

관심 영역 보존을 고려한 이미지 리사이징 최적화 기법 연구

이승준, *강석주
서강대학교, *서강대학교
lsjleelsj@naver.com, sjkang@sogang.ac.kr

The image resizing optimization method considering preservation of Region of interest (ROI)

SeungJoon Lee, *Suk-Ju Kang
Sogang University, *Sogang University

요약

본 논문에서는 관심 영역 보존을 고려한 이미지 리사이징 최적화 기법을 제안한다. 이미지 리사이징은 입력 영상을 다양한 비율의 디스플레이이나 하드웨어 플랫폼에 적용이 가능한 비율의 영상으로 변환하는 것에 목적을 둔다. 변환 과정에서 인지적 특성을 고려하여 관심 영역 검출을 통해 주요 객체의 왜곡을 최소화하고자 한다. 목표 비율로의 리사이징 시 각 영역별 변환 비율이 상이하게 결정되어야 하고, 이 과정에서 관심 영역 왜곡과 영상 보간 불가능의 문제가 발생한다. 관심 영역 왜곡과 보간 불가능 상태를 최소화하기 위해 영역별 변환 비율을 결정하는 최적화 기법을 제안하여 관심 영역이 보존된 최적화된 결과 영상을 획득하고자 한다.

1. 서론

최근 들어 각종 디스플레이 제품과 하드웨어 플랫폼의 개발 및 멀티미디어 플랫폼의 증가로 다양한 비율의 영상의 필요성이 증가하고 있다. 영상을 다양한 비율로 출력하기 위해서 linear scaling, cropping, letter box 삽입 등의 영상 크기 조정 기법이 제안되었다[1]. Linear scaling은 입력 영상을 목표 비율로 단순히 선형적으로 크기를 증가시키거나 혹은 감소시키는 방식이다. 인지적 특성을 전혀 고려하지 않아 내용 왜곡이 발생한다. 영상 cropping 기법은 영상의 테두리 영역을 제거하여 비율을 조정하는 방식으로 내용 손실을 야기한다. letter box를 삽입하는 방식은 영상의 테두리에 검은 영역을 덧붙이는 방식으로 영상 출력 영역의 낭비를 유발한다.

이러한 문제점들을 해결하기 위해 사람의 인지적 특성을 고려한 이미지 리사이징 기법이 대두되었다[2]. 입력 영상의 관심 영역을 획득하여 비 관심 영역 위주의 scaling 을 함으로써 목표 비율의 결과 영상을 획득하는 것을 공통적인 방법으로 하여 구현한다. 하지만 이러한 이미지 리사이징 기법들은 사람의 인지적 특성을 고려한 것이기 때문에 정확한 해가 없다는 단점이 존재하고, 관심 영역 검출 알고리즘도 모든 경우에 대해서 완벽하게 적용되기 힘들다[3].

따라서 본 논문에서는 검출된 관심 영역에 따라 영상의 영역별 중요도를 분배한 뒤 관심 영역의 보존을 최우선으로 하여 영상 크기를 조정하고자 한다. 이 과정에서 입력 영상과 출력 영상의 비교로부터 객체 보존 정도를 평가하는 관심 영역 보존 함수 $f(\lambda)$ 를 정의한다. 해당 함수의 값을 최소화하기 위해 영역별 부여된 scaling ratio를 지속적으로 갱신하여 최적 값을 얻는 최적화 알고리즘을 제안한다.

2. 관심 영역 검출



그림 1. 관심 영역 검출 결과

입력 영상의 관심 영역 검출은 Structure tensor[4] 방법과 Higher order statistics(HOS)[5] 방법을 사용한다. Structure tensor는 함수의 gradient로부터 얻어진 행렬로, 한 점에서부터 특정 이웃한 지점으로의 저명한 방향을 요약한다. 이차원 structure tensor를 영상의 각 픽셀에 적용함으로써 인접 픽셀들간의 RGB luminance 값 차이를 통해 관심 영역을 검출할 수 있다. Higher order statistics 방법은 영상의 에지를 검출하는 데에 쓰인다. 현재 픽셀을 중심으로 주변 픽셀들의 값이 얼마나 차이가 나는지를 luminance 값으로 반환함에 따라 에지 검출이 이루어진다.

위의 Structure tensor 방법과 HOS 방법으로부터 얻은 관심영역 영상을 실험적으로 얻은 가중치로 분배하여 합하면 그림 1과 같은 최종 관심 영역 영상을 얻을 수 있다. 이렇게 얻은 관심영역 영상을 세로 방향으로 누적하여 합산하여 각

column에 대한 관심영역 중요도를 획득할 수 있다[6]. 해당 column이 영상에서 관심 영역일 가능성을 수치적으로 구분할 수 있다. 평활화 과정을 거쳐 관심영역을 포함할 것으로 예상되는 column은 0에 가깝게, 비 관심 영역으로 예상되는 부분은 1에 가까운 값을 가진다.

3. 이미지 리사이징 최적화

관심 영역 추출로부터 얻은 1 차원 행렬 $m[x], (x = 1, 2, \dots, \text{width})$ 을 바탕으로 각 column의 scaling 비율을 결정한다. 입력 영상의 width size를 W_i 라고 하고 aspect ratio에 따른 출력 영상의 width size를 W_0 라고 하면, Scaling ratio λ 를 1 차원 행렬의 모든 성분에 일괄적으로 곱함으로써, $(m[1] + m[2] + \dots + m[\text{width}]) \cdot \lambda = W_0$ 를 얻는다. 이 때, 각 column의 지나친 확장을 방지하기 위해 max scaling ratio λ_{\max} 의 값을 지정하여 각 column 확장 성분이 다음 식을 만족하도록 한다.

$$m[x] \cdot \lambda \geq \lambda_{\max}, (x = 1, 2, \dots, \text{width})$$

각 column 확장 비율이 λ_{\max} 로 제한되기 때문에 $m[x] \cdot \lambda$ 의 값이 λ_{\max} 를 초과하면 λ_{\max} 의 값으로 만들어준다. 각 column 별 확장 비율이 정해지면 Column 데이터를 새로운 크기의 영상에 확장 비율에 따라 새롭게 위치시키고, 데이터가 입력되지 않은 column에는 보간법을 적용한다.

위의 과정으로 이미지 리사이징을 할 때, 핵심적인 고려 사항은 λ_{\max} 의 값을 결정하는 방법이다. λ_{\max} 의 값이 다소 작다면 각 column 별 확장 비율이 낮은 값으로 제한되어 전체적으로 유사하게 확장되어 관심영역이 왜곡되는 현상이 나타난다. 값이 너무 크다면 데이터가 존재하지 않는 column의 밀집도가 높아져서 결과 영상을 생성할 때, 보간법을 적용하기 어렵다. 따라서 이러한 문제를 야기하지 않는 조건으로 최적의 결과 영상을 얻기 위해서 다음과 같은 관심 영역 보존 함수를 정의한다.

$$f(\lambda) = S'_{\alpha} - S_{\alpha}$$

위의 함수에서 $S'_{\alpha} = \sum_{x=1}^{\text{size of object } \alpha} m[x] \cdot \lambda$, (if $m[x] \cdot \lambda \geq \lambda_{\max}$, then λ_{\max}) 성분은 결과 영상의 관심 영역 α 의 가로방향 길이를 나타낸다. $S_{\alpha} = \sum_{x=1}^{\text{size of object } \alpha} m[x]$ 성분은 입력 영상의 관심 영역의 가로방향 길이이다. 입력 영상의 관심 영역의 크기와 출력 영상의 관심 영역의 크기의 차이를 함수로 정의하여 그 차이가 적을수록 관심 영역이 잘 보존된 것으로 판단할 수 있다. 결과적으로 $f(\lambda)$ 의 값을 최소화시키는 λ_{\max} 의 값을 찾는 것이 최적화 과정이라고 할 수 있다. 또한 보간법을 고려하면 다음과 같은 제약이 존재한다.

$$\sum_{y=1}^{\text{height}} p(x, y) > 0, (\text{for every column } x)$$

위의 식은 보간법을 적용한 결과 영상에서 데이터가 비어 있는 column이 존재하지 않아야 한다는 제약이다. 결과적으로 위의 제약을 만족시키면서 $f(\lambda)$ 값을 최소화시키는 λ_{\max} 의 값을 찾는 것을 최적화의 목적으로 한다.

실험을 위해 16:9 영상을 21:9 영상으로 리사이징하는 과정에서 최적화 기법을 적용하였고, λ_{\max} 의 값을 21/16부터 특정 단위로 증가시키면서 최적화 알고리즘에 대입하여 최적

해 λ_{\max} 를 찾았다. 그 결과 영상은 그림 2와 같다. (a)는 원본, (b)는 linear scaling, (c)는 letter box 삽입, (d)는 제안하는 최적화 기법 기반 이미지 리사이징 결과이다. 관심 영역이 보존된 상태의 리사이징 결과를 확인할 수 있다.



그림 2. 제안하는 최적화 기법의 성능

4. 결론

본 논문에서는 관심 영역 보존을 고려한 이미지 리사이징 기법을 제안하였다. 관심 영역의 보존 정도를 고려한 최적화 함수와 보간법을 고려한 제약조건을 정의하여 함수를 최소화시키는 것으로 최적 해 λ_{\max} 를 얻는 과정을 실험적으로 확인하였다. 본 연구를 통해 다양한 이미지에 대하여 관심 영역을 보존하는 것에 초점을 맞춘 이미지 리사이징에 최적화 문제로 접근하였고, 관련 연구에 기여할 것으로 사료된다.

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행되었으며(No. 20161210200560), 또한 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행되었습니다.
(No. 2018R1D1A1B07048421)

참고 문헌

- [1] ACHANTA, Radhakrishna, et al. SLIC superpixels compared to state-of-the-art superpixel methods. *IEEE transactions on pattern analysis and machine intelligence*, 2012, 34.11: 2274-2282.
- [2] WANG, Yu-Shuen, et al. Optimized scale-and-stretch for image resizing. In: *ACM Transactions on Graphics (TOG)*. ACM, 2008. p. 118.
- [3] KRÄHENBÜHL, Philipp, et al. A system for retargeting of streaming video. In: *ACM Transactions on Graphics (TOG)*. ACM, 2009. p. 126.
- [4] KÖTHE, Ullrich. Edge and junction detection with an improved structure tensor. In: *Joint Pattern Recognition Symposium*. Springer, Berlin, Heidelberg, 2003. p. 25-32.
- [5] PORAT, Boaz; FRIEDLANDER, Benjamin. Direction finding algorithms based on high-order statistics. *IEEE Transactions on Signal Processing*, 1991, 39.9: 2016-2024.
- [6] CHO, Donghyeon, et al. Weakly-and Self-Supervised Learning for Content-Aware Deep Image Retargeting. In: *2017 IEEE International Conference on Computer Vision (ICCV)*. IEEE, 2017. p. 4568-4577.

HOG 특징 기반 SVM을 활용한 화물차 분류 시스템

강건우, *강석주
서강대학교, *서강대학교
gunkun00@gmail.com, *sjkang@sogang.ac.kr

Truck Classification System Using HOG Feature-based SVM

Keon-Woo Kang, *Suk-Ju Kang
Sogang University, *Sogang University

요약

차종 별 교통량 자료는 도로의 유지관리나 분석 등의 행정 처리 업무에 필요한 기본 자료임과 동시에 각종 연구에 활용된다. 본 시스템은 그 일환으로서 화물차나 일반차량을 구분하여 특정 도로의 화물차 비율이나 교통량을 파악하는데 활용할 수 있다. 머신 러닝 알고리즘 중에서 높은 성능을 보이는 Support Vector Machine (SVM) 알고리즘을 이용하여 도로 위의 일반차량과 화물차를 구분하였다. 우선, 화물차와 일반차량의 차이를 구분하고자 각각의 영상에 대해 Histogram of Oriented Gradients (HOG) 기반 특징점을 추출하고 이에 따라 1 차원 벡터로 표현된 데이터를 SVM으로 분류하여 구분한다.

1. 서론

차종에 따른 교통량 자료는 국도나 고속도로 등의 건설 계획이나 추이 분석, 유지, 관리 등의 행정적 업무에 사용되는 기초적 자료이다. 또한, 각종 연구의 기초 자료로 활용되기도 한다. 주어진 도로에 대한 일반 차량과 화물차, 승합차 등의 비율이나 실시간 교통량 등을 통해 현재 교통 상황이나 특정 도로의 이용량 등 다양하게 활용 가능하다.

최근, 머신 러닝을 이용한 인공지능에 대한 관심이 높아지고 있고 머신 러닝에 해당하는 알고리즘 등의 중요성과 필요성이 극도로 강조되고 있다. 특히, 여러 활용분야 중에서 컴퓨터 비전은 최근의 연구에서 좋은 성능을 보이고 있어 주목 받고 있다 [1]. 머신 러닝이란 컴퓨터가 미래에 어떻게 동작할 것인지 추론하고 기존 데이터를 분류하고 분석하는 등의 학습을 통하여 추론 모델을 실행할 수 있는 기술을 뜻한다 [2]. 즉, 데이터가 갖는 특정 패턴을 찾아내어 그 패턴을 인식할 수 있도록 한다.

Support Vector Machine (SVM)은 딥 러닝 이전에 뛰어난 성능으로 많은 주목을 받았다. SVM은 기본적으로 두 특정 범주를 어떻게 나눌 것인지 대해서 푸는 문제이다. 범주를 어떻게 나눌 것인지에 대한 최적해를 구하는 것이 목표라고 할 수 있다. 따라서, 주어진 조건과 특정 상황에 대해서 특정 데이터를 여러 가지 클래스로 분류하는데 적용이 쉽고 성능이 강력하여 매우 실전적이다. 또한, 영상 기반의 분류를 위해서는 데이터를 미리 가공할 필요가 있고 영상에 존재하는 특징점을 추출하여 데이터를 활용하면 SVM을 활용한 분류에 더 적합하게 문제를 바꿀 수 있다. 특히, 자동차와 같이 외관에 대한 특징이 확실한 경우에 더 유리하다.

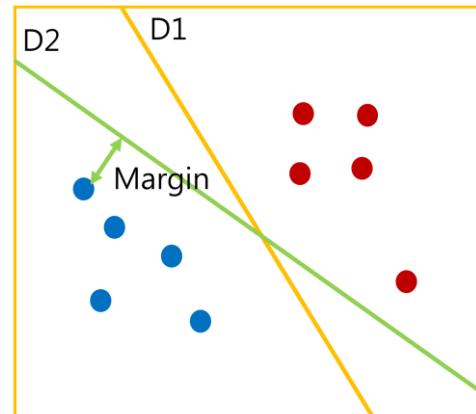


그림 1. SVM Decision boundary 개념도

2. Support Vector Machine

SVM은 기본적으로 두 범주를 나누는 분류 문제를 푸는데 적합하다. 그림 1과 같이, decision boundary인 D1과 D2 모두 클래스를 분류하고 있다. D2의 margin이 D1보다 더 크기 때문에 더 좋은 분류 경계면은 D1이다. Decision boundary인 D1과 D2는 모두 hyperplane이고 이 기법을 이용하여 마진을 최대로 크게 하는 hyperplane을 찾는 것이 SVM의 목표이다. 그림 1에서의 파란색 영역에서 margin이 0인 hyperplane과 빨간색 영역에서의 margin이 0인 hyperplane 사이의 거리를 반으로 나눴을 때로 볼 수 있다. 최적화 측면에서 목적식과 제약식은 수식 (1)과 같다.

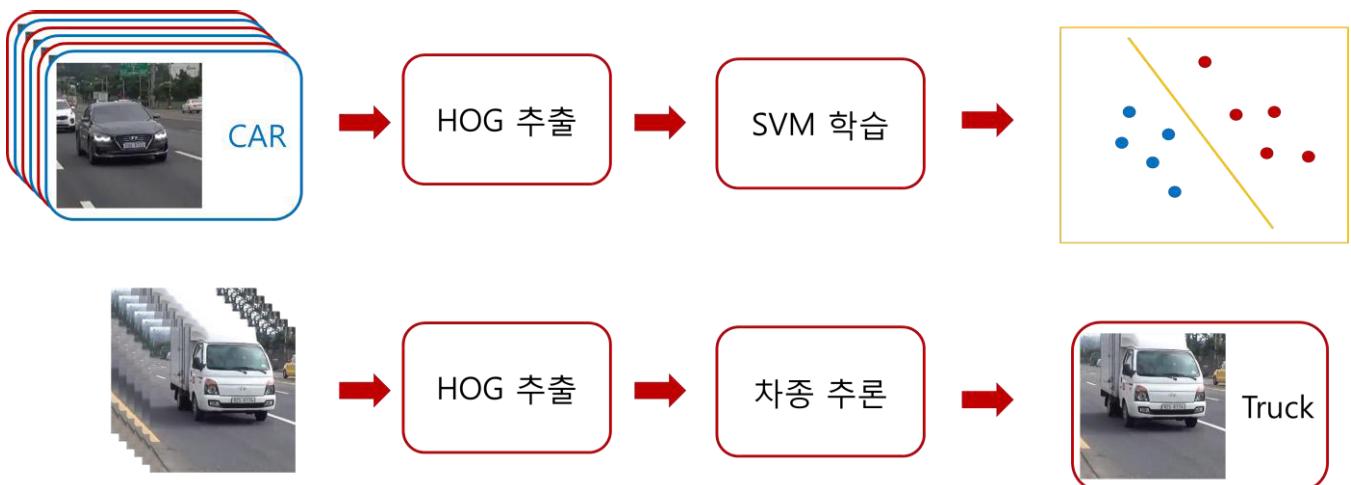


그림 2. 차종 분류 시스템 전체 과정

$$\max \frac{2}{\|w\|_2} \\ y_i(w^T x_i + b) \geq 1 \quad (1)$$

목적식의 경우는 앞서 언급하였듯이 마진의 크기를 최대로 하고 이 때 w 는 decision boundary의 법선 벡터를 뜻한다. 또한, 제약식의 y_i 는 클래스를 뜻하고 x_i 는 데이터의 정보, b 는 원점으로부터 데이터까지의 거리를 뜻한다.

$$w = \sum_{i=1}^n a_i y_i x_i \quad (2)$$

수식 (2)는 수식 (1)의 최적화 문제를 라그랑지안 문제로 변환하여 구한 최적해를 뜻한다 [4]. a_i 는 라그랑지안 승수를 뜻하고 최적해는 Karush–Kuhn–Tucker (KKT) 조건에서 dual 문제로 변환된다. 수식 (2)에서 나타난 최적해는 라그랑지안 승수를 알 수 있다면 마진의 최대값에 대한 결정을 할 수 있음을 뜻한다.

3. 차종 분류 시스템

제안하는 화물차 분류 시스템은 자동차의 입력 영상에 대해 화물차인지 일반 차량인지 혹은 대형 버스와 같은 승합차인지 구분한다. 전체 시스템은 그림 2 와 같이 나타난다. 영상 기반의 데이터를 가공하여 SVM 알고리즘을 이용하여 학습을 진행한다. 데이터의 특징점을 추출하기 위해서 Histogram of oriented gradients (HOG)를 이용했다 [3]. 제안하는 시스템의 전반적인 흐름은 그림 1 과 같다.

HOG의 경우, 영상의 지역적인 gradient를 해당 영상의 특징으로 사용하는 방식이다. 즉, 영상의 수평축 edge와 수직축 edge를 이용하여 방향을 계산한다. 그 다음 양자화를 통하여 총 각도를 9 개로 나눈다. 이렇게 구해진 gradient를 이용하여 orientation map을 만들고 이를 histogram으로 생성하여 이어 붙이면 HOG 특징이 된다. 주로 사람 검출과 같이 검출하고자 하는 객체의 윤곽이나 edge 들의 기울기가 비슷한 경우에 대해 좋은 성능을 보인다. 자동차 차종의 분류 또한 마찬가지이다.

추출한 HOG를 이용하여 SVM의 학습에 이용한다. 여기서 학습은 decision boundary의 최적해를 구하는 방법이다. 데이터를 분류하는 최적해를 찾아 정확한 예측을 할 수 있다. 이 때, 특정 데이터에 대한 과적합을 방지하고 올바른 추론을 위하여 학습시키는 데이터의 양이 많고 종류가 다양해야 한다.

4. 실험 결과

일반 차량 영상 1000 장과 화물차 영상 1000 장 그리고, 버스 영상 400 장으로 SVM을 학습시켰다. 시험용 set은 각각 50 장씩으로 구성하였다. 버스 영상은 74%, 일반차량 영상은 91%, 화물차 영상은 95%의 정확도로 분류하였다. 버스에 대한 분류의 정확도가 낮은 이유는 버스 영상의 데이터 부족이 원인인 것으로 보인다. 나머지 클래스의 정확도 또한 데이터가 더 충분하다면 더 높아질 것으로 보인다.

본 연구는 산업통상자원부(MOTIE)와 한국에너지기술평가원(KETEP)의 지원을 받아 수행되었으며(No. 20161210200560), 또한 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행되었습니다.
(No. 2018R1D1A1B07048421)

참고 문헌

- [1] Goldberg, David E., and John H. Holland. "Genetic algorithms and machine learning." *Machine learning* 3.2 (1988): 95–99.
- [2] Rosten, Edward, and Tom Drummond. "Machine learning for high-speed corner detection." *European conference on computer vision*. Springer, Berlin, Heidelberg, 2006.
- [3] Dalal, Navneet, and Bill Triggs. "Histograms of oriented gradients for human detection." *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*. Vol. 1. IEEE, 2005.
- [4] Mangasarian, Olvi L., and David R. Musicant. "Lagrangian support vector machines." *Journal of Machine Learning Research* 1.Mar (2001): 161–177.

Generative Adversarial Network를 이용한 야간 도로 영상 보정 시스템

안남현, *강석주
서강대학교, *서강대학교
neition503@gmail.com, *sjkang@sogang.ac.kr

Night to day image translation with Generative Adversarial Network

Namhyun Ahn, *Suk-Ju Kang
Sogang university, *Sogang university

요약

본 논문에서는 야간 도로 영상을 보정하여 주간 영상으로 변환하는 알고리즘을 제안한다. 영상 변환 딥러닝 알고리즘인 Generative Adversarial Network(GAN)를 기반으로 주야간 도로 영상을 학습시켜 주야간 상호 변환이 가능한 시스템을 구현한다. 우선, 입력 영상에 대해 변환된 영상을 출력하는 generative network를 정의한다. 또한, 변환된 영상을 다시 본래 영상으로 변환하는 inverse network를 정의한다. Generative network와 inverse network를 모두 통과한 결과 영상과 본래 영상의 차 영상을 통해 손실 함수를 정의함으로써 파라미터를 목적에 맞게 학습시킬 수 있다. 또한, generative network를 통과한 결과 영상과 목적하는 영상을 구분하는 discrimination network를 정의하여 discrimination network와 generative network의 minimax two-player game을 통해 변환된 영상이 실제 목적 영상과 유사하도록 유도한다. 제안하는 알고리즘을 적용하여 야간 도로 영상의 보정을 수행하면 주변 물체 인식이 어려운 야간 영상을 물체 인식이 용이한 주간 영상으로 변환 할 수 있다.

1. 서론

최근 들어 자동차 기술 분야에서 안전과 관련된 기술이 급격한 관심을 받고 있다. 교통사고가 일어나는 상황은 대부분 낮 시간보다는 시야가 제한된 야간이나 흐린 날씨에 자주 발생한다. 레이더나 라이다 센서를 통해 차량 주변의 이동물체를 감지하는 기술이 연구되고 있지만, 운전자의 시야를 직접적으로 개선시켜주는 기술에 대한 연구는 없는 실정이다. 따라서, 영상을 통해 운전자의 시야를 개선시켜주는 기술이 요구된다.

[1] Generative Adversarial Network(GAN)은 실제와 같은 영상을 인공적으로 생성하는데 주로 사용되는 알고리즘이다. 하지만, GAN 알고리즘의 또 다른 응용분야는 주어진 입력 영상을 원하는 특성을 가진 영상으로 변환하는 분야이다. 일반적으로 GAN 알고리즘은 목적하는 영상을 생성하는 generator와 인공적으로 생성 혹은 변환된 영상을 실제 영상과 구별해 내는 discriminator로 구성된다. 학습 데이터를 기반으로 generator는 discriminator가 구별하지 못하는 영상을 만들어내도록 학습되고, discriminator는 generator가 만든 영상과 실제 영상을 잘 구별할 수 있도록 학습된다. 이와 같이 generator와 discriminator의 minimax two-player game을 통해 GAN 알고리즘의 학습이 이루어진다.

[2] 영상 특성 변환 분야에서 높은 성능을 보이는 GAN 알고리즘으로 pix2pix가 대표적이다. 하지만, pix2pix 알고리즘은 입력 영상에 대해 목적 영상(우리가 부여하고자 하는 특성을 지닌 영상)이 쌍으로 존재해야 하는 제한 요소가 있다. 따라서, 학습을 위한 데이터베이스 구축에 어려움이 있다. [3] 이를 해결하기 위해 제안된 알고리즘이 CycleGAN이다.

CycleGAN은 입력 영상에 대해 목적 영상 쌍을 요구하지 않는다. 대신에, 그로 인한 성능의 손실을 막기 위해 Cycle consistency 개념이 도입된다. Generator를 통해 변환된 영상을 본래 영상으로 재 변환하는 inverse network가 추가된다. Inverse network를 통해 재 변환된 영상이 본래 입력 영상과 동일하도록 제한을 둠으로써 generator를 통한 변환 과정에서 입력 영상이 형태를 유지할 수 있도록 구현한다.

본 논문에서 사용하는 야간 도로 영상은 입력 영상과 쌍을 이루는 목적 영상(주간 도로 영상)을 수집하기가 어렵다는 문제를 가지고 있다. 이를 고려하여 본 논문에서는 CycleGAN을 적용한 시스템 구현을 제안하였다. 입력 영상과 목적 영상으로 각각 야간 도로 영상과 주간 도로 영상을 수집하고 이를 통해 알고리즘을 학습시킴으로써 야간 도로 영상 보정 시스템을 구현하였다.

본 논문의 구성은 다음과 같다. 2 절에서는 CycleGAN에 대해 살펴본 후, 3 절에서는 수집한 데이터를 기반으로 학습한 결과를 설명한다. 그리고, 마지막 4 절에서는 본 논문에 대한 결론을 맺는다.

2. CycleGAN

CycleGAN은 4 개의 Network로 구성된다. 입력 영상을 목적 영상으로 변환하는 generator(G)와 목적 영상을 입력 영상으로 되돌리는 inverse network(F), 그리고 generator를 통해 만들어진 영상과 실제 목적 영상을 구분하는 discriminator(D_Y)와 Inverse network를 통해 재 변환된 영상과 실제 입력 영상을 구분하는 discriminator(D_X)가 존재한다.

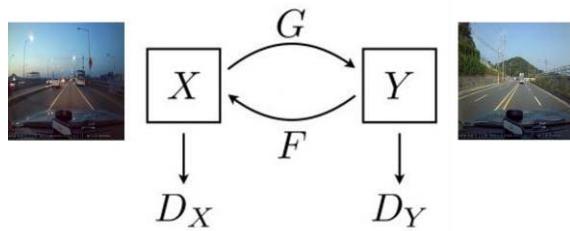


그림 1: CycleGAN 은 두 개의 Mapping function ($G : X \rightarrow Y$, $F : Y \rightarrow X$) 과 두 개의 associated adversarial discriminators (D_Y , D_X) 를 포함한다. D_Y 는 G 가 X 를 변환하여 Y 영역의 다른 영상과 구분할 수 없게 만드는데 도움을 주며, D_X 는 이와 정반대로 동작한다.

이 4 가지 Network 는 다음과 같은 3 가지 손실 함수에 의해 학습된다. 첫 번째는 generator(G) 와 discriminator(D_Y) 의 adversarial loss 로 다음과 같이 나타낸다. 해당 손실 함수는 generator(G) 와 discriminator(D_Y) 의 minimax problem 을 의미한다.

$$\begin{aligned} \mathcal{L}_{\text{GAN}}(G, D_Y, X, Y) = & \mathbb{E}_{y \sim p_{\text{data}}(y)} [\log D_Y(y)] \\ & + \mathbb{E}_{x \sim p_{\text{data}}(x)} [\log(1 - D_Y(G(x)))] \end{aligned} \quad (1)$$

두번째는 inverse network(F) 와 discrimination(D_X) 의 adversarial loss 로 위 손실과 마찬가지 의미를 가지다. 위 손실 함수에서 D_Y 대신 D_X , G 대신 F 를 사용하면 inverse network(F) 와 discrimination(D_X) 의 adversarial loss 가 된다. 마지막은 generator 와 inverse network 를 통과하여 재 복원된 영상이 본래 영상과 동일한지를 나타내는 손실함수로 다음과 같다.

$$\begin{aligned} \mathcal{L}_{\text{cyc}}(G, F) = & \mathbb{E}_{x \sim p_{\text{data}}(x)} [\|F(G(x)) - x\|_1] \\ & + \mathbb{E}_{y \sim p_{\text{data}}(y)} [\|G(F(y)) - y\|_1]. \end{aligned} \quad (2)$$

이렇게 구한 세 손실 함수는 다음과 같이 결합되어 최종 손실이 된다.

$$\begin{aligned} \mathcal{L}(G, F, D_X, D_Y) = & \mathcal{L}_{\text{GAN}}(G, D_Y, X, Y) \\ & + \mathcal{L}_{\text{GAN}}(F, D_X, Y, X) \\ & + \lambda \mathcal{L}_{\text{cyc}}(G, F), \end{aligned} \quad (3)$$

이 손실 함수를 기반으로 4 개의 network 가 학습을 진행하고 결과적으로 generator 가 입력 영상으로부터 자연스러운 출력 영상을 만들어 내게 된다.

3. 학습 결과

학습에 사용된 데이터는 총 2000 장으로 야간 도로 영상과 주간 도로 영상 각각 약 1000 장씩을 사용하였다. 학습 횟수는 50 epoch 으로 진행하였고 input resolution 은 256 으로 설정하였다. 그림 2 를 통해 야간 도로 영상이 generative network 를 통과하여 자연스러운 주간 도로 영상으로 변환되는 것을 확인 할 수 있다.



그림 2: CycleGan 결과 예시 영상

4. 추후 연구

Input resolution 이 256 인 경우에는 자연스러운 변환 영상을 얻을 수 있음을 확인하였지만, resolution 이 더 큰 영상에 대해서는 추가 연구가 필요하다. 또한, 좀 더 어두운 야간 영상에 대해서도 적용이 가능한지에 대해서도 추후 연구가 요구된다.

본 연구는 산업통상자원부(MOTIE) 와 한국에너지기술평가원(KETEP) 의 지원을 받아 수행되었으며 (No. 20161210200560), 또한 2018년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 기초연구사업의 지원을 받아 수행되었습니다.
(No. 2018R1D1A1B07048421)

참고 문헌

- [1] Ian J. Goodfellow, Jean Pouget-Abadie, Mehdi Mirza, Bing Xu, David Warde-Farley, Sherjil Ozair, Aaron Courville, Yoshua Bengio. Generative Adversarial Networks arXiv preprint arXiv: 1406.2661, 2014. 6.
- [2] Phillip Isola, Jun-Yan Zhu, Tinghui Zhou, Alexei A. Efros. Image-to-Image Translation with Conditional Adversarial Networks arXiv preprint arXiv: 1611.07004, 2017. 11.
- [3] Jun-Yan Zhu, Taesung Park, Phillip Isola, Alexei A. Efros. Unpaired Image-to-Image Translation using Cycle-Consistent Adversarial Networks. arXiv preprint arXiv: 1703.10593v4, 2018. 2.

웹 서버 기반 전기차 충전소 전력 소모량 및 교통량 모니터링 시스템

이윤수, *강석주
서강대학교, *서강대학교
profitshore@gmail.com, *sjkang@sogang.ac.kr

Web server-based electric vehicle charging station power consumption and traffic volume monitoring system

Yunsoo Lee *Suk-Ju Kang
Sogang University *Sogang University

요약

본 논문에서는 전기 자동차 충전소의 전력 소모량 추정 알고리즘을 웹 서버에 도입하여, 충전소에 의한 전력소비가 주변 전력 계통에 미치는 영향을 모니터링할 수 있는 시스템을 제안한다. 우선, 관련 기관으로부터 공급 받는 지역 내 실시간 충전소 별 이용 상태 정보로부터 충전 시간과 그 횟수를 도출하고, 이를 충전소마다 누적하여 소비 전력을 추정한다. 이렇게 추정된 충전소 별 전력 소모량을 웹 페이지를 통해 사용자에게 시각화하여 제공한다. 또한 같은 지역의 구간별 실시간 교통량 또한 같은 방식으로 제공하여, 전기 자동차 충전소 전력소모량의 변화 추이와 교통량의 변화 추이 간 상관관계를 확인할 수 있도록 한다. 따라서 제안하는 시스템은 지역 내 전기 자동차 충전소의 전력 소모량 및 그 변화 추이 관측하고 이를 바탕으로 지역 내 충전소 추가 설치 필요성, 전력 계통 부하 예측, 충전소 재배치 등 전기 자동차 충전소 운영 전략을 수립하는데 사용할 수 있다.

1. 서론

최근 들어 이산화탄소 배출로 인한 대기오염, 화석연료 사용 증가로 인한 자원 고갈 등의 문제가 야기됨에 따라 친환경 자동차의 필요성과 그 가치가 높아지고 있다. 배터리와 전기모터를 활용하는 전기 자동차(Electric Vehicle, EV), 전기모터와 가솔린엔진을 혼용하는 하이브리드 자동차(Hybrid vehicle), 수소연료전지와 전기모터를 활용한 수소자동차(Fuel Cell Electric Vehicle, FCEV) 등 친환경 자동차는 현재까지 지속적으로 발전하고 있다. 이중에서 전기 자동차는 하이브리드 자동차와 달리 화석연료 사용이 전혀 없다는 점과, 충전 인프라가 상용으로는 거의 구축되어 있지 못한 수소 자동차에 비해 연료 공급이 용이하다는 점에서 현재 가장 촉망받는 친환경 자동차이다.

정부의 친환경 자동차 구매 보조금 정책 및 활발한 전기 자동차 충전 인프라 구축에 힘입어 전기 자동차의 보급이 증가하였고, 각 지역마다 전기 자동차 충전소 또한 증가하였다. 전기 자동차 충전소는 해당 지역의 전력 계통 관점에서 기존에 없던 새로운 부하이므로, 어떠한 지역에 충전소를 도입할 때는 충전소 도입 후에도 해당 지역 전력계통의 안정성을 확보할 수 있도록 충전소가 야기할 새로운 부하의 정도를 예측하여 도입해야 한다. 그러나 이는 지역 내 충전소의 위치 분포, 교통사고 등으로 인한 한시적 교통량 변화, 차량의 충전 전 잔여 배터리 량(Initial state of charge, SOC) 등 많은 불규칙적인 변수를 지니므로 대단히 어렵다[1]. 전기 자동차의 충전으로 인한 전력 부하를 예측하는 방법으로 충전소 주변 온도와 충전 시간을 사용하는 방법[2], 차량에 충전 전류

변화를 감지하는 센서를 부착하는 방법[3] 등의 기존 연구 사례가 있으나, 충전 전 잔여 배터리 량을 고려하지 않는 점과 차량에 센서를 부착함이 야기하는 비용적 문제로 실질적인 예측 방법이 되지 못했다. 그러나, 충전 시간과 충전 횟수로부터 충전 소비 전력량을 추정하는 방법[4]의 경우 국가 기관으로부터 제공받을 수 있는 데이터를 활용한 방법으로 그 구현이 쉽고 추정 정확도 또한 높다.

본 논문에서는 전기 자동차 충전소의 충전 시간과 충전 횟수를 활용하여 전력소모량을 추정하는 알고리즘을 웹 서버에 도입하여 실시간으로 전기 자동차 충전소의 전력 소모량을 추정하고, 이를 누적하여 데이터베이스화 한 뒤, 웹 페이지를 통해 표와 그래프로 시각화하고 문서화하여, 충전소의 전력 소모량을 관측하고 그 변화 추이를 해당 지역 실시간 교통량과 함께 분석하여, 충전소로 인한 전력계통 부하 예측 및 향후 충전소 운용 전략을 수립할 수 있도록 하는 데이터 모니터링 시스템을 제안한다.

2. 전기 자동차 충전소 전력 소모량 추정 데이터베이스 시스템

높은 추정 정확도를 위해서는 다량의 데이터가 필요하며, 이를 위해 단위 면적 당 충전소 설치 비율이 높은 제주특별자치도를 데이터 수집 지역으로 선정하였다. 본 모니터링 시스템에 적용된 데이터베이스는 “공공데이터의 제공 및 이용 활성화에 관한 법률”(제 11956 호)에 따라

OpenAPI 형태로 제공되는 환경부 전기 자동차 충전소의 실시간 이용현황 데이터를 활용하여 제작되었다. 충전 시간과 충전 횟수를 활용한 전력 소모량 추정알고리즘[6]을 적용하기 위해 각 충전소의 충전 시간과 횟수가 필요하지만, 제공되지 않고 충전기 사용상태 여부와 그 시간 정보만 제공된다. 따라서, 충전기의 상태 정보가 “사용 중”에서 “대기 중”으로 바뀌는 시점을 수집하여 그 시간차를 충전시간으로 삼고 충전시간이 수집되는 횟수를 충전 횟수로 하여 데이터베이스를 구성하고 선형회귀분석모델을 활용하여 전기 자동차 충전소의 전력 소모량을 추정하였다. 추정에 사용된 수식은 다음과 같다.

Error

$$\begin{aligned} \text{Error} &= P(X_{\text{Charging time}}, X_{\text{Number of charging}}) - w \\ &= w_{\text{Charging time}} X_{\text{Charging time}} \\ &= w_{\text{Number of charging}} X_{\text{Number of charging}} \end{aligned} \quad (1)$$

수식(1)에서 P 는 충전 전력, w 는 예측변수, X 는 예측변수에 대한 가중치이며, Error 를 최소화하는 예측변수값을 최소자승법에 의해 구하여 예측 모델을 생성한다. 단, 방대한 양의 데이터를 가지고 예측변수 값을 매번 갱신한다면 그 정확도는 높을 수 있으나 처리시간이 길어져 충전소 현황 데이터를 실시간으로 가져오지 못하게 된다. 따라서 시스템 구축과 별도로 과거 2개월 분의 데이터를 따로 제공 받고 그에 대한 추정 모델을 생성하고, 수식화하여 데이터베이스에 적용하였다. 적용된 모델은 다음과 같다.

$$\begin{aligned} \text{Estimated Charging Power Consumption} &= -10.058 + 0.0019333 \\ &\quad * \text{Charging Time} + 7.8479 \\ &\quad * \text{Number of Charging} \end{aligned} \quad (2)$$

위 모델을 활용하여 본 데이터베이스는 매 1분마다 OpenAPI를 호출하여 충전기 사용 상태정보를 갱신하고 충전소 별로 충전 횟수와 그 시간을 계산하여 저장한다. 외부로부터 입력 기간이 주어지면 데이터베이스는 해당기간간의 충전소 별 충전 횟수와 시간을 변수로 위 모델에 따라 계산하여 추정전력소모량을 제공한다.

3. 웹 서버 기반 전기 자동차 충전소 전력 소모량 모니터링 시스템

앞서 살펴본 데이터베이스를 기반으로 데이터를 시각화하는 방안으로 웹 페이지를 선택하였다.

