

바서스테인 GAN 에서 칸트로비치 거리와 KL-발산에 관한 차이 분석

이우용, 김근영, 조동욱*

한국전자통신연구원 6G 무선방식연구실, 충북도립대학교*

{wylee, kykim12}@etri.re.kr, ducho@cpu.ac.kr

Difference analysis of Kantorovich-Wasserstein (KW) metric and Kullback-Leibler (KL)-divergence in Wasserstein GAN

Lee Woo Yong, Kim Keunyoung, and Cho Dongwook*

6G Wireless Technology Research Section
Telecommunication & Media Research Laboratory
Electronics and Telecommunications Research Institute (ETRI) and
Chungbuk Provincial University*

요약

칸토로비치-바서스테인(KW: Kantorovich-Wasserstein) 거리(metric)는 바서스테인 GAN (Wasserstein Generative Adversarial Networks)과 같은 생성 모델을 학습하는 데 사용되는 손실(Loss) 함수이다. 기존의 바닐라(vanilla) GAN 손실에 비해 많은 장점이 있다. 이는 샘플 품질과 관련이 있고 최적화 과정의 향상된 안정성을 제공하며 Vanishing Gradient 문제를 겪지 않는다. 콜백-레이블러(KL: Kullback-Leibler)-발산(divergence)과 칸토로비치-바서스테인(KW) 거리 관계가 규명되었다. KL-발산은 정보량을 엔트로피와 함께 정의되기 때문에, 정보 이론 분야에서 중요한 역할을 하고 있다. 그 동안 겉으로 보기에 관련이 없어 보이는 이 두 가지 KW 거리와 KL 발산에 어떤 공통점이 있는지 여부가 중요한 관심사였다. 최근 연구에서 최적 운송 문제(OTP: Optimal Transport Problem)가 암묵적 제약(조건)을 가짐으로써, 이 운송 문제는 전송률 왜곡과 정보 이론에서 연구된 최적 채널을 찾는 변분(variational) 문제와 관련될 수 있음이 입증되었다. 본 논문은 이들 결과를 바서스테인 GAN 에 손실함수로 적용했을 때, KL 발산과 칸토로비치 거리 관계에서 차이를 분석하고, 향후 썬네틱(Semantic) 통신에서 정보량을 측정하기 위한 보다 효과적인 손실 함수 적용 방안을 검토한다.

I. 서론

칸토로비치-바서스테인(KW) 거리(metric, 길이)는 기계 학습 생성 모델을 학습하는 데 널리 사용되는 손실(Loss) 함수이다[1, 2]. 기존의 바닐라(vanilla) GAN 손실[3]에 비해 많은 장점이 있다. 이는 샘플 품질과 관련이 있고 최적화 과정의 향상된 안정성을 제공하며 Vanishing Gradient 문제를 겪지 않는다[1]. 콜백-레이블러(KL)-발산(divergence)과 칸토로비치-바서스테인(KW) 거리 관계가 규명되었다[4]. 가스파르 몽지(Gaspar Monge)에 의해 시작된 최적 운송 문제(OTP)에 대한 연구는 레오나드 칸토로비치(Leonid Kantorovich)가 확률 이론의 문제로 재구성하면서 크게 발전했다[4, 5]. 확률 변수(random variables) X 와 Y 를 두 개의 측도 가능(measurable, 가측) 집합으로 설정하고, $P(X)$ 와 $P(Y)$ 를 각각 X 와 Y 에 대한 모든 확률 측도의 집합이라 하고, $P(X \times Y)$ 를 $X \times Y$ 에 대한 모든 결합 확률 측도 집합이라고 하자. $c: X \times Y \rightarrow \mathbb{R}$ 을 음이 아닌(non-negative) 측도 가능 함수라고 할 때, 이를 비용 함수(cost function)라고 한다. 종종 $X \equiv Y$ 와 $c(x, y)$ 를 거리(metric)으로 사용한다. 확률 측도 $\omega \in P(X \times Y)$ 에 대한 기대 비용 $E_\omega\{c\}$ 은 다음 적분 값을 표현된다:

$$E_\omega\{c\} = \int_{X \times Y} c(x, y) d\omega(x, y)$$

여기서, 이 비용 함수를 위의 적분 값이 ω 의 하반연속(lower semicontinuous) 또는 닫힌 범함수(functional)라고 가정한다(즉, 집합 $\{\omega: E_\omega\{c\} \leq v\}$ 는 모든 $v \in \mathbb{R}$ 에 대해 닫힌). 특히, $c(\omega) = E_\omega\{c\}$ 가 연속 선형 범함수인 경우이다.

II. 본론: WGAN 에서 칸트로비치와 KL-발산 차이 분석

X 는 실제 영상이고 GAN 에 의해 생성된 페이크(Fake) 영상을 $Y=G(Z)$ 라고 할 때, 바서스테인 GAN 의 생성형 기계학습 구조는 그림 1 같다.

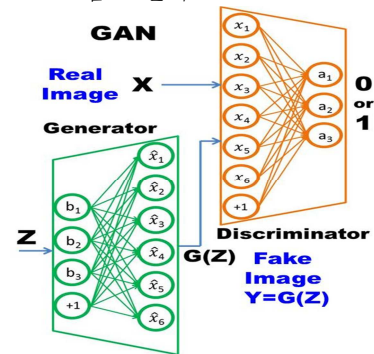


그림 1. 바서스테인 GAN 의 생성형 기계학습 구조.

비용 함수 $c: X \times Y \rightarrow \mathbb{R}$ 이 주어질 때, 모든 $(x, y) \in X \times Y$ 에 대하여 $f(x) - g(y) \leq c(x, y)$ 의 조건을 만족하는 실수 함수 $f: X \rightarrow \mathbb{R}$ 과 $g: Y \rightarrow \mathbb{R}$ 를 고려하자. 그때 쌍대 공식 $J_c\{p, q\}$ 은 이 모든 함수에 대해 다음과 같은 최대화이다.

$$J_c\{p, q\} = \sup\{E_p\{f\} - E_q\{g\}: f(x) - g(y) \leq c(x, y)\}$$

여기서, 우리는 $X \equiv Y$ 라고 가정한다. 다음과 같은 부등식을 만족함이 자명하다. 왜냐하면 칸트로비치의 쌍대성을 만족하기 때문이다.

$$J_c\{p, q\} \leq K_c\{p, q\}$$

KL-발산과 칸토로비치 거리 사이의 관계를 찾기 위해 이 쌍대 공식을 사용하려고 한다. 먼저, KL-발산의 다음과

같이 분해할 수 있다.

$$\begin{aligned} D[p, q] &= D[p, r] + D(r, q) - \int_X \ln \frac{dq(x)}{dr(x)} [dq(x) - dr(x)] \\ &= D[p, r] - D(q, r) \\ &\quad - \int_X \ln \frac{dq(x)}{dr(x)} [dp(x) - dq(x)] \end{aligned}$$

이제 추가 제약(조건)을 만족하는 함수: $f(x) - g(y) \leq c(x, y)$ 를 고려한다[5].

$$\begin{aligned} \beta f(x) &= \nabla D[p, r] = \ln \frac{dp(x)}{dr(x)}, \beta \geq 0, \\ \alpha g(x) &= \nabla D[q, r] = \ln \frac{dq(x)}{dr(x)}, \alpha \geq 0 \end{aligned}$$

정리 1(바서스테인 GAN 에서 칸트로비치 거리와 KL-발산 관계): 한 쌍의 함수 (f, g)을 쌍대 OTP 에 대한 해라고 하자. $f = \nabla D[p, r]$ 와 $g = \nabla D[q, r]$ 와 같은 기준 측도 $r \in \mathcal{Q}(Y)$ 이 존재한다면, 임의의 $\epsilon \geq 0$ 에 대하여 바서스테인 GAN 에서 KL-발산 $I(X, Y)$ 와 이에 해당하는 칸트로비치 정보(거리) $K_c[\omega, p \otimes q]$ 는 다음 수식을 만족한다.

$$K_c[\omega, p \otimes q] \geq I(X, Y) + \epsilon.$$

요약 증명: 바서스테인 GAN 에서 x 는 실제 영상이고 GAN 에 의해 페이크(Fake) 영상을 $y=G(z)$ 을 생성한다고 하자. 바서스테인 GAN 의 정의 $y=G(z)$ 에 의하여 다음 식을 만족한다.

$$g(y) - g(G(z)) = 0$$

임의의 $\epsilon \geq 0, \epsilon' \geq 0$ 에 대하여, 바서스테인 GAN 은 생성된 영상 $G(z)$ 와 실제 영상 x 사이의 차이를 다음 식이 만족하도록 훈련된다.

$$\begin{aligned} \sup |x - G(z)| &\leq \epsilon \\ \sup |f(x) - f(G(z))| &\leq \epsilon \end{aligned}$$

그러므로, 실수함수 $f: X \rightarrow \mathbb{R}$ 과 $g: Y \rightarrow \mathbb{R}$ 에 대하여 다음 식을 만족한다.

$$\sup |f(x) - f(G(z)) - g(y) + g(G(z))| \leq \epsilon$$

생성된 영상 $G(z)$ 에 대하여, 비용 함수 $c: X \times Y \rightarrow \mathbb{R}$ 이 주어질 때 모든 $(x, y) \in X \times Y$ 에 대하여 $f(x) - g(y) \leq c(x, y)$ 의 조건을 만족하고, 비용 함수 c 에 대하여 L_2 -놈(norm)을 가정한다면 다음 식을 만족한다[2].

$$\sup |f(G(z)) - g(G(z))| = c(x, G(z)) = \|x - G(z)\|_2 \leq \epsilon$$

위 수식들로부터 다음 제한 조건을 만족한다.

$$\sup |f(x) - g(y)| \leq \epsilon$$

따름 정리 2[6]의 수식의 우변 첫 번째 $\kappa[f] - \kappa[g]$ 식은 다음 조건을 만족한다.

$$\begin{aligned} \kappa[f] - \kappa[g] &= \ln \int_X \frac{dp(x)}{dr(x)} dr(x) - \ln \int_Y \frac{dq(y)}{dr(y)} dr(y) \\ &= \ln \frac{p(x)}{q(y)} = f(y) - g(y) \leq \epsilon \end{aligned}$$

여기서, $\kappa(\cdot) = \ln \int_Y e^{(\cdot)} dr(y)$ 는 정규화 상수(누적 생성 함수의 값)이다. 따름 정리 2[6]의 수식의 우변 두 번째 $\int_X g(x) [dp(x) - dq(x)]$ 식은 다음 조건을 만족한다.

$$\begin{aligned} dp(y) - dq(y) &= (e^{f(y)-\kappa[f]} - e^{g(y)-\kappa[g]}) dr(y) \\ &= (e^{f(y)} - e^{g(y)}) dr(y) \end{aligned}$$

누적 생성함수 $\kappa(\cdot)$ 정의에 의하여 다음 수식을 만족한다.

$$\ln \int_Y (e^{f(y)} - e^{g(y)}) dr(y) = \kappa[f] - \kappa[g] \leq \epsilon$$

$$\int_Y \frac{g(y)}{dr} [dp(y) - dq(y)] dr = \epsilon \int_Y \frac{g(y)}{dr} dr \leq \epsilon' \text{ QED.}$$

III. 따름 정리 요약 증명

따름 정리 2(칸트로비치 거리와 KL-발산에서 정보량 관계)[6]: $f = \nabla D[p, r]$ 와 $g = \nabla D[q, r]$ 와 같은 기준 측도 $r \in \mathcal{P}(X)$ 이 존재한다면, KL-발산 정보 $I(X, Y)$ 와 이에 해당하는 칸트로비치 정보(거리) $K_c[\omega, p \otimes q]$ 의 차이의 하한은

다음 수식을 만족한다.

$$\begin{aligned} K_c[\omega, p \otimes q] - I(X, Y) &\geq (\kappa[f] - \kappa[g]) \\ &\quad + \int_X g(x) [dp(x) - dq(x)] \end{aligned}$$

여기서, $\kappa(\cdot) = \ln \int_Y e^{(\cdot)} dr(y)$ 는 정규화 상수이다.

요약 증명: 주변 측도 $\pi_X w = p$ 및 $\pi_Y w = q$ 와 함께 결합 확률 측도 $w \in \mathcal{P}(X \times Y)$ 는 $\mathcal{P}(X \times Y)$ 에서 삼각형($w, p \otimes q, p \otimes p$)을 정의한다고 하자. 칸트로비치 거리는 삼각부등식에 의해 다음 식을 만족한다[3].

$$\begin{aligned} K_c[\omega, p \otimes p] &\leq K_c[\omega, p \otimes q] + K_c[p \otimes q, p \otimes p] \\ &= K_c[\omega, p \otimes q] + K_c[q, p] \end{aligned}$$

위 수식을 주변 측도 $\pi_X w = p$ 와 $\pi_Y w = q$ 의 곱 $p \otimes q \in \mathcal{P}(X \times Y)$ 에 대한 결합 확률 측도 $\omega \in \mathcal{P}(X \times Y)$ 의 칸트로비치 거리는 다음 식으로 나낼 수 있다.

$$K_c[\omega, p \otimes q] \geq K_c[\omega, p \otimes p] - K_c[q, p]$$

KL-발산은 칸트로비치 거리에서 주변 측도에 대한 제약이므로 $K_c[\omega, p \otimes p] \geq D[\omega, p \otimes p]$ 가 성립하므로[6] 다음 식으로 쉽게 표현될 수 있다.

$$K_c[\omega, p \otimes p] - K_c[q, p] \geq D[\omega, p \otimes p] - K_c[q, p]$$

가정 $f = \nabla D[p, r]$ 과 $g = \nabla D[q, r]$ 는 라그랑지 승수가 $\alpha = \beta = 1$ 인 것을 의미하며, 확률 측도는 $p = \exp(f - \kappa[f])r$ 와 $q = \exp(g - \kappa[g])r$ 의 형태를 갖고, 따름 정리 2에 의해 다음 식이 된다.

$$\begin{aligned} D[\omega, p \otimes p] - K_c[q, p] &= D[\omega, p \otimes p] - D[q, p] + (\kappa[f] - \kappa[g]) \\ &\quad + \int_X g(x) [dp(x) - dq(x)] \end{aligned}$$

이때 상호 정보는 $I(X, Y) = D[\omega, p \otimes p] - D[q, p]$ 이므로 다음 식을 만족한다.

$$K_c[\omega, p \otimes q] \geq I(X, Y) + (\kappa[f] - \kappa[g]) + \int_X g(x) [dp(x) - dq(x)].$$

그러므로 정보량차이의 하한 값이 유도된다.QED.

ACKNOWLEDGMENT

본 논문은 한국전자통신연구원 내부연구개발사업 인공지능 기반 시맨틱 통신 기술 선행 연구(23RH1300, 23YH1500 매칭) 개발과제의 논문이다.

참고 문헌

- [1] M. Arjovsky, S. Chintala, and L. Bottou, "Wasserstein GAN," arXiv preprint arXiv:1701.07875, 2017.
- [2] A. Korotin, A. Kolesov, and E. Burnaev, "Kantorovich Strikes Back! Wasserstein GANs are not Optimal Transport?" Advances in Neural Information Processing Systems, 2022.
- [3] I. Goodfellow, J. Pouget-Abadie, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. Courville, and Y. Bengio, "Generative adversarial nets," In Advances in neural information processing systems, pp. 2672-2680, 2014.
- [4] C. Villani, "Optimal Transport: Old and New," Grundlehren der mathematischen Wissenschaften. Springer, Berlin, 2009.
- [5] L.V. Kantorovich, "On translocation of masses," USSR AS Doklady 37(7-8), pp. 227-229, 1942 (in Russian). English translation: J. Math. Sci., vol. 133, no. 4, pp. 1381-1382, 2006.
- [6] 이우용, 김정표, 김용선, "칸트로비치-바서스테인 거리 관점에서 사논의 상호 정보량에 관한 연구," CEIC 2019, Dec. 2019.