



(19) 대한민국특허청(KR)
(12) 공개특허공보(A)

(11) 공개번호 10-2025-0068019
(43) 공개일자 2025년05월16일

- | | |
|---|---|
| <p>(51) 국제특허분류(Int. Cl.)
 <i>A61B 5/055</i> (2006.01) <i>A61B 5/00</i> (2021.01)
 <i>G06N 3/08</i> (2023.01) <i>G06T 7/00</i> (2017.01)
 <i>G16H 50/20</i> (2018.01)</p> <p>(52) CPC특허분류
 <i>A61B 5/055</i> (2022.01)
 <i>A61B 5/0042</i> (2013.01)</p> <p>(21) 출원번호 10-2023-0153769
 (22) 출원일자 2023년11월08일
 심사청구일자 2023년11월08일</p> | <p>(71) 출원인
 조선대학교산학협력단
 광주광역시 동구 조선대길 126(서석동, 산학협력단)</p> <p>(72) 발명자
 권구락
 광주광역시 서구 화운로 24 힐스테이트 303동 303호</p> <p>(74) 대리인
 특허법인주원</p> |
|---|---|


전체 청구항 수 : 총 5 항

(54) 발명의 명칭 **비유사성 보정 생성적 대립 신경망을 이용한 뇌질환 진단정보 제공방법**

(57) 요약

본 발명은 비유사성 보정 생성적 대립 신경망을 이용한 뇌질환 진단정보 제공방법에 관한 것이다.

대표도



(52) CPC특허분류

A61B 5/4064 (2025.01)
A61B 5/4076 (2025.01)
A61B 5/4088 (2013.01)
G06N 3/088 (2023.01)
G06T 7/0012 (2013.01)
G16H 50/20 (2018.01)
G06T 2207/10088 (2013.01)
G06T 2207/20081 (2013.01)
G06T 2207/30016 (2013.01)

이 발명을 지원한 국가연구개발사업

과제고유번호	1345365105
과제번호	2021R1I1A3050703
부처명	교육부
과제관리(전문)기관명	한국연구재단
연구사업명	이공학학술연구기반구축
연구과제명	치매케어를 위한 ATN(V), MRI-PET, 커넥툼 기반 진단 지원 및 진행 예측 기술
기 여 율	1/2
과제수행기관명	조선대학교
연구기간	2023.03.01 ~ 2024.02.29

이 발명을 지원한 국가연구개발사업

과제고유번호	1425170613
과제번호	S3312710
부처명	중소벤처기업부
과제관리(전문)기관명	중소기업기술정보진흥원
연구사업명	산학협력거점형플랫폼(R&D)
연구과제명	인지 기능 저하에 따른 문진과 MRI를 이용한 자가진단 서비스
기 여 율	1/2
과제수행기관명	조선대학교산학협력단
연구기간	2022.09.01 ~ 2022.12.31

명세서

청구범위

청구항 1

- 1) 뇌 MRI 이미지를 입력하는 단계;
- 2) 손실 함수로서 다이스 유사계수(dice similarity coefficient, DSC)를 사용하여 생성기(generator)를 업데이트하는 제1 업데이트 단계;
- 3) 상기 뇌 MRI 이미지와 동일한 이미지를 입력하여 출력물을 획득하고, 이때 비유사성(dissimilarity)을 계산하여 생성기를 업데이트하는 제2 업데이트 단계;
- 4) 분할(segmentation) 이미지를 출력하는 단계;
- 5) 실측 결과(ground truth)와 비교하여 입력된 뇌 MRI 이미지를 참과 거짓으로 판별하는 단계; 및
- 6) DSC와 VOE(Volumetric Overlap Error)의 두 가지 유형의 메트릭을 사용하여 결과를 평가하는 단계;를 포함하고,

상기 생성기는 하기 [수학식 1]을 사용하는 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법

[수학식 1]

$$\mathcal{L}_{cGAN}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_{x,z}[\log(1 - D(x, G(x, z)))]$$

여기서 생성 모형 G는 $\mathcal{L}_{cGAN}(G, D)$ 를 최소화하려고 하고 판별기 D는 최대화하려고 함.

청구항 2

제1항에 있어서, 상기 제1 업데이트를 위한 손실 l^{u1} 은 DSC 손실과 적대적 손실의 가중합이고, 하기 [수학식 2] 및 [수학식 3]을 사용하는 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법

[수학식 2]

$$l^{u1} = l_{DSC} + 10^{-3}l_{Gen}$$

여기서 l_{DSC} 는 DSC 값에 음수이며, 하기 [수학식 3]과 같이 계산할 수 있음.

[수학식 3]

$$DSC = \frac{2|I \cap \hat{I}|}{|I| + |\hat{I}|}$$

여기서 I는 실측 결과이고 $\hat{I}$ 는 예측 출력임.

청구항 3

제1항에 있어서, 상기 제2 업데이트를 위한 손실 l^{u2} 는 DC 손실과 적대적 손실의 가중합이고, 하기 [수학식 4] 및 [수학식 5]를 사용하는 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법

[수학식 4]

$$I^{u2} = I_{DC} + 10^{-3} I_{Gen}$$

여기서 생성 손실 I_{Gen} 은 모든 훈련 데이터에 대한 판별기의 확률에 기초하여 [수학식 5]와 같이 정의됨.

[수학식 5]

$$I_{Gen} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I))$$

여기서 G_{θ_G} 와 D_{θ_D} 는 각각 θ_G 와 θ_D 에 의해 매개변수화된 생성기 및 판별기 네트워크임.

청구항 4

제1항에 있어서, 상기 DSC와 VOE는 각각 [수학식 3] 및 [수학식 10]을 사용하는 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법

[수학식 3]

$$DSC = \frac{2|I \cap \hat{I}|}{|I| + |\hat{I}|}$$

여기서 I는 실측 결과이고 $\hat{I}$ 는 예측 출력임.

[수학식 10]

$$VOE = 1 - \frac{|S \cap S'|}{|S \cup S'|}$$

여기서 S는 실측 분할 맵이고, S'는 예측 분할 맵으로 정의함.

청구항 5

제1항에 있어서, 상기 뇌질환은 알츠하이머병 및 다발성경화증으로 이루어진 군에서 선택된 하나 이상인 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법

발명의 설명

기술 분야

[0001]

본 발명은 비유사성 보정 생성적 대립 신경망을 이용한 뇌질환 진단정보 제공방법에 관한 것이다.

배경 기술

[0003]

각 픽셀에 특정 값을 할당함으로써 의미 분할(semantic segmentation)은 이미지 상의 클래스를 현지화한다. 자기공명영상(MRI)은 뇌를 연구하기 위해 가장 널리 사용되는 영상 기술이다. MRI는 다양한 여기(excitation)를 반복하여 대비 영상을 생성한다. MRI는 알츠하이머병(AD)과 다발성 경화증을 진단하는 데 사용될 수 있다. AD 진단을 위한 일반적인 바이오마커 중 하나는 조직 위축이다. 이러한 진단을 위해서는 뇌 조직의 정확한 식별과 분류가 중요하다. MRI 데이터셋을 수동으로 분석하는 것과 같은 어려운 작업을 피하기 위해 자동 분할 기술이

개발된다. 최근 뇌 조직의 분할을 위한 딥러닝 모델이 많이 개발되고 있다. 뇌 MRI는 3D 영상이기 때문에 그 과정을 위해 많은 전산 자원을 소모하게 된다. 3D 영상이 2D 영상의 더미(stack)이다. 2D 영상이 쌓이면 3차원이 추가되어 3D가 된다. 더 적은 자원으로 더 빠른 처리를 위해 3D의 모든 슬라이스가 처리될 때까지 각 슬라이스를 하나씩 처리하는 2D 접근법을 사용할 수 있다. 한 번에 3D를 처리하거나 각 슬라이스를 처리하고 추가하여 전체 영상을 만드는 방식은 동일하다.

[0004] 딥러닝 이전에는 분할 목적으로 알고리즘이 구현되었다. 그러나 이러한 과정에서 결과를 얻기 위해서는 많은 시간이 소요된다. 딥러닝과 달리 데이터 자체로부터 학습할 수 없기 때문에 사용자는 알고리즘의 파라미터와 단계를 수동으로 변경해야 한다. 의료 영상의 분할은 딥러닝 모델의 발전과 함께 발전된다. 최근 생성적 대립 신경망(generative adversarial networks, GAN)에서 상당한 발전이 있었다. GAN은 영상으로부터 비디오를 생성하고 해상도를 높이며 텍스트로부터 영상을 생성하는 등 다양한 응용 분야에 사용된다. GAN 구조는 두 부분, 즉 생성기(generator)와 판별기(discriminator)로 구성된다. 다른 유형의 판별기가 개발되었다. 생성기의 출력만 분류하는 일반적인 판별기와 달리 패치 수준에서 영상을 판별하는 새로운 판별기가 도입되었다. 최근의 연구들은 GAN으로 의미 분할이 개선될 수 있음을 보여주었다. 전통적인 GAN과 달리 작업자 기계의 부담을 분산시키기 위해 다중 판별기 GAN (multiple-discriminator GAN)이 도입되었다.

[0005] 다이스 유사계수(dice similarity coefficient, DSC)는 대부분의 분할 작업에 대한 평가 지표로 사용된다. 이는 Dice에 의해 처음 제안되었다. 분할의 경우 기본적으로 DSC는 출력과 실측 결과(ground truth) 사이의 교집합 면적을 구하여 계산된다. DSC의 값은 항상 0과 1 사이에 있다. DSC의 값이 높을수록 좋은 결과를 얻을 수 있다. 다중 클래스 분할의 DSC를 구하기 위해서는 각 클래스에 대한 DSC를 구하여 평균을 계산한다. 본 발명에서는 이 평가 행렬을 훈련 시에도 손실 함수로 사용할 수 있다. 딥러닝이 훈련 시 오차를 최소화하려고 노력하기 때문에 DSC의 음수를 손실 함수로 사용할 수 있다. 다만 DSC의 한계는 정확하게 예측된 픽셀에 대한 정보만 준다는 것이다.

[0006] 본 발명에서는 정확도를 업데이트하기 위한 새로운 수정 알고리즘과 비유사성을 기반으로 한 새로운 손실 함수를 제안한다.

선행기술문헌

특허문헌

- [0008] (특허문헌 0001) 한국등록특허 제2344157호
(특허문헌 0002) 한국등록특허 제2450409호
(특허문헌 0003) 한국공개특허 제2022-0128505호
(특허문헌 0004) 한국공개특허 제2023-0030789호
(특허문헌 0005) 한국공개특허 제2023-0070128호

발명의 내용

해결하려는 과제

[0009] 본 발명의 목적은 비유사성 보정 생성적 대립 신경망을 이용한 뇌질환 진단정보 제공방법을 제공하는 것이다.

과제의 해결 수단

[0011] 본 발명은 1) 뇌 MRI 이미지를 입력하는 단계; 2) 손실 함수로서 다이스 유사계수(dice similarity coefficient, DSC)를 사용하여 생성기(generator)를 업데이트하는 제1 업데이트 단계; 3) 상기 뇌 MRI 이미지와 동일한 이미지를 입력하여 출력물을 획득하고, 이때 비유사성(dissimilarity)을 계산하여 생성기를 업데이트하는 제2 업데이트 단계; 4) 분할(segmentation) 이미지를 출력하는 단계; 5) 실측 결과(ground truth)와 비교

하여 입력된 뇌 MRI 이미지를 참과 거짓으로 판별하는 단계; 및 6) DSC와 VOE(Volumetric Overlap Error)의 두 가지 유형의 메트릭을 사용하여 결과를 평가하는 단계;를 포함하고, 상기 생성기는 하기 [수학식 1]을 사용하는 것인, 머신러닝 시스템에 의한 뇌질환 진단정보 제공방법을 제공한다.

[수학식 1]

$$\mathcal{L}_{cGAN}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_{x,z}[\log(1 - D(x, G(x, z)))]$$

여기서 생성 모형 G는 $\mathcal{L}_{cGAN}(G, D)$ 를 최소화하려고 하고 판별기 D는 최대화하려고 함.

뇌의 구조적 변화를 적절히 분석함으로써 뇌 질환에 대한 보다 정확한 진단을 달성할 수 있다. 뇌 구조의 변화를 정량화하기 위해서는 분할(segmentation) 작업이 매우 중요하다. 뇌는 도 1과 같이 뇌척수액(CSF), 회백질(GM), 백색물질(WM)의 세 가지 유형의 조직으로 구성된다.

본 발명에서는 다중 판별기 GAN의 동기를 얻어 DSC와 새로운 제안된 손실 함수를 사용하여 두 판별기로 GAN을 교대로 업데이트하는 새로운 방법을 제안한다. 예측된 출력의 구조를 연구하고 DSC에서 교차점으로 포함되지 않는 영역에 대한 정보를 줄 수 있는 새로운 함수를 공식화했다. 모든 손실 함수의 평균을 한 번에 사용하는 대신 GAN의 새로운 수정 대체 업데이트가 생성기를 제대로 훈련시킬 수 있을 것이라고 가정한다. 본 발명의 알고리즘에서 생성기 가중치는 반복적으로 두 번 업데이트될 것이다. 첫 번째 것은 DSC를 기반으로 할 것이다. 업데이트 후 동일한 이미지가 생성기를 통과하고 이것의 출력은 비유사성을 계산하는 데 사용될 것이다. 이 업데이트는 주로 비유사성 또는 잘못된 예측을 최소화하는 데 초점이 맞춰질 것이다.

본 발명의 일 구현예에 따르면, 상기 제1 업데이트를 위한 손실 l^{u1} 은 DSC 손실과 적대적 손실의 가중합이고, 하기 [수학식 2] 및 [수학식 3]을 사용하는 것이다.

[수학식 2]

$$l^{u1} = l_{DSC} + 10^{-3}l_{Gen}$$

여기서 l_{DSC} 는 DSC 값에 음수이며, 하기 [수학식 3]과 같이 계산할 수 있음.

[수학식 3]

$$DSC = \frac{2|I \cap \hat{I}|}{|I| + |\hat{I}|}$$

여기서 I는 실측 결과이고 $\hat{I}$ 는 예측 출력임.

본 발명의 다른 구현예에 따르면, 상기 제2 업데이트를 위한 손실 l^{u2} 은 DC 손실과 적대적 손실의 가중합이고, 하기 [수학식 4] 및 [수학식 5]를 사용하는 것이다.

[수학식 4]

$$l^{u2} = l_{DC} + 10^{-3}l_{Gen}$$

여기서 생성 손실 l_{Gen} 은 모든 훈련 데이터에 대한 판별기의 확률에 기초하여 [수학식 5]와 같이 정의됨.

[수학식 5]

$$l_{Gen} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I))$$

여기서 G_{θ_G} 와 D_{θ_D} 는 각각 θ_G 와 θ_D 에 의해 매개변수화된 생성기 및 판별기 네트워크임.

[0031] 본 발명의 또 다른 구현예에 따르면, 상기 DSC와 VOE는 각각 [수학식 3] 및 [수학식 10]을 사용하는 것이다.

[0032] [수학식 3]

$$DSC = \frac{2|I \cap \hat{I}|}{|I| + |\hat{I}|}$$

[0033]

[0034] 여기서 I는 실측 결과이고 $\hat{I}$ 는 예측 출력임.

[0035] [수학식 10]

$$VOE = 1 - \frac{|S \cap S'|}{|S \cup S'|}$$

[0036]

[0037] 여기서 S는 실측 분할 맵이고, S'는 예측 분할 맵으로 정의함.

[0038] 본 발명의 다른 구현예에 따르면, 상기 뇌질환은 뇌에서 발생하는 질환으로서 MRI 이미지를 기반으로 진단할 수 있는 모든 질환을 포함하고, 바람직하게는 알츠하이머병 및 다발성경화증으로 이루어진 군에서 선택된 하나 이상인 것이나, 이에 제한되는 것은 아니다.

발명의 효과

[0040] 본 발명은 비유사성 보정 생성적 대립 신경망을 이용한 뇌질환 진단정보 제공방법으로 DSC와 함께 사용된 새로 제안된 비유사성 계수를 사용하여 GAN 생성기를 업데이트하는 알고리즘을 제공하여 여러 주제에 대해 서로 다른 평면에서 분할을 사용함으로써, 비유사성 계수와 생성기의 대체 업데이트를 사용하는 것이 DSC만 사용하는 것보다 훨씬 견고하고 정확하다는 것을 확인했다.

도면의 간단한 설명

[0042] 도 1은 본 발명의 일 실시예에 따른 여러 클래스에 대해 실측 결과에서 생성된 이진맵을 나타낸 것이다.

도 2는 본 발명의 일 실시예에 따른 매번 다른 판별기를 사용하여 반복적으로 생성기를 두 번 업데이트하는 모식도를 나타낸 것이다.

도 3은 본 발명의 일 실시예에 따른 각 컨볼루션의 상단에 표시된 채널의 수를 갖는 생성기 네트워크의 아키텍처를 나타낸 것이다.

도 4는 본 발명의 일 실시예에 따른 (a) 조건부 GAN 및 (b) patchGAN의 판별기 네트워크의 아키텍처를 나타낸 것이다. 대응하는 커널 크기 'k', 스트라이드 's' 및 각 컨볼루션 레이어에 표시된 다수의 특징 맵 'n'을 포함한다.

도 5는 본 발명의 일 실시예에 따른 (a) 실측 결과, (b) 예측 출력, (c) 반전 예측 출력, (d) (a,c)를 곱하여 얻은 거짓 음의 영역에 대한 이진맵을 나타낸 것이다.

도 6은 본 발명의 일 실시예에 따른 (a) 실측 결과, (b) 예측 출력, (c) 반전 실측 결과, (d) (a,c)를 곱하여 얻은 거짓 양의 영역에 대한 이진맵을 나타낸 것이다.

발명을 실시하기 위한 구체적인 내용

[0043] 이하, 실시예를 통하여 본 발명을 더욱 상세히 설명하기로 한다. 이들 실시예는 단지 본 발명을 예시하기 위한 것이므로, 본 발명의 범위가 이들 실시예에 제한되는 것으로 해석되지는 않는다.

[0045] 본 발명에서는 이진 이미지 간의 비유사성을 측정하는 새로운 계수와 두 개의 판별기로 GAN을 수정 방식으로 대

안적으로 업데이트하는 새로운 알고리즘에 대해 설명한다. 본 발명의 주요 기여는 다음과 같다:

- [0046] - 본 발명은 두 개의 판별기를 대안적으로 사용하여 생성기의 가중치를 업데이트하는 새로운 수정 방법을 제안한다. 첫 번째 업데이트에서 사용된 판별기는 패치 레벨로 이미지를 판별하는 반면, 두 번째 업데이트는 한 번에 전체 이미지를 판별한다. 이러한 서로 다른 업데이트는 서로 다른 손실 함수에 기초할 것이다;
- [0047] - 본 발명은 영상의 비유사성에 기초하여 새로운 손실 함수를 제안한다. 본 발명은 함수들을 공식화하고 영상으로부터 함수들을 계산하는 알고리즘을 정의한다;
- [0048] - 본 발명은 테스트 데이터에 대한 모델의 DSC 점수를 통해 제안된 알고리즘 및 손실 함수가 DSC 단독으로 훈련된 일반적인 생성기를 능가하는 데 도움이 된다는 것을 확인하였다.

[0050] <실시예 1> Data

[0051] 본 발명은 OASIS 1(Open Access Series of Imaging Studios 1) 데이터 세트를 사용한다. 훈련을 위해 60명의 피험자를 무작위로 선택한다. 각 피험자의 MRI 검사는 $176 \times 208 \times 176$ 의 치수를 갖는다. 세 개의 평면(축, 관상, 시상)이 있다. 각 평면에 대해 2D 영상을 개별적으로 추출, 훈련 및 테스트한다. 추출된 영상은 훈련 및 테스트 전에 256×256 의 크기로 크기가 조정된다. 뇌 MRI 검사에서는 뇌 바깥쪽에 빈 공간이 있다. MRI에서 2D 영상을 추출하는 동안 가장자리의 영상은 비어 있으며 뇌에 대한 정보는 없다. 본 발명에서는 빈 영상을 제거하고 뇌 부분이나 정보가 있는 영상만을 고려한다. MRI 검사를 시각적으로 분석하여 각 평면에 사용되는 슬라이스 수의 범위를 결정한다. 축 평면의 경우 15 ~ 145의 슬라이스를 사용한다. 마찬가지로 관상 평면의 경우 30 ~ 180의 슬라이스를 사용하고 시상 평면의 경우 25 ~ 145의 슬라이스를 사용한다. 모델을 개별적으로 훈련하는 동안 축, 관상 및 시상 평면에 대해 각각 7800, 9000 및 7200 이미지를 모두 사용했다. OASIS 1 데이터 세트에서 제공되는 실측 영상은 마코프 랜덤 필드 모델과 관련 기대-최대화 알고리즘을 사용하여 생성된다.

[0053] <실시예 2> Method

[0054] 수학적 1은 조건부 GAN의 목적을 제공한다

[0056] [수학적 1]

$$[0057] \mathcal{L}_{cGAN}(G, D) = \mathbb{E}_{x,y}[\log D(x, y)] + \mathbb{E}_{x,z}[\log(1 - D(x, G(x, z)))]$$

[0059] 여기서 생성 모형 G는 $\mathcal{L}_{cGAN}(G, D)$ 를 최소화하려고 하고 판별기 D는 최대화하려고 한다. GAN 대상을 혼합하는 것과 보다 전통적인 손실을 혼합하는 것이 유익한 것으로 밝혀졌다. 생성자의 임무는 판별기를 속여서 가능한 한 실측에 가깝게 분할을 산출하는 것일 것이다. 대조적으로 판별기의 임무는 변하지 않는다.

[0060] 본 발명은 두 개의 판별기로 GAN 네트워크를 훈련시키는 것을 목표로 하며, 여기서 생성기는 첫 번째 업데이트에서 손실 함수로서 DSC에 따라 반복적으로 두 번 업데이트되고, 손실 함수로서 새로운 제안된 비유사성 계수에 대한 업데이트가 이어진다. 판별기에 따른 생성기의 업데이트는 도 2에 나타나 있다. 본 발명은 다른 업데이트에서 생성기의 출력을 판별하기 위해 다른 판별기를 사용한다. 비유사성 계수를 계산하는 과정은 알고리즘 1에 요약되어 있고 생성기를 업데이트하는 과정은 알고리즘 2에 요약되어 있다.

[0061] 첫 번째 업데이트 과정에서 생성기 모델은 해당 입력에 대한 세그먼트화된 출력을 생성한다. DSC는 손실 함수로서 사용된다. DSC의 값은 항상 0과 1 사이에 있으므로 그 값이 클수록 좋은 결과가 될 것이다. 따라서 손실 함수로서 계산된 DSC의 음수를 사용한 다음 패치 GAN 판별기가 패치 레벨에서 불이익을 준다. 첫 번째 업데이트를 위한 손실 l^1 은 DSC 손실과 적대적 손실의 가중합이다:

[0063] [수학식 2]

$$l^{u1} = l_{DSC} + 10^{-3}l_{Gen}$$

[0066] 여기서 l_{DSC} 는 DSC 값에 음수이며, 다음과 같이 계산할 수 있다:

[0068] [수학식 3]

$$DSC = \frac{2|I \cap \hat{I}|}{|I| + |\hat{I}|}$$

[0071] 여기서 I 는 실측 결과이고 $\hat{I}$ 는 예측 출력이다. 두 번째 업데이트는 첫 번째 업데이트 동안 잘못된 예측을 최소화하고 정보를 주는 것에 대한 모델을 훈련시키는 것이다. 생성기를 업데이트 한 후, 생성기를 통해 동일한 영상을 예측하고 실측 결과와 예측 영상 사이의 비유사성을 계산한다. 비유사성과 관련된 두 가지 유형의 계수를 제안한다. 비유사성 계수(DC)는 거짓 양과 거짓 음 예측과 관련이 있다. 이 계수들의 계산은 수학식 7과 9에 주어진다. 총 DC 손실은 이 두 계수의 합이다. 두 번째 업데이트는 비유사성을 수정하는 것과 최소화하는 것을 생성기를 훈련시키는 것에 초점을 맞춘다. 두 번째 업데이트를 위한 손실 l^{u2} 는 DC 손실과 적대적 손실의 가중합이다:

[0073] [수학식 4]

$$l^{u2} = l_{DC} + 10^{-3}l_{Gen}$$

[0076] 두 번째 업데이트의 경우, 생성 손실 l_{Gen} 은 모든 훈련 데이터에 대한 판별자의 확률에 기초하여 다음과 같이 정의된다:

[0078] [수학식 5]

$$l_{Gen} = \sum_{n=1}^N -\log D_{\theta_D}(G_{\theta_G}(I))$$

[0081] 여기서, G_{θ_G} 와 D_{θ_D} 는 각각 θ_G 와 θ_D 에 의해 매개변수화된 생성기 및 판별기 네트워크이다.

[0083] 1) UNet as Generator

[0084] 의료 영상 분할을 위해 UNet 아키텍처가 가장 널리 사용된다. 또한 UNet을 제안된 모델의 생성기 모델로 사용하였으며, 이는 도 3과 같다. UNet 아키텍처는 인코더와 디코더 경로를 가진다. 인코더는 컨볼루션 계층들과 최대 풀링으로 구성되는 반면 디코더는 컨볼루션 계층들과 업 컨볼루션으로 구성된다. 인코더로부터의 특징맵은 생략 연결을 사용하여 디코더의 대응하는 특징 맵과 연결된다. 본 발명은 두 컨볼루션 계층을 사용하고 배치 정규화 계층과 LeakyReLU를 인코더의 각 단계에서 활성화 함수로 사용한다. 각 단계는 2×2 최대 풀링으로 이어진다.

디코더 경로에서 각 업 샘플링에는 인코더에서와 같이 두 컨볼루션 계층이 이어진다. 업 샘플링의 출력은 컨볼루션을 거치기 전에 인코더로부터의 특징 맵과 연결된다.

[0086] 2) Multiple Discriminators

[0087] 본 발명은 두 개의 판별기에 기초하여 연구를 수행하였다. 한 판별기는 생성된 세그먼트 이미지로부터 실제 세그먼트 이미지를 판별하는 조건부 GAN이다. 또 다른 판별기는 마르코프식 판별기(patchGAN)이다.

[0088] 조건부 GAN에 기초한 판별기의 경우, 다음과 같이 요약된 아키텍처를 따른다. 이 아키텍처는 최대 풀링의 사용을 피한다. 수학적 1의 최대화 문제는 판별기 네트워크를 훈련시킴으로써 해결된다. VGG 아키텍처에서와 동일하게 64에서 512로 2배 증가하는 8개의 컨볼루션 층이 있다. 특징 번호가 2배 증가할 때 해상도를 줄이기 위해 스트라이드 컨볼루션이 사용된다. 활성화 함수로 LeakyReLU를 사용한다($\alpha = 0.2$). 최종 특징맵에 두 개의 조밀한 레이어가 뒤따른 다음 시그모이드 활성화 함수로 분류에 대한 확률을 제공한다. 그림 4a는 이 조건부 GAN의 아키텍처를 보여준다. 판별기의 과제는 생성기의 출력을 검사하고 원래의 실측 결과와 유사한지 아닌지를 결정하는 것이다. 만약 그것이 실측 결과와 비교적 유사하다면, 그것은 "진짜(real)"로 예측할 것이고, 그렇지 않으면 그것은 "가짜(fake)"가 될 것이다. 따라서 생성기는 가능한 한 실측 결과와 유사한 이미지를 생성하기 위해 이 손실을 고려할 것이다. 도 4a의 판별기는 진짜가 참이고 가짜가 거짓으로 표현되는 이진 분류기와 같은 기능을 한다.

[0089] 본 발명은 기존 patchGAN 아키텍처 지침을 따랐다. patchGAN에서의 판별기는 패치 규모로만 구조를 판별한다. 크기가 $N \times N$ 인 패치는 진짜 또는 가짜로 분류된다. 패치 이상으로 분리된 픽셀들이 독립적이라고 가정하면, 이 판별기는 이미지를 마르코프 무작위 필드로 모델링한다. 도 4b는 이 patchGAN의 아키텍처를 보여준다. 구조는 조건부 GAN과 유사하다. 이 판별기도 64에서 512로 2배 증가하는 8개의 컨볼루션 레이어로 구성되며, LeakyReLU($\alpha = 0.2$)가 활성화 함수로 사용된다. 이 아키텍처에서 최종 2개의 밀집 레이어는 커널 크기가 3×3 인 단일 특징맵으로 단일 컨볼루션 레이어로 대체된다. 이 판별기의 최종 결과는 16×16 이다.

[0091] <실시예 3> Proposed Loss Functions

[0092] DSC에서는, 예측 및 실측 결과의 교차점만이 계산된다. 따라서, 손실 함수로서 DSC를 사용하는 것은 결과 이미지 내의 진정한 양의 픽셀들에 관한 정보만을 줄 것이다. 예측된 출력 내에는 진정한 양의 픽셀들과 함께 거짓의 음과 양의 픽셀들이 존재한다. 이러한 픽셀 정보는 또한 교차점 또는 진정한 양의 픽셀들을 개선하는 것을 도울 수 있다.

[0094] 1) Dissimilarity from False Negative

[0095] 거짓 음성 픽셀을 연구하고 그 수를 줄이는 것은 자동적으로 진정한 양의 픽셀을 증가시키는 데 도움이 될 것이다. 거짓 음성 픽셀과 DSC의 관계는 반비례한다. 거짓 음성 픽셀의 수가 적을수록 DSC의 값은 커진다.

[0097] [수학적 6]

[0098]
$$DSC \propto \frac{1}{P_{FN}}$$

[0100] 여기서 P_{FN} 은 예측된 영상에서 거짓 음성의 픽셀 수이다. 도 5는 예측된 출력에서 거짓 음성 픽셀을 얻는 과정을 보여준다. 거짓 음성 픽셀을 얻기 위해서 먼저 예측된 출력 영상을 반전시킨다. 이를 위해서 출력 영상의 각 픽셀을 정수 값 1에서 뺀다. 그런 다음 반전된 영상에 실측 영상이 곱해진다. 두 영상(실측 결과 및 예측된 출력)이 모두 이진 영상이므로 이들 사이의 교차점만 0이 되지 않을 것이다. 이 영역이 실측 결과에서는 0이 아니기 때문에 이 0이 아닌 나머지 영역이 거짓 음성 픽셀이다. 이 픽셀 값으로부터 비유사성 계수를 계산할 수 있다. 거짓 음성 픽셀 예측을 위한 비유사성 계수는 수학적 7과 같이 계산된다.

[0102] [수학식 7]

$$DC_{FN} = \frac{|I \cap inv(\hat{I})|}{|inv(\hat{I})|}$$

[0105] 여기서 $|inv(\hat{I})|$ 는 반전 예측 출력으로부터의 ROI의 픽셀 수이다. DC_{FN} 은 실측 결과와 반전 예측 영상 사이의 영역 중첩의 메트릭이다. $|I \cap inv(\hat{I})|$ 는 실측 결과 영상에서 배경으로 예측되지만 배경이 아닌 픽셀의 수를 나타낸다. 따라서, 이 픽셀들을 거짓 음으로 간주한다. 거짓 음의 값에 대한 비유사성 계수를 계산하는 과정은 알고리즘 1에 요약되어 있다. 수학식 7로부터, DC_{FN} 이 예측된 전체 배경 픽셀 수에 대한 거짓 음의 픽셀 수, 즉 거짓 배경 픽셀의 비율이라고 말할 수 있다. 이 비율은 예측된 배경 픽셀 중 얼마나 많은 픽셀이 실제 실측 배경 픽셀과 일치하지 않는지를 알려준다.

[0107] 2) Dissimilarity from False Positive

[0108] 예측된 픽셀들 중에는 거짓 양의 픽셀들이 존재한다. 모델은 실측 결과와의 교집합을 증가시키면서 미래에 해당 픽셀들의 예측을 최소화하기 위해 거짓 양의 픽셀들에 대해서도 알아야 한다. 거짓 양의 픽셀들의 개수와 거짓 양의 픽셀들의 개수의 관계도 반비례한다. 거짓 양의 픽셀들의 감소는 초점을 맞추거나 정보를 주는 것을 도와 실측 결과와 예측된 영역의 교집합을 증가시켜 결과적으로 DSC의 향상을 가져올 것이다.

[0110] [수학식 8]

$$DSC \propto \frac{1}{P_{FP}}$$

[0113] 여기서 P_{FP} 는 예측된 영상에서 위양성의 픽셀 수이다. 도 6은 예측된 출력에서 위양성 픽셀을 구하는 과정을 보여준다. 위음성 픽셀을 얻기 위해서 먼저 실측 영상을 반전시킨다. 그러기 위해서 정수 값 1에서 기저영상의 각 픽셀을 뺀다. 그러면 반전영상은 예측된 영상에 곱해진다. 두 영상(실측 결과 및 반전 예측된 출력)이 모두 이진영상이므로 그들 사이의 교차점만 0이 되지 않을 것이다. 이 나머지 0이 아닌 영역은 출력 영상에서 이 영역이 0이 아니기 때문에 위양성 픽셀이다. 이 픽셀 값으로부터 위양성에 대한 비유사성 계수를 계산할 수 있다. 위양성 픽셀 예측에 대한 비유사성 계수는 수학식 9와 같이 계산된다.

[0115] [수학식 9]

$$DC_{FP} = \frac{|inv(I) \cap \hat{I}|}{|\hat{I}|}$$

[0118] 여기서 $|inv(I)|$ 는 반전 실측 결과로부터의 ROI의 픽셀 수이고, $|\hat{I}|$ 는 예측된 출력 영상으로부터의 ROI의 픽셀 수이다. DC_{FP} 은 반전 실측 결과와 예측 영상 사이의 영역 중첩의 메트릭이다. $|inv(I) \cap \hat{I}|$ 는 전경으로 예측되지만 실측 영상에서 전경이 아닌 픽셀의 수를 나타낸다. 따라서, 이 픽셀들을 거짓 양성으로 간주한다.

거짓 양성 값에 대한 비유사성 계수를 계산하는 과정은 알고리즘 1에 요약되어 있다. 수학적 식 9로부터 DC_{FP} 가 전체 전경 픽셀, 즉 예측된 ROI에 대한 거짓 양성 픽셀의 수, 즉 거짓 전경 픽셀의 비율이라고 말할 수 있다. 이 비율은 예측된 ROI 픽셀 중 몇 개가 실제 실측 결과 ROI 픽셀과 일치하지 않는지를 알려준다.

Algorithm 1 Computation of dissimilarity coefficient for false negative DC_{FN} and false positive DC_{FP}

Input: ground truth image I , predicted image $\hat{I}$

Output: DC_{FN} , DC_{FP}

1. Inverse_ $\hat{I} \leftarrow 1 - \hat{I}$
 2. Intersection_FN $\leftarrow I \times \text{inverse_}\hat{I}$
 3. union_FN $\leftarrow \text{sum}(\text{inverse_}\hat{I})$
 4. $DC_{FN} \leftarrow 2 * \text{Intersection_FN} / \text{union_FN}$
 5. Inverse_I $\leftarrow 1 - I$
 6. Intersection_FP $\leftarrow \text{inverse_I} * \hat{I}$
 7. union_FP $\leftarrow \text{sum}(\hat{I})$
 8. $DC_{FP} \leftarrow 2 * \text{Intersection_FP} / \text{union_FP}$
 9. return DC_{FP} , DC_{FN}
-

Algorithm 2 Our proposed algorithm to update generator G with two different discriminators (D_1 and D_2)

1. for epoch do
 2. Obtain segmented image $\hat{I}$ from input I : $\hat{I} = G(I)$
 3. Export the ground truth I^{GT} and segmented image $\hat{I}$ as input to discriminator D_1
 4. Train D_1 (update weights):

$$\nabla_{\theta_{d1}} = \frac{1}{m} \sum_{i=1}^m [\log D_1(I^{GT}) + \log(1 - D_1(\hat{I}))]$$
 5. Train G (update weights):

$$\nabla_{\theta_g} = \nabla_{\theta_{DSC}} + 10^{-3} * \nabla_{\theta_{gen}}$$

$$\nabla_{\theta_{gen}} = \frac{1}{m} \sum_{i=1}^m -\log D_1(G(I))$$

$$\nabla_{\theta_{DSC}} = \frac{1}{m} \sum_{i=1}^m [-2 * (|I \cap \hat{I}|) / (|I| + |\hat{I}|)]$$
 6. Obtain segmented image $\hat{I}$ from input I : $\hat{I} = G(I)$
 7. Export the ground truth I^{GT} and segmented image $\hat{I}$ as input to discriminator D^2
 8. Train D_2 (update weights):

$$\nabla_{\theta_{d2}} = \frac{1}{m} \sum_{i=1}^m [\log D_2(I^{GT}) + \log(1 - D_2(\hat{I}))]$$
 9. Train G (update weights):

$$\nabla_{\theta_g} = \nabla_{\theta_{DC}} + 10^{-3} * \nabla_{\theta_{gen}}$$

$$\nabla_{\theta_{gen}} = \frac{1}{m} \sum_{i=1}^m -\log D_2(G(I))$$

$$\nabla_{\theta_{DC}} = \frac{1}{m} \sum_{i=1}^m [DC_{FP} + DC_{FN}]$$
 10. end for
-

<실시예 4> Training Details and Parameters

본 발명은 서로 다른 평면에서 개별적으로 추출된 이미지를 사용하여 NVIDIA GeForce RTX 3090 GPU의 모든 평면에 대해 모델을 훈련시켰다. 훈련을 위한 MRI 대상은 테스트 대상과 다르다. MRI에서 입력과 실측 영상을 획득하고 네트워크에 공급하기 전에 256×256 차원으로 재스케일링했다. DSC를 손실 함수로 사용하고 있기 때문에 각 클래스에 해당하는 이진 맵이 필요하다. 각 클래스(배경, CSF, GM, WM)에 대한 이진 맵을 추출했다. 이를 위해 클래스 또는 조직이 실측 결과에 존재하는 픽셀에서만 1 값을 가지는 이진 이미지를 생성했으며, 그렇지 않으면 값이 0으로 설정되었다. 최적화를 위해 $\beta_1 = 0.9$ 인 Adam을 사용했다. 제안된 모델 네트워크는 10^{-3} 의 학습률로 훈련되었다. 생성기는 서로 다른 판별기가 있는 반복에서 두 번 업데이트되며, 판별기는 각 업데이트마다

교대로 업데이트된다.

[0126] <실시예 5> Evaluation Metrics

[0127] 본 발명은 평가를 위해 DSC와 VOE(Volumetric Overlap Error)의 두 가지 유형의 메트릭을 사용했다. 수학식 3을 사용하여 DSC 점수를 계산할 수 있다. VOE에 대해 분할과 실측 결과의 교차점 및 결합을 계산한다.

[0128] 수학식 10에서, 실측 분할 맵 S 및 예측 분할 맵 S'에 대한 VOE를 정의한다.

[0130] [수학식 10]

[0131]
$$VOE = 1 - \frac{|S \cap S'|}{|S \cup S'|}$$

[0133] <결과>

[0134] 본 발명의 주요 목표는 비유사성 손실 함수를 가진 GAN과 DSC를 손실 함수로 훈련시켜 DSC 점수를 향상시키는 것이다. 업데이트된 가중치를 수정하기 위해 단일 판별기 대신 다수의 판별기로 생성기를 업데이트하는 새로운 알고리즘을 제안하였다. 제안된 방법의 성능을 확인하기 위해, 하기 두 가지 실험을 수행하였다.

[0136] 1) Single Discriminator GAN Model with DSC and DC Loss Functions (Exp_model_1)

[0137] 첫번째 실험에서는 제안한 알고리즘과 같이 UNet 생성기를 사용하였다. 그러나 이 경우에는 단일 판별기만을 사용하였다. 훈련 과정에서 동일한 분할 출력으로부터 DSC와 DC를 계산하고 생성기와 판별기를 업데이트한다. 본 모델의 생성기 업데이트에 대한 손실 함수는 다음과 같다:

[0139] [수학식 11]

[0140]
$$l = l_T + 10^{-3}l_{Gen}$$

[0142] [수학식 12]

[0143]
$$l_T = l_{DSC} + l_{DC}$$

[0145] 2) Single Discriminator GAN Model with Only DSC Loss Functions (Exp_model_2)

[0146] 두번째 실험에서는 DSC 손실 함수만으로 모델의 성능을 비교한다. 이 실험에서 동일한 훈련 데이터셋과 함께 모든 파라미터를 동일하게 유지했다. 생성기 업데이트를 위한 손실 함수는 다음과 같다:

[0148] [수학식 13]

[0149]
$$l = l_{DSC} + 10^{-3}l_{Gen}$$

[0151] 테스트를 위해 훈련 데이터와 유사하게 축, 관상, 시상면에서 각각 15개에서 145개, 30개에서 180개, 25개에서 145개의 슬라이스를 얻었다. 따라서 축, 관상, 시상면에서 피험자당 각각 130개, 150개, 120개의 슬라이스가 있다. 훈련 데이터에 포함되지 않은 데이터 세트에서 25개의 피험자를 선택했다. 각 피험자에서 슬라이스를 추출

하고 해당 평면에 대한 평균 DSC 점수를 계산했으며 계산된 각 평균에 대한 표준 편차를 계산했다. 논의한 바와 같이 테스트 데이터는 세 가지 모델(개선 사항을 확인하기 위해 제안된 모델과 실험에서 다른 두 모델)을 사용하여 예측되었다. 모델에 추가적인 비유사성 손실을 제공하여 DSC 점수를 향상시키는 것을 목표로 하기 때문에 결과를 주로 모델에서 얻은 DSC 점수에 비교 및 초점을 맞추었다.

[0152] 본 발명은 표 1과 같이 또 다른 평가 지표인 VOE를 사용하여 모델을 평가하였다. 표 1을 보면, 축 및 관상면의 경우에 따라 VOE 점수가 최대 2% 감소하는 것을 알 수 있다. VOE의 값이 낮을수록 더 나은 결과를 나타낼 수 있다. 따라서, 축 및 관상면의 경우 모델의 부피 오차가 적다고 말할 수 있다. 그러나 시상면의 점수는 Exp_model_1과 비슷하다. 시상면의 값은 Exp_model_1보다 높지 않고, 다른 두 평면의 값은 Exp_model_1보다 작으므로, 본 발명에서 뇌 조직의 분할에서 제안한 모델이 다른 모델보다 성능이 뛰어나다고 주장할 수 있다.

표 1

Axial			
Model	CSF	GM	WM
Exp_model_1	0.0991	0.0958	0.1164
Exp_model_2	0.1075	0.1057	0.1237
Proposed model	0.0907	0.0831	0.0913
Coronal			
Exp_model_1	0.0924	0.0803	0.0688
Exp_model_2	0.0947	0.0862	0.0790
Proposed model	0.0890	0.0784	0.0688
Sagittal			
Exp_model_1	0.0885	0.0811	0.0821
Exp_model_2	0.0962	0.0938	0.1037
Proposed model	0.0877	0.0806	0.0829

[0156] 표 2에서 모델의 DSC 점수를 비교했다. 평면에서 2D 영상을 추출하고 분할하여 해당 2D 슬라이스로부터 분할된 3D 영상을 생성했다. 측면에서 WM, GM, CSF의 DSC 점수가 제안된 모델에서 exp_model_1보다 1% 더 높다는 것을 알 수 있다. 또한 exp_model_2와 비교하면 모든 클래스의 점수가 2% 향상되었다. 따라서 측면에서 제안된 모델이 다른 모델보다 더 우수하다고 주장할 수 있다. 관상면의 경우 exp_model_1보다 약간 더 높지만 상당한 차이는 아니다. 반면에 exp_model_2보다 최대 1% 더 높은 점수를 얻었다. 제안된 모델의 점수가 exp_model_2보다 1% 더 높지만 exp_model_1과 비교하면 약간 향상된 것에 불과한 시상면에서도 같은 조건이 발생했다. 그러나 이미 제안된 모델에서 측면과 관상면의 VOE가 적음을 확인했다. 또한 시상면에서 제안한 모델의 점수는 다른 모델보다 작지 않다. 따라서 본 발명의 모델이 뇌 조직의 분할에서 다른 모델보다 더 우수하다고 주장할 수 있다.

표 2

Axial			
Model	CSF	GM	WM
Exp_model_1	0.9463±0.0445	0.9472±0.0591	0.9304±0.1098
Exp_model_2	0.9399±0.0703	0.9390±0.0902	0.9235±0.1271
Proposed model	0.9518±0.0200	0.9555±0.0374	0.9467±0.09458
Coronal			
Exp_model_1	0.9511±0.0220	0.9578±0.0198	0.9635±0.0312
Exp_model_2	0.9497±0.0252	0.9541±0.0326	0.9564±0.0585
Proposed model	0.9530±0.0212	0.9589±0.0192	0.9634±0.0340
Sagittal			
Exp_model_1	0.9534±0.0198	0.9573±0.0223	0.9551±0.0538
Exp_model_2	0.9487±0.0303	0.9492±0.0457	0.9395±0.0926
Proposed model	0.9537±0.0199	0.9575±0.0232	0.9546±0.0553

[0160] <고찰>


[0161] 본 발명에서는 테스트에서 DSC 점수를 사용하여 제안된 모델의 우수한 성능을 확인하였다. exp_model_1 및 exp_model_2로 테스트를 실행함으로써 비유사성 계수가 존재하거나 존재하지 않는 결과를 추가로 조사한다. exp_model_1 및 제안된 모델은 DSC와 함께 손실 함수로서 비유사성 계수를 갖는다. 유일한 차이점은 모델이 그러한 손실 함수에 대해 한 번 또는 대안으로 업데이트된다는 것이다. 표 1 및 표 2로부터 비유사성에 대한 정보를 가진 네트워크가 DSC 단독으로 사용하는 것보다 더 나은 성능을 보임을 알 수 있다. 비유사성 정보를 가진 모델과 비유사성 정보를 가진 모델의 결과를 비교하면 네트워크의 점수는 최대 3% 향상된다. 세 평면 및 테스트 피실험자 모두에서 제안된 추가 손실 함수를 가진 모델이 DSC 손실 함수만을 가진 모델보다 성능이 뛰어났다.

[0162] 모델의 대체 업데이트는 시간이 많이 걸리지만, 제안된 알고리즘은 DSC 단독을 손실 함수로 한 모델보다 DSC 점수를 최대 2% 더 향상시켰다. 모델의 단일 업데이트와 대체 업데이트를 비교하는 동안, 대체 업데이트가 축 및 관상 면에서 더 우수한 성능을 보였다. 점수는 최대 1% 향상되었다. 그러나 시상면에서는 성능이 크게 향상되지는 않았지만, 전반적인 성능은 단일 업데이트와 유사하다. 시상면에 대해 추출된 슬라이스를 시각화하여 확인했다. 얻은 훈련 및 테스트 슬라이스가 수동으로 정의된 범위에서 MRI 스캔을 슬라이스 할 때 동일하지 않다는 것을 발견했다. 슬라이스는 고정된 범위를 정의하는 것보다 동적으로 균일하게 추출되어야 한다.


[0163] 결론적으로, 본 발명은 DSC와 함께 사용된 새로 제안된 비유사성 계수를 사용하여 GAN 생성기를 업데이트하는 알고리즘에 대해 설명했다. 목적은 모델을 업데이트하여 진정한 양의 영역뿐만 아니라 거짓 양의 영역과 거짓 음의 영역에도 초점을 맞추는데 있다. 본 발명의 방법은 두 가지 업데이트로 구성되며, 첫 번째 업데이트는 참 양의 영역에 기초하고, 두 번째 업데이트는 거짓 양의 영역과 거짓 음의 영역에 기초하여 수정한다. 본 발명은 기존의 가중치 업데이트 후 이상적인 조건으로 모델을 테스트했다. 비교에서 모델이 다른 모델보다 성능이 뛰어나다는 것을 발견했다. 또한 본 발명의 방법을 뇌 조직 분할에 사용된 이전 방법과 비교했다. 이번 비교에서도 이전의 접근 방식보다 성능이 뛰어났다. DSC 손실 함수의 한계를 강조하고 비유사성 계수를 새로운 손실 함수로 도입했다. 그러나 본 발명의 방법은 시간과 자원 소모가 크기 때문에 몇 가지 단점이 있다. 그럼에도 불구하고 DSC 점수 측면에서는 본 발명의 모델이 최고이다. 여러 주체에 대해 서로 다른 평면에서 분할을 사용함으로써, 비유사성 계수와 생성기의 대체 업데이트를 사용하는 것이 DSC만 사용하는 것보다 훨씬 견고하고 정확하다는 것을 확인했다. DSC 점수와 VOE 점수로 모델의 더 나은 성능을 평가하고 입증했다.

도면


도면1




도면2




도면3



도면4



도면5



도면6

