k=1}^{n_1}$
step 16
Obtain $\{(X_k^{new}, Y_k^{base})\}_{k=1}^{n_1}$ (Algorithm1)
Fixed - update
All - update
step 17
Obtain preprocessed dataset $\{(x_k^n, y_k^b)_{k=1}^{n_1}\}$
Apply steps 4 – 9 to
$\{(X_i, Y_i)\}_{i=m_1+1}^{m} \bigcup \{(X_k^{new}, Y_k^{base})\}_{k=1}^{n_1}$
step 18
Compute $\{y_k^{r,out}\}_{k=1}^{n_1}$ with W^{out} or W^{qpout}
Obtain $\{Y_k^{new}\}_{k=1}^{n_1}$
Compute $W_{n_1}^{up,out}$ or $W_{n_1}^{up,out}$
step 19
Compute error with $\{Y_k^{base}\}_{k=1}^{n_1}$ & $\{Y_k^{new}\}_{k=1}^{n_1}$
Reset $W^{out} = W_{n_1}^{up,out}$
or $W^{qpout} = W_{n_1}^{up,qpout}$
Replace $\{Y_k^{base}\}_{k=1}^{n_1}$ to $\{Y_k^{new}\}_{k=1}^{n_1}$ if necessary