

정확히 재가중되는 온라인 전체 에러율 최소화 기반의 객체 추적*

장세인

싱가폴국립대학 통계학과
(sjiang@nus.edu.sg)

박충식

U1대학교 스마트IT학과
(leciel@yd.ac.kr)

영상 기반의 보안 시스템의 증가함에 따라 각 용도마다 다른 다양한 객체들에 대한 처리들이 중요해지고 있다. 객체 추적은 객체 인식, 검출과 같은 작업들과 함께 필수적인 작업으로 다뤄진다. 이 객체 추적을 달성하기 위해서 다양한 머신러닝이 적용될 수 있다. 성공적인 분류기로써 전체 에러율 최소화(total-error-rate minimization) 기반의 방법론이 사용될 수 있다. 이 전체 에러율 최소화 기반의 방법론은 오프라인 학습을 기반으로 하고 있다. 객체 추적은 실시간으로 처리하며 갱신해야하는 것이 필수적이므로 온라인 학습(online learning)을 기반으로 하는 것이 적합하다. 온라인 전체 에러율 최소화 방법론이 개발되었지만 점근적으로 재가중되는(approximately reweighted) 작업이 포함되어 에러를 누적시킬 수 있다는 단점이 있다. 본 논문에서는 정확하게 재가중되는(exactly reweighted) 방법론을 제안하면서 온라인 전체 에러율 최소화가 달성되었다. 이 제안된 온라인 학습 방법론을 객체 추적에 적용하여 총 8개의 데이터베이스에서 다른 추적 방법론들 보다 좋은 성능이 달성되었다.

주제어 : 객체 추적, 온라인 학습, 전체 에러율 최소화, 정확한 재가중

논문접수일 : 2019년 11월 12일 논문수정일 : 2019년 12월 9일 게재확정일 : 2019년 12월 16일
원고유형 : 일반논문 교신저자 : 박충식

1. 서론

객체 추적(object tracking)은 보안 관련 시스템에 필수적인 작업으로써 적용되고 있다. 예를들어 얼굴 인식(face recognition), 걸음걸이 인식(gait recognition), 군중 추적(people tracking) 등 다양한 분야에 적용될 수 있다(Hu et al., 2004). 객체 추적을 달성하기 위해 주로 쓰이는 방법은 생성적 모델(generative model)과 분류적 모델(Discriminative model)로 나누어질 수 있다(Yilmaz et al., 2006).

생성적 모델은 추적하고자 하는 객체에 초점을 맞추어 모델을 생성하는 것이다. 이 생성적 모델은 하나의 객체에만 초점을 맞추어 모델링하기 때문에 추적하는 대상 주위에 유사한 객체가 나타나면 쉽게 추적에 실패하는 경향이 있다. 이에 대한 부분을 극복하기 위해 분류적 모델을 사용할 수 있다. 이 분류적 모델은 추적하고자 하는 객체와 그 주위의 배경을 이용하여 이분법적인 분류 문제(binary classification problem)로 다뤄질 수 있다. 이 분류 문제는 객체 추적 뿐만 아니라

* 이 논문은 2017년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2017S1A6A3A01078538).

영상 분류, 주식 예측 등 다양한 분야에서도 다뤄지고 있다(Batkhuu et al., 2018, Lee et al., 2018, Kim et al., 2018).

생성적 모델과 분류적 모델을 구현하기 위해 다양한 머신러닝 방법론이 적용될 수 있지만 객체 추적은 실시간으로 인식 및 모델을 갱신하는 작업이 필요하므로 온라인 학습(online learning) 방법론이 필수적이다. 온라인 생성적 모델에는 Incremental Principal Component Analysis (Ross et al., 2008)와 같은 방법론이 사용 가능하다. 온라인 분류적 모델에는 Perceptron(PE) 방법(Rosenblatt, 1958), Passive-Aggressive(PA) 방법(Crammer et al., 2006), Confidence Weighted(CW) 방법(Dredze et al., 2008), Adaptive Regularization Of Weight vectors(AROW) 방법(Crammer et al., 2009) 같은 방법론이 사용 가능하다. 위 소개된 PE, PA, CW, AROW와 같은 학습 방법은 확률론적(stochastic) 방법론이 들어가 있다. 이 확률론적 방법을 사용하면 최적화(optimization)을 진행할 때에 local minima를 계속 찾아야만 하는 단점이 있다. 이와 반대로 최소자승법(Least-Squares, LS) 최소화나 전체에러율(Total-Error-Rate, TER) 최소화(Toh, 2008) 같은 결정론적(deterministic) 방법론은 global minimum을 찾기 때문에 local minima에 대한 결점을 극복할 수 있다.

이 TER 최소화 방법론은 가중된 최소자승법(Weighted Least-Squares, WLS) 기반으로 개발되었다. 이에 해당하는 온라인 학습 방법은 Approximately Reweighted Total-Error-Rate(ARTER) 최소화 방법으로 (Kim et al., 2013) 제안되었지만 점근적으로 재가중되는 기법이 적용되었다. 이 점근적 재가중 기법은 머신러닝 방법론에서 해답찾기에서 에러를 누적시킬 수 있다.

본 논문에서는 점근적 재가중 기법이 가지는

단점을 극복하는 정확히 재가중하는 TER 최소화(exactly reweighted TER minimization, ERTER) 방법을 제안할 것이다. 또한, 이 제안된 ERTER를 객체 추적에 적용하여 결정론적 방법이라는 장점을 가지는 객체추적 방법론을 제안할 것이다. 본 논문의 기여를 아래와 같이 정리하였다:

- 1) 정확히 재가중하는 온라인 머신 러닝 분류 학습 방법론
- 2) 정확히 재가중하는 학습 방법을 기반으로 하는 객체 추적 방법론

본 논문은 다음과 같이 구성된다: 2장에서는 배치(batch) 기반의 최소화 방법론에 대해서 다룰 것이며, 3장에서는 온라인(online) 기반의 최소화 방법론을 다룰 것이다. 4장에서는 ERTER 방법론을 제안할 것이며, 5장에서는 ERTER 기반의 추적 방법론을 제안할 것이다. 6장에서는 실험 결과를 설명할 것이며 7장에서는 결론으로 본 논문을 마무리 지을 것이다.

2. 배치(batch) 기반의 최소화 방법론

2.1 최소 자승 최소화

(Least-Squares Minimization)

최소 자승(Least-Squares, LS) 최소화 방법론은 회귀문제(regression problem)에서 자주 사용되는 방법론이다. 이 LS 방법론은 자승 에러(squared error)의 합을 기반으로 다음과 같은 LS 솔루션을 구할 수 있다:

$$\theta = (\mathbf{X}^T \mathbf{X} + b\mathbf{I})^{-1} \mathbf{X}^T \mathbf{y}, \quad (1)$$

\mathbf{X} 는 데이터 행렬(data matrix)이고, $\mathbf{y} \in \{-1, 1\}$ 는 타겟 레이블(target label)이다. b 는 솔루션의 불안정한 문제(ill-posed problem)을 해결하기 위한 정규화(regularization) 값이다. \mathbf{I} 는 $\mathbf{X}^T \mathbf{X}$ 와 같은 차원을 갖는 단위 행렬(identity matrix)이다.

2.2 전체 에러율 최소화(Total-Error-Rate Minimization)

위 LS 방법론은 분류(classification) 문제에도 사용될 수 있지만 해당 솔루션의 내재된 목적 함수(objective function)이 회귀 문제에 특화 되어있다. 전체 에러율(Total-Error-Rate, TER) 최소화 방법에서 전체 에러율은 긍정적과 부정적 클래스(positive and negative classes)로 잘못 분류된 False Negative Rate(FNR)과 False Positive Rate(FPR)의 비율의 합으로 정의 된다 (Toh, 2008): $TER = FNR + FPR$. 이 TER이 포함된 목적 함수를 이용하여 다음과 같이 솔루션을 구할 수 있다:

$$\boldsymbol{\theta} = (\mathbf{X}^T \mathbf{W} \mathbf{X} + b \mathbf{I})^{-1} \mathbf{X}^T \mathbf{W} \mathbf{y}, \quad (2)$$

$\mathbf{W} = \text{diag} \left(\left[\frac{1}{n^-}, \dots, \frac{1}{n^-}, \frac{1}{n^+}, \dots, \frac{1}{n^+} \right] \right)$ 는 각 클래스에 해당하는 가중치 행렬이다. n^- 과 n^+ 는 부정적 클래스(negative class)와 긍정적 클래스(positive class)의 샘플 갯수를 나타낸다.

3. 온라인(online) 기반의 최소화 방법론

3.1 재귀 최소 자승법 (Recursive Least-Squares)

재귀 최소 자승법(Recursive Least-Squares, RLS)은 LS의 목적 함수와 같지만 순차적(sequential)으로 들어오는 데이터를 온라인으로 학습하기 위한 방법론이다. 이 RLS 방법론은 다음과 같이 구해지며 갱신된다:

$$\boldsymbol{\theta}_t = \boldsymbol{\theta}_{t-1} + \mathbf{R}_t^{-1} \mathbf{x}_t \left(y_t - (\mathbf{x}_t \cdot \boldsymbol{\theta}_{t-1}) \right), \quad (3)$$

$\mathbf{R}_t^{-1} = \mathbf{R}_{t-1}^{-1} - \mathbf{R}_{t-1}^{-1} \mathbf{x}_t \left(\mathbf{I} + \mathbf{x}_t^T \mathbf{R}_{t-1}^{-1} \mathbf{x}_t \right)^{-1} \mathbf{x}_t^T \mathbf{R}_{t-1}^{-1}$ 는 2차 미분을 나타내는 헤시안(Hessian) 행렬이며 이 또한 온라인으로 학습된다.

3.2 점근적으로 재가중되는(approximately reweighted) 온라인 전체 에러율 최소화

전체 에러율 최소화를 순차적 데이터에 적용을 위해서는 온라인 방법론이 필수적이다. 이 TER을 온라인으로 최소화하는 방법이면서 점근적으로 재가중되는 방법론 (approximately reweighted TER, ARTER)은 다음과 같이 제안되었다 (Kim et al., 2013):

$$\boldsymbol{\theta}_t = \boldsymbol{\theta}_{t-1} + w_t \mathbf{R}_t^{-1} \mathbf{x}_t \left(y_t - (\mathbf{x}_t \cdot \boldsymbol{\theta}_{t-1}) \right), \quad (4)$$

$\mathbf{R}_t^{-1} = u_t^{-1} \mathbf{R}_{t-1}^{-1} - u_t^{-1} \mathbf{R}_{t-1}^{-1} \mathbf{x}_t \left(w_t^{-1} + \mathbf{x}_t^T u_t^{-1} \mathbf{R}_{t-1}^{-1} \mathbf{x}_t \right)^{-1} \mathbf{x}_t^T u_t^{-1} \mathbf{R}_{t-1}^{-1}$ 는 온라인으로 학습되는 헤시안 행렬이며, $u_t = \frac{1}{2} \left(\frac{w_{t-1}^-}{w_t^-} + \frac{w_{t-1}^+}{w_t^+} \right)$ 는 점근적으로 얻어진 재가중 값이다.

4. 정확히 재가중되는(exactly reweighted) 온라인 전체 에러율 최소화

4.1 개요

우리는 여기서 정확히 재가중되는 온라인 전체 에러율 최소화 방법론(exactly reweighted recursive TER minimization, ERTER)을 제안할 것이다. 이 ERTER은 점근적으로 재가중되는 ARTER의 단점을 극복하면서 온라인 학습 방법론을 달성하는데 초점이 맞추어져있다. 먼저 배치기반의 TER 방법론을 시간 인덱스와 함께 다음과 같이 재유도될 수 있다:

$$\theta_t = \left(\sum_{i=1}^{\bar{n}_t} \frac{1}{n_i^-} \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^T + \sum_{j=1}^{\bar{n}_t^+} \frac{1}{n_j^+} \mathbf{x}_j^+ \mathbf{x}_j^{+T} + b\mathbf{I} \right)^{-1} \times \left(\sum_{i=1}^{\bar{n}_t} \frac{1}{n_i^-} \bar{\mathbf{x}}_i \bar{y}_i + \sum_{j=1}^{\bar{n}_t^+} \frac{1}{n_j^+} \mathbf{x}_j^+ y_j \right), \quad (5)$$

n_i^- 과 n_i^+ 는 부정적 클래스(negative class)와 긍정적 클래스(positive class)의 샘플 갯수를 나타낸다. 위에 재유도된 식을 간단하게 바꾸면 다음과 같이 나타낼 수 있다:

$$\begin{aligned} \theta_t &= \left(\underbrace{\sum_{i=1}^{\bar{n}_t} \frac{(1-\lambda_t)}{n_i^-} \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^T}_{\mathbf{S}_t^-} + \underbrace{\sum_{j=1}^{\bar{n}_t^+} \frac{\lambda_t}{n_j^+} \mathbf{x}_j^+ \mathbf{x}_j^{+T}}_{\mathbf{S}_t^+} + b\mathbf{I} \right)^{-1} \times \left(\underbrace{\sum_{i=1}^{\bar{n}_t} \frac{(1-\lambda_t)}{n_i^-} \bar{\mathbf{x}}_i \bar{y}_i}_{\bar{\mathbf{z}}_t^-} + \underbrace{\sum_{j=1}^{\bar{n}_t^+} \frac{\lambda_t}{n_j^+} \mathbf{x}_j^+ y_j}_{\mathbf{z}_t^+} \right) \\ &= (\mathbf{S}_t^- + \mathbf{S}_t^+ + b\mathbf{I})^{-1} (\bar{\mathbf{z}}_t^- + \mathbf{z}_t^+) \\ &= (\mathbf{S}_t + b\mathbf{I})^{-1} \mathbf{z}_t \\ &= \mathbf{R}_t^{-1} \mathbf{z}_t, \end{aligned} \quad (6)$$

이 식에서 $\lambda_t = \begin{cases} 0 & \text{if } \bar{\mathbf{x}}_t^- \\ 1 & \text{if } \mathbf{x}_t^+ \end{cases}$ 는 각 클래스를 가리키는 값이다. 그 이후 업데이트될 ERTER의 해

시간 역행렬 \mathbf{R}_t^{-1} 과 타겟 벡터 \mathbf{z}_t 의 행렬 곱을 통해 최종 솔루션을 구한다.

4.2 재귀되는 역행렬(recursive inverse matrix), \mathbf{R}_t^{-1}

재귀되는 역행렬 \mathbf{R}_t^{-1} 에는 $b\mathbf{I}$, \mathbf{S}_t^- , \mathbf{S}_t^+ 의 세개의 합으로 구성되어있다. 여기서 $b\mathbf{I}$ 는 재귀되는 부분이 아니므로 제외할 수 있다. \mathbf{S}_t^- 와 \mathbf{S}_t^+ 를 재귀적으로 계산하기 위해 다음과 같이 표현될 수 있다:

$$\begin{aligned} \mathbf{S}_t^- &= \sum_{i=1}^{\bar{n}_t} \frac{(1-\lambda_t)}{n_i^-} \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^T \\ &= \frac{(1-\lambda_t)}{n_t^-} \bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} + \frac{n_{t-1}^-}{n_t^-} \sum_{i=1}^{\bar{n}_{t-1}} \frac{(1-\lambda_{t-1})}{n_{i-1}^-} \bar{\mathbf{x}}_i \bar{\mathbf{x}}_i^T \\ &= \frac{(1-\lambda_t)}{n_t^-} \bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} + \frac{n_{t-1}^-}{n_t^-} \mathbf{S}_{t-1}^- \\ &= \frac{(1-\lambda_t)}{n_t^-} \bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} + \left(1 - \frac{(1-\lambda_{t-1})}{n_{t-1}^-} \right) \mathbf{S}_{t-1}^- \\ &= \frac{(1-\lambda_t)}{n_t^-} \bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} + \mathbf{S}_{t-1}^- - \frac{(1-\lambda_{t-1})}{n_{t-1}^-} \mathbf{S}_{t-1}^- \\ &= \mathbf{S}_{t-1}^- + \frac{(1-\lambda_t)}{n_t^-} \bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} - \frac{(1-\lambda_{t-1})}{n_{t-1}^-} \mathbf{S}_{t-1}^- \\ &= \mathbf{S}_{t-1}^- + \underbrace{\frac{(1-\lambda_t)}{n_t^-} (\bar{\mathbf{x}}_t^- \bar{\mathbf{x}}_t^{-T} - \mathbf{S}_{t-1}^-)}_{\mathbf{E}_t^-}, \end{aligned} \quad (7)$$

$$\begin{aligned} \mathbf{S}_t^+ &= \sum_{i=1}^{\bar{n}_t^+} \frac{\lambda_t}{n_i^+} \mathbf{x}_i^+ \mathbf{x}_i^{+T} \\ &= \mathbf{S}_{t-1}^+ + \underbrace{\frac{\lambda_t}{n_t^+} (\mathbf{x}_t^+ \mathbf{x}_t^{+T} - \mathbf{S}_{t-1}^+)}_{\mathbf{E}_t^+}. \end{aligned} \quad (8)$$

위 재귀적으로 나타낸 \mathbf{S}_t^- 와 \mathbf{S}_t^+ 를 결합하면 다음과 같다:

$$\begin{aligned} \mathbf{R}_t &= \underbrace{\mathbf{S}_{t-1}^- + \mathbf{S}_{t-1}^+ + \mathbf{b}\mathbf{I}}_{\mathbf{R}_{t-1}} + \underbrace{\mathbf{E}_t^- + \mathbf{E}_t^+}_{\mathbf{E}_t} \\ &= \mathbf{R}_{t-1} + \mathbf{E}_t. \end{aligned} \quad (9)$$

$$\begin{aligned} \mathbf{E}_t &= \mathbf{E}_t^- + \mathbf{E}_t^+ \\ &= \frac{(1-\lambda_t)}{n_t^-} (\mathbf{x}_t \mathbf{x}_t^T - \mathbf{S}_{t-1}^-) + \frac{\lambda_t}{n_t^+} (\mathbf{x}_t \mathbf{x}_t^T - \mathbf{S}_{t-1}^+) \\ &= \frac{(1-\lambda_t)}{n_t^-} \mathbf{x}_t \mathbf{x}_t^T + \frac{\lambda_t}{n_t^+} \mathbf{x}_t \mathbf{x}_t^T - \frac{(1-\lambda_t)}{n_t^-} \mathbf{S}_{t-1}^- - \frac{\lambda_t}{n_t^+} \mathbf{S}_{t-1}^+ \\ &= \left(\frac{(1-\lambda_t)}{n_t^-} + \frac{\lambda_t}{n_t^+} \right) \mathbf{x}_t \mathbf{x}_t^T - \left(\frac{(1-\lambda_t)}{n_t^-} \mathbf{S}_{t-1}^- + \frac{\lambda_t}{n_t^+} \mathbf{S}_{t-1}^+ \right) \\ &= \beta_t \mathbf{x}_t \mathbf{x}_t^T - \left(\frac{(1-\lambda_t)}{n_t^-} \sum_{i=1}^{n_{t-1}^-} \frac{(1-\lambda_i)}{n_{i-1}^-} \mathbf{x}_i \mathbf{x}_i^T + \frac{\lambda_t}{n_t^+} \sum_{j=1}^{n_{t-1}^+} \frac{\lambda_j}{n_{j-1}^+} \mathbf{x}_j \mathbf{x}_j^T \right) \\ &= \beta_t \mathbf{x}_t \mathbf{x}_t^T - \left(\sum_{i=1}^{n_{t-1}^-} \frac{(1-\lambda_i)(1-\lambda_t)}{n_i^- n_{i-1}^-} \mathbf{x}_i \mathbf{x}_i^T + \sum_{j=1}^{n_{t-1}^+} \frac{\lambda_j \lambda_t}{n_j^+ n_{j-1}^+} \mathbf{x}_j \mathbf{x}_j^T \right) \\ &= \beta_t \mathbf{x}_t \mathbf{x}_t^T - \left(\sum_{k=1}^{t-1} \left(\frac{(1-\lambda_t)(1-\lambda_k)}{n_t^- n_{k-1}^-} + \frac{\lambda_t \lambda_k}{n_t^+ n_{k-1}^+} \right) \mathbf{x}_k \mathbf{x}_k^T \right) \\ &= \beta_t \mathbf{x}_t \mathbf{x}_t^T - \sum_{k=1}^{t-1} \beta_{t,k} \mathbf{x}_k \mathbf{x}_k^T, \end{aligned} \quad (10)$$

$$\beta_t = \left(\frac{(1-\lambda_t)}{n_t^-} + \frac{\lambda_t}{n_t^+} \right) \text{와} \quad \beta_{t,k} = \left(\frac{(1-\lambda_t)(1-\lambda_k)}{n_t^- n_{k-1}^-} + \frac{\lambda_t \lambda_k}{n_t^+ n_{k-1}^+} \right)$$

는 각 클래스 마다 계산되는 부분이 결합되었다. 이로 인해, 공식 (6)에 있는 \mathbf{R}_t 을 위한 재귀되는 행렬이 위 공식 (9)와 같이 얻어졌다. 이 다음은 이것을 위한 역행렬을 구하는 것이다.

공식 (9)와 (10)을 결합하면 다음과 같이 재구성될 수 있다:

$$\begin{aligned} \mathbf{R}_t &= \mathbf{R}_{t-1} + \mathbf{E}_t \\ &= \mathbf{R}_{t-1} + \beta_t \mathbf{x}_t \mathbf{x}_t^T - \sum_{k=1}^{t-1} \beta_{t,k} \mathbf{x}_k \mathbf{x}_k^T \\ &= \mathbf{R}_{t-1} - \underbrace{\sum_{k=1}^{t-1} \beta_{t,k} \mathbf{x}_k \mathbf{x}_k^T}_{\mathbf{Q}_k} + \beta_t \mathbf{x}_t \mathbf{x}_t^T. \end{aligned} \quad (11)$$

이것을 자세하게 풀어내면 다음과 같이 세 부분으로 나누어질 수 있다:

$$\begin{aligned} \mathbf{Q}_0 &= \mathbf{R}_{t-1}, \\ \mathbf{Q}_k &= \mathbf{Q}_{k-1} - \beta_{t,k} \mathbf{x}_k \mathbf{x}_k^T, \quad \forall k=1,2,\dots,t-1 \\ \mathbf{R}_t &= \mathbf{Q}_k + \beta_t \mathbf{x}_t \mathbf{x}_t^T. \end{aligned} \quad (12)$$

이 공식 (12)에서 간단하게 유명한 역행렬의 기본형(matrix inversion lemma)을 사용하면 다음과 같이 역행렬이 얻어질 수 있다:

$$\begin{aligned} \mathbf{Q}_0^{-1} &= \mathbf{R}_{t-1}^{-1}, \\ \mathbf{Q}_k^{-1} &= \mathbf{Q}_{k-1}^{-1} + \alpha_k \frac{\mathbf{Q}_{k-1}^{-1} \mathbf{x}_k \mathbf{x}_k^T \mathbf{Q}_{k-1}^{-1}}{\frac{1}{\beta_{t,k}} - \mathbf{x}_k^T \mathbf{Q}_{k-1}^{-1} \mathbf{x}_k}, \quad \forall k=1,2,\dots,t-1 \\ \mathbf{R}_t^{-1} &= \mathbf{Q}_k^{-1} - \frac{\mathbf{Q}_k^{-1} \mathbf{x}_t \mathbf{x}_t^T \mathbf{Q}_k^{-1}}{\frac{1}{\beta_t} + \mathbf{x}_t^T \mathbf{Q}_k^{-1} \mathbf{x}_t}, \end{aligned} \quad (13)$$

$\alpha_k = 1 - \lambda_t - \lambda_k + 2\lambda_t \lambda_k$ 는 각 클래스를 가리키기 위해 사용된다.

4.3 재귀되는 타겟 벡터

(recursive target vector), \mathbf{z}_t

식 6에서 타겟 벡터인 \mathbf{z}_t 는 \mathbf{z}_t^- 와 \mathbf{z}_t^+ 로 나누어질 수 있다. 이 나뉜 타겟 벡터들을 식 (7)과 (8)과 같이 간단히 얻어질 수 있다.

$$\mathbf{z}_t^- = \mathbf{z}_{t-1}^- + \frac{(1-\lambda_t)}{n_t^-} (\mathbf{x}_t^- y_t^- - \mathbf{z}_{t-1}^-) \quad (14)$$

$$\mathbf{z}_t^+ = \mathbf{z}_{t-1}^+ + \frac{\lambda_t}{n_t^+} (\mathbf{x}_t^+ y_t^+ - \mathbf{z}_{t-1}^+) \quad (15)$$

4.4 제안하는 학습 알고리즘의 개요

본 논문에서 제안하는 온라인 학습 알고리즘은 먼저 수식 (13)을 이용하여 역행렬을 계산하고, 수식 (14), (15)를 이용하여 타겟 벡터를 계산한다. 이후 수식 (6)에 있는 마지막 수식을 이용하면 최종 솔루션을 얻을 수 있다.

5. ERTER 기반의 객체추적 방법론

본 논문에서는 객체추적에 대한 추론 방법으로 파티클 필터(particle filter) 방법론을 사용한다. 이 파티클 필터는 Sequential Monte Carlo(SMC) 방법이라고도 알려져 있다. 이 SMC는 Bayesian 샘플링을 기반으로 다음과 같이 정의될 수 있다 (Ross et al., 2008):

$$p(\mathbf{M}_t | \mathbf{O}_t) \propto p(\mathbf{o}_t | \mathbf{M}_t) \int p(\mathbf{M}_t | \mathbf{M}_{t-1}) p(\mathbf{M}_{t-1} | \mathbf{O}_{t-1}) d\mathbf{M}_{t-1}, \quad (16)$$

여기서 \mathbf{M}_t 은 어파인 모션 값(affine motion parameters)을 가지는 상태변수(state variables)이고 \mathbf{O}_t 는 관측변수(observation variables)이다. 이 SMC는 두개의 모델로 나누어질 수 있다. 하나는 동적 모델(dynamic model), $p(\mathbf{M}_t | \mathbf{M}_{t-1})$ 이고 다른 하나는 관측 모델(observation model), $p(\mathbf{o}_t | \mathbf{M}_t)$ 이다. 본 논문에서는 이 동적 모델을 균일 분포(uniform distribution)로 가정할 것이며 관측 모델은 생성적(generative) 방법과 분류적(discriminative) 방법을 같이 사용할 것이다. 본 논문에서 제안하는 관측 모델은 다음과 같이 나타낼 수 있다 (Jang et al., 2015):

$$p(\mathbf{o}_t | \mathbf{M}_t) = \alpha p_{ERTER}(\mathbf{o}_t | \mathbf{M}_t) + (1 - \alpha) p_{dist}(\mathbf{o}_t | \mathbf{M}_t), \quad (17)$$

상기 4장에서 소개된 ERTER 방법론을 이용하여 분류적 관측 모델은 다음과 같이 얻어질 수 있다:

$$p_{ERTER}(\mathbf{o}_t | \mathbf{M}_t) \approx \frac{\exp(\hat{\mathbf{y}}_t)}{\text{sum}(\exp(\hat{\mathbf{y}}_t))}. \quad (17)$$

또한, 생성적 관측 모델은 다음과 같이 얻어질 수 있다:

$$p_{dist}(\mathbf{o}_t | \mathbf{M}_t) \approx \frac{\exp(\hat{\mathbf{d}}_t)}{\text{sum}(\exp(\hat{\mathbf{d}}_t))}. \quad (18)$$

$\hat{\mathbf{y}}_t$ 는 ERTER 분류기를 통해 얻어진 신뢰도 값(confidence values)이며 $\hat{\mathbf{d}}_t$ 는 유클리디언 거리(Euclidean distance)를 구한 신뢰도 값이다.

6. 실험

6.1 실험 방법

본 논문에서는 추적 방법론에 대한 성능 평가를 위해서 8개의 데이터베이스와 7개의 추적 알고리즘과 비교할 것이다. <Table 1>에 본 논문에서 사용될 8개의 데이터베이스의 속성을 나열하였다 (Ross et al., 2008). 비교할 7개의 추적 알고리즘은 Incremental Visual Tracking(IVT) 방법 (Ross et al., 2008), Online AdaBoost (OAB) 방법 (Grabner et al., 2006), Multiple Instance Learning (MIL) 방법 (Babenko et al., 2011), Tracking-Learning-Detection(TLD) 방법 (Kalal et al., 2010), Structured Output Tracking(STRUCK) 방법 (Hare

et al., 2011), Sparsity-based Collaborative Model (SCM) 방법 (Zhong, et al., 2012), Approximated Recursive TER(ARTER) 방법이 (Jang et al., 2015) 있다. 본 논문에서는 각 기법의 평가 기준으로 추적 분야에서 자주 사용되는 Root Mean Squared Error(RMSE)를 사용하였다.

<Table 1> Database for Object Tracking

Database	Number of Frames
David Indoor	1176
Car 4	405
Car 11	393
Sylvester	1368
Tea Box	218
Surfer	375
Jumping	313
Coupon Book	326

6.2 성능 평가

성능 평가를 위해서 8개의 데이터베이스와 7개의 방법론들을 이용하여 RMSE를 제안하는 방법론(ERTER)과 비교하였다. <Table 2>는 정확도 성능을 나타내며 평균 RMSE를 사용하였고 10번을 시행하였다. 최고 좋은 성능은 **볼드체**로 테이블에 표기되었다. 제안한 ERTER 방법론은 8개의 데이터베이스 중에 3개의 데이터베이스에서 다른 방법론과 비교하여 최고 성능을 얻었다. 점근적으로 재가중되는 기법을 기반으로하는 방법론인 ARTER은 정확히 재가중되는 기법을 기반으로하는 ERTER 보다 낮은 성능이 관찰되었다. 모든 데이터베이스에서 각 알고리즘들의 평균에러를 구하여 비교하였을 때 제안하는 ERTER 방법론이 제일 좋은 성능을 얻는 것이 관찰되었다. <Table 3>에 대응표본 T검정(paired t-test) 결과를 나타내었다. 대부분의 결과를 비교하였을 때 유의미한 결과값인 1이 다른 알고리즘과 비교하였을 때 많이 발견되었다. 그 중 ARTER의 결과

<Table 2> Comparison of Averaged RMS Errors over 10 Runs

Database	IVT	OAB	MIL	TLD	STR UCK	SCM	ARTER	ERTER (Proposed)
David Indoor	3.52	41.67	23.53	10.19	8.83	3.29	4.93	5.27
Car 4	3.54	90.43	92.19	7.76	10.02	4.30	2.31	1.18
Car 11	2.11	14.54	37.38	28.22	2.91	1.67	1.62	1.45
Sylvester	78.76	28.63	13.87	8.36	8.92	21.05	8.62	8.42
Tea Box	18.98	16.16	9.96	8.74	7.61	21.34	8.35	7.97
Surfer	106.04	23.23	11.44	6.81	6.00	11.73	8.92	9.56
Jumping	46.75	33.49	15.18	3.78	7.21	3.68	5.82	4.17
Coupon Book	11.84	18.83	21.54	31.67	14.38	3.72	3.61	2.90
Average	33.94	33.37	28.13	13.19	8.23	8.84	5.52	5.11

〈Table 3〉 A statistical significance paired t-test using the averaged RMS Errors

Database	IVT	OAB	MIL	TLD	STRUCK	SCM	ARTER
David Indoor	1	1	1	1	1	1	1
Car 4	1	1	1	1	1	1	1
Car 11	1	1	1	1	1	1	0
Sylvester	1	1	1	0	1	1	0
Tea Box	1	1	1	1	0	1	1
Surfer	1	1	1	1	1	1	1
Jumping	1	1	1	1	1	1	1
Coupon Book	1	1	1	1	1	1	1

와 비교하였을 때 8개의 데이터베이스 중에 6개의 데이터베이스에서 유의미한 결과를 얻을 수 있었다.

계산적 성능을 비교하기 위해서 Frame per Second(FPS)를 구하여 <Table 4>에 나타내었다. 제일 좋은 성능은 OAB 방법에서 관측되었으며 제안하는 ERTER은 여섯번째로 좋은 성능을 얻었다. ARTER과 비교하였을 때 느린 성능이 관측 되었지만 정확도 성능 측면에서는 우수한 성능을 얻을 수 있었다.

〈Table 4〉 Comparison of Frame Per Second over 10 Runs

Method	Frame Per Second
IVT	23.9
OAB	36.7
MIL	31.2
TLD	13.7
STRUCK	8.6
SCM	0.5
ARTER	18.5
ERTER (Proposed)	4.3

7. 결론

본 논문에서는 정확히 재가중되는(exactly reweighted) 전체에러를 최소화 방법론(ERTER)이 제안되었다. 또한 이 제안된 ERTER 방법론은 객체 추적에 많이 사용되는 SMC 방법인 파티클 필터에 적용되었다. 이를 8개의 데이터베이스에서 7개의 방법론과 비교하였을 때 보다 우수한 성능을 얻을 수 있었다. 계산적인 측면에서 점근적으로 재가중되는(approximately reweighted) 방법보다 낮은 성능이 얻어졌지만 정확도 측면에서 우수한 성능을 얻을 수 있었다. 본 논문에서 제안된 방법론이 계산적인 측면에서 다른 방법론보다 느린 성능이 얻어졌다. 하지만 이는 ERTER의 수식 개선을 통해 이루어질 수 있으며, GPU를 코딩을 통해 계산 성능을 최적화하여 개선할 수 있다. 본 논문에서 제안된 방법론은 가중된 최소 자승법을 기반하기 때문에 정확히 재가중되는 작업이 필요한 다른 이론적 방법론들이 적용될 수 있다. 또한, 실무적으로 객체 추적 뿐만 아니라 객체 검출 및 인식에 충분히 적용이 가능하며 특히 실시간 학습이 필요한 분야에 성공적으로 적용될 수 있을 것이다.

참고문헌(References)

- Babenko, B., M.-H. Yang, and S. Belongie, "Robust Object Tracking with Online Multiple Instance Learning," *IEEE Trans. Pattern Analysis and Machine Intelligence*, Vol.33, No.8(2011), 1619~1632.
- Batkhuu, B., A. Jumabek, F. Yang, S. Ko, and G. S. Jo, "Transfer Learning using Multiple ConvNet Layers Activation Features with Principal Component Analysis for Image Classification," *Journal of Intelligence and Information Systems*, Vol. 24, No. 1(2018), 205~225.
- Crammer, K., O. Dekel, J. Keshet, S. Shalev-Shwartz, and Y. Singer, "Online Passive-Aggressive Algorithms," *Journal of Machine Learning Research*, Vol.7(2006), 551~585.
- Crammer, K., A. Kulesza, and M. Dredze, "Adaptive Regularization of Weight Vectors," *Advances in Neural Information Processing Systems*, (2009), 414~422.
- Dredze, M., K. Crammer, and F. Pereira, "Confidence-Weighted Linear Classification," *International Conference on Machine Learning*, (2008), 264~271.
- Hu, W., T. Tan, L. Wang, and S. Maybank, "A Survey on Visual Surveillance of Object Motion and Behaviors," *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, Vol.34, No.3 (2004), 334~352.
- Hare, S., A. Saffari, and P. H. S. Torr, "Struck: Structured Output Tracking with Kernels," *IEEE International Conference on Computer Vision*, (2011), 263~270.
- Lee, M.-S., and H. Ahn, "A Time Series Graph based Convolutional Neural Network Model for Effective Input Variable Pattern Learning : Application to the Prediction of Stock Market," *Journal of Intelligence and Information Systems*, Vol. 24, No. 1(2018), 167~181.
- Jang, S.-I., K. Choi, K.-A. Toh, A.B.J. Teoh, and J. Kim, "Object Tracking Based on An Online Learning Network with Total Error Rate Minimization," *Pattern Recognition*, Vol.48, No.1(2015), 126~139.
- Kim, Y., K.-A. Toh, A. B. J. Teoh, H.-L. Eng, and W.-Y. Yau, "An Online Learning Network for Biometric Scores Fusion," *Neurocomputing*, Vol.102(2013), 65~77.
- Kalal, Z., J. Matas, and K. Mikolajczyk, "P - N Learning: Bootstrapping Binary Classifiers by Structural Constraints," *IEEE Conference on Computer Vision and Pattern Recognition*, (2010), 49~56.
- Yilmaz, A., O. Javed, and M. Shah, "Object Tracking: A Survey," *ACM Computing Surveys*, Vol.38, No.4(2006), 1~46.
- Ross, D. A., R.-S. Lin, and M.-H. Yang, "Incremental Learning for Robust Visual Tracking," *International Journal of Computer Vision*, Vol.77, No.1(2008), 125~141.
- Rosenblatt, F., "The Perceptron: A Probabilistic Model for Information Storage and Organization in The Brain," *Psychological Review*, Vol.65, No.6(1958), 386~408.
- Kim, S., and J. Kim, "Customer Behavior Prediction of Binary Classification Model Using Unstructured Information and Convolution Neural Network: The Case of Online Storefront," *Journal of Intelligence and Information Systems*, Vol. 24, No. 2(2018), 221~241.

Toh, K.-A., “Deterministic neural classification,”
Neural computation, Vol.20, No.6(2008),
1565~1595.

Grabner, H., M. Grabner, and H. Bischof,
“Real-Time Tracking via On-line Boosting,”
British Machine Vision Conference, (2006),
47~56.

Zhong, W., H. Lu, and M.-H. Yang, “Robust
Object Tracking via Sparsity-based
Collaborative Model,” *IEEE Conference on
Computer Vision and Pattern Recognition*,
(2012), 1838~1845.

Abstract

Object Tracking Based on Exactly Reweighted Online Total-Error-Rate Minimization

Se-In JANG* · Choong-Shik PARK**

Object tracking is one of important steps to achieve video-based surveillance systems. Object tracking is considered as an essential task similar to object detection and recognition. In order to perform object tracking, various machine learning methods (e.g., least-squares, perceptron and support vector machine) can be applied for different designs of tracking systems. In general, generative methods (e.g., principal component analysis) were utilized due to its simplicity and effectiveness. However, the generative methods were only focused on modeling the target object. Due to this limitation, discriminative methods (e.g., binary classification) were adopted to distinguish the target object and the background. Among the machine learning methods for binary classification, total error rate minimization can be used as one of successful machine learning methods for binary classification. The total error rate minimization can achieve a global minimum due to a quadratic approximation to a step function while other methods (e.g., support vector machine) seek local minima using nonlinear functions (e.g., hinge loss function). Due to this quadratic approximation, the total error rate minimization could obtain appropriate properties in solving optimization problems for binary classification. However, this total error rate minimization was based on a batch mode setting. The batch mode setting can be limited to several applications under offline learning.

Due to limited computing resources, offline learning could not handle large scale data sets. Compared to offline learning, online learning can update its solution without storing all training samples in learning process. Due to increment of large scale data sets, online learning becomes one of essential properties for various applications. Since object tracking needs to handle data samples in real time, online learning based total error rate minimization methods are necessary to efficiently address object tracking problems. Due to the need of the online learning, an online learning based total error rate minimization method was developed. However, an approximately reweighted technique was developed. Although the approximation

* Department of Statistics and Applied Probability, National University of Singapore

** Corresponding Author: Choong-Shik PARK

Department of Smart IT, U1 University

52-70 Yeonamsan-ro, Eumbong-myeon, Asan city, Chungcheongbuk-do (31415), Korea

Tel: +82-41-536-5723, Fax: +82-41-536-5729, E-mail: leciel@u1.ac.kr

technique is utilized, this online version of the total error rate minimization could achieve good performances in biometric applications. However, this method is assumed that the total error rate minimization can be asymptotically achieved when only the number of training samples is infinite. Although there is the assumption to achieve the total error rate minimization, the approximation issue can continuously accumulate learning errors according to increment of training samples. Due to this reason, the approximated online learning solution can then lead a wrong solution. The wrong solution can make significant errors when it is applied to surveillance systems.

In this paper, we propose an exactly reweighted technique to recursively update the solution of the total error rate minimization in online learning manner. Compared to the approximately reweighted online total error rate minimization, an exactly reweighted online total error rate minimization is achieved. The proposed exact online learning method based on the total error rate minimization is then applied to object tracking problems. In our object tracking system, particle filtering is adopted. In particle filtering, our observation model is consisted of both generative and discriminative methods to leverage the advantages between generative and discriminative properties. In our experiments, our proposed object tracking system achieves promising performances on 8 public video sequences over competing object tracking systems. The paired t-test is also reported to evaluate its quality of the results.

Our proposed online learning method can be extended under the deep learning architecture which can cover the shallow and deep networks. Moreover, online learning methods, that need the exact reweighting process, can use our proposed reweighting technique. In addition to object tracking, the proposed online learning method can be easily applied to object detection and recognition. Therefore, our proposed methods can contribute to online learning community and object tracking, detection and recognition communities.

Key Words : Object Tracking, Online Learning, Total-Error-Rate Minimization, Exact Reweighting

Received : November 12, 2019 Revised : December 9, 2019 Accepted : December 16, 2019

Publication Type : Regular Paper Corresponding Author : Choong-Shik PARK

저 자 소개



장세인

현재 싱가포르국립대학(National University of Singapore)의 통계학과에서 연구원(research fellow)으로 재직중에있다. 연세대학교 전기전자공학과에서 박사 학위를 취득하였으며, 주요 관심 분야는 인공지능, 머신러닝, 온라인 학습이다.



박충식

현재 유원대학교 스마트IT학과 교수이다. 대학원 전자공학과에서 박사학위를 취득하였다. 컴퓨터비전, 빅데이터, 그리고 인공지능의 기호처리 기술과 신경망 기술의 융합 연구에 관심을 가지고 있다.