명세서

발명의 명칭: 비식별화된 이미지를 이용한 신경망 학습 방법 및 이를 제공하는 서버

기술분야

[1] 본 발명은 신경망 학습 방법에 관한 것으로 보다 상세하게는 비식별화된 이미지를 통한 신경망의 학습 방법에 관한 것이다.

배경기술

[2] 빅데이터 기반의 분석 기술이 다양한 산업 분야에 적용됨에 따라, 수집되는 데이터 중 개인에 관한 정보를 포함하는 개인 정보들은 별도로 보호하고 관리해야 할 필요가 있다.

[3] 이와 함께, 인공지능 기술 역시 기존의 데이터 분석 기술을 대신하여 그 적용 범위가 확대되고 있다. 예를 들어 본인 인증을 위한 방식으로 지문이나 안면 등의 생체 정보를 이용하여 인공지능이 사용자의 본인 여부를 확인하고 이에 따른 개인화된 서비스를 제공하는 방식들이 늘고 있다.

[4] 이때 개인의 생체 정보를 이용하여 본인 인증을 위해서는 인공지능에 이용되는 신경망(Neural Network)이 다양한 생체 정보들을 학습해야 하는데, 학습에 이용되는 학습 데이터 자체가 생체 정보로서 개인 정보를 포함하므로 개인 정보의 이용과 관리에 따른 주의가 필요하다.

[5] 따라서, 인공지능 분야에 개인 정보를 포함하는 빅데이터를 활용하여 학습하고 이에 기반한 서비스를 제공하기 위해서는 활용 근거의 확보가 필요한데 최근에는 이러한 개인 정보를 비식별화하고 비식별화된 정보는 개인신용정보보호 대상에서 제외하는 등의 법안이 마련되고 있다.

[6] 금융 업계의 경우 인터넷 은행의 출범 등으로 인해 비대면 방식의 계좌개설과 금융 서비스를 제공하기 위해서, 필연적으로 요구되는 사용자의 안면 영상 또는 신분증 촬영 영상 등을 보호하고, 인공지능이 학습하기 위해서는 이러한 개인 정보들의 비식별화가 더욱 요구되고 있다.

[7] 하지만 현재의 인공지능에 이용되는 학습 방법은 일반적인 형식의 데이터에 관한 것으로 개인 정보의 보호와 비식별화에 대해서는 고려한 바가 없다.

[8] 인공지능에 이용되는 신경망의 학습을 위해서는 많은 학습 데이터의 확보가 필요하며 인공 지능 기반의 효율적인 서비스를 제공하기 위해서 보다 효율적인 학습 데이터의 비식별화 방법과 이를 통한 학습 방법이 필요한 상황이다.

발명의 상세한 설명

기술적 과제

[9] 상술한 기술적 과제를 해결하기 위해 본 발명은 비식별화된 이미지를 이용하는 신경망의 학습 방법을 제안하는 것을 목적으로 한다.

[10] 또한 본 발명은 신경망의 예측 정확도를 고려한 이미지의 비식별화 방법을

제안하는 것을 목적으로 한다.

기술적 해결방법

[11] 상기 기술적 과제를 해결하기 위한 본 발명에 따른 비식별화된 이미지를 이용한 신경망의 학습 방법은 제n 차원의 벡터로 표현된 제1 이미지를 미리 결정된 제p 차원의 제2 이미지로 인코딩하는 단계; 상기 제2 이미지를 제q 차원의 제3 이미지로 디코딩하는 단계; 상기 제3 이미지를 신경망에 입력하고, 상기 제3 이미지에 포함된 객체 정보를 추출하는 단계; 및 상기 추출된 객체 정보를 이용하여 상기 신경망 내 연산에 이용되는 적어도 하나의 파라미터 정보를 학습하는 단계를 포함한다.

[12] 상기 학습하는 단계는 상기 추출된 객체 정보에 따라 상기 인코딩 또는 디코딩 연산에 이용되는 파라미터 정보를 학습하는 것이 바람직하다.

[13] 상기 학습하는 단계는 상기 제3 이미지와 제1 이미지의 유사도를 정의하는 비식별화 정도와 상기 신경망의 객체 정보에 대한 예측 정확도 간의 상관 관계를 이용하여 상기 파라미터 정보를 학습하는 것이 바람직하다.

[14] 상기 제p 차원의 크기는 상기 비식별화 정도에 따라 결정되는 것이 바람직하다.

[15] 상기 제n 차원의 크기와 상기 제q 차원의 크기는 동일한 것이 바람직하다.

[16] 상기 결정된 제p 차원으로 인코딩 된 제2 이미지를 저장하는 단계를 더 포함하고, 상기 디코딩하는 단계는 상기 신경망 학습 시, 상기 저장된 제2 이미지를 제3 이미지로 디코딩하는 것이 바람직하다.

[17] 상기 디코딩 하는 단계는 상기 제2 이미지를 상기 제q 차원으로 디코딩 하는 경우 상기 제1 이미지와 상이한 데이터 값을 갖도록 디코딩하는 것이 바람직하다.

[18] 상기 기술적 과제를 해결하기 위한 본 발명에 따른 비식별화된 이미지를 이용한 신경망의 학습 서버에 있어서, 제n 차원의 벡터로 표현된 제1 이미지를 미리 결정된 제p 차원의 제2 이미지로 인코딩 후, 상기 제2 이미지를 제q 차원의 제3 이미지로 디코딩하는 비식별화부; 및 상기 제3 이미지를 신경망에 입력하고, 상기 제3 이미지에 포함된 객체 정보를 추출하여 상기 신경망 내 연산에 이용되는 적어도 하나의 파라미터 정보를 학습하는 학습부를 포함한다.

[19] 상기 학습부는 상기 추출된 객체 정보에 따라 상기 인코딩 또는 디코딩 연산에 이용되는 파라미터 정보를 학습하는 것이 바람직하다.

[20] 상기 학습부는 상기 제3 이미지와 제1 이미지의 유사도를 정의하는 비식별화 정도와 상기 신경망의 객체 정보에 대한 예측 정확도 간의 상관 관계를 이용하여 상기 파라미터 정보를 학습하는 것이 바람직하다.

[21] 상기 결정된 제p 차원으로 인코딩 된 제2 이미지를 저장하는 데이터베이스를 더 포함하고, 상기 비식별화부는 상기 신경망 학습 시, 상기 저장된 제2 이미지를 제3 이미지로 디코딩하는 것이 바람직하다.

[22] 상기 비식별화부는 상기 제2 이미지를 상기 제q 차원으로 디코딩 하는 경우

상기 제1 이미지와 상이한 데이터 값을 갖도록 디코딩하는 것이 바람직하다.

발명의 효과

[23] 본 발명에 따르면, 비식별화된 이미지를 신경망 학습에 이용하므로 이미지에 포함된 개인 정보의 이용 없이 신경망을 학습시킬 수 있다.

[24] 또한 본 발명은 원 이미지로 복원이 불가능하도록 이미지를 비식별화하여 저장하므로 학습 데이터 관리의 효율성을 높일 수 있다.

[25] 또한, 본 발명은 이미지에 포함된 정보의 차원을 신경망의 예측 성능에 따라 조절하여 인코딩 함으로써 이미지 처리의 효율성을 높일 수 있다.

도면의 간단한 설명

[26] 도 1은 본 발명의 일 실시예에 따른 비식별화된 이미지 인식 기반 서비스를 제공하는 시스템을 나타낸 예시도이다.

[27] 도 2는 본 발명의 일 실시예에 따른 서비스 운영 서버의 신경망 학습 방법의 객체 정보 검출을 나타낸 예시도이다.

[28] 도 3은 본 발명의 일 실시예에 따른 서비스 운영 서버의 학습 프로세스를 나타낸 흐름도이다.

[29] 도 4는 본 발명의 일 실시예에 따른 서비스 운영 서버의 이미지 인코딩 방법을 나타낸 예시도이다.

[30] 도 5는 본 발명의 일 실시예에 따른 서비스 운영 서버의 이미지 디코딩 방법을 나타낸 예시도이다.

[31] 도 6은 본 발명의 일 실시예에 따른 서비스 운영 서버의 신경망 구성을 나타낸 예시도이다.

[32] 도 7은 본 발명의 일 실시예에 따른 서비스 운영 서버의 신경망 학습 방법을 나타낸 예시도이다.

[33] 도 8은 본 발명의 일 실시예에 따른 서비스 운영 서버의 구성을 나타낸 블록도이다.

발명의 실시를 위한 형태

[34] 이하의 내용은 단지 발명의 원리를 예시한다. 그러므로 당업자는 비록 본 명세서에 명확히 설명되거나 도시 되지 않았지만 발명의 원리를 구현하고 발명의 개념과 범위에 포함된 다양한 장치를 발명할 수 있는 것이다. 또한, 본 명세서에 열거된 모든 조건부 용어 및 실시 예들은 원칙적으로, 발명의 개념이 이해되도록 하기 위한 목적으로만 명백히 의도되고, 이와 같이 특별히 열거된 실시 예들 및 상태들에 제한적이지 않는 것으로 이해되어야 한다.

[35] 상술한 목적, 특징 및 장점은 첨부된 도면과 관련한 다음의 상세한 설명을 통하여 보다 분명해질 것이며, 그에 따라 발명이 속하는 기술분야에서 통상의 지식을 가진 자가 발명의 기술적 사상을 용이하게 실시할 수 있을 것이다.

[36] 또한, 발명을 설명함에 있어서 발명과 관련된 공지 기술에 대한 구체적인 설명이 발명의 요지를 불필요하게 흐릴 수 있다고 판단되는 경우에 그 상세한

설명을 생략하기로 한다. 이하에는 첨부한 도면을 참조하여 본 발명의 바람직한 실시 예에 대해 상세하게 설명한다.

[37] 도 1은 본 발명의 일 실시예에 따른 비식별화된 이미지 인식 기반 서비스를 제공하는 시스템을 나타낸 예시도이다.

[38] 도 1을 참조하면 사용자(5)는 사용자 단말(10)을 이용하여 자신의 안면을 촬영할 수 있다.

[39] 서비스 운영 서버(100)는 사용자(5)로부터 촬영된 안면 이미지(20)를 수신하고, 예를 들어 신분증의 이미지와 촬영된 안면 이미지(20)를 비교하여 본인 인증을 수행하고 이에 따른 서비스를 제공해 줄 수 있다.

[40] 이때, 서비스 운영 서버(100)는 본인 인증을 신경망을 이용하여 수행할 수 있으며 신경망을 통해 기존의 영상 처리 방식에 비해 보다 빠르고 정확한 본인 확인 절차를 수행할 수 있다.

[41] 본인 인증에 이용되는 신경망이 이미지를 통해 본인 여부를 판단하기 위해서는 반복적인 학습이 필요하며 따라서 서비스 운영 서버(100)는 별도의 데이터베이스(200)를 통해 다양한 학습 데이터를 보관할 수 있다.

[42] 다만, 상술한 바와 같이 본인 인증에 이용되는 신경망은 사용자(5)의 안면 정보를 포함하는 이미지들을 학습 데이터로 학습해야 하므로 개인 정보를 직접적으로 이용해야 하는 문제가 발생할 수 있다.

[43] 따라서, 본 실시예에서 서비스 운영 서버(100)는 학습 데이터로 이용되는 안면 정보 등 개인 정보를 포함하는 이미지를 비식별화 하고 원 이미지로 복원이 불가능하도록 함으로써 개인 정보를 보호한다.

[44] 본 실시예에 따른 서비스 운영 서버(100)는 사용자 단말(10)로부터 수신되는 이미지를 비식별화하고 비식별화된 이미지를 학습 데이터로 데이터베이스(200)에 저장하여 신경망의 학습에 이용할 수 있다.

[45] 일반적으로 이미지 검출에 이용되는 신경망은 색공간(color space) 상의 다차원(multi-dimension) 벡터로 표현되는 이미지 들의 데이터 값을 이용한다.

[46] 이미지 내 데이터 값들은 3차원의 벡터로 크기를 정의하는 높이(height)와 너비(width) 및 깊이(depth)로 정의될 수 있다. 이때 깊이는 각 픽셀의 정보를 표현하는 방식인 채널의 크기로 정의될 수 있다.

[47] 일 예로 이미지의 깊이는 색상을 정의하는 정보로서 RGB 코드로 표현될 수 있다. RGB 코드로 이미지가 표현된 경우에는 채널의 크기는 3이며 각 채널에 해당 픽셀의 RGB 값이 저장될 수 있다.

[48] 또는 채널로서 그레이스케일(Grayscale) 또는 HSV(색상(Hue, 채도(Saturation), 명도(Value))를 구성하여 다차원의 벡터로 이미지 내 정보들을 표현하는 것도 가능하다.

[49] 또한, 신경망의 학습을 위해서는 여러 장의 이미지가 이용될 수 있으며 이러한 이미지의 수를 추가하여 4차원의 벡터로 학습 데이터를 구성하는 것도 가능하다.

[50] 신경망은 다차원 벡터로 표현된 이미지 내 데이터 값들에 채널 별로 정의된 필터를 적용하여 합성곱(Convolution) 연산하고 이미지 내 특징 정보들을 추출할 수 있다.

[51] 합성곱 연산은 순차적인 신경망을 구성하는 레이어를 단위로 수행되며 따라서 신경망은 합성곱 레이어들이 적층된 형태의 네트워크로 구성될 수 있다.

[52] 예를 들어 특정 색의 분포나 패턴으로 객체가 정의되는 경우 특정 색을 강조하는 필터의 가중치를 조절하는 방식으로 신경망은 학습될 수 있다.

[53] 구체적으로 본 실시예에서 신경망은 본인 확인을 위해 사용자(5)의 안면 정보를 포함하는 안면 이미지로부터 객체 정보(30)를 추출하도록 학습될 수 있다. 이 때, 객체 정보(30)는 수 많은 데이터들을 구별하는 데 가장 중요도가 높은 특징 정보로서, 예컨대, 안면 정보 내에서 가장 식별력이 높은 고유 정보일 수 있다. 예를 들어, 안면 정보 내 포함되는 눈, 코, 입 등을 이미지 내에서 추출할 수 있고, 이들의 형상, 상대적인 위치 관계 등 누구의 안면 이미지임을 식별하기 위해 필요할 것으로 판단된 정보를 객체 정보(30)로서 추출하도록 학습될 수 있다.

[54] 객체 정보(30)는 하나 이상의 특징 정보를 포함할 수 있고, 식별에 필요한 중요도에 따라 각각의 특징 정보에 가중치를 둘 수 있다.

[55] 다만 이때의 안면 이미지는 개인 정보를 그대로 포함하며 학습에 이용되는 학습 데이터 자체가 개인 정보일 수 있다. 또한 신경망은 다양한 촬영 조건의 이미지에 대해서 강인한 성능을 갖도록 실제 이미지를 학습 데이터로 이용하므로 실제 이미지는 보다 다양한 개인 정보들을 포함할 수 있다.

[56] 따라서 신경망의 학습에 안면 이미지 등을 이용하기 위해서는 별도의 개인 정보의 보호를 위한 부가적인 처리 프로세스가 요구될 수 있는데, 본 발명에 따른 학습 방법은 이러한 개인 정보를 포함하는 이미지를 비식별화하고 신경망을 학습시킨다.

[57] 이하, 본 실시예에 따른 서비스 운영 서버(100)의 학습 방법에 대하여 보다 상세히 설명한다.

[58] 도 2를 참조하면 본 실시예에 따른 서비스 운영 서버(100)는 비식별화부(110) 및 학습부(120)로 구성될 수 있다.

[59] 비식별화부(110)는 사용자 단말(10)로부터 촬영되어 전송된 안면 이미지를 비식별화한다.

[60] 구체적으로 비식별화부(110)는 인코더(112)와 디코더(114)를 포함하여 구성된다.

[61] 비식별화부(110)는 인코더(112)를 이용하여 수신된 안면 이미지를 인코딩하고, 다시 디코딩하는 것을 통해 이미지를 변환하여 학습 데이터를 생성한다.

[62] 이때, 디코더(114)로 변환된 이미지는 원래의 안면 이미지와 다른 형식으로 표현된 정보를 포함할 수 있다.

[63] 구체적으로 변환된 이미지는 육안으로 이미지 내에 포함된 객체의 신분 인식이

불가능한 형태로 변환되며, 원래의 안면 이미지로 복원이 불가능한 형식으로 구성될 수 있다.

[64] 변환된 이미지는 신경망 모델의 입력 데이터로 이용되므로 육안으로는 신분 인식이 불가능하나 신경망 모델의 객체 정보(30) 추출에는 보다 효율적인 형식으로 표현된 정보일 수 있다.

[65] 학습부(120)는 비식별화부(110)로부터 비식별화된 이미지를 이용하여 객체 정보(30)를 추출하는 신경망을 학습시킨다.

[66] 비식별화된 이미지가 신경망에 입력되면 신경망은 객체 정보(30)를 출력한다. 출력된 객체 정보(30)를 이용하여 학습부(120)는 신경망 내 특징 정보 추출에 이용되는 다양한 파라미터들의 가중치를 학습하여 갱신할 수 있다.

[67] 또한 학습부(120)는 신경망과 함께 이미지를 비식별화하는데 이용되는 인코더(112) 또는 디코더(114)의 여러 파라미터들도 함께 학습시킬 수 있다.

[68] 이하 도 3을 참조하여 학습 방법을 순차적으로 보다 상세히 설명한다.

[69] 먼저, 제n 차원의 벡터로 표현된 제1 이미지(20)를 미리 결정된 제p 차원의 제2 이미지(21)로 인코딩한다(S10).

[70] 제n 차원은 사용자 단말(10)로 촬영되어 서비스 운영 서버(100)로 전송된 제1 이미지(20)에 포함된 정보를 표현하는 특성들의 수를 정의할 수 있다. 예를 들어, 제n 차원은 이미지의 크기로서 높이와 너비 및 깊이의 3차원으로 정의될 수 있다.

[71] 즉, 제n 차원의 제1 이미지(20)를 인코더(112)를 이용하여 압축하여 제p 차원의 제2 이미지(21)로 변환한다.

[72] 도 4를 참조하면, 수신된 제1 이미지(20)가 인코더(112)에 입력되고, 인코더(112)는 미리 결정된 압축 규칙에 의해 제p 차원의 제2 이미지(21)를 생성할 수 있다.

[73] 제2 이미지(21)는 제1 이미지(20)를 표현하는 차원과 다른 축소된 차원인 제p 차원으로 인코딩될 수 있다.

[74] 예를 들어 제1 이미지(20)를 표현하는 제n 차원 상의 데이터 값들은 인코딩 기준에 따라 압축될 수 있으며, 따라서 제n 차원에 비하여 축소된 데이터 크기를 갖는 제p 차원으로 제2 이미지(21)는 표현될 수 있다.

[75] 또는 제n 차원 중 특정 차원을 기준으로 데이터 값들을 투영(projection) 시킴으로 차원의 수를 축소시키고, 축소된 제p 차원의 제2 이미지(21)를 생성하는 것도 가능하다.

[76] 이상 인코더(112)는 제n 차원과 비교하여 차원의 수 자체가 축소되거나 또는 각 차원의 데이터 값을 표현하는 데이터 크기가 축소된 제p 차원으로 제1 이미지(20)를 인코딩할 수 있다.

[77] 다음, 인코더(112)에서 생성된 제p 차원의 제2 이미지(21)를 제q 차원의 제3 이미지(22)로 디코딩한다(S20).

[78] 제q 차원은 디코더(114)를 통해 제p 차원을 재 확장시킨 것으로 입력된 제2

이미지(21) 내 데이터 값들을 재 정의한다.

[79] 도 5를 참고하면 디코더(114)는 제p 차원으로 정의된 제2 이미지(21)의 데이터 값들을 다시 제q 차원 상의 데이터 값으로 확장시킨다. 구체적으로 디코더(114)는 제2 이미지(21)의 데이터 값들을 가중치 파라미터들을 이용해 제q 차원의 정보로 확장시킨다.

[80] 이때, 본 실시예에서 디코딩되는 제q 차원은 인코딩 전의 제1 이미지(20)의 제n 차원과 동일한 차원으로 정의될 수 있다. 하지만, 제q 차원으로 디코딩 된 제3 이미지(22)는 인코딩된 제2 이미지(21)로부터 생성되는 것으로 원래의 제1 이미지(20)와는 서로 다른 데이터 값을 동일 차원 상에서 가질 수 있다.

[81] 즉, 제1 이미지(20)의 경우 일반적인 방식으로 촬영된 이미지로 육안으로 포함된 객체를 식별할 수 있으나 제3 이미지(22)는 인코딩 후 재 정의된 정보로서 육안으로 객체를 식별이 불가능한 형태로 데이터 값들로 구성될 수 있다.

[82] 이상의 과정을 통해 본 실시예에 따른 학습 방법은 제1 이미지(20)를 비식별화하여 제2 이미지(21) 및 제3 이미지(22)를 생성한다.

[83] 다음, 비식별화된 제3 이미지(22)를 신경망에 입력하고, 상기 제3 이미지(22)에 포함된 객체 정보(30)를 추출한다(S30).

[84] 또한 추출된 객체 정보(30)를 이용하여 신경망을 학습시킨다(S40).

[85] 신경망은 입력 데이터인 비식별화된 이미지에 대해서 보다 강인한 성능을 갖도록 네트워크 내 파라미터들을 갱신시킬 수 있다.

[86] 도 6을 참조하면, 신경망은 입력 레이어(122)와 출력 레이어(128) 내에 합성곱 연산을 수행하는 다수의 히든 레이어(124, 126)들로 구성될 수 있다. 히든 레이어(124, 126)는 입력 데이터에 대응하여 가중치 연산을 수행하는 노드로 구성될 수 있다.

[87] 본 실시예에서 신경망은 합성곱 연산을 수행하는 합성곱 레이어들로 구성될 수 있으므로 히든 레이어(124, 126) 내 노드는 비식별화된 이미지 내 데이터 값들을 단위 영역 별로 합성곱 연산을 수행하는 필터로 구성될 수 있다.

[88] 즉, 입력된 이미지 내의 채널 별 데이터 값들은 복수의 합성곱 레이어들을 통과하면서 순차적으로 연산되며, 이를 통해 강조되는 데이터 값들의 특징적인 분포 나 패턴을 찾고 이미지 내의 객체 정보(30)를 추출한다.

[89] 학습을 위해 출력 신호로 추출된 객체 정보(30)는 실제 이미지의 타겟 값과 비교하여 오차를 산출하고, 산출된 오차를 역전파((Backpropagation) 알고리즘에 따라 신경망 내에서 역방향으로 전파시킬 수 있다. 예를 들어 역전파 알고리즘을 이용하여 에러를 발생시키는 원인을 찾고 신경망 노드들 간의 연결 가중치를 변경하는 방식으로 학습될 수 있다.

[90] 또한 도 7을 참조하면 본 실시예에 따른 학습 방법은 신경망 내 합성곱 연산을 수행하는 각 노드 간의 가중치 파라미터(W2)를 학습하는 것과 함께, 인코딩 또는 디코딩에 이용되는 비식별화 파라미터(W1)를 함께 학습하는 방식으로 수행될 수 있다.

[91] 즉, 추출된 객체 정보(30)를 이용하여 역전파 알고리즘에 따라 레이어 내 노드들 간의 연결 가중치를 정의하는 파라미터(W2)를 갱신하되 비식별화부(110)의 인코딩 또는 디코딩 연산에 이용되는 파라미터(W1)를 갱신하는 것도 가능하다.

[92] 예를 들어 비식별화부(110)의 비식별화 정도로서 압축율을 고려하여 제p 차원(z)의 크기가 결정되면, 제n 차원의 제1 이미지(20)를 제p 차원(z)으로 축소를 위한 인코딩 파라미터 들을 학습을 통해 결정할 수 있다.

[93] 일 예로 인코더(112)의 차원 축소 시 데이터 샘플링 기준이 되는 단위 블록의 크기, 샘플링 비율로서 연산에 이용되는 파라미터 들을 갱신하는 방식으로 학습할 수 있다.

[94] 또한, 반대로 디코딩에 이용되는 차원 확장 시 관련된 가중치 파라미터 들을 갱신하는 방식으로 학습하는 것도 가능하다.

[95] 이상의 과정을 통해 본 실시예에 따른 학습 방법은 추출된 객체 정보(30)를 이용하여 신경망 내의 파라미터를 갱신함과 동시에 비식별화를 수행하는 인코더(112)와 디코더(114)의 파라미터들을 갱신할 수 있다.

[96] 또한 비식별화 정도는 인코더(112)의 압축율에 따라 결정되므로, 비 식별화 정도가 높아지면 이미지에 포함된 개인정보의 보호에는 유리해질 수 있으나 디코딩된 제3 이미지(22)를 통한 신경망의 예측 정확도는 낮아질 수 있다.

[97] 따라서, 학습부(120)는 비식별화 정도와 예측 정확도를 고려하여 상대적으로 비식별화에 이용되는 파라미터를 조절하는 것도 가능하다. 예를 들어 육안으로 신분을 인식하는데 필요한 정보들을 약화시키되, 신경망의 특징 정보 추출에는 유리한 정보 들을 강화시키도록 인코딩 또는 디코딩 파라미터를 갱신할 수 있다.

[98] 제3 이미지(22)와 제1 이미지(20)의 유사도를 정의하는 비식별화 정도와 상기 신경망의 객체 정보(30)에 대한 예측 정확도 간의 상관 관계를 이용하여 파라미터 정보를 더욱 학습할 수 있다.

[99] 이상 본 실시예에 따른 학습 방법은 인코더(112), 디코더(114) 및 신경망을 다 같이 학습시키고, 사람이 아닌 기계가 잘 인식할 수 있는 부분을 특정하도록 이미지를 변경함과 동시에 신경망이 적응하도록 한다.

[100] 즉, 신경망은 이미지 내에서 기계적으로 객체를 추출하는데 필요한 부분을 강조하고 나머지는 부분은 약화시키는 방식으로 학습될 수 있다.

[101] 이하, 도 8을 참조하여 본 실시예에 따른 서비스 운영 서버(100)의 구성에 대하여 설명한다.

[102] 본 실시예에서 서비스 운영 서버(100)는 비식별화부(110) 및 학습부(120)로 구성될 수 있다.

[103] 비식별화부(110)는 인코더(112)와 디코더(114)를 포함한다.

[104] 인코더(112)는 사용자 단말(10)로 촬영한 제n 차원의 제1 이미지(20)를 압축하고 압축된 제p 차원의 제2 이미지(21)를 생성한다.

[105] 인코더(112)는 제1 이미지(20) 내의 제n 차원 상의 데이터 값들을 인코딩

기준에 따라 압축할 수 있으며, 따라서 제n 차원에 비하여 축소된 차원으로 제p 차원의 제2 이미지(21)를 생성할 수 있다.

[106] 디코더(114)는 제1 이미지(20)에 비해 압축된 정보를 갖는 제2 이미지(21)를 디코더(114)는 제q 차원의 제3 이미지(22)로 변경할 수 있다.

[107] 이때 제q 차원은 제1 이미지(20)의 제n 차원과 같은 차원으로 정의될 수 있다.

[108] 다만, 제q 차원으로 변경된 제3 이미지(22)는 제2 이미지(21)로부터 디코딩 되어 원래의 제1 이미지(20)와는 서로 다른 데이터 값들을 가질 수 있다.

[109] 궁극적으로 제3 이미지(22)는 인코딩 후 재 정의된 정보로서 육안으로 객체를 식별이 불가능한 형태의 데이터 값들로 구성될 수 있다.

[110] 즉, 비식별화부(110)는 인코더(112)와 디코더(114)를 이용하여 제2 이미지(21)를 중간 이미지로 최종적으로 학습 데이터인 제3 이미지(22)를 생성한다.

[111] 학습부(120)는 제3 이미지(22)를 입력 데이터로 객체 정보(30)를 신경망을 이용하여 추출한다.

[112] 신경망은 입력 데이터에 대해 순차적으로 합성곱 연산을 수행하는 복수의 레이어로 구성되며 각 레이어는 합성곱 연산을 위한 ?터를 포함하는 복수의 노드로 구성된다.

[113] 본 실시예에서는 신경망은 제3 이미지(22)의 제q 차원 내 데이터 값들에 대한 합성곱 연산을 수행한다. 즉 합성곱 레이어 내 노드는 필터를 통해 데이터 값들을 합성곱 연산한다.

[114] 이때 각각의 노드들은 데이터 값을 전달할 때의 가중치를 파라미터로 정의하며 본 실시예에서는 신경망으로 출력된 객체 정보(30)를 이용하여 가중치를 갱신하는 방식으로 학습을 수행할 수 있다.

[115] 또한 학습부(120)는 신경망 외에 비식별화부(110)의 파라미터를 학습시키는 것도 가능하다.

[116] 비식별화부(110)는 제2 이미지(21)로 제1 이미지(20)를 인코딩하고 다시 제q 차원으로 인코딩 하므로, 제2 이미지(21)의 차원을 정의하는 제p 차원의 수를 학습을 통해 결정할 수 있다.

[117] 또한, 그 외 인코더(112)와 디코더(114)에서 이용되는 기타 파라미터 들도 학습을 통하여 갱신하는 것도 가능하다.

[118] 이상, 학습부(120)는 비식별화 정도와 신경망의 예측 정도는 모두 고려하여 신경망이 비식별화된 이미지에 대해서 최적의 결과를 출력하도록 학습시킬 수 있다.

[119] 나아가 서비스 운영 서버(100)는 비식별화된 이미지를 저장하는 별도의 데이터베이스(200)를 포함하여 구성될 수 있다.

[120] 신경망의 학습을 위해서는 다량의 학습 데이터를 통해 반복적인 학습이 수행되어야 하므로 데이터베이스(200) 내에 비식별화된 이미지를 저장하고 이를 통해 신경망을 학습시키는 것도 가능하다.

[121] 즉, 서비스 운영 서버(100)는 수신된 제1 이미지(20)들은 비식별화 후에 삭제하고, 비식별화된 제2 이미지(21) 또는 제3 이미지(22) 만을 데이터베이스(200)에 저장하도록 하여 개인 정보의 유출에 따른 피해를 방지할 수 있다.

[122] 또한 제2 이미지(21)를 데이터베이스(200)에 저장하는 경우 결정된 양의 제2 이미지(21)들을 축적하고, 축적된 제2 이미지(21)들을 대량으로 디코딩하여 제3 이미지(22)로 생성함으로써 신경망 학습의 효율을 더욱 높일 수 있다.

[123] 이상 본 발명에 따르면, 비식별화된 이미지를 신경망 학습에 이용하므로 이미지에 포함된 개인 정보의 직접적인 이용 없이 신경망을 학습시킬 수 있다. 또한 본 발명은 원 이미지로 복원이 불가능하도록 이미지를 비식별화하여 저장하므로 개인 정보 보호 및 데이터 관리의 효율성을 높일 수 있다.

[124] 또한, 본 발명은 이미지에 포함된 정보의 차원을 신경망의 예측 성능에 따라 조절하여 인코딩 함으로써 이미지 처리의 효율성을 높일 수 있다.

[125] 한편, 명세서 및 청구범위에서 "제 1", "제 2", "제 3" 및 "제 4" 등의 용어는, 만약 있는 경우, 유사한 구성요소 사이의 구분을 위해 사용되며, 반드시 그렇지는 않지만 특정 순차 또는 발생 순서를 기술하기 위해 사용된다. 그와 같이 사용되는 용어는 여기에 기술된 본 발명의 실시예가, 예컨대, 여기에 도시 또는 설명된 것이 아닌 다른 시퀀스로 동작할 수 있도록 적절한 환경하에서 호환 가능한 것이 이해될 것이다. 마찬가지로, 여기서 방법이 일련의 단계를 포함하는 것으로 기술되는 경우, 여기에 제시된 그러한 단계의 순서는 반드시 그러한 단계가 실행될 수 있는 순서인 것은 아니며, 임의의 기술된 단계는 생략될 수 있고/있거나 여기에 기술되지 않은 임의의 다른 단계가 그 방법에 부가 가능할 것이다.

[126] 이상, 여기에 설명되는 다양한 실시예는 예를 들어, 소프트웨어, 하드웨어 또는 이들의 조합된 것을 이용하여 컴퓨터 또는 이와 유사한 장치로 읽을 수 있는 기록매체 내에서 구현될 수 있다.

[127] 하드웨어적인 구현에 의하면, 여기에 설명되는 실시예는 ASICs (application specific integrated circuits), DSPs (digital signal processors), DSPDs (digital signal processing devices), PLDs (programmable logic devices), FPGAs (field programmable gate arrays, 프로세서(processors), 제어기(controllers), 마이크로 컨트롤러(micro-controllers), 마이크로 프로세서(microprocessors), 기타 기능 수행을 위한 전기적인 유닛 중 적어도 하나를 이용하여 구현될 수 있다. 일부의 경우에 본 명세서에서 설명되는 실시예들이 제어 모듈 자체로 구현될 수 있다.

[128] 소프트웨어적인 구현에 의하면, 본 명세서에서 설명되는 절차 및 기능과 같은 실시예들은 별도의 소프트웨어 모듈들로 구현될 수 있다. 상기 소프트웨어 모듈들 각각은 본 명세서에서 설명되는 하나 이상의 기능 및 작동을 수행할 수 있다. 적절한 프로그램 언어로 씌여진 소프트웨어 어플리케이션으로 소프트웨어 코드가 구현될 수 있다. 상기 소프트웨어 코드는 메모리 모듈에

저장되고, 제어모듈에 의해 실행될 수 있다.

[129] 이상의 설명은 본 발명의 기술 사상을 예시적으로 설명한 것에 불과한 것으로서, 본 발명이 속하는 기술 분야에서 통상의 지식을 가진 자라면 본 발명의 본질적인 특성에서 벗어나지 않는 범위 내에서 다양한 수정, 변경 및 치환이 가능할 것이다.

[130] 따라서, 본 발명에 개시된 실시 예 및 첨부된 도면들은 본 발명의 기술 사상을 한정하기 위한 것이 아니라 설명하기 위한 것이고, 이러한 실시 예 및 첨부된 도면에 의하여 본 발명의 기술 사상의 범위가 한정되는 것은 아니다. 본 발명의 보호 범위는 아래의 청구 범위에 의하여 해석되어야 하며, 그와 동등한 범위 내에 있는 모든 기술 사상은 본 발명의 권리 범위에 포함되는 것으로 해석되어야 할 것이다.