



(19) 대한민국특허청(KR)  
(12) 공개특허공보(A)

(11) 공개번호 10-2013-0052432  
(43) 공개일자 2013년05월22일

(51) 국제특허분류(Int. Cl.)

G06F 17/00 (2006.01) G06F 17/10 (2006.01)

(21) 출원번호 10-2011-0117870

(22) 출원일자 2011년11월11일

심사청구일자 2011년12월05일

(71) 출원인

경희대학교 산학협력단

경기도 용인시 기흥구 덕영대로 1732, 국제캠퍼스 내 (서천동, 경희대학교)

(72) 발명자

이승룡

경기도 성남시 분당구 구미로144번길 25, 102동 102호 (구미동, 삼환빌라)

이영구

경기도 수원시 영통구 덕영대로 1709, 706호 (영통동, 경희유니빌)

라더빈

경기도 용인시 기흥구 덕영대로 1732, 전자정보대학 351호 (서천동, 경희대학교)

(74) 대리인

특허법인 신지


전체 청구항 수 : 총 8 항

(54) 발명의 명칭 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법

(57) 요약

본 발명은 전체 가우스 공분산이 적용된 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법에 관한 것으로서, 트레이닝을 위한 입력 신호를 분할하여 프레임 시퀀스로 출력하는 과정과, 상기 프레임 시퀀스에서 특징 벡터를 추출하는 과정과, 상기 특징 벡터를 이용 상기 가우스 공분산이 적용된 은닉 조건부 랜덤 필드 모델을 통해 매개 변수를 계산하고, 상기 구해진 매개 변수를 적용한 은닉 조건부 랜덤 필드 모델이 측정된 테스트 입력 신호를 상기기와 동일한 분할하여 프레임 시퀀스로 출력하고 특징 벡터를 추출하는 과정을 거친 특성 벡터를 입력 받아 상기 실제 패턴을 지시하는 라벨을 추론하는 단계와, 이를 해석하는 방법으로 각각 조건부 확률 벡터/전이 확률 벡터/가우스 혼합 가중치/가우스 분포 평균/가우스 분포의 공분산에 대한 기울기 값의 계산법을 제안하는 과정을 포함한다.

대표도 - 도2



이 발명을 지원한 국가연구개발사업

|        |                            |
|--------|----------------------------|
| 과제고유번호 | NIPA-2010-(C1090-1021-003) |
| 부처명    | 지식경제부                      |
| 연구사업명  | 대학 IT연구센터 지원 사업            |
| 연구과제명  | 동서신의학 u-라이프케어 기술 연구        |
| 주관기관   | 경희대학교 산학협력단                |
| 연구기간   | 2006.11.01 ~ 2014.12.31    |

---

## 특허청구의 범위

### 청구항 1

- (A) 특정 패턴에 대하여 측정되는 트레이닝 입력 신호로부터의 특징 벡터를 추출하는 단계;
- (B) 전체 공분산 가우스 분포의 조합을 적용한 은닉 조건부 랜덤 필드 모델이, 상기 특징 벡터와 상기 특정 패턴을 지시하는 라벨의 조합을 다수 개 입력 받아서 상기 은닉 조건부 랜덤 필드 모델의 매개 변수를 구하는 단계; 및
- (C) 상기 매개 변수가 적용된 상기 은닉 조건부 랜덤 필드 모델이, 실제 패턴에 대하여 측정되는 테스트 입력 신호로부터 추출된 특징 벡터를 입력 받아서 상기 실제 패턴을 지시하는 라벨을 추론하는 단계를 포함하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

### 청구항 2

제1항에 있어서, 상기 단계(A)는

- (A1)상기 트레이닝 입력 신호를 분할하여 프레임 시퀀스로 출력하는 단계; 및
- (A2)상기 프레임 시퀀스에서 상기 트레이닝 입력 신호의 특징 벡터를 추출하는 단계를 포함하는 것을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

### 청구항 3

제1항에 있어서,

상기 단계 (C)에서 사용 되는 특징 벡터는 상기 단계 (A)에 적용 된 알고리즘과 동일한 알고리즘을 사용하여 추출되는 것을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

### 청구항 4

제1항에 있어서,

상기 단계 (C)는 상기 매개 변수가 적용된 상기 은닉 조건부 랜덤 필드 모델이 상기 테스트 입력 신호의 특징 벡터를 입력 받아서 어느 특정 상태의 시퀀스를 나타내는 상태 시퀀스의 확률을 산출하는 과정을 포함하는 것을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

### 청구항 5

제1항에 있어서,

상기 전체 공분산 가우스 분포의 조합은 상기 특징 벡터의 서로 다른 쌍들 사이의 상관관계 정보가 포함된 것을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

### 청구항 6

제1항에 있어서,

상기 특징 벡터를 나타내는 특징 함수는 선형적 확률 벡터, 전이 확률 벡터, 관측 확률 벡터의 세 개의 함수를 포함하고,

상기 선형적 확률 벡터는,  $f_s^{Prior}(Y, \bar{S}, X) = \delta(s_1 = s) \forall s$  에 의해 산출 되며,

$$f_{ss'}^{Transition}(Y, \bar{S}, X) =$$

상기 전이확률 벡터는,  $\sum_{t=1}^T \delta(s_{t-1} = s) \delta(s_t = s') \forall s, s'$  에 의해 산출 되며,

$$f_s^{Observation}(Y, \bar{S}, X) = \sum_{t=1}^T \log \left( \sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m}) \right) \delta(s_t = s)$$

상기 관측확률 벡터는,  $\delta(s_t = s)$ 에 의해 산출되며,

$$N(x, \mu_{s,m}, \Sigma_{s,m}) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_{s,m}|^{\frac{1}{2}}} \exp \left( -\frac{1}{2} (x - \mu_{s,m})' \Sigma_{s,m}^{-1} (x - \mu_{s,m}) \right)$$

$$\Lambda_s^{Obs} = 1 \forall s$$

이 때 정규 분포 N은,  $\Lambda_s^{Obs} = 1 \forall s$ 에 의해 산출되며,

X는 입력 트레이닝 데이터, Y는 입력 값 X의 트레이닝 라벨,  $\Lambda$ 는 선형적 확률 가중치, 전이 가중치, 관측 가중치를 포함하는 설정 모델의 매개변수 벡터,  $f$ 는 모델의 특징 벡터, S는 상태의 시퀀스,  $\bar{S}$ 은 숨겨진 상태의 시퀀스,  $\delta$ 는 델타 함수, m은 밀도 함수의 개수, D는 트레이닝 데이터의 차원,  $\Gamma$ 는 스칼라 값을 가지는 가우스 혼합 가중치,  $\mu$ 는 가우스 분포의 평균 벡터,  $\Sigma$ 는 가우스 분포의 공분산 행렬,  $x_t$ 는 시간 t에 대한 데이터 벡터, 임을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

#### 청구항 7

제6항에 있어서,

상기 선형적 확률 벡터의 선형적 확률 변수에 대한 기울기 함수는,

$$\frac{dScore(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Lambda_s^{Prior}} = \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Lambda_s^{Prior}} \exp(g(Y, \bar{S}, X))$$

$$= \sum_{\bar{S}} f_s^{Prior}(Y, \bar{S}, X) \exp(g(Y, \bar{S}, X))$$

$$= \beta_1(s)$$

에 의해 산출되며,

상기 전이 확률 벡터의 전이 확률 변수에 대한 기울기 함수는

$$\frac{dScore(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Lambda_{ss'}^{Transition}} = \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Lambda_{ss'}^{Transition}} \exp(g(Y, \bar{S}, X))$$

$$= \sum_{\bar{S}} f_{ss'}^{Transition}(Y, \bar{S}, X) \exp(g(Y, \bar{S}, X))$$

$$= \sum_{t=1}^T \alpha(t, s) \beta(t+1, s')$$

에 의해 산출되며,

상기 가우스 혼합 가중치의 변수에 대한 기울기 함수는

$$\begin{aligned}
 \frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Gamma_{s,m}^{Obs}} &= \\
 \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Gamma_{s,m}^{Obs}} \exp(g(Y, \bar{S}, X)) \\
 &= \sum_{\bar{S}} \frac{f_s^{Observation}(Y, \bar{S}, X)}{d\Gamma_{s,m}^{Obs}} \exp(g(Y, \bar{S}, X)) \\
 &= \sum_{\bar{S}} \sum_{t=1}^T \frac{N(x_t, \mu_{s,m}, \Sigma_{s,m})}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \delta(s_t = s) \exp(g(Y, \bar{S}, X)) \\
 &= \sum_{t=1}^T \frac{N(x_t, \mu_{s,m}, \Sigma_{s,m})}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1)
 \end{aligned}$$

에 의해 산출되며,

상기 가우스 분포의 평균 벡터 가우스 분포 평균의 기울기는

$$\begin{aligned}
 \frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\mu_{s,m}} &= \\
 \sum_{t=1}^T \frac{\Gamma_{s,m}^{Obs} \frac{dN(x_t, \mu_{s,m}, \Sigma_{s,m})}{d\mu_{s,m}}}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1)
 \end{aligned}$$

에 의해 산출되며,

상기 가우스 분포의 공분산 행렬에 대한 기울기 함수는

$$\begin{aligned}
 \frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Sigma_{s,m}} &= \\
 \sum_{t=1}^T \frac{\Gamma_{s,m}^{Obs} \frac{dN(x_t, \mu_{s,m}, \Sigma_{s,m})}{d\Sigma_{s,m}}}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1)
 \end{aligned}$$

에 의해 산출되며,

이 때, 함수  $\gamma(t)$ 는,

$$\gamma(t) = \sum_s \beta(t, s)$$

에 의해 산출되는,

것을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

## 청구항 8

제7항에 있어서,

상기 상태 시퀀스의 확률인  $p(Y | X; \Lambda)$ 는,

$$p(Y | X; \Lambda) = \frac{\sum_{\bar{S}} \sum_{m=1}^M \exp\{\Lambda f(Y, \bar{S}, m, X)\}}{z(X, \Lambda)}$$

에 의해 산출되며,

이  $z(X, \Lambda)$  함수는 정규화 인자로,

$$z(X, \Lambda) = \sum_{Y'} P(Y' | X; \Lambda)$$

에 의해 산출되며,

상기에서  $X$ 는 트레이닝 데이터 이고,  $Y$ 는 트레이닝 라벨 이고,  $\Lambda$  는 모델의 매개변수 벡터,  $f$  는 모델의 특징 벡터,  $\bar{S}$  은 숨겨진 상태의 시퀀스,  $m$ 은 가우스 분포의 숫자임을 특징으로 하는 마르코프 연쇄 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법.

## 명세서

### 기술분야

[0001] 본 발명은 은닉 조건부 랜덤 필드 모델 기반의 패턴 인식 방법에 관한 것이다.

### 배경기술

[0002] 산업 영역에서 이제는 일상의 생활 영역에까지 다양한 패턴 인식이 적용되고 있기 때문에 그 중요성과 활용도가 점점 더 높아지고 있다.

[0003] 패턴을 인식하는 알고리즘과 관련하여, 조건부 랜덤 필드 모델(conditional random fields model)을 자주 사용하고 있다. [John Lafferty 외 다수 2001].

[0004] 하지만, 종래의 조건부 랜덤 필드는 지속적이고 오랜 기간들의 패턴들을 모델링 할 수 없다. 이러한 문제점을 해결하기 위한 다양한 연구가 진행되고, 조건부 랜덤 필드의 다양한 변화들[Sunita Sarawagi 외 다수 2004, D.L.Vail외 다수 2001]등이 발표되었지만, 이와 같은 조건부 랜덤 필드의 여러 변형물들은 과도한 복잡성을 가지거나 상기 명시 된 문제점을 완전하게 해결하지 못하였다. 한 예로, 2001년 John Lafferty외 다수에 의해 제시된 최초의 조건부 랜덤 필드는 마르코프 가정(Markov assumption) 때문에 상태의 양의 지속 기간을 모델링 할 수 없다.

[0005] 마르코프 연쇄 은닉 조건부 랜덤 필드 모델(Markov chain hidden random fields model)은 특히 말이나 비디오 영상과 같은 순차적인 데이터에 대한 뛰어난 분류 방법임이 입증되었다. 지난 십 수년간 은닉 마르코프 모델(Hidden Markov Model)은 음성 인식, 영상 분류와 유전자 분류와 같은 많은 패턴 인식 관련 어플리케이션들에 널리 사용되었다.

[0006] 하지만 최근 생성적 본성과 상태와 관측 사이의 독립적인 가정에서 은닉 마르코프 모델의 한계가 드러났다 [A.Gunawardana 외 다수, 2005; S.B.Wang외 다수, 2006]. 최대 엔트로피 마르코프 모델(Maximum Entropy Markov Model:MEMM)은 은닉 마르코프 모델의 한계를 극복하고 특히 언어의 품사를 구분하는 작업[A. Ratnaparkhi, 1996]과 자동 음성 인식(ASR)[H.K.J. Kuo외 다수, 2006], 정보 추출[A. McCallum, 2000]등의 분야에서 뛰어난 결과를 보여주고 있다. 그렇지만 최대 엔트로피 마르코프 모델은 라벨 바이어스 문제에 취약하다고 알려져 있다.

[0007] 마르코프 연쇄 은닉 조건부 랜덤 필드 모델(Markov chain hidden conditional random fields model)은 최대 엔트로피 마르코프 모델의 장점을 전부 가지고 있으며 라벨 바이어스 문제를 해결하였다. 마르코프 연쇄 은닉 조건부 랜덤 필드 모델은 마르코프 은닉 모델이나 최대 엔트로피 마르코프 모델보다 가중치를 허용한 더 넓은 파라미터 공간을 만들 수 있다. 그러나 마르코프 연쇄 은닉 조건부 랜덤 필드 모델에는 가우스 밀도 함수의 전체 공분산 조합을 활용할 수 있는 도구가 없다.

- [0008] 참고문헌:
- [0009] 1. John Lafferty, Andrew McCallum, and Fernando Pereira,
- [0010] "Conditional random field: Probability models for segmenting and labeling sequence data". In Proceeding of International Conference on Machine Learn (ICML), Williams College, Williamstown, MA, USA, June 28-July 1, 2001. Morgan Kaufmann 2001, ISBN 1-55860-778-1.
- [0011] 2. Sunita Sarawagi and William Cohen.
- [0012] "Semi-makov conditional random fields for information extraction". In Proceeding of Advances in Neural Information Processing System(NIPS), MIT Press, Cambridge, MA, USA, December 2004.
- [0013] 1. A. Gunawardana, M. Mahajan, A. Acero, J. C. Platt.
- [0014] "Hidden conditional random fields for phone classification", in: Proceedings of the International Conference on Speech Communication and Technology, 2005, pp.1117-1120.
- [0015] 4. S. B.Wang, A. Quattoni, L.-P. Morency, D. Demirdjian, T. Darrell, "Hidden conditional random fields for gesture recognition", in: Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition, vol.2, 2006, pp.1521-1527.
- [0016] 5. A. Ratnaparkhi,
- [0017] "A maximum entropy model for part-of-speech tagging", in: Proceedings of the Empirical Methods in Natural Language Processing, 1996, pp.133-142.
- [0018] 6. McCallum, D. Freitag, F. C. N. Pereira,
- [0019] "Maximum entropy markov models for information extraction and segmentation", in: Proceedings of the Seventeenth International Conference on Machine Learning, 2000, pp.591-598.
- [0020] 7. H.-K.J.Kuo, Y. Gao,
- [0021] "Maximum entropy direct models for speech recognition", IEEE Transactions on Audio, Speech, and Language Processing 14(3)(2006)873-881.

## 발명의 내용

### 해결하려는 과제

- [0022] 본 발명이 해결하고자 하는 과제는 전체 공분산 가우스 밀도 함수를 사용할 수 있는 은닉 조건부 랜덤 필드 모델의 도구가 없기 때문에 이를 조합하여 활용하는 새로운 은닉 조건부 랜덤 필드 모델과 이 새로운 은닉 조건부 랜덤 필드 모델을 적용하여 패턴을 인식하는 알고리즘을 제공하는 것이다.

### 과제의 해결 수단

- [0023] 본 발명은 다양한 입력으로부터 측정되는 입력 신호를 분할하여 프레임 시퀀스를 출력하는 과정과, 상기 프레임 시퀀스에서 특징 벡터를 추출하는 과정과 은닉 조건부 랜덤 필드 모델에 전체 공분산 가우스 분포를 조합하는 과정과, 상기 은닉 조건부 랜덤 필드 모델이, 상기 특징 벡터와 상기 특정 행위를 지시하는 라벨의 조합들을 입력 받아서 상기 은닉 조건부 랜덤 필드 모델의 매개 변수를 구하는 단계와, 상기 매개 변수가 적용된 상기 은닉 조건부 랜덤 필드 모델이, 실제 행위에 대하여 측정되는 테스트 입력 신호로부터 추출된 특징 벡터를 입력 받아서 상기 실제 행위를 지시하는 라벨을 추론하여 어느 특정 상태의 시퀀스를 나타내는 과정과, 상기 특정 상태의 시퀀스를 해석하기 위한 기율기 함수 적용 알고리즘을 적용하는 과정과, 이를 통해 상태 시퀀스의 확률을 산출하는 과정을 포함한다.

### 발명의 효과

- [0024] 본 발명은 다양한 실제 행위들과 같은 패턴을 인식함에 있어서, 전체 공분산 가우스 분포가 조합 된 은닉 조건

부 랜덤 필드 모델에서 트레이닝(training)과 추론(inference)을 동시에 진행함으로써, 장시간의 행위들의 변화를 효과적으로 인식할 수 있는 효과가 있으며 상기 은닉 조건부 랜덤 필드 모델을 해석하는 새로운 해석방법을 제시함으로써 상기 변화의 인식을 실시간으로 가능하게 하는 효과가 있다.

### 도면의 간단한 설명

[0025] 도 1은 전체 공분산 가우스 혼합 은닉 조건부 랜덤 필드 모델을 사용한 분류 시스템에서 트레이닝 단계의 블록 선도를 도시한 그림이다.

도 2는 전체 공분산 가우스 혼합 은닉 조건부 랜덤 필드 모델을 사용한 분류 시스템에서 분류 단계의 블록 선도를 도시한 그림이다.

### 발명을 실시하기 위한 구체적인 내용

[0026] 이하, 본 발명의 실시 예들의 상세한 설명이 첨부된 도면들을 참조하여 본 발명의 실시예를 상세하게 설명한다. 사용되는 용어들은 실시예에서의 기능을 고려하여 선택된 용어들로서, 그 용어의 의미는 사용자, 운용자의 의도 또는 관례 등에 따라 달라질 수 있다. 그러므로 후술하는 실시예들에서 사용된 용어의 의미는, 본 명세서에 구체적으로 정의된 경우에는 그 정의에 따르며, 구체적인 정의가 없는 경우는 당업자들이 일반적으로 인식하는 의미로 해석되어야 할 것이다.

[0027] 본 발명은 행위 인식등과 같은 패턴 인식과 관련된다. 여기서 행위 인식이란 걷고, 뛰고, 눕거나 돌기와 같은 상태와 움직임을 판별하는 것을 말한다. 뿐만 아니라 본 발명은 음성 인식, 얼굴 인식, 지문 및 홍채 인식과 같은 다양한 패턴 인식 분야에 응용 할 수 있다. 이하, 패턴 인식의 일례로 행위 인식에 대하여 설명한다.

[0028] 지금까지의 행위 인식 분야에서 마르코프 연쇄 은닉 조건부 랜덤 필드 모델은 명시적으로 공분산 가우스 분포를 사용하지 않아 인식 시스템의 정확도를 감소시킨다.

[0029] 본 발명은, 마르코프 연쇄 은닉 조건부 랜덤 필드 모델에서 공분산 가우스 분포를 적용하여 그 정확도를 높이고 새로운 해석 방법을 적용하는 은닉 조건부 랜덤 필드 모델이다.

[0030] 결국, 본 발명은 은닉 조건부 랜덤 필드 모델을 확장하여, 종래의 은닉 마르코프 모델보다 트레이닝과 추론을 동시에 정확하고 빠르게 하는 알고리즘을 가진 은닉 조건부 랜덤 필드 모델이다.

[0031] 기존 은닉 조건부 랜덤 필드 모델의 한계를 극복하는 전체 공분산 가우스 분포를 조합한 새로운 상기 은닉 조건부 랜덤 필드 모델로 수학식1, 수학식2, 수학식3이 결정된다.

### 수학식 1

$$p(Y|X;\Lambda) = \frac{\sum_{\bar{S}} \exp\{\Lambda \cdot f(Y, \bar{S}, X)\}}{z(X, \Lambda)}$$

$$z(X, \Lambda) = \sum_{Y'} P(Y'|X; \Lambda)$$

상기 수학식 10에서  $z(X, \Lambda)$  는 정규화 인자이고, X는 입력 트레이닝 데이터, Y는 입력 값 X의 트레이닝 라벨이고,  $f$  는 모델의 특징 벡터, S는 상태의 시퀀스,  $\bar{S}$  는 숨겨진 상태의 시퀀스 이다.  $\Lambda$  는 선형적/전이/관측의 특징을 나타내는 가중치를 포함하는 설정 모델의 매개변수 벡터이다.

입력 된 데이터와 상기 도1에서 산출 된 매개변수(206)이 적용 된 은닉 조건부 랜덤 필드 모델(205)로부터 산출 된 데이터 라벨(207)의 상태 확률은 라벨 상태 시퀀스 확률인  $p(Y|X;\Lambda)$  에 의해 계산 된다.  $p(Y|X;\Lambda)$  는 상기 수학식 10으로 정의 된다.

### 수학식 2

$$f_s^{Prior}(Y, \bar{S}, X) = \delta(s_1 = s) \forall s$$

$$f_{ss'}^{Transition}(Y, \bar{S}, X) = \sum_{t=1}^T \delta(s_{t-1} = s) \delta(s_t = s') \forall s, s'$$

$$f_s^{Occurence}(Y, \bar{S}, X) = \sum_{t=1}^T \delta(s_t = s) \forall s$$

$$f_s^{M1}(Y, \bar{S}, X) = \sum_{t=1}^T \delta(s_t = s) x_t \forall s$$

$$f_s^{M2}(Y, \bar{S}, X) = \sum_{t=1}^T \delta(s_t = s) x_t^2 \forall s$$

수학식 2는 단일 가우스 분포와 함께 마르코프 연쇄 모델 구성하며 상기와 같이 선택하였다. 상기에서  $\delta$ 는 델타 함수,  $m$ 은 밀도 함수의 개수,  $D$ 는 트레이닝 데이터의 차원,  $\Gamma$ 는 스칼라 값을 가지는 가우스 혼합 가중치,  $\mu$ 는 가우스 분포의 평균 벡터,  $\Sigma$ 는 가우스 분포의 공분산 행렬이고,  $x_t$ 는 시간  $t$ 에 대한 데이터 벡터이고,  $x_t^2$ 는  $x_t$ 의 컴퍼넌트 당 제곱을 나타낸다.

$x_t^2$ 는 상기 설명처럼  $x_t$ 의 컴퍼넌트 당 제곱이기 때문에  $x_t^2$ 의 컴퍼넌트(component)는 상호교차관계 정보를 배울 수 없다. 즉, 각각 독립적으로 페어와이즈(pair-wise)하다고 가정하여 가우스 분포는 대각 공분산 행렬을 가진다. 하지만 이는 실제 현실에 적용함에 있어 차이가 존재하는 한계를 가진다.

### 수학식 3

$$p(Y | X; \Lambda) = \frac{\sum_{\bar{S}} \sum_{m=1}^M \exp\{\Lambda f(Y, \bar{S}, m, X)\}}{z(X, \Lambda)}$$

상기 수학식 3는 상기 수학식 1에서 가우스 밀도 함수의 조합을 활용하여 확장한 상태 시퀀스 확률이다

상기 수학식 2가 가지는 한계를 극복하기 위해 대각 공분산 행렬이 아닌 전체 공분산 가우스 분포(full-covariance Gaussian distributions)의 조합을 활용 할 수 있는 새로운 은닉 조건부 랜덤 필드 모델을 아래와 같이 정의하였다.

### 수학식 4

$$f_s^{Prior}(Y, \bar{S}, X) = \delta(s_1 = s) \forall s$$

수학식 5

$$f_{ss'}^{Transition}(Y, \bar{S}, X) = \sum_{t=1}^T \delta(s_{t-1} = s) \delta(s_t = s') \forall s, s'$$

[0047]

수학식 6

$$f_s^{Observation}(Y, \bar{S}, X) = \sum_{t=1}^T \log \left( \sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m}) \right) \delta(s_t = s)$$

[0048]

[0049] 수학식4, 수학식5, 수학식6은 각각 상기 특징 벡터로부터 산출 된 특징 함수로 선형적 확률 벡터, 전이 확률 벡터, 관측 확률 벡터를 나타낸다. 상기 수학식 6에서 정규 분포 N은 수학식7에 의해 구해질 수 있다.

수학식 7

$$N(x, \mu_{s,m}, \Sigma_{s,m}) = \frac{1}{(2\pi)^{\frac{D}{2}} |\Sigma_{s,m}|^{\frac{1}{2}}} \exp \left( -\frac{1}{2} (x - \mu_{s,m})' \Sigma_{s,m}^{-1} (x - \mu_{s,m}) \right)$$

$$\Lambda_s^{Obs} = 1 \forall s$$

[0050]

수학식 8

$$\frac{dScore(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Lambda_s^{Prior}} = \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Lambda_s^{Prior}} \exp(g(Y, \bar{S}, X))$$

$$= \sum_{\bar{S}} f_s^{Prior}(Y, \bar{S}, X) \exp(g(Y, \bar{S}, X))$$

$$= \beta_1(s)$$

[0051]

[0052] 상기 dScore함수는 상기 선형적 확률 벡터의 변수에 대한 기울기 함수이다.

수학식 9

$$\begin{aligned} \frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Lambda_{ss'}^{Transition}} &= \\ \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Lambda_{ss'}^{Transition}} \exp(g(Y, \bar{S}, X)) &= \\ = \sum_{\bar{S}} f_{ss'}^{Transition}(Y, \bar{S}, X) \exp(g(Y, \bar{S}, X)) &= \\ = \sum_{t=1}^T \alpha(t, s) \beta(t+1, s') \end{aligned}$$

[0053]

[0054] 상기 dScore함수는 상기 전이 확률 벡터의 변수에 대한 기울기 함수이다.

수학식 10

$$\begin{aligned} \frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Gamma_{s,m}^{Obs}} &= \\ \sum_{\bar{S}} \frac{dg(Y, \bar{S}, X)}{d\Gamma_{s,m}^{Obs}} \exp(g(Y, \bar{S}, X)) &= \\ = \sum_{\bar{S}} \frac{f_s^{Observation}(Y, \bar{S}, X)}{d\Gamma_{s,m}^{Obs}} \exp(g(Y, \bar{S}, X)) &= \\ = \sum_{\bar{S}} \sum_{t=1}^T \frac{N(x_t, \mu_{s,m}, \Sigma_{s,m})}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \delta(s_t = s) \exp(g(Y, \bar{S}, X)) &= \\ = \sum_{t=1}^T \frac{N(x_t, \mu_{s,m}, \Sigma_{s,m})}{\sum_{m=1}^M \Gamma_{s,m}^{Obs} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1) \end{aligned}$$

[0055]

[0056] 상기 dScore함수는 가우스 혼합 가중치 변수에 대한 기울기 함수이다. 여기서 함수  $\gamma(t)$ 는  $\gamma(t) = \sum_s \beta(t, s)$ 에 의해 계산된다.

수학식 11

$$\frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\mu_{s,m}} = \sum_{t=1}^T \frac{\Gamma_{s,m}^{Obs} \frac{dN(x_t, \mu_{s,m}, \Sigma_{s,m})}{d\mu_{s,m}}}{\sum_{m=1}^M \Gamma_{s,m} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1)$$

[0057]

[0058] 상기 dScore함수는 상기 가우스 분포 평균에 대한 기울기 함수이다.

수학식 12

$$\frac{d\text{Score}(Y | X; \Lambda, \Gamma, \mu, \Sigma)}{d\Sigma_{s,m}} = \sum_{t=1}^T \frac{\Gamma_{s,m}^{Obs} \frac{dN(x_t, \mu_{s,m}, \Sigma_{s,m})}{d\Sigma_{s,m}}}{\sum_{m=1}^M \Gamma_{s,m} N(x_t, \mu_{s,m}, \Sigma_{s,m})} \alpha(t, s) \gamma(t+1)$$

[0059]

[0060] 상기 dScore함수는 가우스 분포의 공분산에 대한 기울기 함수이다.

[0061] 수학식 8, 수학식9, 수학식10, 수학식11은 상기 수학식4, 수학식5, 수학식6으로부터 구해진 선형적 확률 벡터와 전이 확률 벡터 그리고 관측 확률 벡터의 특성 함수와 가우스 분포의 평균과 공분산에 대한 기울기 값을 계산하는 해석방법 알고리즘을 나타낸다.

[0062] 본 발명은 다양한 실제 행위들을 인식함에 있어 트레이닝 단계와 추론 단계로 나뉘어 진다. 트레이닝 단계는 인식하고자 하는 대상의 다양한 상태를 알고 있는 데이터를 입력하여 상기 은닉 조건부 랜덤 필드 모델을 트레이닝 시키는 단계를 말한다. 예를 들어 음성을 통한 감정 인식의 경우 미리 상태를 알고 있는 기쁨, 슬픔, 즐거움, 우울함과 감정을 표현하는 음성등을 트레이닝 데이터로서 입력하게 된다. 추론 단계는 상기 트레이닝 단계에서 산출된 매개 변수들을 바탕으로 실제 측정하고자 하는 입력을 분류하게 된다.

[0063] 도 1은 전체 공분산 가우스 혼합 은닉 조건부 랜덤 필드 모델을 사용한 분류 시스템에서 트레이닝 단계의 블록 선도를 도시한 그림이다.

[0064] 트레이닝 용도로 입력된 신호(101)가 슬라이딩 윈도우(102)로 입력되면 슬라이딩 윈도우(102)는 입력된 신호를 프레임 시퀀스(103)로 분할한다. 상기 슬라이딩 윈도우는 해밍 함수를 이용하여 입력 신호를 분할할 수 있다. 상기 해밍 함수는 필터 설계에 흔히 사용되는 함수로서, 개수로 된 인수를 분할하는 기능을 수행한다.

[0065] 특징 추출부(104)는 상기 분할된 프레임 시퀀스(103)를 입력 받아 특징 벡터를 추출한다. 여기서 특징 벡터란 예를 들어 음성 신호와 같은 경우 음성이 가지고 있는 진폭과 주파수, 위상 및 평균값과 같은 구분되어지는 특징들을 말한다. 추출된 특성 벡터는 본 발명의 상기 전체 공분산 가우스 혼합 은닉 조건부 랜덤 필드 모델(105)에 입력된다.

[0066] 상기 은닉 조건부 랜덤 필드 모델(105)은 특징 벡터를 라벨(106)과 함께 입력 받아, 상기 수학식 4, 수학식5, 수학식6에 의하여 기울기 함수에 기반을 둔 트레이닝 알고리즘을 수행하여 매개변수(107)를 생성하여 이를 도2의 매개변수(206)에 제공한다.

[0067] 도 2는 전체 공분산 가우스 혼합 은닉 조건부 랜덤 필드 모델을 사용한 분류 시스템에서 분류 단계의 블록 선도

를 도시한 그림이다.

- [0068] 테스트 용도의 입력 신호(201) 상기 도2의 슬라이딩 윈도우(202)에 입력되면, 슬라이딩 윈도우는 하나의 프레임 단위로 생성하여 특징 추출부(204)에 제공한다. 특징 추출부는 프레임 단위의 신호들에서 특징 벡터들을 추출한다.
- [0069] 상기와 같이 추출된 특징 벡터들은 상기 도1과정의 결과로 만들어진 매개 변수(206)가 적용된 상기 은닉 조건부 랜덤 필드 모델(205)에 입력되어 데이터 라벨(207)을 생성한다.
- [0070] 결국 본 발명은, 시퀀스의 특징 벡터들에 의한 트레이닝과 추론을 동시에 빠르게 진행하여, 행위 인식 결과를 출력할 수 있게 된다.
- [0071] 은닉 조건부 랜덤 필드 모델의 트레이닝 단계는 일반적으로 LBFG 방법에 의해 특성 기울기를 계산한다. 하지만 현재의 기울기 계산법은 순방향 및 역방향 반복 수행(Forward and Backward) 알고리즘을 반복적으로 호출하여 매우 많은 연산량을 요구하고 이는 결국 연산 속도의 저하를 불러 일으킨다. 이에 상기 순방향 및 역방향 반복 수행 알고리즘의 호출을 줄이는 새로운 해석 방법을 고안했다. 수학식8, 수학식9, 수학식10, 수학식11, 수학식12를 적용해 계산해 낸 상기의 5가지의 기울기 함수를 통해 상기 기존의 해석 방법에 비해 연산량이 줄어들어 이에 따른 속도 증가를 통해 실시간 연산을 가능케 한다.
- [0072] 이상에서 상술한 본 발명은 도면을 참조하면서 기술되는 바람직한 실시예를 중심으로 설명되었지만 이에 한정되는 것은 아니다. 따라서 본 발명은 기재된 실시예로부터 도출 가능한 자명한 변형예를 포괄하도록 의도된 특허 청구범위의 기재에 의해 해석되어야 한다.

### 산업상 이용가능성


- [0073] 행위 인식, 얼굴 인식, 지문 인식, 음성 인식 및 홍채 인식 등과 같은 다양한 패턴 인식과 관련한 상업 응용이 발명에서 혜택을 얻을 수 있다.

### 부호의 설명

- [0074] 101: 트레이닝 용도의 입력 신호  
 102: 슬라이딩 윈도우  
 103: 프레임 시퀀스  
 104: 특징 추출부  
 105: 은닉 조건부 랜덤 필드  
 106: 매뉴얼 라벨  
 107: 매개변수  
 201: 테스트 용도의 입력 신호  
 202: 슬라이딩 윈도우  
 203 프레임 시퀀스  
 204: 특징 추출부  
 205: 은닉 조건부 랜덤 필드 모델  
 206: 매뉴얼 라벨  
 207: 데이터 라벨

도면

도면1



도면2

