

무인주행차량을 위한 비포장 도로추적

정 홍, 구본석

포항공과대학교 전자전기공학과

hjeong@postech.ac.kr, bskoo@postech.ac.kr

Adaptive and Recursive Tracking of Unpaved Roads

Hong Jeong, Koo Bon Seok
EE Dept., POSTECH

요약

무인 주행 차량에 있어서, 포장 또는 비포장 도로의 시각적 추적은 매우 중요한 문제 중의 하나이다. 따라서, 비디오 이미지로부터 비포장 도로를 추적할 수 있는 신속한 비전 알고리즘의 개발이 필요하다. 이 논문에서는 칼만 필터와 EM(Expectation Maximization) 이론을 이용해 도로를 예측하고 시스템 파라미터를 갱신하는 방법을 제시한다. 시스템 파라미터, 도로 state, 도로 경계선, 그리고 모든 과거 데이터들을 각각 EM 파라미터, hidden data, incomplete data와 complete data로 정의함으로써 도로 state를 예측하고 시스템 파라미터를 추정할 수 있는 시간 회귀적 수식을 유도해낼 수 있다. 이러한 방법을 이용하여 도로 state는 칼만 필터에 의해 매 프레임마다 예측되며, 시스템 파라미터들은 주기적으로 갱신되는 것이다. 결과적으로 이 방법은 주변환경과 날씨에 많은 영향을 받는 도로의 모양과 특징을 잘 찾아낼 수 있다. 또한 도로의 다음 state를 예측할 수 있는 점을 이용하면 계산량을 줄일 수 있으므로 실시간 구현에 용이하다. 이와 같은 방법으로 우리는 0.1sec/frame 처리속도를 보장하는 도로추적 시스템을 구현하였다.

1. 서론

무인 주행 시스템에서 카메라를 통해 들어오는 이미지로부터 주행도로를 인식하고 차량 속도를 측정하는 일은 매우 중요하다. 도로 경계선주위의 정보를 얻기 위해 칼만 필터를 사용한 방법[1][2]이 제시된 적이 있다. 이 논문들에서는 모델링에 기초한 도로 인식을 사용하였으며, 차량 다이내믹스를 고려하였다. 따라서, 날씨 변화에 따른 나쁜 기후 조건에서도 비교적 좋은 결과를 보였다. 그러나, 칼만 필터에서 사용되는 파라미터들에 대한 갱신 기법에 대해서는 소개되지 않았다. 이 논문에서는 회귀적 필터링을 이용한 도로 추적과 EM (Expectation-Maximization) 기법을 이용한 파라미터 적용에 기초한 주행 도로 인식 방법을 소개하고자 한다. 이와 같은 방법으로 도로는 시간 영역에서 회귀적으로 추적되며, 파라미터들은 일정한 이미지 프레임마다 반복적으로 결정되게 된다.

2. 도로 다이내믹스의 표현

이 장에서는 도로 추적을 위한 모델링과 전체적인 도로 추적 시스템에 대해 설명한다.

2.1 도로의 형태 표현

먼저 도로의 모양을 적절한 파라미터들로 표현하며 그것들을 상태 변수(state variable)로 표현하는 것이 필요하다. 도로의 모양은 원근감을 고려하여 일차 사다리꼴로 표현하는 것이 합당하다고 할 수 있다. (사다리꼴의 차수는 그것의 개수를 말한다) 그림 1은 이 모델로 표현된 도로 모양에서 state가 정의된 것을 보여준다.




그림 1: state의 정의

이 그림에서 $x_H(k)$, $x_L(k)$, $w_H(k)$ 와 $w_L(k)$ 들은 도로의 영역을 결정하는 state가 된다. $x_L(k)$ 과 $x_H(k)$ 은

오른쪽 도로 경계선을 결정하며, $w_L(k)$ 과 $w_H(k)$ 은 도로의 위쪽과 아래쪽 폭을 결정하게 된다. 따라서 도로의 state를 나타내는 벡터 $x(k)$ 는 다음 네 개 state의 집합이 된다.

$$x^1(k) = [x_L(k), \dot{x}_L(k)]^T,$$

$$x^2(k) = [x_H(k), \dot{x}_H(k)]^T,$$

$$x^3(k) = [w_L(k), \dot{w}_L(k)]^T,$$

$$x^4(k) = [w_H(k), \dot{w}_H(k)]^T.$$

여기서 우리는 이 네 종류의 state들이 서로 독립적이라고 가정한다. 따라서, 이후 모든 식의 유도는 한 종류의 state에 대해서만 이뤄질 것이다. 즉 $x(k)$ 는 $x^i(k)$, $i \in [1, 4]$ 를 나타내게 된다.

실제 측정값을 $y(k)$ 라 할 때 state와 관측값 사이의 관계를 선형 다이내믹 방정식으로 표현하면 다음과 같다.

$$\begin{aligned} x(k) &= Fx(k-1) + w, \\ y(k) &= Hx + v. \end{aligned} \quad (1)$$

이 식에서 F 는 상태전이 행렬(state transition matrix)가 되며 H 는 측정 행렬(measurement matrix)가 된다. w 와 v 는 각각 $N(0, Q)$ and $N(0, R)$ 의 분포를 따르는 상호 독립적인 가우시안 노이즈를 나타낸다. 측정 행렬 H 의 의미는 state 공간상의 변수들을 관측 공간상으로 옮겨주는 변환에 해당한다.

위 선형 다이내믹 방정식을 이루는 파라미터들을 다음과 수식 (2)와 같이 정의 한다. 여기서 네 개의 파라미터들 $(\alpha, q_{11}, q_{22}, r)$ 이 시스템의 특성을 결정하게 된다.

$$\begin{aligned} F &= \begin{pmatrix} 1 & \alpha \\ 0 & 1 \end{pmatrix}, & H &= (1, 0), \\ Q &= \begin{pmatrix} q_{11} & 0 \\ 0 & q_{22} \end{pmatrix}, & R &= r. \end{aligned} \quad (2)$$

2.2 가변 적용적 세그멘테이션과 예측 시스템의 구조
상태 방정식(state equation)은 도로 경계선을 나타내는 관측치 y 를 필요로 한다. 이것은 예측부분에 앞서서 세그멘테이션의 작업과정이 첨가되어야 하는 것을 의미한다. 이 세그멘테이션 부분의 목적은 입력으로 들어오는 칼라 이미지로부터 도로 경계영역을 추출해내는 것이다. 이를 위해 세그멘테이션 부분에서는 들어오는 칼라 이미지 $f(k)$ 를 이진화된 이미지 $w(k)$ 로 바꾸어 준다. 그 구조는 그림 2와 같다. 이 구조에서는 경계선을 포함한 국부적인 영역만을 취하여, 각 픽셀이 도로인지 배경인지에 따라 1 또는 0의 값을 가지게 된다. 이렇게 획득된 도로 경계선 부근의 국부적인 영역 데이터로부터 식 (3)과 같이 LMSE를 이용하여 도로 경계선은 최적 라인 $y = ax + b$ 로 모델링된다.

$$(a, b) = \arg \min_{(a, b)} \sum_{(x, y) \in S(k)} w_x \left(\frac{y-b}{a} - x \right)^2. \quad (3)$$

세그멘테이션으로부터 얻어진 데이터는 칼만 필터의 관측치로 사용되어 state를 갱신시킨다. 이렇게




그림 2: 도로 추적 시스템

measurement update를 한 후, time update를 통해 다음 도로의 모양을 예측하게 된다. 결국 이러한 세그멘테이션을 통해 도로 예측에 필요한 지속적인 관측 데이터를 제공하게 된다. 우리는 이 세그멘테이션을 위해 뉴럴 네트워크를 사용하였다.

3. 도로 State의 예측

지금까지 도로의 다이내믹스를 state 방정식으로, 그리고 도로의 모양을 state 벡터로 표현하였다. 이 장에서는 칼만 필터를 이용한 예측 문제를 다루기로 한다.

3.1 State 예측

앞장에서의 state 정의의 불확실성 때문에 도로 추적(road tracking)문제는 일반적인 state 예측 문제로 볼 수 있다. 예측 필터는 관측치 $y(k)$ 를 얻은 후 measurement update $x(k|k)$ 를 계산하여 다시 timeupdate $x(k+1|k)$ 를 얻는 과정이다. 이러한 개념은 다음과 같이 칼만 필터를 이용하여 구현이 가능하다.

$$\begin{aligned} x(k|k) &= x(k|k-1) + G(k)\{y(k) - Hx(k|k-1)\}, \\ x(k+1|k) &= Fx(k|k). \end{aligned} \quad (4)$$

여기서, $G(k)$ 는 칼만 이득으로서 다음과 같다.

$$G(k) = P(k|k-1)H^T S^{-1}(k). \quad (5)$$

위 칼만 이득식에서 $P(k|k-1)$ 와 $S(k)$ 는 각각 time-updated predicted state-error covariance 행렬과 measurement prediction covariance 행렬을 나타내며 다음과 같다.

$$P(k|k-1) = FP(k-1|k-1)F^T + Q. \quad (6)$$

여기서 $P(k-1|k-1)$ 는 measurement-updated predicted state-error covariance 행렬이 된다.

$$P(k-1|k-1) = [I - G(k-1)H]P(k-1|k-2). \quad (7)$$

또한 the measurement prediction covariance 행렬 $S(k)$ 는 다음과 같다.

$$S(k) = HP(k|k-1)H^T + R. \quad (8)$$

4. 시스템 파라미터의 예측

앞에서 정의된 바와 같이 시스템 파라미터들은 상태 전이 행렬(state transition matrix) F 와 covariance

행렬들 Q 와 R 이다. 이러한 파라미터들은 시간에 따라 변화하므로 가능하면 자주 갱신시켜주는 것이 바람직하다. 이 장에서는 이 파라미터들을 자동으로 갱신시키는 방법에 대해서 알아본다. 칼만 필터에 의한 예측은 시간의 진행에 따라 계속적으로 이뤄져가지만 특정 시간 t 에서는 파라미터 갱신을 위해 추가적인 계산이 필요하게 된다. 이 파라미터 갱신은 EM(Expectation Maximization)기법[3]에 의해 이뤄진다. 그림 3은 칼만 필터와 EM 루프사이의 관계를 보여준다.




그림 3 칼만 필터와 EM 루프로 구성된 시스템

ϕ 를 필요한 모든 파라미터를 포함하는 프로세스라 정의하면, $\phi = (F, Q, R)$ 가 된다. 따라서 파라미터 ϕ 는 새로 갱신되기 전까지는 고정된 상수값이 된다. 관측치 $y(t)$ 는 complete data $z(t) = \{y(t), x(t)\}$ 에서 missing data인 $x(t)$ 를 제외한 부분적인 정보로서 정의된다. 이 관계는 다음과 같이 표현된다:

$$\phi \rightarrow Z' \rightarrow y(t) \quad (9)$$

여기서, Z' 는 시간 t 이전에 파라미터가 갱신된 이후부터 시간 t 까지의 모든 state와 측정치를 포함하는 값이 된다. 따라서, 목적은 새로운 데이터 Z' 를 이용하여 시스템 파라미터 ϕ 를 추정하는 것이다.

먼저 posterior $P(\phi | z')$ 를 생각하자. 이것은 Baye's theory에 의해 다음과 같이 분리될 수 있다.

$$P(\phi | z') = P(z(t) | \phi, z(t-1))P(\phi | \phi') / P(z(t) | z^{t-1}). \quad (10)$$

사전 정보(prior knowledge)에 해당하는 $P(\phi | z^{t-1})$ 은 갱신전의 파라미터 ϕ' 를 초기값으로 가진다. 따라서 $P(\phi | \phi')$ 으로 표현될 수 있다. 이제 식 (10)에 EM[3]을 적용하자. $Q(\cdot)$ 함수로써 조건부 확률인 $P(z(t) | \phi, z(t-1))$ 의 평균값(E-Step)이 이용된다.

E-step :

$$Q(\phi | \phi^{(s)}) = E[\log P(z(t) | \phi, z(t-1)) | \phi^{(s)}, y(t)] \quad (11)$$

M-step:

$$\phi^{(s+1)} = \arg \max_{\phi} \{Q(\phi | \phi^{(s)}) + \log P(\phi | \phi')\} \quad (12)$$

그런데, 사전 정보(prior knowledge)인 $P(\phi | \phi')$ 은 ϕ

에 대해 또다른 Markovian관계를 필요로 한다. 여기서 문제의 단순화를 위해 사전 정보의 확률이 uniform 분포를 가진다고 가정한다. 그렇게 되면 M-Step에서 이 분포의 고려는 빠지게 된다.

5. 실험 결과

실험은 비디오 카메라로 녹화된 데이터를 바탕으로 실 내에서 이루어졌다. 전체 시스템은 CCD 카메라와 overlay보드가 장착된 Pentium-III PC로 이루어진다.



그림 4.1 입력 영상



그림 4.2 도로 추적 상태




그림 5 칼만 필터에 의한 예측 결과

그림 4는 CCD 카메라로부터 이미지를 받아 다음 도로 상태를 예측하여 도로 경계선을 계속적으로 찾아가고 있는 상태를 나타낸다. 그림 5에서는 임의의 관측치를 가지고 칼만 필터를 이용하여 다음 도로 state를 추적 해가는 과정을 그래프로 보여주고 있다.

6. 결론

이 논문에서 우리는 회귀적 적응 필터를 이용한 비포장 도로 추적기법을 제시하였다. 그 실제적 구현을 위해 도로 경계선 예측을 위한 칼만 필터와 주기적인 파라미터 갱신을 위한 EM 알고리즘이 사용되었다. 실제 실험을 통해 0.1sec/frame이상의 처리속도를 가지는 시스템을 구현할 수 있었다.

7. 참고 문헌

- (1) Jin-Chuan Hsu, Wen-Liang Chen, Ruey-Hong Lin, Edge Chu Yeh, "Estimation of previewed road curvatures and vehicular motion by a vision-based data fusion scheme," *Machine Vision and Applications Vol.9* pp179-192, 1997
- (2) Arata Takahashi and Yoshiki Nimomiya, "Model-based Lane Recognition," *Proc. Intelligent Vehicle '96*, pp201-206, 1996.
- (3) A.P.Dempster, N.M.Laird and D.B. Rubin, "Maximum Likelihood from Incomplete Data via the EM Algorithm," *J.R.Statist. Soc. B vol.39 No.1*, pp1-38, 1976