



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2023-0084423
(43) 공개일자 2023년06월13일

- (51) 국제특허분류(Int. Cl.)
G06N 20/00 (2019.01) G06N 3/08 (2023.01)
- (52) CPC특허분류
G06N 20/00 (2021.08)
G06N 3/08 (2023.01)
- (21) 출원번호 10-2022-7034545
- (22) 출원일자(국제) 2021년12월03일
심사청구일자 2022년10월05일
- (85) 번역문제출일자 2022년10월05일
- (86) 국제출원번호 PCT/JP2021/044400
- (87) 국제공개번호 WO 2023/100339
국제공개일자 2023년06월08일

- (71) 출원인
미쓰비시덴키 가부시카이가이사
일본국 도쿄도 지요다쿠 마루노우치 2초메 7반 3고
- (72) 발명자
사와다 도모야
일본 도쿄도 지요다쿠 마루노우치 2초메 7반 3고
미쓰비시덴키 가부시카이가이사 내
- (74) 대리인
제일특허법인(유)

전체 청구항 수 : 총 9 항


(54) 발명의 명칭 학습된 모델 생성 시스템, 학습된 모델 생성 방법, 정보 처리 장치, 기록 매체, 학습된 모델, 및 추정 장치

(57) 요약

학습된 모델을 생성하는 학습된 모델 생성 시스템으로서, 학습 데이터에 대한 추정을 행하는 추정부와, 추정부에 의한 추정 결과에 대해, 손실의 구배를 산출하는 손실 구배 산출부와, 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부를 구비하고, 옵티마이저부는, 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용한다. 이것에 의해 학습이 정체된 상태에서부터 탈출할 수가 있다.

대표도 - 도1

10



명세서

청구범위

청구항 1

학습된 모델(trained model)을 생성하는 학습된 모델 생성 시스템으로서,
 학습 데이터에 대한 추정을 행하는 추정부와,
 상기 추정부에 의한 추정 결과에 대해, 손실의 구배를 산출하는 손실 구배 산출부와,
 상기 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부
 를 구비하고,

상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체가 되었을 때
 에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할
 수록 상기 학습이 정체가 되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하
 는,

학습된 모델 생성 시스템.

청구항 2

제 1 항에 있어서,

상기 제 1 인수는, 상기 구배의 절대치가 클수록 상기 학습률을 억제하는 효과가 얻어지고, 상기 에폭 수가 증
 가할수록 상기 학습률을 억제하는 효과가 커지는, 학습된 모델 생성 시스템.

청구항 3

제 1 항 또는 제 2 항에 있어서,

상기 학습률을 산출하는 식은, 학습의 시초에는, 학습에 따른 상기 복수의 파라미터 각각의 누적 갱신량에 따라
 학습률을 억제하는, 최대치가 1인 제 2 인수를 포함하고, 상기 학습의 시초 이후는, 상기 제 2 인수를 포함하지
 않는, 학습된 모델 생성 시스템.

청구항 4

제 3 항에 있어서,

상기 제 2 인수는, 상기 누적 갱신량이, 임계치보다 작을 때는 절대치가 1보다 작고, 상기 임계치보다 클 때는,
 단조 감소하는, 학습된 모델 생성 시스템.

청구항 5

학습된 모델을 생성하는 학습된 모델 생성 방법으로서,

학습 데이터에 대한 추정을 행하는 제 1 스텝과,

상기 제 1 스텝에 의한 추정 결과에 대해, 손실의 구배를 산출하는 제 2 스텝과,

상기 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 제 3 스텝

을 갖고,

상기 제 3 스텝에 있어서, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체가 되었
 을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증
 가할수록 상기 학습이 정체가 되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이
 용하는,

학습된 모델 생성 방법.

청구항 6

학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부

를 구비하고,

상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는,

정보 처리 장치.

청구항 7

컴퓨터를,

학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부

로서 기능시키기 위한 프로그램으로서,

상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는,

프로그램.

청구항 8

학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 것에 의해 생성된 학습된 모델로서,

상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식이 이용된,

학습된 모델.

청구항 9

학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 것에 의해 생성된 학습된 모델로서,

상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식이 이용된, 학습된 모델을 이용하여,

입력된 정보에 대한 추정을 행하는, 추정 장치.

발명의 설명

기술 분야

본 발명은, 학습된 모델(trained model) 생성 시스템, 학습된 모델 생성 방법, 정보 처리 장치, 프로그램, 학습된 모델, 및 추정 장치에 관한 것이다.

[0001]

배경 기술

- [0002] 종래부터, 뉴럴 네트워크 등을 이용한 기계 학습에 있어서, 뉴럴 네트워크의 가중치 등의 파라미터를 구하는 수법(옵티마이저(optimizer))으로서, 구배 하강법(gradient descending method)이 알려져 있다. 구배 하강법의 대표적인 것으로서, SGD(Stochastic Gradient Descent), Momentum SGD, Adagrad(Adaptive Gradient Algorithm), RMSprop(Root Mean Square Propagation), Adam(Adaptive Moment estimation) 등이 알려져 있다(예를 들면, 특허 문헌 1 참조).
- [0003] SGD에서는, 안장점(saddle point) 부근에서 구배가 제로에 가깝게 되기 때문에, 학습이 진행되지 않게 되는 경우가 있다. 그래서, Momentum SGD에서는, 관성항(inertia term)을 도입한 산출식이 이용되고 있다. 이것에 의해, 안장점 부근에서 빠져 나가는 것이 가능해지고 있다. 이러한 옵티마이저에서는, 학습률(Learning Rate)이 고정이기 때문에, 학습이 수속하기까지 방대한 시간을 필요로 하고 있었다. 그래서, 학습률의 변동을 파라미터마다 적응적으로 변화시키는 Adagrad, RMSprop, Adam 등이 제안되고 있다.
- [0004] Adagrad에서는, 캐쉬에 각 파라미터 방향의 구배의 제곱화가 보존된다. 그 캐쉬의 평방근으로 학습률을 나누는 것으로, 희귀한(rare) 특징에 대해서 학습률을 높게 설정하는 것이 가능해지고 있다. 그러나, 에폭(epoch)을 거듭하면 캐쉬가 커지기 때문에, 학습률은 제로에 점근(漸近)해 버린다고 하는 문제와, 학습의 초기에, 어느 축(파라미터) 방향의 구배가 큰 구배 필드를 지나면, 캐쉬가 커지기 때문에, 그 이후의 학습에서는, 그 축 방향의 학습률이 작아져 버린다고 하는 문제가 있다.
- [0005] RMSprop에서는, 구배 정보의 지수 이동 평균이 이용되고 있다. 지수 이동 평균에서는, 과거의 정보가 지수 함수적으로 감쇠하므로, 지극히 먼 과거의 구배 정보를 제거하고, 최근의 구배 정보가 보다 더 반영되도록 하고 있다.
- [0006] Adam에서는, 구배치의 일차(평균), 2차(분산)의 모멘트를 추정하는 것으로, Adagrad와 같이 희귀한 정보에 대해서 큰 갱신을 행하고, RMSprop와 같이 지극히 먼 과거의 구배 정보를 제거하는 것이 가능해지고 있다.
- [0007] 그러나, 학습이 진행됨에 따라, 학습률과, 파라미터의 갱신량이 단조 감소하는 지수 이동 평균이었기 때문에, 희귀한 정보를 효율적으로 학습하지 못하고 학습이 정체되어 버리는 경우가 있고, 학습 초기에 보정 계수가 극단적으로 큰 값이 되어 발산하는 경우가 있는 등의 문제가 있다.

선행기술문헌

특허문헌

- [0008] (특허문헌 0001) [특허 문헌 1] 국제 공개 제2017/183587호

발명의 내용

해결하려는 과제

- [0009] 본 개시는, 이러한 사정을 감안하여 된 것으로, 학습이 정체된 상태에서부터 탈출할 수가 있는 학습된 모델 생성 시스템, 학습된 모델 생성 방법, 정보 처리 장치, 프로그램, 학습된 모델, 및 추정 장치를 제공한다.

과제의 해결 수단

- [0010] 본 개시는 상술한 과제를 해결하기 위해서 된 것으로, 본 개시의 일 태양은, 학습된 모델을 생성하는 학습된 모델 생성 시스템으로서, 학습 데이터에 대한 추정을 행하는 추정부와, 상기 추정부에 의한 추정 결과에 대해, 손실의 구배를 산출하는 손실 구배 산출부와, 상기 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부를 구비하고, 상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는, 학습된 모델 생성 시스템이다.
- [0011] 또, 본 개시의 다른 일 태양은, 상술한 학습된 모델 생성 시스템으로서, 상기 제 1 인수는, 상기 구배의 절대치가 클수록 상기 학습률을 억제하는 효과가 얻어지고, 상기 에폭 수가 증가할수록 상기 학습률을 억제하는 효과

가 커진다.

- [0012] 또, 본 개시의 다른 일 태양은, 상술한 학습된 모델 생성 시스템으로서, 상기 학습률을 산출하는 식은, 학습의 시초에는, 학습에 따른 상기 복수의 파라미터 각각의 누적 갱신량에 따라 학습률을 억제하는, 최대치가 1인 제 2 인수를 포함하고, 상기 학습의 시초 이후는, 상기 제 2 인수를 포함하지 않는다.
- [0013] 또, 본 개시의 다른 일 태양은, 상술한 학습된 모델 생성 시스템으로서, 상기 제 2 인수는, 상기 누적 갱신량이, 임계치보다 작을 때는 절대치가 1보다 작고, 상기 임계치보다 클 때는, 단조 감소한다.
- [0014] 또, 본 개시의 다른 일 태양은, 학습된 모델을 생성하는 학습된 모델 생성 방법으로서, 학습 데이터에 대한 추정을 행하는 제 1 스텝과, 상기 제 1 스텝에 의한 추정 결과에 대해, 손실의 구배를 산출하는 제 2 스텝과, 상기 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 제 3 스텝을 갖고, 상기 제 3 스텝에 있어서, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는, 학습된 모델 생성 방법이다.
- [0015] 또, 본 개시의 다른 일 태양은, 학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부를 구비하고, 상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는, 정보 처리 장치이다.
- [0016] 또, 본 개시의 다른 일 태양은, 컴퓨터를, 학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 옵티마이저부로서 기능시키기 위한 프로그램으로서, 상기 옵티마이저부는, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식을 이용하는, 프로그램이다.
- [0017] 또, 본 개시의 다른 일 태양은, 학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 것에 의해 생성된 학습된 모델로서, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식이 이용된, 학습된 모델이다.
- [0018] 또, 본 개시의 다른 일 태양은, 학습 데이터에 대한 추정 결과에 대해 산출된 손실의 구배에 근거하여, 학습된 모델을 구성하는 복수의 파라미터를 산출하는 것에 의해 생성된 학습된 모델로서, 상기 복수의 파라미터를 산출할 때의 학습률을 산출하는 식으로서, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어지는 제 1 인수로서, 에폭 수가 증가할수록 상기 학습이 정체되었을 때에 상기 학습률을 크게 하는 효과가 커지는 제 1 인수를 포함하는 식이 이용된, 학습된 모델을 이용하여, 입력된 정보에 대한 추정을 행하는, 추정 장치이다.

발명의 효과

- [0019] 본 개시에 의하면, 학습이 정체된 상태에서부터 탈출할 수가 있다.

도면의 간단한 설명

- [0020] 도 1은 본 개시의 실시 형태에 따른 학습된 모델 생성 등록 시스템(10)의 구성을 나타내는 개략 블록도이다.
- 도 2는 동 실시 형태에 따른 학습된 모델 생성 장치(200)의 구성을 나타내는 개략 블록도이다.
- 도 3은 동 실시 형태에 따른 학습된 모델 생성 장치(200)의 동작을 설명하는 흐름도이다.
- 도 4는 동 실시 형태에 따른 추정부(210)가 구비하는 뉴럴 네트워크의 예를 나타내는 모식도이다.
- 도 5는 동 실시 형태에 있어서의 누적 갱신량에 따른 학습률의 예를 플롯한 그래프이다.

도 6은 동 실시 형태에 있어서의 옵티마이저부(230)의 실시예를 나타내는 모식도이다.

도 7은 동 실시 형태에 따른 감시 카메라 장치(300)의 구성을 나타내는 개략 블록도이다.

발명을 실시하기 위한 구체적인 내용

- [0021] 이하, 도면을 참조하여, 본 개시의 실시의 형태에 대해 설명한다. 도 1은, 본 실시 형태에 따른 학습된 모델 생성 등록 시스템(10)의 구성을 나타내는 개략 블록도이다. 학습된 모델 생성 등록 시스템(10)은, 지도 학습(supervised learning)을 행하는 것으로 학습된 모델을 생성하고, 생성한 학습된 모델을 감시 카메라 장치(300)에 등록한다. 본 실시 형태에 있어서의 학습된 모델 생성 등록 시스템(10)은, 학습된 모델을 생성할 때에, 적응적으로 학습률을 결정하는 본 개시에 따른 구배법을 이용한다. 본 개시에 따른 구배법의 상세에 대하여는 후술한다. 또한, 본 실시 형태에서는, 기계 학습의 예로서, 뉴럴 네트워크를 이용하여, 지도 학습을 행하는 예를 나타내지만, 본 개시에 따른 구배법을 이용한 학습된 모델의 생성 방법은, 이것에 한정되지 않는다. 기계 학습은, 뉴럴 네트워크 이외의 기계 학습, 예를 들면 회귀 분석 등을 이용하여, 지도 학습 이외의 학습 방법, 예를 들면, 비지도 학습(unsupervised learning), 또는 강화 학습을 행해도 좋다.
- [0022] 학습된 모델 생성 등록 시스템은, 학습 데이터 DB(100), 학습된 모델 생성 장치(200), 감시 카메라 장치(300)를 구비한다. 학습 데이터 DB(100)는, 기계 학습하기 위한 학습 데이터가 되는 화상을 기억한다. 후술하는 바와 같이, 감시 카메라 장치(300)는, 시간대 별, 장소 별로 학습된 모델을 구비하므로, 학습 데이터 DB(100)는, 학습 데이터가 되는 화상을, 시간대 별, 장소 별로 기억한다. 시간대 별의 예로서는, 학습 데이터 DB(100)는, 낮에 촬영된 낮의 화상과, 야간에 촬영된 야간의 화상을 나누어 기억해도 좋다. 또, 장소 별의 예로서, 학습 데이터 DB(100)는, 출입구의 화상과, 주차장의 화상을 나누어 기억해도 좋다.
- [0023] 학습된 모델 생성 장치(200)는, 학습 데이터 DB(100)가 기억하는 화상을 이용하여 기계 학습을 행하는 것으로, 학습이 끝난 모델을 생성한다. 예를 들면, 학습된 모델 생성 장치(200)는, 낮의 화상을 학습하여, 낮용의 학습된 모델을 생성하고, 야간의 화상을 학습하여, 야간용의 학습된 모델을 생성한다. 또, 학습된 모델 생성 장치(200)는, 출입구의 화상을 학습하여, 출입구용의 학습된 모델을 생성하고, 주차장의 화상을 학습하여, 주차장용의 학습된 모델을 생성한다.
- [0024] 감시 카메라 장치(300)는, 학습된 모델 생성 장치(200)가 생성한 시간대 별 및 장소 별의 학습된 모델을 기억한다. 이들 학습된 모델은, 감시 카메라 장치(300)의 제조 시에, 감시 카메라 장치(300)가 내장하는 메모리 등에 저장되어도 좋다. 혹은, 감시 카메라 장치(300)가, 인터넷 등의 네트워크를 통하여, 학습된 모델을 저장하고 있는 서버로부터 취득하도록 해도 좋다. 감시 카메라 장치(300)는, 기억하고 있는 시간대 별 및 장소 별의 학습된 모델을 이용하여, 촬영한 영상 중의 물체를 검출한다. 또, 감시 카메라 장치(300)는, 검출한 물체를, 감시 카메라 장치(300)의 유저에게 통지한다.
- [0025] 도 2는, 본 실시 형태에 따른 학습된 모델 생성 장치(200)의 구성을 나타내는 개략 블록도이다. 학습된 모델 생성 장치(200)는, 추정부(210), 손실 구배 산출부(220), 옵티마이저부(230)를 구비한다. 또한, 학습된 모델 생성 장치(200)(학습된 모델 생성 시스템)는, 복수의 장치로 구성되어 있어도 좋고, 1개의 장치로 구성되어 있어도 좋다. 예를 들면, 추정부(210), 손실 구배 산출부(220), 옵티마이저부(230)의 각각이 1개의 정보 처리 장치여도 좋다. 추정부(210)는, 뉴럴 네트워크를 구비하고 있고, 학습 데이터 DB(100)에서 읽어낸 화상에 포함되는 물체를 추정한다. 손실 구배 산출부(220)는, 추정부(210)가 산출한 추정 결과에 대해, 손실의 구배를 산출한다.
- [0026] 여기서, 손실은, 추정 결과와, 정답 등의 이상치(理想値)의 차의 크기를 나타내고 있다. 예를 들면, 어느 화상의 추정 결과가(0.3, 0.2, 0.1, 0.9)이고, 그 화상의 정답이, (0.0, 0.0, 0.0, 1.0)이면, 손실은, 이들 각 항의 차분의 제곱 평균($((0.3-0.0)^2 + (0.2-0.0)^2 + (0.1-0.0)^2 + (0.9-1.0)^2)/4=0.0375$)여도 좋다. 혹은, 손실은, 제곱 평균 제곱근 오차(RMSE : Root Mean Square Error), 평균 절대 오차(MAE : Mean Absolute Error), 평균 평방 제곱 대수 오차(RMSLE : Root Mean Square Logarithmic Error)여도 좋다. 또한, 손실 구배 산출부(220)는, 추정부(210)의 뉴럴 네트워크의 복수의 파라미터 각각의 방향에 대해, 손실의 구배를 산출한다. 예를 들면, 파라미터 x_i 의 방향의 손실의 구배는, 파라미터 x_i 의 값을, x_i+h 로 했을 때의 손실 $Loss(x_i+h)$ 와, x_i-h 로 했을 때의 손실 $Loss(x_i-h)$ 의 차를, $2h$ 로 나눈 값($(Loss(x_i+h) - (Loss(x_i-h)))/2h$)로 근사적으로 구해진다. 옵티마이저부(230)는, 손실 구배 산출부(220)가 산출하는 손실의 구배에 근거하여, 추정부(210)의 뉴럴 네트워크의 복수의 파라미터를 산출한다. 이 복수의 파라미터에 의해, 학습된 모델이 구성된다.
- [0027] 도 3은, 본 실시 형태에 따른 학습된 모델 생성 장치(200)의 동작을 설명하는 흐름도이다. 도 3에서는, 학습된

모델 생성 장치(200)가 행하는 학습된 모델 생성의 처리를 설명한다. 우선, 추정부(210)가, 뉴럴 네트워크의 파라미터의 초기치를 설정한다(스텝 S1). 다음에, 추정부(210)는, 학습 데이터 DB(100)로부터 학습 데이터를 취득한다(스텝 S2). 예를 들면, 낮용의 학습된 모델을 생성할 때는, 낮의 화상을 취득한다. 다음에, 추정부(210)는, 선택한 학습 데이터에 대한 추정을 행한다(스텝 S3). 이 추정은, 추정부(210)가 구비하는 뉴럴 네트워크를 이용하여 행한다. 또, 이 추정은, 학습 데이터의 화상에 포함되는 물체의 추정이다. 다음에, 손실 구배 산출부(220)가, 추정부(210)의 추정 결과에 대해, 손실의 구배를 산출한다(스텝 S4).

[0028] 다음에, 옵티마이저부(230)가, 손실 구배 산출부(220)가 산출한 손실의 구배에 근거하여, 뉴럴 네트워크의 파라미터를 산출하는 옵티마이저를 행한다(스텝 S5). 이 옵티마이저는, 손실이 가능한 한 작아지는 파라미터의 값의 조합을 구하는 최적화 문제를 푸는 것으로 행해진다. 이 최적화 문제를 풀 때에, 본 개시에 따른 구배법을 이용한다. 본 개시에 따른 구배법의 상세에 대하여는, 후술한다.

[0029] 다음에, 옵티마이저부(230)는, 학습된 모델 생성의 종료 조건을 만족시키고 있는지 여부를 판정한다(스텝 S6). 종료 조건으로서, 반복 횟수, 손실의 수축 등, 어떠한 조건이어도 좋다. 종료 조건을 만족시키고 있다고 판정했을 때는(스텝 S6-Yes), 옵티마이저부(230)가, 이 학습된 모델 생성의 처리를 종료하고, 이때의 파라미터로 이루어지는 모델을 학습된 모델로 한다.

[0030] 스텝 S6에 있어서, 종료 조건을 만족시키지 않는다고 판정했을 때는(스텝 S6-No), 옵티마이저부(230)는, 추정부(210)의 뉴럴 네트워크의 파라미터를, 스텝 S5에서 옵티마이저한 파라미터로 갱신한다(스텝 S7). 다음에, 추정부(210)는, 학습 데이터를 변경할지 여부를 판정한다(스텝 S8). 예를 들면, 동일한 학습 데이터에 대해서, 미리 결정된 횟수 이상, 스텝 S3 내지 S7의 처리를 행했을 경우는, 추정부(210)는, 학습 데이터를 변경한다고 판정하고, 그 이외의 경우는, 학습 데이터를 변경하지 않는다고 판정해도 좋다. 혹은, 스텝 S3 내지 S7의 처리를 반복해도, 손실이 줄어들지 않으면, 추정부(210)는, 학습 데이터를 변경한다고 판정하고, 그 이외의 경우는, 학습 데이터를 변경하지 않는다고 판정해도 좋다.

[0031] 스텝 S8에 있어서, 학습 데이터를 변경한다고 판정했을 때는(스텝 S8-Yes), 처리는, 스텝 S2으로 진행하고, 학습 데이터를 변경하지 않는다고 판정했을 때는(스텝 S8-No), 처리는, 스텝 S3으로 진행한다.

[0032] 또한, 본 실시 형태에서는, 스텝 S6에 의한 종료 조건의 판정을, 스텝 S5의 후로 했지만, 이것에 한정되지 않는다. 예를 들면, 스텝 S6을, 스텝 S2의 후로 해도 좋고, 스텝 S3의 후로 해도 좋다.

[0033] 학습된 모델 생성 장치(200)는, 학습 데이터에 대한 추정과, 손실의 구배의 산출과, 파라미터의 옵티마이저를 반복 행하는 것으로, 학습된 모델을 생성한다. 이 반복의 횟수는, 예폭 수라고도 칭해진다. 또한, 스텝 S2에 있어서 취득하는 학습 데이터의 수는, 1개여도 좋고, 복수여도 좋다.

[0034] 도 4는, 본 실시 형태에 따른 추정부(210)가 구비하는 뉴럴 네트워크의 예를 나타내는 모식도이다. 도 4의 예에서는, 입력층 L_1 와, L 개의 중간층 L_1, L_2, \dots, L_L 과, 출력층 L_0 를 구비한다. 입력층 L_1 는, 4개의 노드 x_0, x_1, x_2, x_3 으로 구성된다. 또한, 입력층 L_1 의 노드 x_0, x_1, x_2, x_3 각각에는, 학습 데이터의 화상의 각 화소치가 입력되어도 좋다. 또, 학습 데이터의 화상에 대해서, 윤곽선 추출, 휘도 조정 등의 전 처리를 한 후의 값이, 입력층 L_1 의 노드 x_0, x_1, x_2, x_3 각각에 입력되어도 좋다.

[0035] L 개의 중간층 L_1, L_2, \dots, L_L 중, m 번째의 중간층 L_m 은, n 개의 노드 $u_{0}^{(m)}, u_{1}^{(m)}, \dots, u_{n-1}^{(m)}$ 로 구성된다. 도 4의 예에서는, 1번째의 중간층 L_1 은, 5개의 노드 $u_{0}^{(1)}, u_{1}^{(1)}, u_{2}^{(1)}, u_{3}^{(1)}, u_{4}^{(1)}$ 로 구성되고, L 번째의 중간층 L_L 은, 4개의 노드 $u_{0}^{(L)}, u_{1}^{(L)}, u_{2}^{(L)}, u_{3}^{(L)}$ 으로 구성된다. 출력층 L_0 는, 3개의 노드 y_0, y_1, y_2 로 구성된다. 출력층 L_0 의 노드 y_0, y_1, y_2 각각의 값은, 추정부(210)의 추정 결과를 나타내는 값이며, 예를 들면, 그 노드에 대응하는 물체가 포함되어 있는 확률을 나타낸다.

[0036] 어느 층의 노드에 입력되는 값은, 식(1)로 나타내지는 바와 같이, 1개 전의 층의 노드의 값에 의해 정해진다. 식 1에 있어서, $w_{i,j}^{(l)}$ 는, 가중치이며, $b_i^{(l)}$ 는, 바이어스이다. 이들, 가중치 $w_{i,j}^{(l)}$ 와 바이어스 $b_i^{(l)}$ 의 값이, 뉴럴 네트워크의 파라미터이며, 옵티마이저부(230)에 의해 결정된다. 또, $f()$ 는, 활성화 함수이다. 본 실시 형태에 있어서의 활성화 함수는, 예를 들면, 시그모이드 함수, 정규화 선형 함수 등, 뉴럴 네트워크의 활성화 함수로서 이용되는 것이면, 어느 함수여도 좋다.

[0037] [수 1]

$$u_i^{(l+1)} = f\left(\sum_j w_{i,j}^{(l)} u_j^{(l)} + b_i^{(l)}\right) \dots (1)$$

[0038]

[0039] 단, $x_i = u_i^{(0)}$, $y_i = u_i^{(L+1)}$

[0040] 또한, 도 4에 있어서의 각 층의 노드의 수는, 설명을 간단하고 쉽게 하기 위해서, 4, 5, 4, 3으로 했지만, 이것들로 한정되지 않는다.

[0041] 다음에, 수식을 참조하여, 옵티마이저부(230)가 사용하는 구배법에 대해 설명한다. 옵티마이저부(230)는, 도 3의 스텝 S5를 처리할 때에, 식(2)를 이용하여, 추정부(210)의 뉴럴 네트워크의 파라미터를 옵티마이징한다.

[0042] [수 2]

$$\begin{aligned} m &= \beta_1 * m + (1 - \beta_1) * dx, \quad mt = m / (1 - \beta_1^t) \\ v &= \beta_2 * v + (1 - \beta_2) * (dx^2), \quad vt = v / (1 - \beta_2^t) \\ \text{if } 1/\text{cache} &:= 0 \\ \quad at &= (\beta_3 * at + (1 - \beta_3) * a_0) * ((1/m)^t) \\ \text{else} \\ \quad at &= (\beta_3 * at + (1 - \beta_3) * a_0) \\ &\quad * ((1/m)^t * (1/\text{cache})^{\log(|\text{cache}|)}) \\ x &+= - at * mt / (\text{sqrt}(vt) + \text{eps}) \\ \text{cache} &+= x \\ &\dots (2) \end{aligned}$$

[0043]

[0044] 식(2)에 있어서, x는, 옵티마이징하는 파라미터, 즉, 뉴럴 네트워크의 파라미터인 가중치 $w_{i,j}^{(1)}$ 와 바이어스 $b_i^{(1)}$ 중 어느 하나이다. 즉, 옵티마이저부(230)는, 가중치 $w_{i,j}^{(1)}$ 와 바이어스 $b_i^{(1)}$ 의 각각에 대해서, 식(2)의 처리를 행한다. $\beta_1, \beta_2, \beta_3$ 은, 0보다 크고, 1보다 작은 값이며, 미리 결정된 상수이다. 이들 값은, 학습된 모델 생성 장치(200)의 오퍼레이터가 설정해도 좋다.

[0045] dx는, 손실 구배 산출부(220)가 산출한, 손실의 x방향의 구배이다. 즉, x가 가중치 $w_{i,j}^{(1)}$ 인 때는, dx는, 가중치 $w_{i,j}^{(1)}$ 방향의 구배이다. x가 바이어스 $b_i^{(1)}$ 인 때는, dx는, 바이어스 $b_i^{(1)}$ 방향의 구배이다. t는, 에폭 수다. at는, 학습률이다. a0은, 학습률의 초기치이다. a0의 값은, 학습된 모델 생성 장치(200)의 오퍼레이터가 설정해도 좋다. eps는, 분모가 0이 되지 않게 하기 위한, 미리 결정된 매우 작은 상수이다.

[0046] 연산자 「^」은 거듭승을 나타낸다. log는, 상용 대수이다. sqrt()는, 양의 제곱근이다. :=는, 좌변의 값이 우변의 값에 가까운 것을 나타낸다. 즉, 좌변의 값과, 우변의 값의 차의 절대치가, 미리 결정된 수 이하 또는 미만인 것을 나타낸다. +=는, 우변의 값을, 좌변의 변수의 값에 가산하고, 좌변의 변수로 저장하는 것을 나타낸다. 따라서, cache는, 각 에폭에 있어서의 x의 값을 누적한 값이 된다. 여기에서는, cache를, 누적 갱신량이라고 부른다.

[0047] 도 5는, 본 실시 형태에 있어서의 누적 갱신량에 따른 갱신치의 예를 플롯한 그래프이다. 도 5에 있어서, 횡축은, 누적 갱신량(식(2)의 cache)이며, 종축은, 파라미터 X의 갱신치(식(2)의 $-at*mt/(\text{sqrt}(vt)+\text{eps}))$ 이다. 도 5에 나타내는 예에서는, 동그라미표를 부여한 3개소에서, 갱신치가 들출되어 있다. 이것들은, 식(2)의 학습률 at의 산출식에 포함되는 인수 $(1/m)^t$ (이후, 제 1 인수라고 한다)에 의한 효과이다. 손실의 극값에 빠져 버려, 학습이 정체되었을 때는, 구배 dx의 절대치가 매우 작은 상태가 계속되어 버린다. 그러한 상태가 계속되면, 구배 dx의 지수 이동 평균인 m의 절대치도 작아진다(1 미만이 된다). 그러면, m의 역수의 t승인 제 1 인수

의 절대치는 커진다. 이것에 의해, 학습률이 커지므로, 지금까지와 다른 경향의 학습 데이터이며, 돌연 구배 dx가 0으로부터 떨어진 값을 가졌을 때에, 파라미터 X의 갱신치가 작아져 버리는 것을 억제할 수가 있다. 그리고, 파라미터 X의 값이 적당히 갱신되는 것으로, 학습이 정체된 상태로부터의 탈출을 기대할 수가 있다. 또, 에폭 수가 증가할수록, t의 값은 커진다. 학습이 정체되어 있어 m의 절대치가 1 미만일 때는, m의 값이 동일하면, 에폭 수가 증가할수록, t승의 효과에 의해, 이 제 1 인수의 절대치가 커진다. 따라서, 제 1 인수는, 에폭 수가 증가할수록 학습이 정체되었을 때에 학습률을 크게 하는 효과가 커진다.

[0048] 이와 같이, 제 1 인수는, 학습이 정체되었을 때에 절대치가 1보다 커지는 것으로 상기 학습률을 크게 하는 효과가 얻어진다. 또한, m의 역수를 t승하고 있기 때문에, 제 1 인수는, 에폭 수가 증가할수록 학습이 정체되었을 때에 학습률을 크게 하는 효과가 커진다. 이것에 의해, 학습이 정체된 상태로부터 탈출할 수가 있다.

[0049] 그러나, 구배 dx가 연속하여 큰 값을 취하며, 구배 dx의 지수 이동 평균인 m의 절대치는 커져, 그 역수 1/m는 작아진다. 따라서, 제 1 인수는, 구배 dx의 절대치가 클수록, 그 절대치가 작아져, 학습률을 억제하는 효과가 얻어진다. 또한, m의 절대치가 1을 넘고 있으면, 에폭 수가 증가할수록, 제 1 인수에 의해 학습률을 억제하는 효과가 커진다. 이것에 의해, 에폭 수가 증가하여, 즉, 학습이 진행되고 있을 때, 구배 dx가 연속하여 큰 값을 취했다고 해도, 학습률이 억제된다. 따라서, 지금까지의 학습 결과로부터 크게 떨어져 버리는 것, 즉 지금까지의 학습 정보를 파괴해 버리는 것을 피할 수가 있다.

[0050] 또, 도 5에 나타내는 예에서는, 누적 갱신량이 작은 구간 T1에 있어서의 학습률은, 구간 T2, 구간 T3에 있어서의 학습률보다 작아지고 있다. 이것은, 식(2)에 있어서의 if 1/cache := 0이 성립하지 않는 경우, 즉 학습의 시초인 구간 T1, T2의 학습률 at의 갱신치의 산출식에 포함되는 인수(1/cache)^{log(|cache|)}(이후, 제 2 인수라고 한다)에 의한 효과이다. 이 제 2 인수의 값은, 예를 들면, cache가 0.01인 때는, 0.0001과 같이 작은 값으로 되어 있다. 또한, 제 2 인수의 값은, cache가 1인 때에, 최대치인 1이 되고, 그 후는, 단조 감소한다.

[0051] 학습의 초기에 있어서, 예를 들면, 파라미터의 초기치가 최적치로부터 크게 벗어나 있는 경우 등에, 구배가 큰 경우가 있다. 그리고, 구배가 큰 것에 기인하여, 파라미터의 갱신량이 커져, 학습이 발산해 버리는 경우가 있다. 그러나, 이와 같이 누적 갱신량의 작은 구간 T1에서 학습률을 작게 해 두면, 학습의 초기에서는 누적 갱신량이 작기 때문에, 학습의 초기에 있어서의 학습률을 작게 할 수가 있다. 그리고, 학습률이 작으면 구배가 큰 것에 기인하여, 파라미터의 갱신량이 커져, 학습이 발산해 버리는 것을 방지할 수가 있다.

[0052] 그러나, 학습률이 작은 상태에서는, 학습이 진행되지 않기 때문에, 제 2 인수의 값은, 누적 갱신량이 임계치인 1이 될 때까지는 1 이하이지만, 누적 갱신량이 1인 때는, 1이 된다. 또, 누적 갱신량이 1을 넘고 있는 구간 T2에서는, 제 2 인수의 값은 단조 감소하고 있으므로, 동그라미표를 부여한 돌출부를 제외하고, 갱신치도 감소한다. 이것에 의해, 지금까지의 학습으로부터 벗어나 버려, 학습이 발산하는 것, 및 진동을 계속하는 것을 방지할 수가 있다.

[0053] 또한, 누적 갱신량이 커져, if 1/cache := 0이 성립하는 경우는, 학습률 at의 산출식은, 제 1 인수를 포함하지만, 제 2 인수를 포함하고 있지 않다. 이것에 의해, 제 1 인수에 의한 갱신치의 돌출이 제 2 인수에 의해 억제되어 버리는 것을 방지할 수가 있다. 그 한편, 학습이 진행되고 있을 때는, 구배 dx가 연속해서 큰 값을 취했다고 해도, 제 1 인수에 의해 학습률은 억제된다. 따라서, 지금까지의 학습 결과로부터 크게 떨어져 버리는 것, 즉 지금까지의 학습 정보를 파괴해 버리는 것을 피할 수가 있다.

[0054] 도 6은, 본 실시 형태에 있어서의 옵티마이저부(230)의 실시예를 나타내는 모식도이다. 도 6에서는, 설명을 간단하고 쉽게 하기 위해서, 파라미터 수는, w_i와 w_j의 2개만이라고 했지만, 물론, 파라미터의 수는, 이것에 한정되지 않는다. 도 6은, 파라미터 w_i와 w_j의 값의 조합에 대한 손실을 플롯한 그래프이다. 수평면은, 파라미터 w_i와 w_j의 축으로 이루어진다. 연직 방향은, 손실(Loss)의 축이다.

[0055] 파라미터 w_i와 w_j의 초기치는, 도 6에 있어서의 동그라미표, 즉 구배가 큰 장소이지만, 도 5에서 설명한 것처럼, 학습의 초기에 있어서, 누적 갱신량이 작고, 학습률이 억제되어 있다. 이것에 의해, 파라미터 w_i와 w_j의 값은, 발산하지 않고, 스무스하게 구배를 낮추도록 변경된다. 그 후, 파라미터 w_i와 w_j의 값이, 1번의 기에 의해 나타나는 극값에 들어가면, 학습이 정체되어 버린다. 그러나, 제 1 인수의 효과에 의해, 파라미터 w_i와 w_j의 값은, 바운드(bound)하도록 갱신된다. 그 후, 파라미터 w_i와 w_j의 값이, 2번의 기에 의해 나타나는 극값에 들어갔을 때 도 마찬가지이다. 그리고, 파라미터 w_i와 w_j의 값은, 도 6에 있어서의 손실이 최소가 되어 있는 3번의 기에 의해

나타나는 극값에, 가까스로 도착할 수가 있다.

- [0056] 도 7은, 본 실시 형태에 따른 감시 카메라 장치(300)의 구성을 나타내는 개략 블록도이다. 감시 카메라 장치(300)는, 영상 입력부(301), 특징 추출부(302), 학습된 모델 일차 유지부(303), 물체 인식부(304), 이상 검지부(305), 인식 결과 표시부(306), 인식 결과 경고부(307), 고정밀도 로케이터(308), 시계(309), 학습 정보 교환부(310), 장소 별 학습 DB(311), 시간 별 학습 DB(312)를 구비한다. 감시 카메라 장치(300)는, 1개의 장치여도 좋고, 복수의 장치로 구성되어 있어도 좋다. 예를 들면, 특징 추출부(302)와, 학습된 모델 일차 유지부(303)로, 추정 장치를 구성하고 있어도 좋다.
- [0057] 영상 입력부(301)는, 촬상 소자와, 촬상 소자의 촬상면에 피사체의 영상을 결상시키기 위한 광학계를 구비한다. 영상 입력부(301)은, 촬상면에 결상된 피사체의 영상을 전기 신호로 변환한다. 특징 추출부(302)는, 전기 신호로 변환된 피사체의 영상에 포함되는 물체의 추정을, 뉴럴 네트워크를 이용하여 행한다. 학습된 모델 일차 유지부(303)는, 특징 추출부(302)의 뉴럴 네트워크의 파라미터인 학습된 모델을 유지한다.
- [0058] 물체 인식부(304)는, 특징 추출부(302)의 추정 결과로부터, 영상에 포함되는 물체를 인식한다. 이상 검지부(305)는, 물체 인식부(304)가 인식한 물체가, 경고를 발해야 할 이상(異常)한 것인지 여부를 판정한다. 인식 결과 표시부(306)는, 물체 인식부(304)가 인식한 물체의 명칭 등을 화면 표시하여, 오퍼레이터에게 통지한다. 인식 결과 경고부(307)은, 이상 검지부(305)가, 경고를 발해야 할 이상한 것이라고 판정했을 때에는, 경고를 음성으로 발하여, 오퍼레이터에게 통지한다. 이때, 인식 결과 경고부(307)는, 이상의 내용에 따라, 발하는 음성을 변경해도 좋다.
- [0059] 고정밀도 로케이터(308)는, GPS(Global Positioning System) 등에 의해, 감시 카메라 장치(300)가 설치되어 있는 위치를 검출한다. 시계(309)는, 현재 시각을 통지한다. 학습 정보 교환부(310)는, 고정밀도 로케이터(308)가 검출한 위치, 혹은, 시계(309)가 통지한 현재 시각에 따른 학습된 모델을, 장소 별 학습 DB(311) 또는 시간 별 학습 DB(312)로부터 취득한다. 학습 정보 교환부(310)는, 취득한 학습된 모델을, 특징 추출부(302)를 통하여, 학습된 모델 일차 유지부(303)에 저장한다. 장소 별 학습 DB(311)는, 학습된 모델 생성 장치(200)가 생성한 학습된 모델을, 장소 별로 기억한다. 시간 별 학습 DB(312)는, 학습된 모델 생성 장치(200)가 생성한 학습된 모델을, 시간 별로 기억한다.
- [0060] 또한, 장소 별 학습 DB(311) 및 시간 별 학습 DB(312)는, 복수의 감시 카메라 장치(300)가 이용하도록 해도 좋다. 예를 들면, 복수의 감시 카메라 장치(300)가, 네트워크를 통하여, 동일한 장소 별 학습 DB(311) 및 시간 별 학습 DB(312)에 액세스하도록 해도 좋다.
- [0061] 또, 감시 카메라 장치(300)가, 학습 데이터 DB(100)와, 학습된 모델 생성 장치(200)를 포함하고 있어도 좋다. 그 경우, 학습 데이터 DB(100)가 기억하는 학습 데이터는, 영상 입력부(301)가 출력하는 영상의 데이터여도 좋다.
- [0062] 또, 옵티마이저부(230)는, 헤시안 행렬 등에 의한 극값 회귀를 포함하고 있어도 좋다. 즉, 손실의 구배 dx 뿐만이 아니라, 손실의 2차 미분 등 고차 미분을 이용하여, 파라미터를 산출하는 경우 등, 식(2) 이외의 산출 방법을 이용하여 파라미터를 산출하는 경우에도, 옵티마이저부(230)는, 식(2)와 마찬가지로 하여 학습률 at를 산출하도록 해도 좋다. 또한 학습률 at를 산출할 때에, 옵티마이저부(230)는, 제 1 인수, 제 2 인수에 더하여, 다른 인수를 승산하거나, 혹은, 다른 항을 가산하도록 해도 좋다.
- [0063] 또, 도 1에 있어서의 학습된 모델 생성 장치(200), 또는 감시 카메라 장치(300)의 기능을 실현하기 위한 프로그램을 컴퓨터 관독 가능한 기록 매체에 기록하여, 이 기록 매체에 기록된 프로그램을 컴퓨터 시스템로 하여금 읽어 들이게 하여, 실행하는 것에 의해 학습된 모델 생성 장치(200), 또는 감시 카메라 장치(300)를 실현해도 좋다. 또한, 여기서 말하는 「컴퓨터 시스템」이란, OS 또는 주변 기기 등의 하드웨어를 포함하는 것으로 한다.
- [0064] 또, 「컴퓨터 관독 가능한 기록 매체」란, 플렉서블 디스크, 광 자기 디스크, ROM, CD-ROM, DVD 등의 휴대용 매체, 컴퓨터 시스템에 내장되는 하드 디스크, SSD 등의 기억 장치를 말한다. 또한 「컴퓨터 관독 가능한 기록 매체」란, 인터넷 등의 네트워크 또는 전화 회선 등의 통신 회선을 통하여 프로그램을 송신하는 경우의 통신선과 같이, 단시간 동안, 동적으로 프로그램을 유지하는 것, 그 경우의 서버 또는 클라이언트가 되는 컴퓨터 시스템 내부의 휘발성 메모리와 같이, 일정 시간 프로그램을 유지하고 있는 것도 포함하는 것으로 한다. 또 상기 프로그램은, 전술한 기능의 일부를 실현하기 위한 것이어도 좋고, 또한 전술한 기능을 컴퓨터 시스템에 이미 기록되어 있는 프로그램과의 조합으로 실현될 수 있는 것이어도 좋다.
- [0065] 또, 상술한 도 1에 있어서의 학습된 모델 생성 장치(200), 또는 도 7에 있어서의 감시 카메라 장치(300)의 각

기능 블록은 개별적으로 칩화해도 좋고, 일부, 또는 전부를 집적하여 칩화해도 좋다. 또, 집적 회로화의 수법은 LSI로 한정하지 않고, 전용 회로, 또는 범용 프로세서로 실현해도 좋다. 하이브리드(hybrid), 모노리식 중 어느 것이어도 좋다. 일부는, 하드웨어에 의해, 일부는 소프트웨어에 의해 기능을 실현시켜도 좋다.

[0066] 또, 반도체 기술의 진보에 따라, LSI를 대체하는 집적 회로화 등의 기술이 출현했을 경우, 해당 기술에 의한 집적 회로를 이용하는 것도 가능하다.

[0067] 이상, 이 발명의 실시 형태를 도면을 참조하여 상술해 왔지만, 구체적인 구성은 이 실시 형태로 한정되는 것은 아니고, 이 발명의 요지를 일탈하지 않는 범위의 설계 변경 등도 포함된다.


부호의 설명

- [0068] 10...학습된 모델 생성 등록 시스템
- 100...학습 데이터 DB
- 200...학습된 모델 생성 시스템
- 210...추정부
- 220...손실 구배 산출부
- 230...옵티마이저부
- 300...감시 카메라 장치
- 301...영상 입력부
- 302...특징 추출부
- 303...학습된 모델 일차 유지부
- 304...물체 인식부
- 305...이상 검지부
- 306...인식 결과 표시부
- 307...인식 결과 경고부
- 308...고정밀도 로케이터부
- 309...시계
- 310...학습 정보 교환부
- 311...장소 별 학습 DB
- 312...시간 별 학습 DB

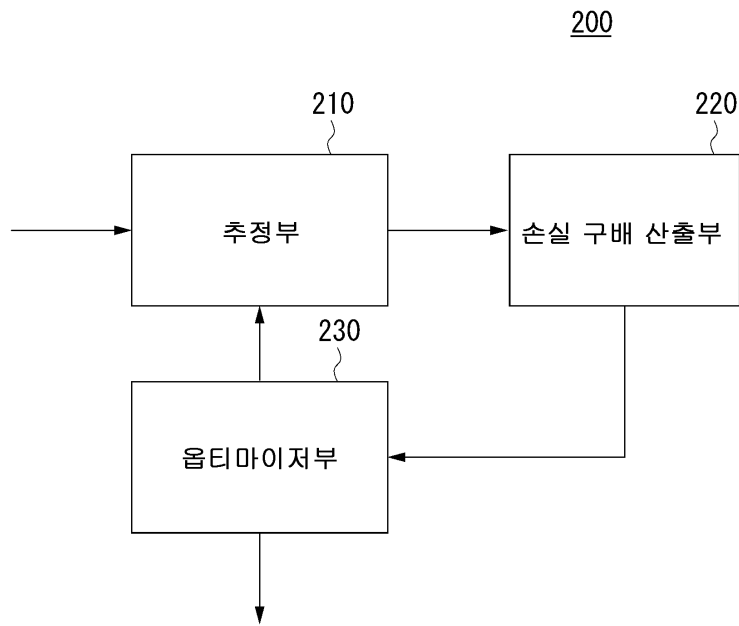
도면

도면1

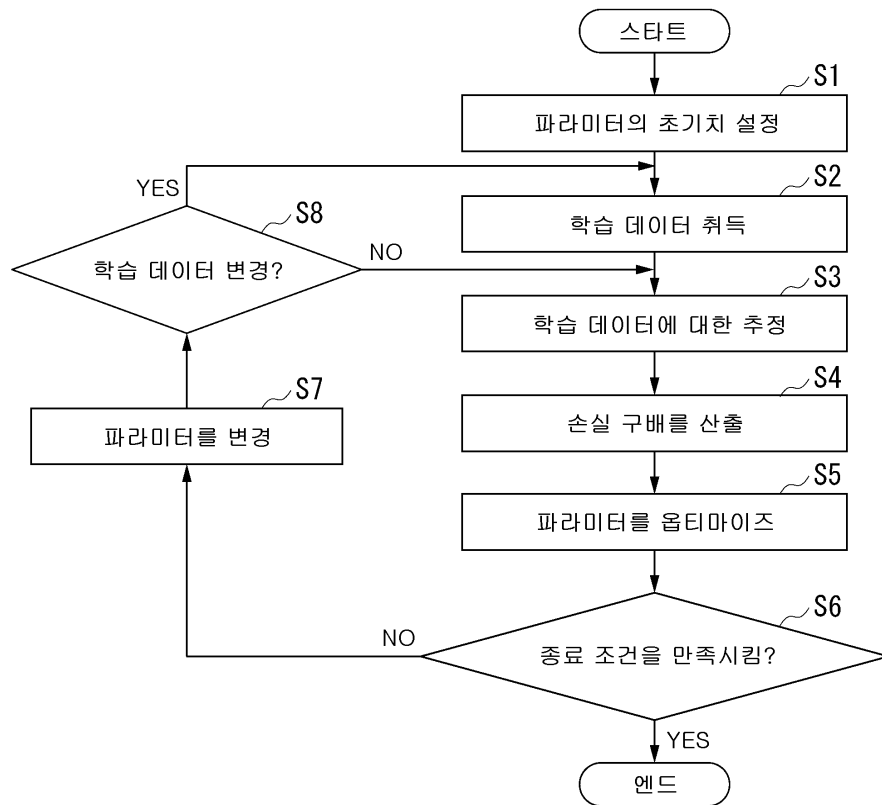
10



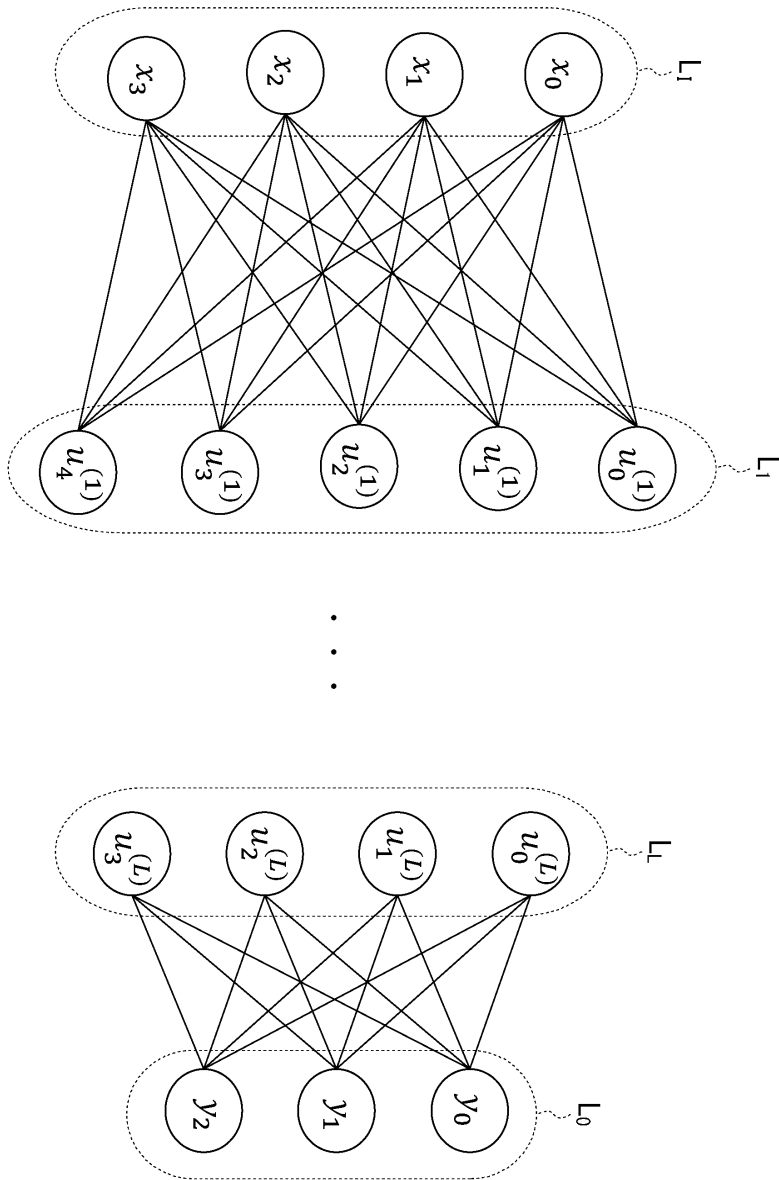
도면2




도면3




도면4



도면5



도면6



도면7

