

시맨틱 통신을 위한 의미론적 불확실성: 의미 정량화를 위한 지표

허강현, 이기송

동국대학교

heoganghyeon63@gmail.com, kslee851105@gmail.com

Semantic Uncertainty for Semantic Communication: A Metric for Quantifying Meaning

Heo Kang Hyun, Lee Kisong
Dongguk Univ.

요약

본 논문에서는 현재 의미론적 통신 연구에서 다루지는 의미 측정 방식에 명확한 기준이 없다는 사실에 착안하여 합리적인 의미 측정 지표의 필요성을 제기한다. 그 후, 의미에 대한 수학적 접근을 기반으로 정보의 의미를 정량적으로 측정할 수 있는 지표를 제안한다. 제안한 지표의 유효성을 실험적으로 검증하기 위해, 시뮬레이션에서는 이미지 정보를 대상으로 기존의 이미지 의미 측정 지표들과 비교·분석을 수행하였다. 그 결과, 제안한 지표가 이미지가 내포한 의미의 양을 보다 정확하게 정량화함을 확인하였다.

I. 서론

최근 인공지능과 센서 기술의 급속한 발전은 자율주행차, 사물인터넷(IoT) 등 다양한 분야의 성장을 이끄는 동시에, 통신 트래픽의 폭증을 초래하고 있다. 이를 해결하기 위해 다중 안테나 기술(MIMO), 재구성 가능한 지능형 반사판(RIS), 자원 최적화 기법 등 다양한 전송 기술이 연구되었지만, 제한된 통신 자원을 이용해 전송률을 향상시키는 것은 근본적인 한계가 존재한다. 이러한 한계를 극복하기 위한 대안으로 의미론적 통신(Semantic Communication)이 제안되었다. 의미론적 통신은 정보의 '의미'를 유지하면서 데이터를 압축·전송하여, 기존 방식보다 더 효율적으로 정보 전달을 가능하게 하는 새로운 통신 패러다임이다. 이에 따라, 통신 수요의 폭증 문제에 효과적으로 대응할 수 있는 기술로 주목받으며 최근 활발한 연구가 이루어지고 있다^{[1], [2]}.

의미론적 통신에 대한 연구는 텍스트 및 이미지 전송 등 다양한 분야에서 이루어져 왔다. 주로 인코더-디코더 구조의 딥러닝 기반 모델을 활용하여 정보를 저차원으로 압축하는 방식이 제안되었으며 문장 유사도, PSNR, 이미지 특징 벡터 거리^[3] 등의 지표를 통해 정보의 의미가 유지되었는지를 평가하였다. 그러나 이러한 지표들은 정보 요소 간의 단순한 차이를 계산하거나 명확한 기준이 부재하여, 근본적인 의미를 정량적으로 측정하는 데 한계가 있다. 이에 본 논문에서는 수학적 접근을 통해 정보의 의미를 정량화하는 지표인 의미적 불확실도(Semantic Uncertainty)를 제안한다. 그 후, 시뮬레이션을 통해 제안한 지표가 기존 지표들보다 의미 측정에 더욱 적합함을 실험적으로 검증한다.

II. 본론

정보의 의미를 수학적으로 정량화하기 위해서는 먼저 '의미'라는 개념을 명확히 이해할 필요가 있다. 그림 1은 특정 사진에 대해 그 의미가 어떻게 결정되는지를 설명한다. 동일한 사진이라도, 동물의 종류를 구분하는 작업에서는 이 사진의 의미가 '강아지'로 정의될 것이며, 동물의 다리 수를 세는 작업에서는 그 의미가 '4'로 정의될 것이다. 이처럼, 같은 정보라도 수행되는 작업이나 목적에 따라 그 의미는 달라질 수 있다.

따라서 정보의 의미는 주어진 작업에서 정보가 생성하는 결과라고 할 수 있다. 이를 수학적으로 표현하기 위해, 정보는 확률 변수 X 로 나타내



사진의 의미는?



'강아지'

동물의 종류 분류



'4'

동물의 다리 수 기록

그림 1. 작업이나 목적에 따라 달라지는 의미

고, 작업은 정보가 가질 수 있는 값의 집합 Y 의 원소에 대응시키는 함수 $U: X \rightarrow Y$ 로 정의할 수 있다. 앞서 언급한 의미의 개념에 따르면, $U(X)$ 는 정보 X 의 의미가 된다. 여기서 Y 는 벡터 공간이며, $U(X) = \{U_1(X), \dots, U_n(X)\}$ 는 일반적으로 n 차원 벡터로 표현된다. 이제 정보가 가진 의미의 양을 수학적으로 측정하기 위해, 먼저 다음과 같이 의미적 불확실도를 정의한다.

Definition 1. 확률변수 X 와 함수 $U: X \rightarrow Y$ 에 대해 의미적 불확실도 $S_{U(X)}$ 는 다음과 같다.

$$S_{U(X)} = E_X[\|U(X) - \hat{U}\|^2]. \quad (1)$$

여기서 \hat{U} 은 n 차원 벡터로 의미의 추정치를 나타낸다. 식 (1)은 정보 X 를 모를 때, 이 정보가 가지는 실제 의미 $U(X)$ 와 추정치 \hat{U} 간의 평균적인 차이를 나타낸다. 이 차이가 작을수록 정보의 의미를 더 정확하게 추정할 수 있으며, 이 차이가 클수록 추정의 정확성이 떨어진다고 할 수 있다. 또한, 확률 변수 X 의 특성상 발생 확률이 작은 사건은 의미 추정이 다소 부정확하더라도 전체적인 의미적 불확실도에 미치는 영향이 적다.

의미적 불확실도는 작업 U , 정보 X 의 확률분포 $p(x)$, 추정치 \hat{U} 에 따라 달라진다. 또한, 의미적 불확실도를 특정 정보를 아는 상황에 대해 확장할 수 있다. 만약 어떤 확률변수 Z 가 사건 z 임을 알고 있을 때, 의미적 불확실도는 다음과 같이 나타낼 수 있다.

$$E_{X|Z=z}[\|U(X) - \hat{U}_{Z=z}\|^2]. \quad (3)$$

$\hat{U}_{Z=z}$ 는 사건 z 임을 알고있을 때의 조건부 추정치이다. 식 (3)는 정보 X

를 모르는 상황에서 정보 Z 가 z 임을 알 때, $U(X)$ 와 추정치 $\hat{U}_{Z=z}$ 간의 평균적인 차이를 나타낸다. 정보 Z 또한 확률변수이기 때문에 여러 가지 사건으로 나타날 수 있다. 식 (3)을 모든 사건에 대해 기댓값을 취함으로써, 조건부 의미적 불확실도를 정의한다.

Definition 2. 확률변수 X, Z 와 함수 $U: \mathbf{X} \rightarrow \mathbf{Y}$ 에 대해 조건부 의미적 불확실도 $S_{U(X|Z)}$ 는 다음과 같다.

$$S_{U(X|Z)} = E_Z E_{X|Z=z} [\| U(X) - \hat{U}_{Z=z} \|^2]. \quad (4)$$

이 식은 정보 Z 를 알 때 평균적으로 정보 X 의 의미를 얼마나 정확히 알 수 있는지를 나타낸다. 조건부 의미적 불확실도는 값이 작을수록 Z 를 알 때 X 의 의미를 정확히 추정할 수 있음을 의미하며, 클수록 추정이 부정확함을 나타낸다.

두 정보 Z_1 과 Z_2 가 있을 때, 더 낮은 의미적 불확실도를 갖는 정보가 원래 정보 X 의 의미를 더 정확하게 추정하게 해준다. 결론적으로, 어떤 정보 Z 가 원래 정보 X 의 의미를 얼마나 포함하고 있는지를 정량적으로 평가할 수 있다. 여기서, 조건부 의미적 불확실도의 하한은 다음과 같이 구할 수 있다.

$S_{U(X|Z)}^{LB} = E_Z E_{X|Z=z} [\| U(X) - E_{E|Z=z} [U(X)] \|^2] \quad (5)$
 $E_{X|Z=z} [U(X)] = \{E_{X|Z=z} [U_1(X)], \dots, E_{X|Z=z} [U_n(X)]\}$ 를 뜻한다. 이는 추정치 벡터의 각 요소가 의미 벡터의 각 요소의 조건부 기댓값일 때, 식 (4)가 최소가 됨을 나타낸다. $S_{U(X|Z)}$ 를 추정치의 i 번째 요소에 대해 미분해서 0이 되는 지점을 구하는 것으로 증명할 수 있다.

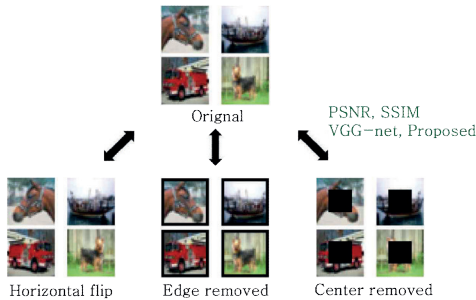


그림 2. CIFAR-10 이미지와 세가지 방식의 변형 이미지

그림 2와 같이 기존의 CIFAR-10 데이터와 좌우반전, 가장자리 영역 제거 (총 240 픽셀 제거), 가운데 영역 제거(총 240 픽셀 제거)한 데이터를 이용해, 기존 의미 지표 PSNR, SSIM, 딥러닝 기반 유사도와 제안한 지표인 조건부 의미적 불확실도로 의미 차이를 계산하여 비교·분석하였다. PSNR은 원본 이미지와 변형 이미지 간의 픽셀 단위 평균 오차인 MSE를 이용하여 계산되어 높을수록 원본 이미지와의 유사성이 크다는 것을 의미한다. SSIM은 밝기, 대비, 구조의 세 가지 요소를 기반으로 유사성을 평가하여 1에 가까울수록 원본과 비슷한 품질을 갖는 것을 의미한다. 딥러닝 기반 유사도는 VGG-Net과 같은 사전 학습된 딥러닝 모델을 사용하여 두 이미지를 입력하고, 출력된 특징 맵의 차이를 비교하여 그 값이 낮을수록 두 이미지의 특징이 유사함을 나타낸다.

제안한 지표에서 작업 U 는 이미지를 10차원의 클래스 벡터로 변환하는 함수로 정의할 수 있고 대표적인 이미지 분류 함수인 ResNet-20을 사용한다고 가정했다. 또한, 이미지 정보의 확률분포는 정확하게 얻기 어렵기 때문에 제안하는 지표에서는 몬테카를로 샘플링을 이용한다. 추정치는 변형 이미지 z 의 작업 결과 $U(z)$ 로 정의했다.

$$E_Z E_{X|Z=z} [\| U(X) - \hat{U}_{Z=z} \|^2] \approx \frac{1}{M} \sum_{m=1}^M \| U(x) - U(z) \|^2.$$

이에 따라, $\| U(x) - U(z) \|^2$ 의 값은 원래 이미지의 의미와 변형된 이미지로 추측한 의미가 같을 경우 0, 다를 경우 2가 된다. 예를 들어, 100개의 변형된 이미지 중에 10개를 원래 이미지와 다른 클래스로 판별했다면 조건부 의미적 불확실도는 0.2의 값을 갖는다.

표 1. 변형된 이미지에 대한 의미 측정

Metric	Horizontal flip	Edge removed	Center removed
PSNR	13.86 dB	12.25 dB	12.43 dB
SSIM	0.2342	0.8071	0.4690
VGG-Net	5.305696	3.445386	2.6390
Proposed	0.1932 (9.6%)	0.1568 (7.8%)	1.0934 (54.6%)

표 1은 10000개의 변형된 CIFAR-10 데이터와 원래 데이터에 대한 의미 지표들을 계산한 값을 나타낸다. 먼저, PSNR은 단순히 픽셀 값의 차이에 기반하여 계산되기 때문에 의미에 상관없이 가장자리 제거, 가운데 제거 방식에서 비슷한 값을 갖는다. SSIM과 VGG-Net(딥러닝 기반 유사도)은 일부 변형 방법 간의 비교에서는 합리적인 결과를 보이지만, 가운데 제거 방식이 좌우 반전 방식보다 더 많은 의미를 보존한다고 나타나, 직관과 어긋나는 결과를 보여준다. 제안한 지표는 가장자리 제거, 좌우반전, 가운데 제거의 순으로 의미를 많이 보존한다고 나타낸다. 가장자리 제거의 경우 0.1568로 이는 전체 데이터 중 약 7.8%가 원본 이미지를 기준으로 판단한 클래스와 다르게 분류되었음을 의미한다. 가운데 제거 방식의 경우 1.0934로 가장자리 제거 방식보다 약 7배 높은 값을 가지며, 원본 이미지와 다르게 판단하는 비율 또한 약 7배 높다. 이는 이미지의 중심부가 가려질 때 의미가 가장자리가 가려졌을 때보다 훨씬 더 크게 손실된다는 것을 정량적이고 합리적으로 설명해준다. 이를 통해 제안한 지표가 정보가 내포한 의미를 더 정확히 파악하고 해석 가능하다는 점을 실험적으로 확인하였다.

III. 결론

본 논문에서는 의미론적 통신에서 정확하고 정량적인 의미 측정을 위해 수학적 기반의 새로운 의미 측정 지표를 제안하였다. 그 후, 시뮬레이션을 통해 이미지 데이터를 대상으로 기존 지표들과 비교한 결과, 제안한 지표가 정보의 의미를 보다 정확하게 반영함을 확인하였다.

ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (RS-2024-00343262).

참 고 문 헌

- [1] S. J. Park et al., "A survey on semantic communications: opportunities and challenges," in Proc. KICS Fall Conf. 2022, pp. 361–362, Gyeongju, Korea, Nov. 2022.
- [2] W. Yang et al., "Semantic communications for future internet: Fundamentals, applications, and challenges," *IEEE Commun. Surv. Tutor.*, vol. 25, no. 1, pp. 213–250, Feb. 2022.
- [3] D. Huang et al., "Toward semantic communications: Deep learning-based image semantic coding," *IEEE J. Sel. Areas Commun.*, vol. 41, no. 1, pp. 55–71, Jan. 2022.