



**(19) 대한민국특허청(KR)**  
**(12) 등록특허공보(B1)**

(45) 공고일자 2017년09월26일  
 (11) 등록번호 10-1778533  
 (24) 등록일자 2017년09월08일

(51) 국제특허분류(Int. Cl.)  
*A61B 5/021* (2006.01) *A61B 5/00* (2006.01)  
*G06N 3/04* (2006.01) *G06N 3/08* (2006.01)

(52) CPC특허분류  
*A61B 5/021* (2013.01)  
*A61B 5/7264* (2013.01)

(21) 출원번호 10-2016-0146595

(22) 출원일자 2016년11월04일

심사청구일자 2016년11월04일

(56) 선행기술조사문헌

논문, On Employing Nonparametric Bootstrap Technique in Oscillometric Blood Pressure Measurement for Confidence Interval Estimation, 멀티미디어학회논문지, (2014. 02.)

논문, Oscillometric Blood Pressure Estimation Based on Maximum Amplitude Algorithm Employing Gaussian Mixture Regression, IEEE transactions on instrumentation and measurement, (2013. 12.)

기술이전 희망 : 기술양도

(73) 특허권자

**인천대학교 산학협력단**

인천광역시 연수구 아카데미로 119 (송도동)

(72) 발명자

**전광길**

인천광역시 연수구 경원대로119번길 21, 114동 904호(동춘동, 풍림2차아파트)

(74) 대리인

**특허법인충정**

전체 청구항 수 : 총 4 항


심사관 : 최석규

**(54) 발명의 명칭 기계 학습에 기반한 오실로메트릭 혈압 추정 방법**

**(57) 요약**

본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, (a) 샘플 혈압 측정치에 기반하여 측정치에 대한 오실로메트릭 파형의 엔벨로프를 획득하는 단계; (b) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프의 최대 진폭(MA)에 기반하여 의사 최대 진폭(PMA)을 획득하는 단계; (c) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프에 기반하여 의사 엔벨로프(PE)를 획득하는 단계; (d) 상기 의사 최대 진폭(PMA)과 상기 의사 엔벨로프(PE)를 연결하는 단계; (e) 기계 학습을 이용하여 개별적인 피험자에 대한 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계; 및 (f) 상기 추정된 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)에 기반하여 신뢰 구간(CI)과 함께 수축기 혈압(SBP) 및 이완기 혈압(DBP)을 추정하는 단계를 포함한다.

**대표도**



(52) CPC특허분류

*G06N 3/04* (2013.01)

*G06N 3/08* (2013.01)

공지예외적용 : 있음

---

**명세서**

**청구범위**

**청구항 1**

- (a) 샘플 혈압 측정치에 기반하여 측정치에 대한 오실로메트릭 파형의 엔벨로프를 획득하는 단계;
  - (b) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프의 최대 진폭(MA)에 기반하여 의사 최대 진폭(PMA)을 획득하는 단계;
  - (c) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프에 기반하여 의사 엔벨로프(PE)를 획득하는 단계;
  - (d) 상기 의사 최대 진폭(PMA)과 상기 의사 엔벨로프(PE)를 연결하는 단계;
  - (e) 기계 학습을 이용하여 개별적인 피험자에 대한 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계; 및
  - (f) 상기 추정된 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)에 기반하여 신뢰 구간(CI)과 함께 수축기 혈압(SBP) 및 이완기 혈압(DBP)을 추정하는 단계를 포함하고,
- 상기 단계 (e)는 가우시안 혼합 모델(GMM) 및 가우시안 혼합 회귀(GMR)에 기반하여 개별적인 피험자에 대한 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계를 포함하며,
- 상기 단계 (f)는,
- (f-1) 상기 단계 (e)에서 기계 학습을 통해 획득된 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)에 기반하여 평균 의사 엔벨로프상의 포인트들과 95%, 5% 백분위 엔벨로프 상의 포인트들을 결정하는 단계; 및
  - (f-2) 상기 평균 의사 엔벨로프 상의 포인트들을 컵 압력에 매핑하여, 상기 수축기 혈압(SBP)과 이완기 혈압(DBP) 및 대응하는 신뢰 구간(CI)을 추정하는 단계를 포함하는, 기계 학습에 기반한 오실로메트릭 혈압 추정 방법.

**청구항 2**

삭제

**청구항 3**

삭제

**청구항 4**

청구항 1에 있어서,

상기 단계 (e)는,

- (e-1) 복수의 오실로메트릭 파형들로부터 특징 벡터들을 추출하는 단계;
- (e-2) K-평균 알고리즘을 사용하여 상기 특징 벡터들을 K개의 클러스터들로 클러스터링하는 단계;
- (e-3) 상기 K개의 클러스터들에 기댓값 최대화(EM) 알고리즘을 적용하여 가우시안 혼합 모델(GMM: Gaussian mixture model) 매개변수들을 획득함으로써 특징 벡터들에 대응하는 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)의 가우시안 혼합 분포를 모델링하는 단계;
- (e-4) 피험자의 오실로메트릭 파형으로부터 특징 벡터를 추출하고 상기 가우시안 혼합 모델에 기반하여 타깃 클러스터를 식별하는 단계; 및
- (e-5) 상기 식별된 타깃 클러스터에 기반하여 가우시안 혼합 회귀를 이용하여 피험자의 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계를 포함하는, 기계 학습에 기반한 오실로메트릭 혈압 추

정 방법.

**청구항 5**

청구항 4에 있어서,

상기 특징 벡터는, 최대 진폭 알고리즘을 사용하여 추정된 평균 동맥압(MAP: mean arterial pressure), 엔벨로프 아래의 면적(AE: area under envelope), 및 오실로메트릭 파형의 엔벨로프의 비대칭 비율(AR: asymmetry ratio)을 포함하고,

상기 오실로메트릭 파형의 엔벨로프의 비대칭 비율은, MAPL/EL에 의해 획득되며, 상기에서 MAPL은 엔벨로프의 시작(t=0)부터 최대 진폭의 위치까지의 경과 시간이고, 상기 EL은 엔벨로프의 시작부터 엔벨로프의 끝까지의 경과 시간인, 기계 학습에 기반한 오실로메트릭 혈압 추정 방법.

**청구항 6**

청구항 5에 있어서,

상기 클러스터들의 개수 K는 4 내지 6인, 기계 학습에 기반한 오실로메트릭 혈압 추정 방법.

**발명의 설명**

**기술 분야**

[0001] 본 발명은 오실로메트릭 혈압 추정 방법에 관한 것으로, 특히 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 관한 것이다.

**배경 기술**

[0002] 혈압(BP: blood pressure)은 의료에서 가장 흔하게 측정되는 생리학적 매개 변수들 중 하나이다. 하지만, 혈압은 스트레스, 운동 및 질병과 같은 몇몇 요인들에 따른 본질적인 생리적 변동성으로 인하여 항상 변하기 때문에, 혈압 측정을 정확히 하는 것은 용이하지 않다. 하루에 걸쳐 수 심장 박동 이내에 20 mmHg까지의 변동성과 더 큰 변동성이 예측될 수 있다. 이들 변동성과 혈압 측정에 대한 이들의 영향은 대부분의 임상외에 의해 인지되지 않고 고려되지 않는다. 또한, 이 프로세스에서 획득된 혈압 추정치들은 종종 부정확한데, 왜냐하면 그들은 미국 국립 표준 협회(ANSI: American National Standard Institute)에 의해 설정된 허용가능한 한계치를 넘을 수 있기 때문이다. ANSI는 적어도 두 명의 훈련된 관찰자들에 의해 행해진 청진 기준 판독과 비교하여 표준 편차 8 mmHg를 가지고 5 mmHg의 최대 허용가능한 디바이스 평균 오차를 권고한다. 흥미롭게도, 코로트코프(Korotkoff) 청진 방법은 골든 표준(golden standard)으로서, 훈련된 의사들은 수축기 혈압(SBP: systolic blood pressure)과 이완기 혈압(DBP: diastolic blood pressure)에 대응하는 음(sound)을 경청한다. 청진 방법은 전형적으로 단일 측정 또는 기껏해야 두번의 측정을 포함하기 때문에 변동성을 고려할 아무런 수단도 가지고 있지 않다.

[0003] 최근에 혈압 추정을 위한 오실로메트릭 방법들이 인기를 얻고 있는데 이것은 이 측정 프로세스가 자동화된 것이고 가정용으로 이용가능하기 때문이다. 오실로메트릭 혈압 측정 장치들은 일반적으로 아무런 신뢰 구간(CIs: confidence intervals) 없이 단지 단일 포인트 추정치를 제공하고 생리적인 이유로 인하여 추정치들의 통계적인 변동(추정치들에 기인한 오차)과 본질적인 변동성에 기인한 추정치들의 변동을 구별할 어떤 수단도 제공하지 않는다. 그러므로 혈압 측정치들에 대한 신뢰 구간(CI)을 특정화하는 것이 유익할 수 있다. 청진 방법 이외에 아무런 비침습적 골든 표준도 존재하지 않기 때문에 현재 혈압 추정치들의 변동을 결정하는 아무런 방법도 존재하지 않는다. CI 추정이 혈압 측정 장치들에서 이용가능하다면, 넓은 CI 추정치들은 다른 측정을 유발할 수 있고 현재의 측정치를 폐기하는 것을 권고할 수 있다. 신뢰 구간(CI) 추정치 없이, 혈압 추정치들을 의미 있게 해석하는 것은 어렵다.

**선행기술문헌**

**비특허문헌**

[0004]

- (비특허문헌 0001) [1] D.W. Jones, J.E. Hall, Hypertension-pathways to success, *Hypertens. Editor.* 51 (5) (2008) 1249-1251.
- (비특허문헌 0002) [2] E. O'Brien, J. Petrie, W. Littler, M.D. Swiet, P.L. Padeld, D.G. Altman, M. Bland, A. Coate, N. Atkins, The British hypertension society protocol for the evaluation of blood pressure measuring devices, *J. Hypertens.* 11 (2) (1993) 43-62.
- (비특허문헌 0003) [3] K. Soueidan, S. Chen, H. Dajani, M. Bolic, V. Groza, Augmented blood pressure measurement through the noninvasive estimation of physiological arterial pressure variability, *Physiol. Meas.* 33 (6) (2012) 881-899.
- (비특허문헌 0004) [4] Manual, Electronic or Automated Sphygmomanometers, American National Standard ANSI 2003/AAMI SP 10: 2002 (2003).
- (비특허문헌 0005) [5] S. Lee, M. Bolic, V.Z. Groza, H.R. Dajani, S. Rajan, Confidence interval estimation for oscillometric blood pressure measurements using bootstrap approaches, *IEEE Trans. Instrum. Meas.* 60 (10) (2011) 3405-3415.
- (비특허문헌 0006) [6] BIPM, IEC, IFCC, ISO, IUPAC, OMIL, Guide to the expression of uncertainty in measurement, 1993.
- (비특허문헌 0007) [7] S. Lee, S. Rajan, C.-H. Park, J.-H. Chang, H. Dajani, V. Groza, Estimated confidence interval from single pressure measurement based on algorithmic fusion, *Comput. Biol. Med.* 62 (2015) 154-163.
- (비특허문헌 0008) [8] L.R. Krakoff, Condence limits for interpretation of home blood pressure recordings, *Blood Press. Monit.* 14 (4) (2009) 172-177.
- (비특허문헌 0009) [9] G. Drzewiecki, R. Hood, H. Apple, Theory of the oscillometric maximum and the systolic and diastolic ratios, *Ann. Biomed. Eng.* 22 (1) (1994) 88-96.
- (비특허문헌 0010) [10] S. Lee, G. Jeon, S. Kang, Two-step pseudomaximum amplitude-based on condence interval estimation for oscillometric pressure measurements, *BioMed Res. Int.* 2015 (2015), 1-9, ID 920206.
- (비특허문헌 0011) [11] L.A. Geddes, M. Voelz, C. Combs, D. Reiner, C.F. Babbs, Characterization of the oscillometric method for measuring indirect blood pressure, *Ann. Biomed. Eng.* 10 (6) (1982) 271-280.
- (비특허문헌 0012) [12] P.D. Baker, D.R. Westenskow, K. Kuck, Theoretical analysis of non-invasive oscillometric maximum amplitude algorithm for estimating mean blood pressure, *Med. Biol. Eng. Comput.* 35 (3) (1997) 271-278.
- (비특허문헌 0013) [13] S. Lee, J.-H. Chang, S.W. Nam, C. Lim, S. Rajan, H. Dajani, V. Groza, Oscillometric blood pressure estimation based on maximum amplitude algorithm employing Gaussian mixture regression, *IEEE Trans. Instrum. Meas.* 62 (12) (2013) 3387-3389.
- (비특허문헌 0014) [14] R. Raamat, J. Talts, K. Jagomagi, J. Kivastik, Errors of oscillometric blood pressure measurement as predicted by simulation, *Blood Press. Monit.* 16 (5) (2011) 73-76.
- (비특허문헌 0015) [15] J. Liu, J.O. Hahn, R. Mukkamala, Error mechanisms of the oscillometric fixed ratio blood pressure measurement method, *Ann. Biomed. Eng.* 41 (3) (2013) 587-597.
- (비특허문헌 0016) [16] P.D. Baker, J.A. Orr, D.R. Westenskow, T.P. Egbert, Method for determining blood pressure utilizing a neural network, U.S. Patent 5 339 818, 23, 1994.
- (비특허문헌 0017) [17] S. Narus, T. Egbert, T.-K. Lee, J. Lu, D. Westenskow, Noninvasive blood pressure monitoring from the supraorbital artery using an articial neural network oscillometric algorithm, *J. Clin. Monit.* 11 (5) (1995) 289-297.

- (비특허문헌 0018) [18] S. Colak, C. Isik, Blood pressure estimation using neural networks, in: Proceedings of the IEEE International Conference on CIMS, Boston, MA, July 2004, pp. 21-25.
- (비특허문헌 0019) [19] M. Forouzanfar, H. Dajani, V. Groza, M. Bolic, M.S. Rajan, Feature-based neural network approach for oscillometric blood pressure estimation, IEEE Trans. Instrum. Meas. 60 (8) (2011) 2786-2796.
- (비특허문헌 0020) [20] J. Wang, G. Jeon, J. Jeong, A hybrid algorithm using maximum a posteriori for interlaced to progressive scanning format conversion, IEEE/OSA J. Disp. Technol. 11 (2) (2015) 183-192.
- (비특허문헌 0021) [21] G. Jeon, M. Anisetti, D. Kim, V. Bellandi, E. Damiani, J. Jeong, Fuzzy rough sets hybrid scheme for motion and scene complexity adaptive deinterlacing, Image Vis. Comput. 27 (4) (2009) 425-436.
- (비특허문헌 0022) [22] S. Chen, Improving algorithms for oscillometric blood pressure estimation by suppressing breathing effects (M.S. thesis), University of Ottawa, Ottawa, ON, Canada, 2010.
- (비특허문헌 0023) [23] S. Ahmad, M. Bolic, H. Dajani, V. Groza, I. Batkin, S. Rajan, Measurement of heart rate variability using an oscillometric blood pressure monitor, IEEE Trans. Instrum. Meas. 59 (10) (2010) 2575-2590.
- (비특허문헌 0024) [24] W.L. Martinez, A.R. Martinez, Computational Statistics Handbook with Matlab, Chapman & Hall/CRC, 2008.
- (비특허문헌 0025) [25] S. Lee, S. Rajan, H. Dajani, V. Groza, M. Bolic, Determination of blood pressure using Bayesian approach, in: Proceedings of the International Conference on IEEE Instrumentation and Measurement Technology 2011, Binjiang, China, May 2011, pp. 1-5.
- (비특허문헌 0026) [26] A. Dempster, N. Laird, D. Rubin, Maximum likelihood from incomplete data via the EM algorithm, J. R. Stat. Soc. 39 (1) (1977) 1-38.
- (비특허문헌 0027) [27] B. Efron, R. Tibshirani, Bootstrap methods for standard errors, condence interval, and other measures of statistical accuracy, Stat. Sci. 1 (1) (1986) 54-77.
- (비특허문헌 0028) [28] A.M. Zoubir, B. Boashash, The bootstrap and its application in signal processing, IEEE Signal Process. Mag. 15 (1) (1998) 56-76.
- (비특허문헌 0029) [29] R. Xu, D. Winsch II, Survey of clustering algorithms, IEEE Trans. Neural Netw. 16 (3) (2005) 645-678.
- (비특허문헌 0030) [30] S. Chen, V.Z. Groza, M. Bolic, H.R. Dajani, Assessment of algorithms for oscillometric blood pressure measurement, in: Proceedings of the International Conference on IEEE Instrumentation and Measurement Technology 2009, Singapore, May 2009.
- (비특허문헌 0031) [31] H.C. Lin, Specialised non-invasive blood pressure measurement algorithm (thesis), Master of Engineering, Auckland University of Technology, Auckland, New Zealand, 2007.
- (비특허문헌 0032) [32] S. Theodoridis, K. Koutroumbas, Pattern Recognit, Academic Press, 2009.
- (비특허문헌 0033) [33] C.M. Bishop, Pattern Recognition and Machine Learning, Springer, 2006.
- (비특허문헌 0034) [34] M.M. Chiang, Intelligent choice of the number of clusters in K-means clustering: an experimental study with different cluster spreads, J. Classif. 27 (2010) 3-40.
- (비특허문헌 0035) [35] C.J. Mclachlan, Mixture Model: Inference and Applications to Clustering, Taylor & Francis, 1987.
- (비특허문헌 0036) [36] S. Calinon, F. Guenter, A. Billard, On learning, representing, and generalizing a task in a humanoid robot, IEEE Trans. Syst. Man Cybern. B Cybern. 37 (2) (2007) 286-298.

(비특허문헌 0037) [37] D. Cohn, Z. Ghahramani, M. Jordan, Active learning with statistical models, Artif. Intell. Res. 4 (1996) 129-145.

(비특허문헌 0038) [38] K.V. Mardia, J.T. Kent, J.M. Bibby, Multivariate Analysis, Academic Press, London, United Kingdom, 1979.

(비특허문헌 0039) [39] H.G. Sung, Gaussian mixture regression and classification (Ph.D. thesis), Rice University, Houston, Texas, 2004.

## 발명의 내용

### 해결하려는 과제

[0005] 본 발명이 해결하고자 하는 과제는 부트스트랩과 기계 학습을 조합함으로써 적은 수의 샘플로부터 피험자에 개별화된 특성 비율을 획득하여 정확한 혈압 추정치들 및 개선된 신뢰 구간(CIs)을 제공할 수 있는, 기계 학습에 기반한 오실로메트릭 혈압 추정 방법을 제공하는 것이다.

### 과제의 해결 수단

- [0006] 상기 과제를 해결하기 위한 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은,
- [0007] (a) 샘플 혈압 측정치에 기반하여 측정치에 대한 오실로메트릭 파형의 엔벨로프를 획득하는 단계;
- [0008] (b) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프의 최대 진폭(MA)에 기반하여 의사 최대 진폭(PMA)을 획득하는 단계;
- [0009] (c) 비모수 부트스트랩을 사용하여 상기 측정치에 대한 오실로메트릭 파형의 엔벨로프에 기반하여 의사 엔벨로프(PE)를 획득하는 단계;
- [0010] (d) 상기 의사 최대 진폭(PMA)과 상기 의사 엔벨로프(PE)를 연결하는 단계;
- [0011] (e) 기계 학습을 이용하여 개별적인 피험자에 대한 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계; 및
- [0012] (f) 상기 추정된 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)에 기반하여 신뢰 구간(CI)과 함께 수축기 혈압(SBP) 및 이완기 혈압(DBP)을 추정하는 단계를 포함한다.
- [0013] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 있어서, 상기 단계 (e)는 가우시안 혼합 모델(GMM) 및 가우시안 혼합 회귀(GMR)에 기반하여 개별적인 피험자에 대한 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계를 포함할 수 있다.
- [0014] 또한, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 있어서, 상기 단계 (f)는,
- [0015] (f-1) 상기 단계 (e)에서 기계 학습을 통해 획득된 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)에 기반하여 평균 의사 엔벨로프상의 포인트들과 95%, 5% 백분위 엔벨로프 상의 포인트들을 결정하는 단계; 및
- [0016] (f-2) 상기 평균 엔벨로프 상의 포인트들을 컵 압력에 매핑하여, 상기 수축기 혈압(SBP)과 이완기 혈압(DBP) 및 대응하는 신뢰 구간(CI)을 추정하는 단계를 포함할 수 있다.
- [0017] 또한, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 있어서, 상기 단계 (e)는,
- [0018] (e-1) 복수의 오실로메트릭 파형들로부터 특징 벡터들을 추출하는 단계;
- [0019] (e-2) K-평균 알고리즘을 사용하여 상기 특징 벡터들을 K개의 클러스터들로 클러스터링하는 단계;
- [0020] (e-3) 상기 특징 클러스터들에 기댓값 최대화(EM) 알고리즘을 적용하여 가우시안 혼합 모델(GMM: Gaussian mixture model) 매개변수들을 획득함으로써 특징 벡터들에 대응하는 수축기 혈압 특성 비율(SBPR)과 이완기 혈

압 특성 비율(DBPR)의 가우시안 혼합 분포를 모델링하는 단계;

- [0021] (e-4) 피험자의 오실로메트릭 파형으로부터 특징 벡터를 추출하고 상기 가우시안 혼합 모델에 기반하여 타깃 클러스터를 식별하는 단계; 및
- [0022] (e-5) 상기 식별된 타깃 클러스터에 기반하여 가우시안 혼합 회귀를 이용하여 피험자의 수축기 혈압 특성 비율(SBPR)과 이완기 혈압 특성 비율(DBPR)을 추정하는 단계를 포함할 수 있다.
- [0023] 또한, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 있어서, 상기 특징 벡터는, 최대 진폭 알고리즘을 사용하여 추정된 평균 동맥압(MAP: mean arterial pressure), 엔벨로프 아래의 면적(AE: area under envelope), 및 오실로메트릭 파형의 엔벨로프의 비대칭 비율(AR: asymmetry ratio)을 포함하고,
- [0024] 상기 오실로메트릭 파형의 엔벨로프의 비대칭 비율은, MAPL/EL에 의해 획득되며, 상기에서 MAPL은 엔벨로프의 시작(t=0)부터 최대 진폭의 위치까지의 경과 시간이고, 상기 EL은 엔벨로프의 시작부터 엔벨로프의 끝까지의 경과 시간일 수 있다.
- [0025] 또한, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 있어서, 상기 클러스터들의 개수 K는 4 내지 6일 수 있다.

**발명의 효과**

- [0026] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 의하면, 부트스트랩과 기계 학습을 조합함으로써 적은 수의 샘플로부터 피험자에 개별화된 특성 비율을 획득하여 정확한 혈압 추정치들 및 개선된 신뢰 구간(CIs)을 제공할 수 있다.

**도면의 간단한 설명**

- [0027] 도 1은 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 흐름도.  
 도 2는 가우시안 혼합 모델을 이용하여 수축기 혈압 특성 비율과 이완기 혈압 특성 비율을 결정하기 위한 단계의 상세 도면.  
 도 3a는 SBPR과 모든 다른 특징들 간의 상관을 도시한 도면이고, 도 3b는 DBPR과 다른 모든 특징들 간의 상관을 도시한 도면으로, +, -는 각각 상관 및 역상관을 나타냄.  
 도 4a는 특징 세트에 대한 k-평균 알고리즘을 이용하여 획득된 3개의 클러스터들에 대한 실루엣 플롯을 도시한 것이고, 도 4b 내지 도 4c는 각각 4, 5, 및 6개의 클러스터들에 대한 실루엣 플롯을 도시한 것으로, 1에 가까운 실루엣 값들은 다른 것들보다 그들 자신의 클러스터에 더 근접하다는 것을 나타냄.  
 도 5a는 청진 간호사 측정치들(5×85=425)에 의해 리매핑된 SBPR에 대한 EM 알고리즘을 이용한 가우시안 혼합 밀도이고, 도 5b는 청진 간호사 측정치들(5×85=425)에 의해 리매핑된 DBPR에 대한 EM 알고리즘을 이용한 가우시안 혼합 밀도.  
 도 6은 의사 엔벨로프에 대한 리샘플링 프로세스를 도시한 도면으로, 도 6a는 원래의 엔벨로프, 도 6b는 리샘플 행렬들(j=1, ..., B<sub>1</sub>=100), 도 6c는 리샘플 행렬들(j=1, ..., B<sub>1</sub>=100)을 분류한 도면.  
 도 7은 의사 엔벨로프에 대한 리샘플링 프로세스를 도시한 도면으로, 도 7a는 리샘플 행렬들(j=1, ..., B<sub>1</sub>=100)의 분류된 구성요소들이고, 도 7b는 의사 엔벨로프들(j=1, ..., B<sub>1</sub>=100) 중 첫 번째 의사 엔벨로프를 도시한 도면.

**발명을 실시하기 위한 구체적인 내용**

- [0028] 본 발명의 목적, 특정한 장점들 및 신규한 특징들은 첨부된 도면들과 연관되어지는 이하의 상세한 설명과 바람직한 실시예들로부터 더욱 명백해질 것이다.
- [0029] 이에 앞서 본 명세서 및 청구범위에 사용된 용어나 단어는 통상적이고 사전적인 의미로 해석되어서는 아니되며, 발명자가 그 자신의 발명을 가장 최선의 방법으로 설명하기 위해 용어의 개념을 적절하게 정의할 수 있는 원칙에 입각하여 본 발명의 기술적 사상에 부합되는 의미와 개념으로 해석되어야 한다.
- [0030] 본 명세서에서 각 도면의 구성요소들에 참조번호를 부가함에 있어서, 동일한 구성 요소들에 한해서는 비록 다른

도면상에 표시되더라도 가능한 한 동일한 번호를 가지도록 하고 있음에 유의하여야 한다.

[0031] 또한, "제1", "제2", "일면", "타면" 등의 용어는, 하나의 구성요소를 다른 구성요소로부터 구별하기 위해 사용되는 것으로, 구성요소가 상기 용어들에 의해 제한되는 것은 아니다.

[0032] 이하, 본 발명을 설명함에 있어, 본 발명의 요지를 불필요하게 흐릴 수 있는 관련된 공지 기술에 대한 상세한 설명은 생략한다.

[0033] 이하, 첨부된 도면을 참조하여 본 발명의 바람직한 실시형태를 상세히 설명하기로 한다.

[0034] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, 오실로메트릭 혈압 측정에 대한 불확실성을 감소시킬 수 있으며 고정된 특성 비율(CRs: characteristic ratios)을 사용하지 않고 정확한 혈압 추정치들을 제공할 수 있는 방법을 제공한다. 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, 각 피험자에 대한 특성 비율들을 획득하기 위한 기계 학습 기법 및 부트스트랩 기법을 조합함으로써 신뢰 구간(CIs: confidence intervals)과 함께 혈압 추정치들을 제공하는, 하이브리드 접근법을 채택한다. 이러한 접근법은 오실로메트릭 측정 방법에서 CI와 함께 혈압 추정을 위하여 처음으로 제안된 것이다.

[0035] 요약하면, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에서 사용된 하이브리드 접근법은 CI를 제공하기 위하여 처음으로 제시되며, 정확한 혈압 측정을 위하여 가우시안 혼합 모델(GMM: Gaussian mixture model)과 가우시안 혼합 회귀(GMR: Gaussian mixture regression)가 조합된다.

[0036] 본 발명은 관용적인 기술에 비해 다음과 같은 이점을 가지고 있다.

[0037] - 부트스트랩과 기계 학습 기법을 조합함으로써 오실로메트릭 혈압 측정의 적은 수의 샘플로부터 정확한 혈압 추정치들 및 개선된 신뢰 구간(CIs)을 획득하여 제공할 수 있다.

[0038] - 실루엣 값을 이용하여 K-평균 알고리즘에서 클러스터들의 수를 효과적으로 선택할 수 있다.

[0039] - K-평균 알고리즘에서 상이한 K에 대해 혈압 추정의 부가적인 비교를 제공할 수 있다.

[0040] 데이터 세트

[0041] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에서는 바이오사인 테크놀로지(Biosign Technologies)(토론토, 온타리오, 캐나다)에서 제공한 오실로메트릭 혈압 측정치들을 데이터 세트로 사용하였다. 실험적인 혈압 측정치들은 아무런 심혈관 질환을 가지고 있지 않은, 12세 내지 80세의 건강한 85명의 피험자들로부터 기록되었는데, 이들 중 37명은 여자이고 48명은 남자이다. 각 자원자로부터 5 세트의 오실로메트릭 혈압 측정치들(5×85=425 총 측정치들: 단일 측정의 지속 범위: 31-95s, 지속 중간값: 55s)이 ANSI/AAMI SP 10 표준의 권고에 따라 100 Hz의 샘플링 비로 손목 착용형 UFIT<sup>®</sup> TEN-10 혈압 장치(바이오사인 테크놀로지 주식회사, 토론토, 온타리오, 캐나다)를 사용하여 획득되었다. 특히, 두 독립적인 관찰자(간호사)의 독출값들은 하나의 SBP와 하나의 DBP 독출값을 제공하도록 평균화되었다. 제공된 혈압 측정치 세트는 비교적 안정적인 관찰자(간호사) 독출값들을 포함하였는데, 두 관찰자 간의 최대 차이는 2 mmHg를 넘지 않았고, 평균 차이는 5 mmHg 미만이었기 때문에, ANSI/AAMI SP 10 표준 프로토콜의 권고를 충족하였다. 더 상세히, 혈압 측정치들은 1분의 휴식이 뒤따르는 두 명의 훈련된 간호사들에 의해 안내된 오실로메트릭 혈압 기록을 포함하였다. 이 단계는 5 측정치들의 기록을 형성하기 위하여 4번 더 반복되었다. 데이터 수집 동안, 각 피험자는 편안하게 의자에 앉아 똑바로 있었고, UFIT 측정기의 커프(cuff)가 심장 레벨까지 올라간 피험자의 왼쪽 손목에 부착되었다. 기준 장치인 청진 커프는 또한 심장 레벨에서 상부 좌측 팔 상에 배치되었다. 특히, 상부 커프는 상완동맥을 막도록 팔 주위에서 팽창하였다. 커프에서 공기가 빠질 때, 격동하는 혈류는 코로트코프 음(Korotkoff sounds)을 생성하였고, 이것은 상부 커프 옆에 배치된 청진기를 사용하여 용이하게 들을 수 있다. 상부 커프에 연결된 혈압계에 의해 mmHg 단위로 결정된 첫 번째 코로트코프 음(K1)은 SBP를 결정하는데 사용되었다. 또한, 5번째 음(K5)은 DBP를 추정하는데 사용되었다.

[0042] 상부 팔 혈압계에 의한 상완동맥의 폐색의 어려움 때문에, 동시적인 팔과 손목 측정은 불가능하다. 그래서, 각 펄스 웨이브 신호가 UFIT 자동화된 장치에 의해 획득된 시점에서 거의 1.5분 이후에, 두 명의 훈련된 간호사들은 동시적인 독출을 위한 수단이 제공되는 고전적인 상부 팔 혈압계를 이용하여 수축기 혈압(SBP<sub>1</sub>과 SBP<sub>2</sub>) 및 이완기 혈압(DBP<sub>1</sub>과 DBP<sub>2</sub>)을 동시에 기록하였다. 아래 첨자 1을 갖는 독출값들은 첫 번째 간호사에 의해 획득되었고 아래 첨자 2를 갖는 독출값들은 두 번째 간호사에 의해 획득되었다. 결과적으로, 각각 각 피험자에 대해 5

쌍의 결과들이  $\{SBP_{1j}, SBP_{2j}, |j = 1, \dots, 5\}$  과  $\{DBP_{1j}, DBP_{2j}, |j = 1, \dots, 5\}$  에 의해 주어진다.

[0043] 이우고, 첫 번째 간호사 및 두 번째 간호사에 의해 획득된 5개의 고전적인 상부 팔 혈압계 측정치들( $\{SBP_{1j}, SBP_{2j}, (DBP_{1j}, DBP_{2j}), |j=1, \dots, 5\}$ )은 각 피험자에 대해 자동화된 혈압 측정기  $UFIT_j | j=1, \dots, 5$ 에 의해 기록된 5개의 펄스 웨이브 바이오-신호 각각에 대해 대략 1.5분의 지연에 대응한다. 고전적인 상부 팔과 팔목 측정치들 간의 지연 시간은 시간에 걸친 자연적인 혈압 변동성을 최소화하기 위하여 가능한 한 짧은 것이 좋을 뿐만 아니라 측정 동안 동맥의 폐색 이후에 체계를 안정시키기에 충분할 정도로 길 수 있다. 팔과 손목 측정 간의 약 1.5분의 지연 시간은 방법 오차를 최소화하는데 있어서 타협에 기초하여 선택된다.

[0045] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법

[0046] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, 각각 비모수 부트스트랩과 가우시안 혼합 회귀(GMR: Gaussian mixture regression)의 조합으로서 간주될 수 있다. 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 SBP와 DBP의 특성 비율(CIs)을 개선하고 SBP와 DBP의 기준값들과 관련된 추정치들의 평균 오차(ME: mean error)와 오차의 표준 편차(SDE: standard deviation of the error)를 감소시킨다. 특히, 각 피험자에 대한 상기 SBP와 DBP 비율들(SBPR 및 DBPR)은 상기 SBPR 및 DBPR의 분포를 효과적으로 특징짓는 한 세트의 특징들을 사용하여 추정된다. 이들 특징들은 클러스터들의 스프레드(spread)를 평가하기 위하여 실루엣 기법을 사용하여 효과적으로 다수의 클러스터들로 그룹화될 수 있다. 특히, 상기 SBPR 및 DBPR은 간호사 측정치들을 사용하여 유도되고 평균 동맥압(MAP: mean arterial pressure)은 관용적인 최대 진폭 알고리즘(MAA: maximum amplitude algorithm)을 사용하여 추정된다. 기준값으로서 상기 SBPR 및 DBPR은 하기 수학식 1 및 수학식 2와 같이  $i$ 번째 피험자의  $j$ 번째 측정에 대해 추정된다.

수학식 1

$$\hat{r}_s(i, j) = \frac{s_a(i, j)}{m_a(i, j)}$$

[0047]

수학식 2

$$\hat{r}_d(i, j) = \frac{d_a(i, j)}{m_a(i, j)}$$

[0048]

[0049] 상기에서  $\hat{r}_s$  및  $\hat{r}_d$ 는 청진 간호사 측정치들을 사용하여 획득된 상기 SBPR 및 DBPR을 나타낸다. 수학식 1 및 수학식 2에서,  $S_a$  및  $S_d$ 는 오실로메트릭 파형(OMW: oscillometric waveform) 엔벨로프 상에서 식별되고 각각 SBP 및 DBP에 대한 청진 간호사 측정치들을 제공하는 디플레이션(deflation) 커브에 매핑되는 SBP 및 DBP의 진폭들이며,  $m_a$ 는 상기 오실로메트릭 파형의 엔벨로프 내의 최대 진폭에 대응한다.

[0050] 전체 측정치들을 사용하여, 몇몇 타깃 그룹들이 형성되고 실루엣 기법이 K-평균 알고리즘에서 클러스터들의 수를 효과적으로 선택하는데 사용되는데, 상기 클러스터들은 상기 SBPR과 DBPR의 유사한 값들을 갖는다. 이 혼련 단계에서, 상기 SBPR과 DBPR은 기댓값 최대화(EM: expectation maximization) 알고리즘을 통해 획득된 가우시안 혼합 모델(GMM: Gaussian mixture model) 매개변수들을 통해 모델링된 혼합 분포로부터 도출되는 것으로 가정된다. 따라서, 테스트 단계에서 타깃 그룹들은 GMM에 기반하여 효과적으로 식별된다. 분류된 타깃 그룹들을 사용하여, 개선된 SBPR과 DBPR이 GMR 기법을 사용하여 유도된다. 특히 GMR은 설명 변수들과 종속 변수들 간의 관계가 비선형적인 경우 적용될 수 있는 특별한 형태의 선형 회귀이다. 따라서, 특징 벡터들은 설명 벡터들로서

사용되고 기준 SBP와 DBP로부터 획득된 기준 값(상기 SBPR과 DBPR)은 종속 변수로서 사용된다. 상기 GMM의 매개 변수들 및 설명 벡터들은 따라서 상기 SBPR과 DBPR(종속 변수)을 추정하기 위하여 최대 사후 확률에 의해 결정된 클러스터 인덱스에 따라 이용된다. 본 발명의 일 실시예에 의한 방법의 주된 아이디어는 상기 SBPR과 DBPR가 특정 스페이스내의 광역 클래스-간 거리 및 협역 클래스-내 분산에 기인한 유사한 생리적 특성들을 갖는 작은 그룹들로부터 회귀 기법을 사용하여 획득된다는 것이다. 이것은 관용적인 접근에서 초기에 제안된 바와 같이, 오실로메트릭 혈압 측정의 전체 세트로부터 획득된 고정된 SBPR과 DBPR보다 우월한 비율들을 초래할 것이다.

[0051] SBP와 DBP 추정치들의 신뢰 구간(CIs)을 개선하기 위하여, 초기에 설명된 기계 학습을 통해 획득된 상기 SBPR과 DBPR이 비모수 부트스트랩(NPB) 기법과 함께 사용된다. 상기 NPB 기법은, 특히 관용적인 방법이 실패할 경우, 적은 수의 측정치들로부터 추정치들의 정확도를 개선하는데 사용된다. 이 기법은 원래의 추정치들을 리샘플링(re-sampling)함으로써 많은 수의 독립적인 부트스트랩 추정치들을 제공하고 신뢰 구간은 이렇게 효과적으로 확장된 샘플 크기를 사용하여 결정된다. 상기 기본 아이디어는 미지의 확률 분포( $\Omega_{\Psi}$ )로부터 n 측정치들의 원래의 혈압 측정치들,  $\Psi = (\psi_1, \psi_2, \dots, \psi_n)$  를 리샘플링함으로써 많은 수의 독립적인 부트스트랩 혈압 추정치들을 제공하는 것이다. 원래의 측정치 세트( $\Psi$ )를 0, 1 또는 다수 발생하는 구성요소들로 대체하여 반복적으로 샘플링함으로써 많은 부트스트랩 리샘플들  $\Psi_j^{\otimes} = (\psi_1^{\otimes}, \psi_2^{\otimes}, \dots, \psi_n^{\otimes})$ ,  $j=1, \dots, B$ 을 생성할 수 있다. 각 부트스트랩 리샘플(resample)은 원래의 측정치 세트와 동일한 크기를 갖는다.  $\hat{\mu} = \hat{\mu}(\Psi)$  을  $\Omega_{\Psi}$  의 평균의 관심 추정자라고 하자. 목표는 진정한 평균( $\mu(\Psi)$ )의 분포와 유사한  $\hat{\mu}(\Psi)$ 의 특성을 찾는 것이다. 따라서, 추정된 평균( $\hat{\mu}$ )의 분포는 상기 부트스트랩 리샘플 분포,  $\hat{\Omega}_{\Psi^{\otimes}}$ 로부터의 의사 추정된 평균( $\hat{\mu}$ )의 분포에 의해 근사화된다.

[0052] SBP와 DBP에 대한 CI를 획득하는 방법에 수반되는 주된 단계들의 개요가 하기에 제공된다.

[0053] 모든 피험자에 대해,

[0054] (A) 오실로메트릭 파형들의 엔벨로프가 고려 중인 피험자에 대한 샘플 세트내의 모든 측정치들에 대해 획득되고, 상기 엔벨로프의 피크들이 평균 동맥압(MAP: mean arterial pressure)으로서 추정된다. 이 피크가 발생하는 시간이 또한 획득된다.

[0055] (B) 부트스트랩의 원리를 사용하여, 의사 최대 진폭(PMA: pseudo maximum amplitude)이 95% 및 5% 백분위와 함께 부트스트랩 리샘플들의 분포의 샘플 평균으로서 획득된다.

[0056] (C) 샘플 세트 내의 엔벨로프들에 부트스트랩 기법이 적용되고 평균 엔벨로프, 및 95% 및 5% 백분위에 대응하는 엔벨로프들이 또한 획득된다. 이들은 의사 엔벨로프(PE: pseudo envelopes)로 지칭된다.

[0057] (D) 이전 단계에서 획득된 PMA가 의사 엔벨로프들에 다시 내삽된다.

[0058] (E) 평균 커프(cuff) 압력이 피험자에 대한 모든 커프 압력 측정치들을 사용하여 획득된다.

[0059] (F) 기계 학습을 통해 획득된 SBPR 및 DBPR을 사용하여, 평균 의사 엔벨로프와 95% 및 5% 백분위 엔벨로프에 대한 포인트들이 결정된다.

[0060] (G) 그 다음 평균 엔벨로프 상의 포인트들이 커프 압력에 다시 매핑되는데, 이것에 의해 SBP 및 DBP 추정치들 및 대응하는 신뢰 구간(CIs)이 제공된다.

[0061] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에서 사용되는 혼합 방법은 도 1 및 도 2를 참조하여 설명된다.

[0062] 도 1을 참조하면, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, 단계 S100에서, 85명의 건강한 피험자들로부터 각각 5개의 혈압 측정치들이 획득된다. 단계 S102에서, 신호 처리를 이용하여 상기 측정치들로부터 오실로메트릭 파형을 획득한다. 단계 S104에서, 가중 평균 필터와 가우시안 커브 피

팅을 이용하여 엔벨로프가 획득된다. 단계 S106에서, 비모수 부트스트랩을 이용하여 의사 엔벨로프(PE: pseudo envelope)와 의사 최대 엔벨로프(PMA: pseudo maximum amplitude)가 획득된다. 단계 S108에서, PE와 PMA가 연결된다. 단계 S110에서, 가우시안 혼합 모델(GMM: Gaussian mixture model)과 가우시안 혼합 회귀(GMR: Gaussian mixture regression)를 적용하여 신뢰 구간(confidence interval)과 함께 수축기 혈압(SBP: systolic blood pressure)와 이완기 혈압(DBP: diastolic blood pressure)을 획득한다. 단계 S112에서는, 획득된 수축기 혈압과 이완기 혈압에 대한 평가가 수행된다.

[0063] 한편, 단계 S110은, 도 2에 도시된 가우시안 혼합 모델을 이용하여 수축기 혈압 특성 비율과 이완기 혈압 특성 비율을 결정하기 위한 단계에 의해 수행된다.

[0064] 도 2를 참조하면, 가우시안 혼합 모델을 이용하여 수축기 혈압 특성 비율과 이완기 혈압 특성 비율을 결정하기 위한 단계는 훈련 단계(S200)와 테스트 단계(S202)를 포함한다.

[0065] 훈련 단계(S200)에 대해 설명하면, 우선 단계 S204에서 혈압 측정치들에 대한 오실로메트릭 파형에 대해 전처리가 수행되고, 단계 S206에서 특징 벡터들이 추출된다.

[0066] 그 다음 단계 S208에서 특징 벡터들이 정규화되고, 단계 S210에서 K-평균 알고리즘을 이용하여 특징 벡터들이 클러스터링된다.

[0067] 그 다음 단계 S210에서, 특징 클러스터들에 대해 기댓값 최대화(EM: expectation-maximization) 알고리즘에 의한 훈련이 수행되어 GMM 매개변수들(S216)이 생성된다.

[0068] 다음, 테스트 단계(S200)에 대해 설명하면, 단계 S218에서 소정의 피험자에 대한 오실로메트릭 파형이 획득되고, 단계 S220에서 오실로메트릭 파형에 대해 전처리가 수행되며, 단계 S222에서 특징 벡터가 추출되며 추출된 특징 벡터에 대해 정규화가 수행된다.

[0069] 단계 S224에서는 GMM에 기반하여 추출된 특징 벡터에 대한 클러스터 인덱스가 결정되고, 단계 S226에서 GMR을 이용하여 수축기 혈압 비율(SBPR) 및 이완기 혈압 비율(DPBR)이 추정된다.

[0070] 하기에 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 대해 상세히 설명하기로 한다.

[0072] 의사 최대 진폭 및 의사 엔벨로프를 획득하기 위한 비모수 부트스트랩(NPB: nonparametric bootstrap) 기법

[0073] NPB 기법은 적은 수의 측정치들로부터 획득된 추정치들의 정확도를 개선하는데 사용되는 계산적인 도구이다. 이 기법은 관용적인 통계 접근법이 적용될 수 없는, 샘플 크기가 작은 경우 채택된다. 몬테 카를로 기법을 사용하는 대신에, 부트스트랩 기법에서는, 독립적인 추정치들이 원래의 추정치들을 리샘플링함으로써 획득된다. 이 기법은 신뢰 구간(CI)을 획득할 의도를 가지고, 최대 진폭 알고리즘(MAA: maximum amplitude algorithm)과 함께 고정된 특성 비율들을 사용하여, 오실로메트릭 혈압 측정에 적용되었다. 상기 의사 최대 진폭(PMA)과 의사 엔벨로프(PE) 추정 부분은 본 발명의 혼합 방법의 초기 부분을 형성한다.

[0075] 의사 최대 진폭(PMA)

[0076] 각 피험자에 대해 단지 5개의 측정치들만이 이용가능하기 때문에, 신뢰 구간(CI)을 결정하기 위하여 관용적인 통계 툴을 사용하는 것은 가능하지 않다. 샘플 세트들이 제한적인 경우, 신뢰 구간을 결정하기 위하여, 부트스트랩 기법이 적용될수 있다. 부트스트랩 기법을 적용하기 위하여, 피험자 당 모든 5개의 측정치들로부터 최대치들의 발생의 길이 및 최대 진폭들이 획득될 필요가 있다. 최대 진폭(MA: maximum amplitude)의 예비 값들은 NPB 기법에서 최종 의사 최대 진폭(PMA)을 결정하는데 사용된다.

[0077]  $\Psi = \{\psi_1, \dots, \psi_5\}$  를 MA들의 5 길이 위치의 세트라고 하고  $\Phi = \{\phi_1, \dots, \phi_5\}$  를 대응하는 5개의 MA

값들의 세트라 하자. 이들 두 세트들에 대해 NPB를 적용하여, B(=1000)개의 리샘플들,  $\Psi_j^{\otimes}$ ,  $\Phi_j^{\otimes}$ ,

$j=1, \dots, B$  을 생성하는데, 각각  $\Psi_j^{\otimes} = \{\psi_{1j}^{\otimes}, \dots, \psi_{5j}^{\otimes}\}$  이고  $\Phi_j^{\otimes} = \{\phi_{1j}^{\otimes}, \dots, \phi_{5j}^{\otimes}\}$  이다. 그 다음

$\hat{\mu}_{\Psi(j)}^{\otimes} = (1/N) \sum_{k=1}^N \psi_{kj}^{\otimes}$  와  $\hat{\mu}_{\Phi(j)}^{\otimes} = (1/N) \sum_{k=1}^N \phi_{kj}^{\otimes}$  에 의해 주어지는  $\hat{\mu}_{\Psi(j)}^{\otimes}$ 와

$\hat{\mu}_{\Phi^{(j)}}^{\otimes}$ 를 획득하기 위하여  $\Psi_j^{\otimes}$ 와  $\Phi_j^{\otimes}$ 에서 모든 측정치들의 평균을 계산하는데,  $N=5$ 이고  $j=1, \dots, B$ 이다.

NPB 추정치들  $\hat{\mu}_{\Psi^{(j)}}^{\otimes}$ 와  $\hat{\mu}_{\Phi^{(j)}}^{\otimes}$ 로부터 획득된 분포들은 비특허문헌 [5]에 도시되어 있는데, 이것은 오름차순에 기초하여, 각각 피험자 당 모든 5개의 측정치들로부터 획득된 PMA와 최대치들의 발생의 길이를 나타낸다. 그 다음 분류된 PMA들은  $\hat{\mu}_{\Phi^{(1)}}^{\otimes} \leq \hat{\mu}_{\Phi^{(2)}}^{\otimes} \leq \hat{\mu}_{\Phi^{(3)}}^{\otimes} \dots \leq \hat{\mu}_{\Phi^{(B-1)}}^{\otimes} \leq \hat{\mu}_{\Phi^{(B)}}^{\otimes}$ 로서 획득되고 PMA들의 길이 위치들은  $\hat{\mu}_{\Psi^{(1)}}^{\otimes} \leq \hat{\mu}_{\Psi^{(2)}}^{\otimes} \leq \hat{\mu}_{\Psi^{(3)}}^{\otimes} \dots \leq \hat{\mu}_{\Psi^{(B-1)}}^{\otimes} \leq \hat{\mu}_{\Psi^{(B)}}^{\otimes}$ 로서 획득된다.

[0078] 실제로, PMA의 위치와 PMA에 대해 비모수 부트스트랩을 사용하여 원하는  $100 \cdot (1 - \alpha)\%$  CI가 각각  $(\hat{\mu}_{\Psi^{(Q_1)}}^{\otimes}, \hat{\mu}_{\Psi^{(Q_2)}}^{\otimes})$  및  $(\hat{\mu}_{\Phi^{(Q_1)}}^{\otimes}, \hat{\mu}_{\Phi^{(Q_2)}}^{\otimes})$ 로서 획득되는데,  $Q_1$ 은  $B \cdot \alpha/2$ 의 정수부이고,  $Q_2 = B - Q_1 + 1$ 이며  $Q_3 = B/2$ 이다.  $\alpha=0.05$ 이고  $B=1000$ 에 대해,  $Q_1=25$ ,  $Q_2=976$ ,  $Q_3=500$ 이다. 따라서, 각각 SBP와 DBP의 신뢰 구간(CI)을 추정하기 위하여 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 의해 사용되는 PMA의 3개의 위치들이 획득된다.

[0080] 의사 엔벨로프(PEs: Pseudo Envelope)

[0081] 관용적인 MAA 기법은 SBP와 DBP를 추정하기 위하여 오실로메트릭 측정치들의 엔벨로프를 사용하기 때문에, 의사 엔벨로프(PE)가 고정된 특성 비율들을 가지고 SBP와 DBP의 신뢰 구간(CI)을 추정하기 위하여 비특허문헌 [5, 10]에서 제안되었다.

[0082] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에서는, 일단 의사 엔벨로프들이 피험자에 대해 획득되면, 그 피험자에 대한 GMR을 사용하여 획득된 SBPR과 DBPR은 PE 상에서의 SBP와 DBP의 위치들 및 SBP와 DBP와 연관된 신뢰 구간(CI)을 결정하기 위하여 PMA와 함께 사용된다.

[0083] 수학적 식 3에 표시된 바와 같이 측정 행렬 E는 각 피험자의 오실로메트릭 파형의 수축기와 이완기에 대한 5개의 측정치들에 대한 엔벨로프들로 구성된다;

**수학적 식 3**

$$\mathbf{E} = \begin{bmatrix} \mathbf{e}_{11} & \mathbf{e}_{12} & \cdot & \cdot & \mathbf{e}_{1N} \\ \mathbf{e}_{21} & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \mathbf{e}_{L1} & \cdot & \cdot & \cdot & \mathbf{e}_{LN} \end{bmatrix}$$

[0084]

[0085] 상기에서 L은 PE의 길이를 나타내고 N(=5)은 엔벨로프들의 수를 나타낸다. 각 컬럼은 오실로메트릭 측정치들의 엔벨로프를 나타낸다. 측정치들이 더 긴 경우 길이를 L로 절단하거나, 측정치들이 더 짧은 경우 길이 L로 외삽함으로써, 모든 엔벨로프들이 길이 L로 동일하게 조정되어야 한다는 것에 주목하라. 수학적 식 3에서의 엔벨로프 행렬 E로부터, NPB 기법을 사용하여,  $B_1$  리샘플 엔벨로프 행렬들  $\mathbf{E}_1^{\otimes}, \mathbf{E}_2^{\otimes}, \dots, \mathbf{E}_{B_1}^{\otimes}$ 이 생성된다. 의사 엔벨로프에 대한 리샘플링 프로세스에 대한 상세한 설명은 부록으로 제공된다. j번째 리샘플 엔벨로프 행렬  $\mathbf{E}_j^{\otimes}$  내의 의사 엔벨로프들은 수학적 식 4에 의해 주어진다.

수학식 4

$$\mathbf{E}_j^{\otimes} = \begin{bmatrix} \mathbf{e}_{11}^{\otimes} & \mathbf{e}_{12}^{\otimes} & \cdot & \cdot & \mathbf{e}_{1N}^{\otimes} \\ \mathbf{e}_{21}^{\otimes} & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \cdot & \cdot & \cdot & \cdot & \cdot \\ \mathbf{e}_{L1}^{\otimes} & \cdot & \cdot & \cdot & \mathbf{e}_{LN}^{\otimes} \end{bmatrix}$$

[0086]

[0087]

여기에서,  $j=1,2,\dots,B_1(=100)$ 이다. 또한, 수학식 4에서와 같이 오실로메트릭 파형의 원래의 엔벨로프들로부터 획득된 의사 엔벨로프들의 SBP와 DBP 부분들은 의사 엔벨로프들의 최대점들을 사용하여 분리될 수 있다. 수학식 4에서와 같이 SBP와 DBP에 대한 2개의 상이한 의사 엔벨로프 행렬들이 존재한다는 것에 주목해야 하는데, 이들은 오름차순 또는 내림차순 분류 기법을 제외하곤 거의 동일하기 때문에 수학식 4는 단지 의사 엔벨로프의 SBP 부분만을 나타낸다. 특히, SBP 부분은 (감소하는 커프 압력에 대응하는) 의사 엔벨로프의 상승 단계에 있고 DBP 부분은 의사 엔벨로프의 하강 단계에 있다. (각각 의사 엔벨로프들의 SBP와 DBP 부분들에 대해) 오름차순 및 내림차순 기법을 이용하기 위하여, 리샘플링된 혈압 의사 엔벨로프 행렬들이 재순서화된다. 분류된 행렬들 각각은 5개의 컬럼들을 가지며 각각은 길이 L을 갖는 혈압 측정치들에 대응한다. 그 다음 의사 엔벨로프 프로세스의 마지막 단계로서 획득되는 피험자 당 단일 혈압 엔벨로프 벡터가 수학식 5 내지 수학식 7을 사용하여 획득되는데, 원하는  $100 \cdot (1 - \alpha)\%$  NPB CI는  $(\mathbf{PE}_{Q_1}, \mathbf{PE}_{Q_2})$ 에 의해 주어진다. 여기에서  $Q_1 = \lfloor B_1 \cdot \alpha/2 \rfloor$  은  $B \cdot \alpha/2$  의 정수부이고,  $Q_2 = B - Q_1 + 1$  이며,  $Q_3 = \lfloor B_1/2 \rfloor$  는  $B_1/2$  의 정수부이며, 상기에 서  $\mathbf{PE}_{Q_1}$  내지  $\mathbf{PE}_{Q_3}$ 는 하기와 같다.

수학식 5

$$\mathbf{PE}_{Q_1} = \frac{1}{N} \sum_{i=1}^N \mathbf{E}_{Q_1}^{\otimes}(:, i)$$

[0088]

수학식 6

$$\mathbf{PE}_{Q_2} = \frac{1}{N} \sum_{i=1}^N \mathbf{E}_{Q_2}^{\otimes}(:, i)$$

[0089]

수학식 7

$$PE_{Q_3} = \frac{1}{N} \sum_{i=1}^N E_{Q_3}^{\otimes}(:, i)$$

[0090]

[0091] 상기에서  $E_{Q_1}^{\otimes}(:, i)$ ,  $E_{Q_2}^{\otimes}(:, i)$  및  $E_{Q_3}^{\otimes}(:, i)$  는 행렬  $E_{Q_1}^*$ ,  $E_{Q_2}^*$  및  $E_{Q_3}^*$ 의  $i$ 번째 컬럼을 나타내고,  $i=1, \dots, N(=5)$ 이다. 따라서, 상위, 하위 및 중간 PE들은 각각 수축기 및 이완기 엔벨로프 행렬들을 사용하여 SBP와 DBP에 대한 CI를 결정하는데 사용된다. 상기 접근법은 NPB 기법을 이용하여 PMA와 PE를 연결하기 때문에, 상기 기법은 2개의 방법들인 의사 최대 진폭 및 의사 진폭(PMAE)의 조합으로서 지칭된다. 마지막 단계에서, SBP와 DBP에 대한 CI 추정치를 결정하기 위하여 수학식 8에 도시된 바와 같이 평균 커프 압력(MCP: mean cuff pressure)이 획득될 필요가 있다.

수학식 8

$$CP_{\mu} = \frac{1}{N} \sum_{i=1}^N CP_i$$

[0092]

[0093] 상기에서  $CP_{\mu}$  는 피험자 당 MCP를 나타내고  $CP_i$  는 각 피험자의  $i$ 번째 커프 압력을 나타낸다.

[0094] SBP와 DBP를 추정하기 위하여, 특성 비율들(CRs)(즉 SBPR과 DBPR)은 기계 학습 기법을 이용하여 결정된다. 하기는 개별 피험자에 대한 특성 비율들(CRs)을 추정하기 위한 기계 학습 접근법에 관한 것이다.

[0096] SBPR과 DBPR을 추정하기 위한 기계 학습 접근법

[0097] 모든 피험자들에 대해 단일의 고정된 경험적으로 유도된 SBPR과 DBPR을 사용하는 대신에, 각 피험자에 대해 개별적인 비율들을 추정하기 위하여 기계 학습 기법이 사용된다. SBPR과 DBPR의 데이터 세트가 주어지는 경우, 본 아이디어는 비율들이 아무런 정확한 라벨도 갖지 않는, 어떤 점에서 유사한 방식으로 피험자들을 그룹화 또는 클러스터링하는 것이다. 따라서 라벨링되지 않은 데이터의 수집물로부터 무감독 클러스터링이 사용된다. 클러스터링은 라벨링되지 않은 데이터의 수집물에서 구조를 결정하는 무감독 분류 프로세스이기 때문에 무감독 기계 학습 기법이 사용된다. 클러스터링 알고리즘은 주어진 데이터를 클러스터들로 분할하고 무엇이 클러스터를 구성하는지에 대한 아무런 동의된 정의도 존재하지 않는다. 몇몇 클러스터링 알고리즘들이 존재하고 이들 중 대부분은 하기의 4개의 단계들을 따른다:

- [0098] · 특징 선택
- [0099] · 클러스터 알고리즘 선택
- [0100] · 클러스터 유효화
- [0101] · 결과 해석(주의: 결과들은 GMM과 GMR을 사용하여 결정된 비율들을 통해 해석된다)

[0102] 비율들을 그룹화하기 위하여, 오실로메트릭 파형들로부터의 특징들이 유도되고 유도된 특징들의 유사성에 기초하여 클러스터링이 수행된다. 비율들의 성공적인 그룹화를 위하여, 오실로메트릭 파형으로부터 특징들을 신중하게 선택할 필요가 있다.

[0103] 특징 선택

[0104] 적합한 전처리 이후에, 하기의 특징들이 비율들을 클러스터링하기 위하여 고려된다:

- [0105] · MAP: MAA를 사용하여 추정된 평균 동맥압(MAP: mean arterial pressure)
- [0106] · MA: 오실로메트릭 파형의 엔벨로프의 최대 진폭(MA: maximum amplitude)의 값
- [0107] · MAPL: 엔벨로프의 시작(t=0)과 최대 진폭의 위치(MAPL) 사이의 경과 시간
- [0108] · EL: 엔벨로프의 시작과 엔벨로프의 끝 사이의 경과 시간
- [0109] · AE: 엔벨로프 아래의 면적(AE)
- [0110] · MAPL/EL로서 정의되는, 오셀로메트릭 파형의 엔벨로프의 비대칭 비율(AR)
- [0111] · HR: 엔벨로프 파형의 심박수(HR)
- [0112] · MAXROC: 진폭의 시간적 비율 변화의 오실로메트릭 파형의 최대 포지티브(MAXROC)
- [0113] · MINROC: 변화율의 최대 네거티브(MINROC)
- [0114] · AG: 피험자 나이(AG)

[0115] 콜모고로프 스미르노프(Kolmogorov-Smirnov) 테스트가 각각의 특징 분포의 정규성을 확인하기 위하여 수행되었다. 그 다음 허용된 특징 값들의 범위가 사전 정의된 범위의 최소값과 최대값 사이에 존재하도록 제한하기 위하여 공통 정규화 기법이 적용되었다. 유용한 정보가 있는 특징들만을 보유하기 위하여 양측(two-sided) t-테스트가 수행되고 그 후에 도 3에 도시된 바와 같이 간호사 SBP와 DBP 측정치들을 가지고 상관 분석이 수행된다. 특히, 상기 특징들은 상관 계수의 절대값에 기초하여 순위가 매겨지고 상위 4개의 특징들, 즉 MAP, MAPL, AR 및 AE가 도 3a에의 SBPR 비율들을 클러스터링하기 위하여 고려되며, 상위 4개의 특징들, 즉 MAP, AR, MAP 및 HR이 DBPR을 위해 도 3b에서 고려된다. AR은 MAPL과 EL로부터 계산된다는 것에 주목하라. 따라서, 타깃 비율들을 추정하기 위한 독립 변수들로서 MAP, AR 및 AE가 선택될 수 있다.

[0117] 클러스터링 알고리즘 선택

[0118] 특징 클러스터링은 특징들 사이의 유사성 또는 비유사성에 관한 유용한 정보를 추출하는데 사용된다. 무감독 학습 환경에서, 상기 특징들은 아무런 클래스 라벨도 가지고 있지 않기 때문에, 특징 세트에 존재하는 클러스터들 또는 클래스들의 수가 발견될 필요가 있다. 이 발견은 일반적으로 클러스터링 프로세스를 통해 달성된다. 클러스터링을 위한 몇몇 알고리즘들이 존재한다. 물론, K-평균 알고리즘은 클러스터링 알고리즘에서 일반적으로 사용되는데 클러스터링 알고리즘에서 K-평균 알고리즘 방법은 클러스터-내 제곱합을 최소화하도록 특징 세트를 K 클러스터들로 클러스터링하는데 사용된다. N 특징들을 포함하는 특징 세트  $\{P_1, P_2, \dots, P_N\}$ 을 고려하자. 상기에서 각각의 특징  $P_i$ 는  $D \times 1$  벡터이다.  $c_k$ 를 클러스터들의 중심이라 하자. 상기에서  $k=1, \dots, K$ 이다.

**수학식 9**

$$J = \sum_{n=1}^N \sum_{k=1}^K u_{nk} \| \mathbf{p}_n - \mathbf{c}_k \|^2$$

[0119]

[0120] 상기에서 J는 비용 함수이고,  $\| \cdot \|$ 는 유클리드 거리를 나타내며,  $P_n$ 이  $c_k$ 에 가장 근접한 곳에 있는 경우  $u_{nk}=1$  이고; 그렇지 않으면 0 이다.

수학식 10

$$u_{nk} = \begin{cases} 1 & \text{if } k = \arg \min_j \| \mathbf{p}_n - \mathbf{c}_j \|^2 \\ 0 & \text{otherwise.} \end{cases}$$

[0121]

[0122] 특징 벡터가 클러스터 K에 할당되는 경우  $j \neq k$ 에 대해  $u_{nk}=1$ 이고  $u_{nj}=0$ 이다.

[0124] 클러스터 유효화

[0125] 하기의 2개의 기본적인 질문들이 종종 클러스터링에서 떠오른다:

- [0126] · 클러스터들의 적합한 수는 얼마인가?
- [0127] · 진정한 클러스터들의 적합한 표현은 무엇인가?

[0128] 이와 관련하여, 실루엣(silhouette) 값은 특징 세트에서 클러스터들의 수를 선택하는 균형이 잡힌 방법이고, 종종 실험에서 양호한 성능을 보여주었다. 실루엣 폭은 클러스터내의 포인트들이 클러스터의 외부에 있는 점들에 비해 서로 얼마나 근접하여 있는 지를 나타내는 척도이다. 클러스터 내의  $i$ 번째 특징을 고려하면, 이 멤버에 대한 실루엣 폭은 하기와 같이 정의된다:

수학식 11

$$s_i = \frac{\zeta_i - \eta_i}{\max(\eta_i, \zeta_i)}$$

[0129]

[0130] 상기에서  $\zeta_i$ 는  $i$ 와 다른 클러스터들내의 모든 특징들 간의 평균 거리의 최소값을 나타내고,  $\eta_i$ 는 그 자신의 클러스터 내의 모든 다른 특징들까지의 평균 거리를 나타낸다. 실루엣 값은 -1 부터 1까지 범위를 갖는다. 대조적으로, 실루엣 폭이 1에 근접한 경우, 그것은 상기 특징이 잘 클러스터링되어 있다는 것을 의미한다. 실루엣 폭이 -1에 근접한 경우, 그것은 상기 특징이 잘못 분류되어 있다는 것(즉 잘못된 클러스터에 있다는 것)을 의미한다. 평균 실루엣 값(SV)은 하기와 같이 정의된다.

수학식 12

$$a_s = \frac{1}{N} \sum_i s_i$$

[0131]

[0132] 상기에서  $N$ 은 클러스터링될 필요가 있는 특징들의 총 수이다. 최적의 SV는 클러스터 간 거리를 최대화하고 클러스터내 거리를 최소화한다. SV가 0과 1 사이의 범위에 있고, SV가 클수록, 클러스터링이 더 양호하다는 것을 주목하라. 상이한  $K$  클러스터들 중에서, 최대 SV를 갖는  $K$ 의 값은  $N$ 개의 특징들의 세트에 존재하는 클러스터들의 수로서 취해진다.

[0133] 몇 개의 클러스터들( $K=3-6$ )은 SV를 획득하는데 사용되었다. 도 4에 도시된 바와 같이, 클러스터들  $K(3$ 부터  $6$ 까지)를 가지고, 도 4b에서의  $K=4$  클러스터의 SV는 0.60인데 반하여, 도 4d에서의  $K=6$ 의 SV는 0.54이다. 0.5보다 큰 SV는 특징 세트의 합리적인 클러스터링을 나타낸다. 따라서, 본 발명에서, 클러스터들의 수,  $K=4, 5, 6$ 이 SV

로서 고려될 것인데, 이것은 모든 이들 수의 클러스터들이 0.5보다 큰 SV를 가지기 때문이다. 상술된 프로세스를 통해 결정된 클러스터들의 수는 GMM에 대한 혼합 순서로서 사용된다.

[0135] GMM 및 GMR을 이용한 비율 결정

[0136] 가우시안 혼합 모델(GMM: Gaussian mixture model)의 적용

[0137] MAA에 기반하여 SBPR과 DBPR을 결정하기 위하여, GMM이 이용되는데, 이것은 이들 비율들의 분포가 도 5a 및 도 5b에 도시된 바와 같이 단일 가우시안 분포를 담지 않기 때문이고, 단일 가우시안 분포는 SBPR과 DBPR에 대한 다중 분포를 특징지을 수 없기 때문이며 따라서 가우시안 분포의 혼합이 채택된다. GMM은 임의의 밀도에 대한 유연한 근사값을 획득하는데 사용되는 파라메트릭 확률 밀도 함수이다. 그것은 평균과 공분산 행렬에 의해 매개 변수화되는 개별적인 가우시안 밀도의 선형 조합을 사용함으로써 임의의 밀도를 양호하게 모델링한다. 그것은 분포에서 멀티 모달리티(multi-modality)를 캡처하는 능력을 갖는다. GMM은 어떤 밀도에 대해서도 유연한 근사치들을 형성할 수 있기 때문에, 그것은 SBPR과 DBPR에 대한 분포를 특징짓도록 선택된다. 혈압 측정치들은 초기에 그룹들로 클러스터링되고 이들 그룹들은 K-평균 알고리즘을 사용하여 GMM 매개 변수들에 의해 용이하게 식별될 수 있다.

[0138] 특히, GMM은 하기 형태의 K 성분 가우시안 밀도들의 가중 합이다.

**수학식 13**

$$p(\mathbf{x} | \lambda) = \sum_{k=1}^K w_k \mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$$

[0139]

[0140] 상기에서  $\mathbf{x}$ 는 D-차원 특징 벡터들(SBPR 또는 DBPR, MAP, AR 및 AE)을 나타내고,  $w_k$ 는,  $k=1, \dots, K$ , 혼합 가중치들이며,  $\mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k)$ 은 평균 벡터  $\boldsymbol{\mu}_k$ 와 공분산 행렬  $\boldsymbol{\Sigma}_k$ 를 갖는 가우시안 밀도 성분들이다:

**수학식 14**

$$\mathcal{N}(\mathbf{x} | \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k) = \frac{1}{(2\pi)^{D/2} |\boldsymbol{\Sigma}_k|^{0.5}} \exp\left\{-0.5(\mathbf{x} - \boldsymbol{\mu}_k)' \boldsymbol{\Sigma}_k^{-1} (\mathbf{x} - \boldsymbol{\mu}_k)\right\}$$

[0141]

[0142]  $|\boldsymbol{\Sigma}_k|$ 는  $|\boldsymbol{\Sigma}_k|$ 의 계수(determinant)를 나타냄을 주목하라. 혼합 가중치들  $w_k$ 는 하기의 요건을 만족한다:

$\sum_{k=1}^M w_k = 1$ . 그룹화된 비율의 세트는 GMM 매개 변수들에 의해 모델링되고,  $\lambda_k = \{w_k, \boldsymbol{\mu}_k, \boldsymbol{\Sigma}_k\}$ 이며, 상기 매개 변수들은 기댓값 최대화(EM: expectation maximization) 알고리즘을 사용하여 반복적으로 획득된다.

[0144] 가우시안 혼합 회귀(GMR: Gaussian mixture regression)

[0145] GMR은 비선형 환경에서 설명 변수들과 종속 변수 간의 관계를 나타내기 위한 특별한 형태의 다중 선형 회귀이다. 본 발명의 실시예에서, (MAP, AR 및 AE) 및 기준 SBPR과 DBPR 사이에 상당한 상관이 존재한다. 따라서, 특징 벡터 (MAP, AR 및 AE)가 설명 벡터들로서 사용되고 종속 변수로서 기준 SBPR과 DBPR로부터 획득된 특징 값 (SBPR 또는 DBPR)이 사용된다. 그러므로 GMM의 매개 변수들과 설명 벡터들은 테스트 단계에서 SBPR 또는 DBPR (즉, 종속 변수)을 추정하기 위한 최대 사후 확률에 의해 결정된 클러스터 인덱스에 따라 사용된다.

[0146] 그룹화 동작에서, 각 타깃은 GMM, 즉  $\lambda_k$ 에 의해 특징지어지고, 혼합 순서(MO: mixture order)에 대한 종속성

은  $m_0 \geq 4$  일 때 미미하다. GMM에 기초하여, 하기에 주어진 바와 같이 피험자 특징에 대한 최대 사후 확률을 사용하여 그룹화된 특징 벡터들의 인덱스가 추정된다.

수학식 15

$$\hat{k}_{(i,j)} = \arg \max_{k=1,\dots,K} \log \hat{p}(\lambda_k | \mathbf{u}_{(i,j)})$$

[0147]

상기에서  $\hat{k}$  은 클러스터링된 특징의 인덱스를 나타내고,  $K(=3-6)$ 는 유사한 SBPR과 DBPR을 갖는 타깃들의 수를 나타낸다. 그러므로 상기 SBPR과 DBPR은 GMR에 기초하여 획득되는데 GMR은 각각 각 피험자의 측정치에 대해 추정된 타깃 비율로서  $\hat{y}$  을 추정하기 위하여 첫 번째, 두 번째 및 세 번째 로우들(rows)이 입력 벡터들(MAP, AR 및 AE)로서 사용되는, 설명 벡터들  $\mathbf{u}_{(i,j)} = [u_1, u_2, u_3]^T$  의 조인트 밀도 분포를 모델링하는 것에 의존한다.

[0148]

다변수 가우시안 분포의 중요한 특징은 MAP, AR 및 AR와 같은 입력 특징 벡터들과 SBPR 또는 DBPR과 같은 출력 변수들이 공동으로 가우시안 분포되어 있다는 것이다. 따라서, MAP, AR 및 AE를 조건으로 하는 SBPR 또는 DBPR의 조건부 분포는 또한 가우시안 분포이다.  $x$ 를  $\mathcal{N}(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma})$  을 갖는 D-차원 벡터라고 하고  $x$ 를 두 개의 서브세트  $x_a$ 와  $x_b$ 로 분리한다고 가정하자. 그러면, k번째 GMM 성분의 평균 및 공분산은 또한 하기와 같이 주어진다.

[0149]

수학식 16

$$\boldsymbol{\mu}_k = (\boldsymbol{\mu}_{b,k}, \boldsymbol{\mu}_{a,k}), \quad \boldsymbol{\Sigma}_k = \begin{pmatrix} \boldsymbol{\Sigma}_{bb,k} & \boldsymbol{\Sigma}_{ba,k} \\ \boldsymbol{\Sigma}_{ab,k} & \boldsymbol{\Sigma}_{aa,k} \end{pmatrix}$$

[0150]

$\boldsymbol{\Sigma}_{bb,k}$  와  $\boldsymbol{\Sigma}_{aa,k}$  가 대칭이라고 가정하고, 반면에  $\boldsymbol{\Sigma}_{ba,k} = (\boldsymbol{\Sigma}_{ab,k})^T$  라고 가정하자. 단순한 조인트 분포  $p(\mathbf{x}_a, \mathbf{x}_b) = p(\mathbf{x}_b | \mathbf{x}_a)p(\mathbf{x}_a)$  에 기초하여,  $p(\mathbf{x}_b | \mathbf{x}_a)$  및  $p(\mathbf{x}_a)$  가 또한 다변수 가우시안 분포라는 것이 결정된다. 마르디아 등(Mardia et al.)에 의한 하기 이론이 사용된다(비특허문헌 [38, 39])

[0151]

수학식 17

**Theorem.** If  $[\mathbf{x}_b, \mathbf{x}_a]^T \sim \mathcal{N}_{p+q}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ , where  $\boldsymbol{\mu}_b \in \mathbb{R}^p$  and  $\boldsymbol{\mu}_a \in \mathbb{R}^q$ , and  $\boldsymbol{\Sigma} = \begin{pmatrix} \boldsymbol{\Sigma}_{bb} & \boldsymbol{\Sigma}_{ba} \\ \boldsymbol{\Sigma}_{ab} & \boldsymbol{\Sigma}_{aa} \end{pmatrix}$ , then  $p(\mathbf{x}_b | \mathbf{x}_a)$  is defined as

$$\mathcal{N}_q\left(\boldsymbol{\mu}_a + \boldsymbol{\Sigma}_{ab}(\boldsymbol{\Sigma}_{bb})^{-1}(\mathbf{x}_a - \boldsymbol{\mu}_b), \boldsymbol{\Sigma}_{aa} - \boldsymbol{\Sigma}_{ab}(\boldsymbol{\Sigma}_{bb})^{-1}\boldsymbol{\Sigma}_{ba}\right)$$

[0152]

수학식 17에 이론을 적용하면, GMM 매개 변수를 가지고 다중 선형 방정식을 사용하여 타깃 SBPR에 대한 조건부 기댓값의 평균이 추정된다:

[0153]

수학식 18

$$\hat{y}_{s(i,j)} = \sum_{k=1}^K \zeta_k \left\{ \mu_{a,k} + \Sigma_{ab,k} (\Sigma_{bb,k})^{-1} (\mathbf{u}_{(i,j)} - \mu_{b,k}) \right\}$$

[0154]

[0155] 상기에서  $\hat{y}_{s(i,j)}$  는 피험자의 측정치에 대한 추정된 SBP 타깃 비율을 나타내고, i 및 j는 각각 i번째 피험자와 j번째 측정치를 나타낸다. 더욱이,

수학식 19

$$\zeta_k = \frac{p(\mathbf{u}_{(i,j)} | k)}{\sum_{k=1}^M p(\mathbf{u}_{(i,j)} | k)}$$

[0156]

[0157] 상기에서 가중 계수  $\zeta_k$  는 벡터  $\mathbf{u}_{(i,j)}$  를 생성하는 k번째 GMM 성분으로부터의 확률을 나타낸다. 따라서, SBPR  $\hat{y}_{s(i,j)}$  는 GMR에 의해 주어진다. 유사하게, DBPR  $\hat{y}_{d(i,j)}$  이 또한 하기와 같이 획득될 수 있다:

수학식 20

$$\bar{y}_{s(i)} = \frac{1}{N} \sum_{j=1}^N \hat{y}_{s(i,j)}$$

[0158]

[0159] 상기에서  $\bar{y}_{s(i)}$  는 i번째 피험자의 평균 SBPR을 나타내고 N(=5)은 각 피험자에 대한 측정 횟수를 나타낸다. 유사하게, 평균 DBPR  $\bar{y}_{d(i)}$  가 또한 획득될 수 있다. 이들 제안된 비율들을 사용하여, 평균 SBP와 DBP 포인트들이 PMAE 상에서 식별되고, 그들은 다시 디플렉션(deflection) 커브에 매핑되어 mmHg으로 SBP와 DBP 값들을 제공한다. 마지막으로, GM을 사용하여 획득된 평균 SBP와 DBP 포인트들이 SBP와 DBP의 신뢰 구간(CI)을 추정하는데 사용된다.

[0161] 실험 결과

[0162] 유효화 프로토콜

[0163] 혈압 추정의 성능을 확인하기 위하여, AAMI(Advancement of Medical Instrumentation) 표준 프로토콜의 권고에 따라 추정된 혈압과 기준 청진 방법 간의 ME(mean error) 및 SDE(standard deviation of the error)가 계산되었다. SDE가 8mmHg 미만이고, ME가 5mmHg 미만인 경우 디바이스는 AAMI 프로토콜을 통과한다. 따라서, ME와 SDE의 더 낮은 값들은 양호한 전체 성능에 대응한다. 더욱이, A-D 등급 체계를 갖는 BHS 프로토콜은 그것의 절대 에러의 60%가 5mmHg 이내이고, 그것의 에러의 85%가 10mmHg 이내이며, 그것의 에러의 95%가 15mmHg 이내인 경우, 디바이스에 A 등급을 승인할 것이다. BHS 프로토콜은 B 및 C 등급들에 대해 진보적으로 덜 엄중한 기준을 가지며, 디바이스가 C 보다 나쁘게 동작하는 경우 D 등급을 부여한다.

[0164] 통계 분석

[0165] GMM은 425 측정치들 중에서 SBPR과 DBPR의 유사한 값을 갖는 몇몇 그룹화된 타깃들에 기초하여 구성되었고, GMR 모델은 GMM 매개 변수들을 사용하여 SBPR과 DBPR을 추정하는데 사용되었다. 실루엣 값(SV: silhouette value)은 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 성능을 보장하기 위하여 SBPR과 DBPR의 분포에 기초하여 K-평균 알고리즘에서 클러스터들의 수를 효과적으로 선택하는데 사용되었다. 전반적으로, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 의한 접근법을 유효화하기 위하여 두 가지 유형의 트레이닝 및 테스트 실험들이 수행되었다. 첫 번째 제안된 테스트 시나리오 GMR<sub>I</sub>에서, 425개의 측정치들(85 피험자들로부터 획득된 5개의 측정치들)이 사용되었고, 트레이닝 세트는 340개의 측정치들(85 피험자들로부터 획득된 4개의 측정치들)로 구성되며 테스트 세트는 5번째 측정치로부터 획득된 85개의 측정치들로 구성된다. 그 다음 분석이 반복적으로 수행되었는데, 각 피험자가 테스트 단계에 대해 한번 이용되도록 수행되었다. 두 번째 테스트 시나리오 GMR<sub>II</sub>에서, 85 피험자들 중 (연속적으로 선택된) (65 피험자들) 76.5%는 트레이닝 단계의 부분이었고 모든 5 측정치들은 이 단계에 포함되었다. 첫 번째 제안된 시나리오에서의 테스트는 테스트 이후에 모든 피험자에 대해 새로운 측정치들을 사용하는 테스트로서 간주될 있는 반면에, 두 번째 시나리오는 새로운 피험자들로부터의 측정치들을 가지고 제안된 접근법의 능력의 일반화 능력을 검사하는 것으로서 간주될 수 있다.

[0166] 제안된 GMM 알고리즘을 사용하여 획득된 SBP와 DBP의 ME들은 표 1에 도시된 바와 같이 관용적인 MAA 방법의 것들과 비교되었고 NPB를 사용한 의사 최대 진폭과 엔벨로프(PMAE)(PMAE<sub>NPB</sub>)와 비교되었는데, 본 발명의 방법의 성능이 더 우월함을 확인할 수 있다. 본 발명의 방법과 청진 간호사 측정 간의 SDE는 각각 GMR<sub>I</sub> 및 GMR<sub>II</sub>에서 SBP와 DBP에 대해 5.54 및 5.67 mmHg인 것으로 확인되었고 DBP에 대해 5.49와 5.72 mmHg인 것으로 확인되었다. 이들 SDE들은 표 1에 도시된 바와 같이 관용적인 방법들로부터 획득된 것들을 능가한다. SBP와 DBP에 대해, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법과 관용적인 MAA 간의 SDE의 차이는 본 발명의 방법이 GMR<sub>I</sub>을 가지고 평가된 경우 1.77 및 0.92 mmHg이었고, GMR<sub>II</sub>을 가지고 평가된 경우 1.64 및 0.69 mmHg이었다.

표 1

**Table 1**  
ME and SDE relative to the reference auscultatory method, and AAMI standard protocol in the parenthesis, where P denotes Pass, obtained with the conventional MAA, the PMAE with NPB and fixed ratio [5], and using the two proposed evaluation GMR<sub>I</sub> and GMR<sub>II</sub> in the text.

mmHg	MAA		PMAE <sub>NPB</sub>		GMR <sub>I</sub>		GMR <sub>II</sub>	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
ME	0.51(P)	1.56(P)	2.70(P)	-0.38(P)	0.97(P)	0.27(P)	1.18(P)	0.32(P)
SDE	7.31(P)	6.41(P)	7.61(P)	7.13(P)	5.54(P)	5.49(P)	5.67(P)	5.72(P)

[0167]

[0168] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 절대 오차는 표 2에 도시된 바와 같이, GMR<sub>I</sub>에서 SBP에 대해 84.71%(≤5mmHg), 98.82%(≤10mmHg), 그리고 99.76%(≤15mmHg)이었고, GMR<sub>I</sub>에서 DBP에 대해 84.71%(≤5mmHg), 98.82%(≤10mmHg), 그리고 99.76%(≤15mmHg)이었다. 표 2에 도시된 바와 같이 절대 오차는, GMR<sub>II</sub>에서 SBP에 대해 82.35%(≤5mmHg), 97.65%(≤10mmHg), 그리고 99.76%(≤15mmHg)이었고, DBP에 대해 82.35%(≤5mmHg), 98.82%(≤10mmHg), 그리고 99.76%(≤15mmHg)이었다.

표 2

**Table 2**  
Grading of the proposed algorithm based on the BHS standard using the results of GMR<sub>1</sub> and GMR<sub>0</sub> on (5 × 85=425) measurements. The first 6 columns show the percentage of measurements in which the absolute error is less than 5, 10, and 15 mmHg.

Tests	SBP Absolute difference (%)			DBP Absolute difference (%)			Standard (SBP/DBP) BHS Grade
	≤ 5 mmHg	≤ 10 mmHg	≤ 15 mmHg	≤ 5 mmHg	≤ 10 mmHg	≤ 15 mmHg	
	MAA	47.06	85.88	96.47	56.47	88.24	
PMAE <sub>NPB</sub>	45.88	81.17	95.29	65.88	87.06	95.29	C/B
GMR <sub>1</sub>	84.71	98.82	99.76	84.71	98.82	99.76	A/A
GMR <sub>0</sub>	82.35	97.65	99.76	82.35	98.82	99.76	A/A

[0169]

[0170]

표 2에, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법에 의해 획득된 BHS(British hypertension society) 등급이 제시된다. 여기에서 3개의 카테고리, ≤5mmHg, ≤10mmHg, 그리고 ≤15mmHg에 대한 평균 절대 오차의 백분율이 모든 측정치들(425개의 측정치들)에 대해 계산된다. 결과적으로, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 BHS 등급 체계에 기초하여 전반적인 등급 A를 달성한다. K-평균 알고리즘에서 실루엣 기법을 사용하여 획득된 상이한 K에 대한 ME 및 SDE에 의한 혈압 추정의 부가적인 비교가 표 3에 표시된다. 특징 클러스터링에 기초하여, 상이한 K 클러스터 숫자들에 대한 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 성능이 또한 평가되었다.

표 3

**Table 3**  
ME and SDE relative to the reference auscultatory method obtained with the proposed GMR<sub>1</sub> over different K described in the text.

mmHg	GMR <sub>1(K=6)</sub>		GMR <sub>1(K=5)</sub>		GMR <sub>1(K=4)</sub>		GMR <sub>1(K=3)</sub>	
	SBP	DBP	SBP	DBP	SBP	DBP	SBP	DBP
ME	0.97	0.27	1.05	1.32	1.29	0.39	0.98	0.61
SDE	5.54	5.49	5.40	5.18	6.09	4.92	5.98	5.39

[0171]

[0172]

표 3에서, GMR<sub>1</sub>에서의 상이한 K(3-6) 클러스터들에 대한 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법을 사용하여 획득된 SDE는 SBP에 대해 5.54, 5.40, 6.09 및 5.98 mmHg로 확인되었고, DBP에 대해 5.49, 5.18, 4.92 및 5.39 mmHg로 확인되었다. 이들 결과들은 MAA를 사용하여 획득된 것보다 우월하다. 명백히, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 GMR<sub>1</sub>에서 클러스터들의 수에 상관없이 오실로메트릭 혈압 추정을 개선하였다. 마지막으로, GMR<sub>1</sub>을 사용하는 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법, 및 관용적인 MAA<sub>ST</sub>와 PMAE<sub>NPB</sub>를 사용하여 SBP와 DBP의 신뢰 구간(CIs)에 대한 실험 결과들은 표 4에 제시된다.

표 4

**Table 4**  
Average and SDE of CI relative to the reference auscultatory method obtained with the conventional methods and GMR<sub>1</sub> and GMR<sub>0</sub> described in the text, where L and U are the lower and upper limits, respectively.

mmHg	MAA <sub>ST</sub>	PMAE <sub>NPB</sub>	GMR <sub>1(K=6)</sub>	GMR <sub>1(K=5)</sub>	GMR <sub>1(K=4)</sub>	GMR <sub>1(K=3)</sub>
SBP <sub>CI</sub> (SDE)	13.5(8.1)	2.6(3.1)	2.2(0.8)	2.2(0.7)	2.3(0.7)	2.2(0.7)
DBP <sub>CI</sub> (SDE)	9.3(5.7)	1.5(2.3)	1.4(0.5)	1.5(0.5)	1.5(0.5)	1.5(0.5)
SBP <sub>U</sub> (SDE)	106.7(14.3)	112.4(13.9)	109.5(13.0)	110.8(14.2)	111.1(13.6)	111.0(13.8)
SBP <sub>L</sub> (SDE)	120.2(16.5)	115.7(14.1)	111.7(13.2)	113.0(14.4)	113.4(13.7)	113.2(13.9)
SBP(SDE)	113.4(14.9)	113.6(14.4)	110.5(13.1)	111.9(14.3)	112.2(13.6)	112.0(13.8)
DBP <sub>U</sub> (SDE)	62.0(10.4)	66.7(10.5)	62.2(7.1)	63.4(7.8)	62.6(7.6)	62.8(7.4)
DBP <sub>L</sub> (SDE)	71.7(11.0)	68.2(9.9)	63.6(7.4)	64.9(8.1)	64.0(7.9)	64.3(7.8)
DBP(SDE)	67.1(10.3)	67.2(10.4)	62.9(7.3)	64.1(7.9)	63.3(7.8)	63.6(7.6)

[0173]

[0174]

MAA<sub>ST</sub>는 스튜던트 t-방법(Student's t-method)을 사용하여 MAA로부터 획득된 CI를 지칭한다는 것을 주목하라.

K=6을 가지고  $GMR_1$  하에서 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법을 사용하여 획득된 CI들은 K=3, 4, 5를 가지고  $GMR_1$  하에서 본 발명의 방법을 사용하여 획득된 것들과 유사하다. 표 4에 도시된 바와 같이 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 CI의 SDE가  $PM_{NPB}$  방법의 CI의 SDE보다 더 작다는 것을 주목하라. 표 4에 도시된 바와 같이, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법을 사용하여 획득된 CI 결과들은 관용적인 방법들을 사용하여 획득된 것들보다 더 작다. 5 측정들의 평균 SBPR과 DBPR은 85 개별적인 피험자에 대한 CI를 획득하는데 사용되었다.

[0175] 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 부트스트랩 방법을 GMM 기반 접근법과 조합하는 첫 번째 연구이고, 또한 혈압 추정치에 대한 신뢰 구간(CI)을 획득하기 위하여 기계 학습을 부트스트랩과 조합하는 첫 번째 혼합 접근법이다. GMM과 GMR은 개별화된 비율들을 추정하는데 적용되고 그 다음 이들은 SBP와 DBP 및 SBP와 DBP에 대한 신뢰 구간(CIs)을 추정하는데 사용된다. 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법을 사용하여 획득된 추정치들의 정확도는 그들을 청진 방법을 사용하여 획득된 것들과 비교함으로써 그리고 ME와 SDE를 추정함으로써 AAMI 표준 프로토콜에 따라 계산되었다. 진정으로, SDE는 ME보다 더 중요한데, 이것은 측정치들이 동등하게 포지티브 또는 네거티브일 수 있는 큰 에러를 가지면서 작은 ME를 가질 수 있을 때, 디바이스가 매우 부정확할 수 있기 때문이다. AAMI 표준 프로토콜이 자동 혈압 장치들에 대해 8 mmHg 보다 크지 않은 SDE를 가지고 5 mmHg 미만의 ME 값을 권고한다는 점을 고려하면 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법의 개선은 매우 중요할 수 있다. 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 AAMI 기준을 충족한다. 이들 결과들은 MAA와  $PM_{NPB}$ 와 비교할 때 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법이 정확한 혈압 측정치들을 제공한다는 것을 확인한다. 더욱이, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 강건한 것으로 생각되는데 왜냐하면 트레이닝과 테스트의 두 개의 상이한 방법들이 AAMI와 BHS 프로토콜들 양자에 대해 유사한 결과를 도출하였기 때문이다. 이것은 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법이 측정 불확실성에 기인한 추정치들에 대한 영향을 감소시키고 실루엣 값을 사용하여 결정된 클러스터들의 수의 선택에 의해 영향을 받지 않는다는 것을 나타낸다. 결과적으로, 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은, 관용적인 오실로메트릭 측정에 기초하여 신뢰 구간(CI)을 획득하는 것이 실행 불가능한, 적은 수의 측정치들을 사용하여 SBP와 DBP, 및 SBP와 DBP에 대한 신뢰 구간(CI)을 추정하는데 사용될 수 있다.

[0176] 결론적으로, NPB 기법과 GMM을 조합하는 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 피험자에 대해 개별화된 특성 비율을 유도하기 위한 방법을 제공한다. 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 또한 적은 수의 측정치들을 가지고 SBP와 DBP의 신뢰 구간(CI)을 동시에 생성할 수 있는 유일한 방법이다. 관용적인 MAA 방법 및 다른 방법들과 비교할 때 본 발명의 일 실시예에 의한 기계 학습에 기반한 오실로메트릭 혈압 추정 방법은 SBP와 DBP 추정의 정확성을 향상시키고 추정치들에 대한 더 좁은 신뢰 구간을 제공한다.

[0177] 이상 본 발명을 구체적인 실시예를 통하여 상세하게 설명하였으나, 이는 본 발명을 구체적으로 설명하기 위한 것으로, 본 발명은 이에 한정되지 않으며, 본 발명의 기술적 사상 내에서 당 분야의 통상의 지식을 가진 자에 의해 그 변형이나 개량이 가능함은 명백하다고 할 것이다.

[0178] 본 발명의 단순한 변형 내지 변경은 모두 본 발명의 영역에 속하는 것으로, 본 발명의 구체적인 보호 범위는 첨부된 청구범위에 의하여 명확해질 것이다.

[0179] 부록

[0180] 하기에 의사 엔벨로프에 대한 리샘플링 프로세스를 명확히 설명하기로 한다. 예를 들어, 도 6a에 도시된 바와 같이, 소정의 순서로(원래의 행렬) 발생하는 5회의 샘플들로 구성된 어떤 환자에 대한 5개의 엔벨로프(1, 2, 3, 4, 5)들이 존재한다고 가정하자. 도 6b에 도시된 바와 같이 비모수 부트스트랩에 기반하여 랜덤 인덱스 함수를 사용하여 원래의 행렬 (a)로부터 각각 획득된, 리샘플 행렬들( $j=1, \dots, B_1=100$ )이 생성된다.

[0181] 그 다음, 도 6c에 도시된 바와 같이 리샘플 행렬들( $j=1, \dots, B_1=100$ )이 분류된다. 리샘플 행렬들( $j=1, \dots, B_1=100$ )의 각 구성요소들은 또한 도 7a에 도시된 바와 같이 분류된다. 그러면 도 7b에 도시된 바와 같이 의사 엔벨로프 행렬들( $j=1, \dots, B_1=100$ )이 획득될 수 있다. 도 7b의 의사 엔벨로프 행렬은 의사 엔벨로프 행


렬들( $j=1, \dots, B_1=100$ ) 중에서 첫 번째 것을 나타냄을 주목하라. 마지막으로, 도 7b의 마지막 컬럼에 도시된 바와 같이 평균 함수를 통해 단일 혈압 의사 엔벨로프가 획득될 수 있다. 이들 도면들은 SBP 부분에 대한 실제 예라는 것을 주목하라.

**부호의 설명**


- [0182] S100 : 혈압 측정
- S102 : 오실로메트릭 파형 획득
- S104 : 엔벨로프 획득
- S106 : 비모수 부트스트랩을 이용하여 PE 및 PMA 획득
- S108 : PE와 PMA를 연결
- S110 : GMM과 GMR을 적용하여 CI와 함께 SBP 및 DBP 획득
- S112 : 평가

**도면**


**도면1**




도면2




도면3




도면4



도면5



도면6




도면7

a  
sorting about each elements (1,1,1), (1,1,2),..., (1,1,100)

1.0e+005 \*

1)	0.0434	0.0432	0.0433	0.0432	0.0433
	0.0439	0.0433	0.0438	0.0434	0.0437
	0.0442	0.0439	0.0442	0.0434	0.0446
	0.0444	0.0440	0.0448	0.0437	0.0446
	0.0449	0.0447	0.0453	0.0442	0.0451
	0.0454	0.0448	0.0459	0.0446	0.0458
	0.0466	0.0451	0.0464	0.0447	0.0463
	0.0467	0.0453	0.0467	0.0448	0.0469
	0.0472	0.0464	0.0479	0.0450	0.0470
	0.0472	0.0475	0.0484	0.0460	0.0471



b  
1.0e+005 \*

0.0444	0.0442	0.0443	0.0442	0.0443
0.0449	0.0443	0.0448	0.0444	0.0447
0.0451	0.0449	0.0452	0.0444	0.0456
0.0454	0.0450	0.0458	0.0447	0.0456
0.0459	0.0457	0.0463	0.0452	0.0461
0.0464	0.0458	0.0469	0.0456	0.0458
0.0476	0.0461	0.0474	0.0457	0.0463
0.0477	0.0463	0.0477	0.0458	0.0469
0.0482	0.0474	0.0479	0.0460	0.0470
0.0482	0.0475	0.0484	0.0470	0.0471

1.0e+005 \*

0.0443
0.0446
0.0451
0.0453
0.0458
0.0461
0.0466
0.0469
0.0473
0.0476

【심사관 직권보정사항】

【직권보정 1】

【보정항목】 청구범위

【보정세부항목】 청구항 제1항

【변경전】

(f-2) 상기 평균 엔벨로프

【변경후】

(f-2) 상기 평균 의사 엔벨로프

专利名称(译)	基于机器学习的估算示波血压的方法		
公开(公告)号	<a href="#">KR101778533B1</a>	公开(公告)日	2017-09-26
申请号	KR1020160146595	申请日	2016-11-04
[标]申请(专利权)人(译)	仁川大学校产学协力团		
申请(专利权)人(译)	仁川大学学术合作		
当前申请(专利权)人(译)	仁川大学学术合作		
[标]发明人	JEON GWANG GIL 전광길		
发明人	전광길		
IPC分类号	A61B5/021 A61B5/00 G06N3/04 G06N3/08		
CPC分类号	A61B5/021 A61B5/7264 G06N3/08 G06N3/04		
外部链接	<a href="#">Espacenet</a>		

摘要(译)

但是从所附权利要求中可以明显看出。补充 下面将详细描述伪包络的重采样过程。例如, 假设一个, 存在以预定的顺序(原始矩阵)发生5个5信封用于患者, 由样品的(1, 2, 3, 4, 5)作为如图6a所示我们假设。在从原始矩阵分别获得(a)中, 所示在图6b中重新采样矩阵( $J = 1, \dots, B1 = 100$ ), 使用基于非参数引导随机索引函数生成。那然后, 度在6c城市说明像重新取样矩阵( $j = 1, \dots, B1 = 100$ )被分类。重新取样黑客帝国( $j = 1, \dots, B1 = 100$ )也被分类, 如图7A所示。可以获得伪包络矩阵( $j = 1, \dots, B1 = 100$ ), 如图7B所示。图7b的医生信封矩阵是一个决策矩阵包络( $J = 1, \dots, B1 = 100$ )注意, 在第一指示的方式。最后, 如图7b的最后一栏所示

