

무인 주행을 위한 도로 인식 및 핸들 제어

정 흥, 이상우

포항공과 대학교 전자전기공학과

AUTOMATIC ROAD RECOGNITION AND STEER CONTROL FOR AUTONOMOUS LAND VEHICLE

Hong Jeong, Sang-Woo Lee

F.F. Dept POSTECH

요 약

비전 시스템을 바탕으로 한 무인 주행 시스템은 카메라로부터 입력된 영상에서 도로와 비 도로를 적절히 인식하여 그것을 바탕으로 주행을 위한 여러 장치들을 제어하는 시스템이라 할 수 있다. 한편 이와 같이 영상의 인식 결과가 핸들 제어나 속도 제어의 성능을 결정할 때 무엇보다 도로의 환경 변화에 강건한 비전 시스템의 구현이 요구된다. 본 논문에서는 비전 시스템과 핸들 제어 시스템 두 부분을 구현하였는데, 비전 시스템에서 는 입력 영상에 대해 학습이 가능한 Multilayer Perceptron(MLP)을 이용하여 도로와 비 도로를 적절한 신뢰도로 나눈 후 피라미드 알고리즘을 거쳐 최종 도로 영역을 추출해 낸다. 핸들 세이브 위헤 도로 연역의 의파 신을 모델링한 후 차량의 주행 방향 벡터를 구한다 그 값이 핸들 제어 시스템에서의 MLP의 입력이 되어 차량의 핸들 각도를 결정하게 된다. 끝으로 육외 차량 서브레이션을 통하여 본 논문에서 개인된 알고리즘의 유통성을 확인한다.

1. 개 요

차량의 자율 주행의 실현에서 비전 시스템이 차지하는 비중이 크다. 그 비전 시스템을 통해 주행의 첫 목표라 할 수 있는 도로와 비 도로의 구분이 행해진다. 이때 비전에 사용 할 수 있는 이미지에는 CCD 카메라로부터 쉽게 얻어지는 빛의 밝기에 따른(light intensity) 이미지에서부터 레이저 센서를 이용한 거리(range) 이미지에 이르기까지 다양하다. 하지만 본 논문에서는 CCD 카메라로부터 얻어지는 이미지 정보만을 이용하여 자율 주행 시스템의 구현에 목표를 두었다.

이미지 분할(image segmentation)은 이미지 처리 및 컴퓨터 비전 분야에서 가장 기초적이며 하위 단계에 해당한다. 실제로 최종 결과의 좋고 나쁨이 이미지 분할의 결과에 좌우 되는게 사실이다. 이미지 분할이란 이미지를 여러 동일한 성질을 가지는 부분으로 나누는 것인데, 도로와 비 도로로 분할하는 것을 예로 들 수 있다. 이미지 분할 알고리즘에는 히스토그램을 통한 단순 분할, 예지 검출, 릴랙세이션 등을 이용한 다양한 방법들이 있다. 하지만 대부분의 알고리즘은 노이즈에 약하거나 특정 이미지에 대해서만 좋은 결과를 낼뿐이다. 차율 주행에서 이미지 분할은 도로와 비 도로의 구분이 될 것인데, 주행 중 도로의 환경이 시시각각 바뀌며 그것들이 노이즈 역할을 하여, 무엇보다 환경 변화에 강건한 알고리즘이 요구된다. 본 논문에서 이미지 분할은 R,G,B의 24bits의 칼라 이미지를 Multilayer

Perceptron(MLP)으로 구현된 신경망을 통해 도로와 비 도로를 256 단계로 분할된 흑백 이미지를 만들어 낸다. 그리고 주행 중 외부 환경의 변화에 적용하기 위해 계속적인 MLP의 학습이 이루어진다.

도로 영역의 인식은 Markov Random Field(MRF)로 모델링된 이미지를 베이지안 추정에 바탕을 둔 Maximum a posteriori(MAP) 추정 방법이 사용되었다. MRF로 모델링된 이미지의 확률 분포는 Gibbs 분포를 가지게 된다. 이 분포식에서 얻어지는 에너지 식을 최소화시키는 확률 분포가 최종 도로 인식 결과가 된다. 에너지 식의 최소점을 찾는데는 여러 이론이 있으나 대부분 무인 주행을 위한 실시간으로 적용하기에는 적합하지 않다. 그래서 본 논문에서는 베이지안(Bayesian) 이론을 토대로 하면서 MRF 모델을 피라미드 웹드로 대체한다.

2. 전체 시스템의 구조

전체 시스템은 그림 1.과 같이 세 개의 블록으로 구성되어 있다. 자동차 시스템(car system)의 CCD 카메라로부터 넘어오는 칼라 프레임 데이터 F_n 을 입력받아 비전 시스템(vision system)에서 세그멘테이션과 레이블링을 통해 자동차가 움직이어야 할 방향 벡터 Y_n 을 구한다 그 값은 자동차의 핸들을 제어하기 위해서 핸들 제어 예측 시

스텝(steering control prediction system)으로 들어간다

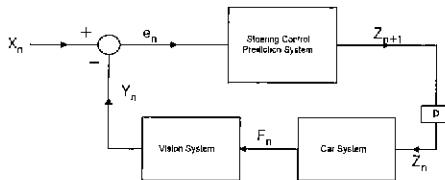


그림 1 전체 시스템 구조

비전 시스템은 CCD로부터 들어오는 컬라 이미지를 바탕으로 도로와 비도로로 구분하는데 우선적인 목적이 있다. 이를 위해 비전 시스템 블록은 아래 그림 2 와 같은 피드백 구조를 가지고 있다.

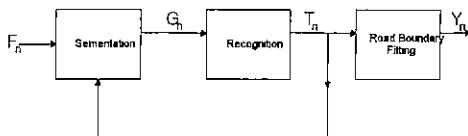


그림 2. 비전 시스템 구조

MLP를 이용하여 세그멘테이션 결과를 MRF 모델링을 바탕으로 한 피라미드 알고리즘에 의한 레이블링 단계에서 도로와 비 도로의 이진화가 이루어진다. 이 결과 이미지 T_n 은 세그멘테이션 부분의 MLP에서 앞으로 들어온 컬라 이미지에 대한 타겟 이미지로 피드백(feedback)된다. 세 번째 단계는 도로와 비 도로로 이진화된 이미지 T_n 에서 도로의 비도로의 경계를 찾은 후 그 테이터를 선형 모델링을 통해 차량의 진행 방향 벡터 Y_n 을 구하는 작업을 한다.

3. MLP를 이용한 영상분할

영상 분할을 위해 그림 3. 과 같은 세 개의 층으로 구성된 MLP가 사용되었다. 입력 값은 이미지에서 각 픽셀의 C,M,Y 값이 된다. 내부 파라메터, 즉 뉴런의 가중치를 수정하기 위한 학습 방법으로는 역 전파(Back propagation)를 사용하였다. 비 선형 출력함수는 식(1)과 같이 시그모이드 함수가 된다

$$F(x) = \frac{1}{1 + \exp(-x)}. \quad (1)$$

가중치의 학습은 모든 숨은 층(hidden layer)를 통과한 순방향 출력과 학습 데이터 출력의 차가 적이지는 방향으로 조금씩 바꾸어 나간다. 모든 출력 노드의 에러값의 합을 E 라면 가중치들은 식(2)과 같이 된다

$$\Delta W_y = -\eta \frac{\partial E}{\partial w_y}. \quad (2)$$

하지만 식(3)과 같이 모멘트항의 첨가로 학습률의 증가를 제하며 가중치의 발산 및 진동을 막을 수 있다

$$\Delta w_y(n) = \alpha \Delta w_y(n-1) + \eta \delta_i(n) v_b(n). \quad (3)$$

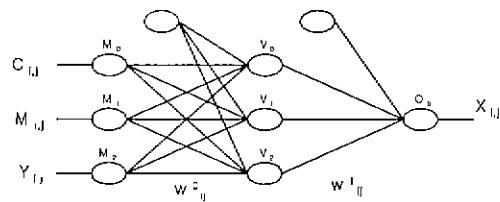


그림 3 Multilayer Perceptron의 구조

따라서 신경망의 학습을 위해 초기에 두 파라메터 α 와 η 가 결정되어야 한다

4. 피라미드 랜덤 필드에 의한 영상 인식

이미지의 각 픽셀을 랜덤 값으로 볼 때 전체 이미지는 랜덤 필드가 되며 이것이 MRF로 모델링 되면 Gibbs 확률 분포를 가진다. 이 등가성을 이용하여 필드의 지역적인 모델로부터 전체의 확률 분포를 유도해 낼 수 있다.

MRF로 모델링 되는 랜덤 필드의 도입은 국소적으로 도로색 분류를 한 신경망의 영상 분할의 오차를 글로벌 관점에서 처리 함으로써 줄이는데 목적이 있다. 그리고 피라미드 랜덤 필드의 도입으로 계산량을 줄이게 된다

신경망에서 세그멘테이션된 결과 이미지에 대해 식(4)와 같이 가우시안 가중치 $w(m, n)$ 에 의해 필터링을 함으로써 피라미드 이미지를 만든다

$$X^n(i, j) = \sum_{m=-2}^{n=2} \sum_{n=-2}^{n=2} w(m, n) X^{n-1}(2i+m, 2j+n). \quad (4)$$

이렇게 주어진 피라미드 이미지 X 에 대해 우리가 찾고자 하는 이미지 Y 를 MAP(Maximum a Posteriori)관점에서 구한다.

$$\text{Given } X = (x^0, x^1, \dots, x^L), \quad (5)$$

$$\text{Find } Y^* = (y^0, y^1, \dots, y^L)^* \quad (6)$$

$$\text{Such that } Y^* = \arg \max_Y P(Y|X). \quad (7)$$

베이즈 이론에 의해 X 에 대한 조건부 확률은 다음과 같다

$$P(Y|X) = \frac{P(X, Y)}{P(X)}. \quad (8)$$

피라미드 이미지에서 y^l 는 윗층 y^{l+1} 과 같은 층 x^l 에 의해서만 좌우된다고 가정한다. X 와 Y 의 조인트 확률 분포를 다음과 같이 전개할 수 있다.

$$P(X, Y) = P(y^0|x^0, y^1)P(y^1|x^1, y^2)\cdots P(y^n|x^n, y^{n+1})\cdots P(y^L|x^L, y^L). \quad (9)$$

윗 식의 각 확률들은 다음과 같다

$$P(y^n|x^n, y^{n+1}) = \begin{cases} P(x^n|y^n)P(y^n|y^{n+1})P(y^{n+1})/P(x^n, y^{n+1}), & n \in [0, 1, \dots, L-1] \\ P(x^n|y^n)P(y^n)/P(x^n), & n=L \end{cases} \quad (10)$$

이미지 Y 를 MRF로 가정하였기 때문에 윗 식에서의 각 조건부 확률은 다음과 같은 Gibbs 분포를 가진다.

$$\begin{cases} P(x^n|y^n) = \frac{1}{C_1} \exp(-\sum_{i,j} (x_{i,j}^n - y_{i,j}^n)^2), \\ P(y^n) = \frac{1}{C_2} \exp(-\alpha \sum_{(k,l) \in N_{i,j}} (y_{i,j}^n - y_{k,l}^n)^2), \\ P(y^n|y^{n+1}) = \frac{1}{C_3} \exp(-\beta \sum_{i,j} (y_{i,j}^n - y_{i,j}^{n+1})^2), \\ P(y^{n+1}) = \text{constant}. \end{cases} \quad (11)$$

식(9)을 최대화하기 위해 웨트식의 지수함수를 고려하여 최소화하고자 하는 에너지식을 구하면 다음과 같다.

$$V(y_{i,j}^n) = \begin{cases} \sum_{i,j} ((y_{i,j}^n - x_{i,j}^n)^2 + \alpha \sum_{(k,l) \in N_{i,j}} (y_{i,j}^n - y_{k,l}^n)^2 + \beta (y_{i,j}^n - y_{P,i}^{n+1})^2), & n \in [0, 1, \dots, L-1] \\ \sum_{i,j} ((y_{i,j}^n - x_{i,j}^n)^2 + \alpha \sum_{(k,l) \in N_{i,j}} (y_{i,j}^n - y_{k,l}^n)^2), & n = L \end{cases} \quad (12)$$

5. 핸들 제어 시스템

그림 4는 핸들 제어 시스템의 구조를 나타낸다. 비전 시스템(vision system)으로부터 얻은 자동차의 방향 벡터 Y_n 과 레퍼런스 값 X_n 의 차, 즉 에러 값 e_n 이 신경망의 입력으로 들어간다. 신경망은 그림 5와 같이 여러의 과거 값이 같이 MLP의 입력으로 사용되는 Time Delay Neural Net(TDNN)의 구조를 가진다. 이와 같이 과거 에러값을 이용함으로써 예측 시스템의 성격을 가진다.

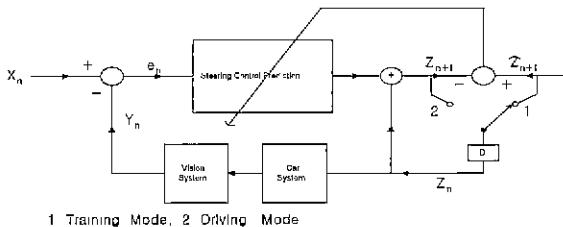


그림 4 핸들 제어 시스템 구조



그림 5. 핸들 제어 시스템에서 신경망 구조

5.1 학습 모드

자율 주행 차량의 핸들 컨트롤 시스템이 작동하기 위해서는 신경망의 초기 학습이 이뤄져야 한다. 이를 위해 초기 출발부터 일정 거리를 운전사가 직접 핸들을 조작해 주어야 한다. 그때 얻어지는 핸들의 각도 값 Z_{n+1} 이 신경망의 결과(핸들 각도의 증분)에 Z_n 을 더한 현재의 핸들 각도의 절대적 값인 Z_{n+1} 의 레퍼런스 값이 되어 그것과의 에러값을 이용해 신경망을 학습해 나간다.

5.2 주행 모드

일정 거리의 학습이 끝나게 되면 스위치가 주행 모드로 바뀌면서 운전사로부터 넘아오는 Z_{n+1} 이 없게 된다. 이때부터는 신경망의 출력값이 자동차 시스템의 핸들 컨트롤을 위한 값으로 사용된다.

6. 실험 및 고찰

차량의 출발점 정지 상태에서 얻어지는 이상에 대해 초기 신경망 학습이 이루어 진다. 그림 6은 $\eta = 0.73$, $\alpha = 0.61$ 에 대해 입력 그림 7-1을 800번의 반복 학습을 시켜 얻은 예리 곡선이다. 그림 7-2는 초기 학습을 통해 얻어진 MLP의 결과 이미지가 되며, 그림 7-3은 펴라미드 알고리즘을 통해 최종 이진화 된 이미지가 된다. 그림 7-4는 그림 7-3을 바탕으로 도로의 경계선 및 차량의 방향 백터를 구한 영상이다.

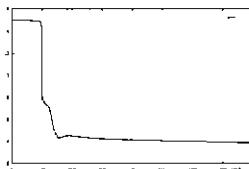


그림 6 초기 학습 곡선



그림 7-1



그림 7-2



그림 7-3



그림 7-4

7. 결론

무인 주행 시스템을 위해 본 논문에서 접근한 방법은 비전 시스템을 바탕으로 한 것과 이미지 처리에 있어서 도로의 국부적인 요소가 아닌 전체 영역을 다루었다는 점이 특징적이다. 그리고 신경망 학습을 주행 중 함으로 해서 도로 변화에 적응하는 시스템을 만들었다. 현재 초당 2.5프레임의 처리 속도를 보이고 있지만, 알고리즘의 개선을 통해서 속도 향상을 위해 지속적으로 연구하고 있다.

참고 문헌

- [1] S. Geman and D. Geman, "Stochastic relaxation, Gibbs distributions, and Bayesian restoration of images", IEEE Trans on PAMI, vol. 6, pp. 721-741, 1984.
- [2] S. Haykin, "Neural Networks", Prentice Hall, 1994
- [3] C. E Thorpe, "Vision and Navigation-The Carnegie Mellon Navlab", Kluwer Academic Publishers, 1990.
- [4] H. Jeong, J. G. Kim and M. S. Chae, "Multilayer Stereo Imag Matching Based upon Phase-Magnitude and Mean Field Approximation", JEEIS, vol 2, No5, 1997