

심박간격의 마코프 국면전환 모형화를 통한 심방세동 탐지

정용한 · 김희영[†]

KAIST 산업 및 시스템 공학과

Detection of Atrial Fibrillation Using Markov Regime Switching Models of Heart Rate Intervals

Yonghan Jung · Heeyoung Kim

Department of Industrial and Systems Engineering, KAIST

This paper proposes a new method for the automatic detection of atrial fibrillation (AF), using Markov regime switching GARCH (1, 1) model. The proposed method is based on the observation that variability patterns of heart rate intervals during AF significantly differ from regular patterns. The proposed method captures the different patterns of heart rate intervals between two regimes : normal and AF states. We test the proposed method using Massachusetts Institute of Technology-Beth Israel Hospital (MIT-BIH) atrial fibrillation database, and demonstrate the effectiveness of the proposed method.

Keywords: Markov Regime Switching GARCH(1, 1), Atrial Fibrillation, Heart Rate Intervals, Volatility Clustering

1. 서론

1.1 연구배경

심장혈관계 질환은 대한민국에서 매우 빈번한 질환으로써, 2014년 통계청에서 발간한 ‘사망원인 통계’에 따르면, 암에 이어 두 번째로 높은 사망원인 비중을 차지하고 있다(Shin *et al.*, 2016). 심장혈관계 질환 중에서 심방세동(atrial fibrillation, AF)은 심정지에 직결될 수 있는 위험한 부정맥으로써, 고령일수록 그 발생빈도가 늘어나는 특성이 있다. 고령화 사회에 진입하고 있는 현재 대한민국의 상황을 고려할 때, 심방세동을 조기에 빠르고 정확하게 감지하는 것은 매우 중요한 문제이다(yoo *et al.*, 2013). 본 논문은 이러한 심방세동을 수리적으로 모형화하여 이를 바탕으로 심방세동을 탐지하는 방법을 제안한다.

심방세동이란 심방이 동결절(SA node)에서 발생한 전기자극의 전달을 통한 심박수 변속기능, 증폭 박출기(booster pump) 기능 등을 상실하여 심방이 불규칙하게 뛰는 상태를 말한다

(Cho, 1999). 심방세동은 심부전을 악화시키고, 치명적인 합병증인 뇌졸중을 초래할 수 있다(Kim, 2011). 또한, 심방세동 환자들에게서 잦은 빈도로 동반되는 합병증인 혈전색전증(thromboembolism)이나 중풍(stroke)은 생명을 위협할 수 있다(Young, 1999). 따라서 심방세동을 정확하게 진단하는 것은 매우 중요하다.

심방세동 진단에 널리 쓰이는 접근방법은 심박간격(심장박동 1회에 소요되는 시간)을 측정하는 것이다. 심박간격은 심방세동 진단에 있어서 심방의 운동에 대한 중요한 정보를 제공한다. 심방세동이 일어나게 되면 심방의 각 부분이 불규칙적이고 가늘게 떨어져서, 심박간격이 불규칙적이고 무질서해지기 때문이다. 따라서 심박간격 정보를 이용해서 심방세동을 효과적으로 분류해 낼 수 있다(Hargittai, 2014). <Figure 1>은 심방세동 시 심박간격의 변동성과 정상상태 시 심박간격의 변동성을 비교한 그래프이다. <Figure 1>에서 보듯, 정상상태에 비해 심방세동 시 심박간격의 변동성이 더욱 크고 불규칙적인 것을 알 수 있다. 본 연구에서는 이러한 현상에 주목하여, 불규칙적이고 무질서한 심박간격(심박와류, heart rate turbulence)

제11회 석사논문경진대회 수상논문.

[†] 연락저자 : 김희영 교수, 34141 대전광역시 유성구 대학로 291, KAIST 산업 및 시스템 공학과, Tel : 042-350-3125, E-mail : heeyoungkim@kaist.ac.kr
2016년 1월 15일 접수; 2016년 4월 29일 수정본 접수; 2016년 5월 25일 게재 확정.

을 바탕으로 심방세동을 모형화하고 탐지하는 방법을 제안한다.

1.2 관련 연구

심박간격을 바탕으로 심방세동 진단을 자동화하려는 선행 연구는 1) 심박간격 변동성을 바탕으로 심방세동을 진단하는 접근방법(변동성 기반 접근방법, volatility-based approach), 2) 심박간격의 자기상관성을 모형화하여 심방세동을 진단하는 접근방법(자기상관성 기반 접근방법, autoregressive-based approach), 3) 심박간격의 마코프 성질을 가정 및 고려하여 심방세동을 진단하는 접근방법(마코프 모형 기반 접근방법, Markov-based approach)으로 크게 분류해 볼 수 있다. 각각의 접근방법에 대한 선행연구들을 아래에 간략히 설명한다.

변동성 기반 접근방법은 심방세동이 심박와류를 초래한다는 사실에 기인하여, 심박간격의 변동성을 토대로 심방세동을 분류한다. Tateno and Glass(2001)는 심방세동 시 심박간격 데이터(RR)와 심박간격 간 차이(ΔRR)데이터의 확률분포를 히스토그램으로 추정하여, 이를 바탕으로 새로운 심박간격 데이터의 심방세동 여부를 판단하는 알고리즘을 제안하였다. Logan and Healey(2005)은 잠음에 강건한 심박간격 알고리즘을 제안하기 위해서, 심박간격의 이동평균을 계산한 뒤, 이동평균 데이터의 분산을 이용하여 심방세동 발생여부를 판단하였다. Huang *et al.*(2011)는 심방세동이 짧은 기간 발생했을 경우, 기존에 제시된 알고리즘들이 심방세동 탐지에 실패할 수 있음을 지적하며, 심박간격 간 차이(ΔRR) 데이터의 분포 차이 곡선(distribution difference curve)을 제안하여, 정확하게 심방세동을 탐지할 수 있도록 하였다. Zhou *et al.*(2014)는 실시간으로 심방세동을 탐지하기 위하여, 심박간격 간 차이 데이터(ΔRR)의 샤논(Shannon) 엔트로피 수치를 통해 변동성을 측정하여 심방세동을 탐지하는 알고리즘을 제안하였다. Mabrouki *et al.*(2014)는 심박간격 데이터의 변동성을 나타내는 그래프 표현방법인 Poincare' plot과 샘플 엔트로피를 결합하여, 변동성을 바탕으로 심방세동을 진단하는 방법론을 제시하였다. Kelwade and Salankar(2016)는 심박간격 데이터에서 Poincare' plot 과 주파수구간 엔트로피 등 변동성 관련 지표를 추출한 뒤, 신경망 분석을 통해 심방세동 여부를 진단하였다. Linker(2016)는 심박간격 데이터의 구간별 변동성 지표를 측정하여, 직전/직후 구간의 변동성과 비교하여 심방세동 여부를 판단하는 알고리즘을 제안하였다. 변동성 기반 접근방법은 심방세동 시 심박간격의 표준편차가 크다는 사실에 근거한 접근방법이므로 알고리즘의 구성이 직관적이다. 그럼에도 불구하고 변동성 기반 접근방법은 다음과 같은 한계점이 존재한다. 1) 변동성에 해당하는 통계치를 해석하는 데 있어 사용자가 임의로 정한 기준(threshold)을 사용한다. 2) 변동성에 근거한 알고리즘은 변동성을 계산하기 위한 창문구간(sliding window)을 설정해야 하기 때문에, 짧은 기간 동안의 심방세동을 탐지하기 어렵다. 3) 심박간격은 다음 시점에 영향을 주는 경향이 있는 시계열 데이터임에도 불구하고, 변동성 기반 접근방법은

이러한 자기상관성을 고려하지 않는다.

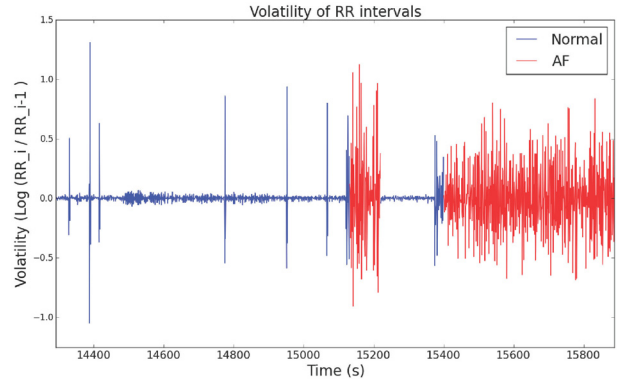


Figure 1. Comparison between Variability of Heart Rate Intervals in Normal Status and Atrial Fibrillation Status(Record 08455 in MIT-BIH atrial fibrillation database)

자기상관성 기반 접근방법은 심박간격의 자기 상관성을 고려하여 심박간격을 모형화하는 방법이다. Cerutti *et al.*(1997)은 정상상태에 비해 심방세동 시 심박간격의 주파수 스펙트럼에 유의미한 차이가 있음에 착안하여, 자기상관성 모형(AR 모형)의 모수를 통해서 주파수 스펙트럼을 파악하여 심방세동을 진단하는 방법을 제시하였다. Ieva *et al.*(2013)는 심방세동 시 불규칙한 심박간격을 자기회귀적분이동평균(ARIMA) 모형으로 모델링 하고(Cammarota and Rogora, 2005), 시계열데이터의 차수(order) 관측을 통해 변화점 감지(change point detection)를 수행하는 심방세동 탐지 알고리즘을 제안하였다(Ieva *et al.*, 2013). 한편, Leite *et al.*(2013)은 심박간격 데이터가 이분산구조(conditional heteroscedasticity), 장기기억과정(long-memory process)을 가지는 것을 지적하며 ARFIMA-GARCH 모형을 통해서 심박간격을 모델링하는 방법을 제안하였다. 자기상관모형은 현재의 패턴이 과거의 패턴에 영향을 받는 심박간격 데이터의 자기상관성을 반영하여 설명력이 높다는 장점이 있으나 Leite *et al.*(2013)이 지적한대로 심박간격 데이터는 이분산구조를 가지고 있고, 장기기억과정 성질이 있기 때문에, 하나의 시계열 모형으로 심방세동/정상상태 시 심박간격 데이터를 모형화하는 데 한계가 있다.

마코프 모형 기반 접근방법은 심박간격의 불규칙성(irregularity)과 불안정성(non-stationarity)을 고려하여, 심박간격을 미리 정의된 상태(state)별로 각기 모형화하는 방법을 말한다. 상태변수(state variable)가 마코프 성질(t시점의 상태는 t-1시점의 상태 혹은 그 이전 일정 기간의 시점의 상태에만 영향을 받는 성질)을 따른다고 가정하기 때문에, 마코프 모형 기반 접근방법이라고 한다. Moody and Mark(1983)는 이동평균 심박간격의 상태를 짧은심박간격/정상심박간격/긴심박간격으로 정의하여, 마코프 전환확률을 계산하고 전환확률에 기반한 조건부 우도확률(conditional likelihood)을 바탕으로 심방세동을 탐지하였다(Moody and Mark, 1983). Young *et al.*(1999)은 Moody

and Mark(1983)가 제안한 방법을 개선하여, 심방세동/비심방세동 여부를 은닉 상태변수(latent state variables)로 정의한 뒤 심박간격 데이터에 은닉 마코프 모형(hidden Markov model, HMM)을 적용하여 심방세동을 탐지하는 방법을 제안하였다. Young *et al.*(1999)은 은닉 마코프 모형이 변동성 기반 접근방법 등에 비해서 더 우수한 성과를 내는 것을 비교실험을 통해 보였다. 한편, Oster and Clifford(2013)는 다중계층 은닉 마코프 모형(multilayer layered HMM)을 이용한 심방세동 진단 알고리즘을 제안했는데, 심방세동/비심방세동 여부를 은닉 마코프 모형의 하위계층으로 정의하고, 짧은심박간격/긴심박간격 상태를 상위계층으로 정의하여, 심방세동 시 심박간격의 불규칙성을 모형화하고자 하였다. Dovancescu and Babaeizadeh(2015)는 원격 심장건강 기기 시스템을 제안하면서, 심방세동을 탐지하는 알고리즘으로 Moody and Mark(1983)을 개선하여 적용하였다(Dovancescu and Babaeizadeh, 2015). 마코프 모형 기반 알고리즘은 심방세동 시, 비심방세동 시 심박간격의 패턴을 분류하여 모형화함으로써 심방세동이 존재하는 심박간격 데이터의 불규칙한 변동성 패턴을 잘 설명할 수 있다는 장점이 있다. 그러나, 심박간격 데이터가 자기상관성을 가지는 시계열 데이터임에도 불구하고, 마코프 모형 기반 알고리즘은 심박간격 데이터의 통계적 독립(independence)을 가정한다는 한계점을 안고 있다.

1.3 새로운 접근방법 제안

한편, 금융공학 분야에서는 불규칙하고 불안정한(irregular and nonstationary) 시계열 데이터(예를 들어, 일일 주식 수익률(Hamilton and Susmel, 1994))를 모델링하기 위해, 마코프 국면전환 모형을 널리 사용하여 왔다. 국면전환 모형이란 각 국면(regime)에 대해서 각기 다른 시계열 모형을 정의하고, 이 모형들을 혼합하는 혼합모형을 말한다. 마코프 국면전환 모형이란 국면전환 모형에서 각 국면을 의미하는 상태 변수가 마코프 성질을 따른다고 가정한 모형을 의미한다(Dahlquist and Gray, 2000). 마코프 국면전환 모형은 변동성의 패턴에 따라 군집화되는 성질(변동성 군집화, volatility clustering)이 있는 시계열 데이터를 모형화하는데 효과적이다(Hamilton and Susmel, 1994). 예를 들어, 마코프 국면전환 모형은 ‘호황’, ‘불황’ 국면별로 비슷한 변동성 패턴이 존재하는 일일 주가 수익률 데이터나 외환 수익률 데이터의 변동성을 모델링하는데 널리 사용되어왔다(Hamilton and Susmel, 1994; Juri, 2005; Klaassen, 2002).

이렇듯, 마코프 국면전환 모형은 변동성 군집화 현상을 보이는 시계열 데이터를 모형화하기에 효과적임에도 불구하고, 마코프 국면전환 모형을 이용하여 심박간격의 변동성 변화를 국면별로 모형화하는 선행연구는 존재하지 않았다. Cammarota and Rogora(2005)이 언급한대로, 심방세동 시 심박간격의 패턴과 정상상태시 심박간격의 패턴은 추세와 변동성에서 큰 차이를 가지는 시계열 데이터이므로, 심방세동이 존재하는 심박간

격 데이터의 변동성 패턴을 마코프 국면전환 모형을 이용하여 효과적으로 모델링할 수 있다.

이에 따라, 본 논문에서는 마코프 국면전환 모형, 특히 마코프 국면전환 GARCH(1, 1) 모형을 이용하여 심방세동을 탐지하는 방법을 제안한다. 마코프 국면전환 모형을 활용하여 심방세동을 탐지하는 방법은 기존의 연구와 비교했을 때 다음과 같은 장점을 갖는다. 1) 제시된 방법은 심박간격 데이터의 구조적 변화(국면의 전환)와 자기상관성을 동시에 고려함으로써, 자기상관성 기반 접근방법이 설명하지 못하는 국면의 전환에 따른 심박간격 데이터의 구조적 변화를 설명할 수 있다. 2) 제시된 모형은 심박간격 데이터의 변동성 군집화 현상을 고려하여 설계되었기 때문에, 변동성 기반 모형이 설명하지 못했던 심박간격 변동성의 자기상관성을 설명할 수 있다. 3) 마지막으로, 제시된 모형은 마코프 모형 기반 접근방법과는 달리 심박간격의 통계적 독립성을 가정하지 않는다.

본 논문의 이후 구성은 다음과 같다. Section 2에서는 마코프 국면전환 GARCH(1, 1) 모형을 이용하여 심박간격 데이터를 분석하는 방법을 설명한다. Section 3에서는 Section 2에서 제안한 방법을 실제 데이터를 이용하여 검증한다. Section 4에서는 본 논문을 요약한다.

2. 분석 모형

2.1 GARCH(1, 1) 모형

GARCH(1, 1) 모형은 금융공학 등 변동성의 패턴을 모형화하는 분야에서 가장 일반적으로 사용되는 모형 중 하나이며, 간단하면서도 강건하게 변동성 구조를 파악해 내는 것으로 알려져 있다(Engle, 2001).

t 시점의 심박간격 데이터 r_t 에 대해서, 변동성을 나타내는 변화율 지표 c_t 는 다음과 같이 정의된다(Klaassen, 2002).

$$c_t = \log r_t - \log(r_{t-1}).$$

본 연구에서는 심박간격 변화율 c_t 의 변동성에 초점을 맞추기 때문에 t 시점의 심박간격 변화율 c_t 은 t 에 독립적인 상수 평균 μ 와 t 에 의존하는 잔차 ϵ_t 로 이루어져 있다고 가정한다(Klaassen, 2002). $t-1$ 시점까지의 관측치 $I_{t-1} = (c_{t-1}, \dots, c_1)$ 가 주어져 있을 때, 잔차 ϵ_t 는 평균이 0이고, 분산이 h_t 인 정규분포를 따른다고 가정한다(Gray, 1996). 그리고, 조건부분산 h_t 는 GARCH(1, 1) 모형으로 모델링된다고 가정한다. 이를 수식화하여 표현하면 다음과 같다(Gray, 1996; Klaassen, 2002) :

$$c_t = \mu + \epsilon_t = \mu + \eta_t \sqrt{h_t}, \quad \eta_t \sim_{i.i.d} N(0, 1)$$

$$h_t = \omega + \alpha \epsilon_t^2 + \beta h_{t-1}$$

여기서 η_t 는 평균 0, 분산 1의 정규분포를 따르는 백색잡음이다. ω 와 α 그리고 β 는 각각 절편(intercept), ARCH 모수, GARCH 모수이다. 심박간격의 변동성 데이터 c_t 의 조건부분산 h_t 이 t 와 관계없이 양수여야 하기 때문에, $\omega > 0, \alpha > 0, \beta > 0$ 을 가정하였다(Juri, 2005).

2.2 마코프 국면전환 GARCH(1, 1) 모형

마코프 국면전환 모형은 국면마다 각기 다르게 정의된 모형들이 국면의 전환에 따라 같이 전환하도록 설계된 모형이다. t 시점의 국면을 나타내는 상태변수 s_t 가 마코프 과정을 따르기 때문에 마코프 국면전환 모형이라고 한다. 상태변수 s_t 는 1차 마코프 과정을 따른다고 가정한다(Juri, 2005). 본 연구에서는 정상상태($s_t = 1$)/심방세동상태($s_t = 2$) 두 가지 국면을 모형화하기 위한 2차 마코프 체인(two state Markov chain)을 사용한다. 즉, $t-1$ 시점에서 서의 상태변수 s_{t-1} 이 i 이고, t 시점에서의 상태변수 s_t 가 j 일 때, 전환확률은

$$p_{ij} = P(s_t = j | s_{t-1} = i), i, j \in \{1, 2\}$$

로 쓸 수 있다.

마코프 국면전환 GARCH(1, 1) 모형은 마코프 국면전환 모형과 GARCH(1, 1) 모형을 결합한 모형이다. 상태변수 s_t 가 i 일때($i = 1$ 또는 2), 심박간격 변화율 c_t 를 마코프 국면전환 GARCH (1, 1) 모형으로 수식화하여 표현하면 다음과 같다(Gray, 1996) :

$$c_t = \mu^{(i)} + \epsilon_t = \mu^{(i)} + \eta_t \sqrt{h_t^{(i)}},$$

$$h_t^{(i)} = \omega^{(i)} + \alpha^{(i)} \epsilon_{t-1}^2 + \beta^{(i)} h_{t-1}^{(i)}.$$

식 (2)에서 표기의 편의상 주어진 조건 $s_t = i$ 를 위첨자로 표시하였다. $\mu^{(i)}$ 와 $h^{(i)}$ 는 상태변수 $s_t = i$ 와 I_t 에 의존하는(dependent) c_t 의 조건부 평균과 조건부 분산을 의미한다. 식 (2)의 h_{t-1} 은 상태변수 s_{t-1} 에 독립적인, 과거 조건부 분산의 평균(average)이다(Juri, 2005). 식 (2)처럼 국면전환을 고려한 모형에서, 상태변수에 의존적인 과거 조건부 분산을 계산하기 위해서는 과거 모든 시점의 국면경로(regime paths)(s_{t-1}, \dots, s_1)를 고려해야 하는데, 이를 모두 고려하는 것은 사실상 불가능(intractable)하다. 이러한 국면 경로의 의존성을 제거하여, 식 (2)의 $h_t^{(i)}$ 를 계산이 가능하도록 만들기 위해서는 조건부 분산이 과거 상태에 의존하지 않도록 하는 과정이 필요하다(Juri, 2005). Klaassen(2002)는 이러한 문제에 대한 대안으로써, 식 (2)의 $h_t^{(i)}$ 를 다음과 같이 수식화하는 모형을 제안하였다(Juri, 2005; Klaassen, 2002) :

$$h_t^{(i)} = \omega^{(i)} + \alpha^{(i)} \epsilon_{t-1}^2 + \beta^{(i)} E[h_{t-1} | s_t = i, I_{t-1}]$$

여기서 h_{t-1} 의 조건부 기댓값 $E[h_{t-1} | s_t = i, I_{t-1}]$ 는 다음과 같이 계산된다(Juri, 2005) :

$$\begin{aligned} E[h_{t-1} | s_t = i, I_{t-1}] &= \tilde{p}_{ii,t-1} [(\mu^{(i)})^2 + h_{t-1}^{(i)}] + \tilde{p}_{ji,t-1} [(\mu^{(j)})^2 + h_{t-1}^{(j)}] \\ &\quad - [\tilde{p}_{ii,t-1} \mu^{(i)} + \tilde{p}_{ji,t-1} \mu^{(j)}]^2, i, j \in \{1, 2\}, i \neq j \end{aligned}$$

여기서 j 는 s_{t-1} 의 값이며, $\tilde{p}_{ji,t-1}$ 은 다음과 같이 계산된다(Juri, 2005; Klaassen, 2002) :

$$\tilde{p}_{ji,t-1} = p(s_{t-1} = j | s_t = i, I_{t-1}) = \frac{p_{ji} P(s_{t-1} = j | I_{t-1})}{P(s_t = i | I_{t-1})}$$

여기서 $P(s_{t-1} = j | I_{t-1})$ 은 I_{t-1} 이 주어졌을 때, $s_{t-1} = j$ 의 확률 $P(s_t = j | I_{t-1})$ 은 I_{t-1} 이 주어졌을 때, $s_t = j$ 의 확률이다.

본 연구는 Klaassen(2002)의 모형을 기반으로 하여, 우도함수(likelihood function)를 최대화함으로써 모형의 모수를 추정하였다(Klaassen, 2002). 모수집합이 추정되면, t 시점의 심박간격 변화율 c_t 가 속한 국면(정상, 심방세동)은 $\operatorname{argmax}_{i \in \{1, 2\}} P(s_t = i | I_t)$ 를 통해서 추정할 수 있다(Gray, 1996; Klaassen, 2002).

3. 실험

3.1 데이터 : MIT-BIH Atrial Fibrillation Database

MIT-BIH Atrial Fibrillation database는 Beth Israel Hospital의 Arrhythmia Laboratory에서 제공하는 데이터로써, 발작성 심방세동이 일어난 25개의 10시간 길이의 심전도(sampling rate : 250Hz) 및 심박간격을 제공하는 데이터베이스이다(Moody and Mark, 1983; Goldberger *et al.*, 2000). Moody and Mark(1983)에서 이 데이터에서 추출한 심박간격을 바탕으로 심방세동 시 심박간격을 마코프 체인으로 모형화하며 처음 MIT-BIH Atrial Fibrillation database를 소개했으며, Physionet webiste(<http://www.physionet.org/physiobank/database/afdb/>)에서 사용이 가능하다(Goldberger *et al.*, 2000).

본 연구에서는 계산의 편의성을 위해서, 250Hz로 샘플링 되어있는 데이터 포인트를 12.5Hz로 downsampling 하였다. 본 연구는 25개의 record 중, 충분한 수의 정상/심방세동 관측치를 가진 10개의 record(00735, 04048, 04746, 04908, 07910, 08215, 08378, 08405, 08434, 08455)에 대해서 제시한 방법을 검증하였다.

3.2 실험결과

<Figure 2>는 MIT-BIH Atrial Fibrillation database 의 08455번 record를 본 연구에서 제시하는 알고리즘을 통해 분석한 결

과를 예로 보여준다. <Figure 2>(a)는 08455번 record의 변화율 지표 c_t 를 보여준다. <Figure 2>(b)에는 데이터베이스에서 제공하는 true state을 바탕으로 심박세동 구간을 음영으로 표시하였다. <Figure 2>(c)는 본 연구에서 제시하는 알고리즘으로 판정한 국면구간을 보여준다. 본 연구에서 제시하는 알고리즘을 통해 추정한 국면구간이 실제 국면구간과 상당히 일치하는 것을 볼 수 있다.

Table 1. Definition of True Positive, True Negative, False Positive, and False Negative Events

		Algorithm	
		Normal	AF
Truth	Normal	true negative	false positive
	AF	false negative	true positive

본 연구에서 제시된 방법의 성능을 수치적으로 측정하기 위하여 <Table 1>과 같이 true positive, true negative, false positive, false negative 이벤트를 정의하였다(Zhou, 2014). 예를 들어, 정상 심박간격의 변화율 c_t 를 알고리즘이 정상으로 진단하였다면 true negative, 심방세동으로 진단하였다면 false positive에 해당한다. true positive, true negative, false positive, false negative 이벤트가 일어난 횟수를 각기 TP, TN, FP, FN이라고 나타내고, 이를 활용하여 Accuracy, Sensitivity, Specificity의 세 가지 성능지표를 정의하였다.

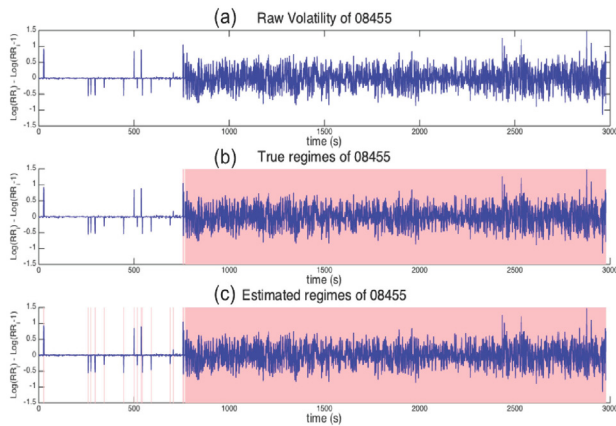


Figure 2. (a) Variability of Heart Rate Intervals(record 08455), (b) True Regimes, (c) Estimated Regimes Diagnosed by the Proposed Method

• Accuracy(Acc) : 전체 관측치 중 정확히 분류된 관측치의 비율

$$Acc = \frac{TN + TP}{TN + TP + FN + FP}$$

• Sensitivity(Se) : 심방세동 관측치 중 심방세동으로 분류된 관측치의 비율

$$Se = \frac{TP}{TP + FN}$$

• Specificity(Spe) : 정상 관측치 중 정상으로 분류된 관측치의 비율

$$Spe = \frac{TN}{TN + FP}$$

<Table 2>는 제시한 알고리즘의 성능지표 결과값이다. 모든 성능지표에서 90% 이상의 평균 성능을 보였다. <Table 3>은 제시한 알고리즘의 평균 성능지표 값을 과거 선행연구에서 제안하는 알고리즘의 성능지표 값과 비교한 결과이다(Larburu, et al., 2011). 세 가지 성능 지표값을 비교했을 때 제안하는 방법이 우수한 성능을 보인다는 것을 알 수 있다.

Table 2. Performance of the proposed method for each record of MIT-BIH Atrial Fibrillation Database

Records	Acc	Se	Spe
00735	97.17	87.50	97.24
04048	97.30	84.62	97.55
04746	96.03	98.96	90.71
04908	91.00	87.85	91.32
07910	93.33	93.51	93.29
08215	97.46	99.52	90.80
08378	94.24	95.11	93.95
08405	97.21	99.65	89.26
08434	90.67	88.79	90.78
08455	97.68	99.19	93.33
Average(%)	95.21	93.47	92.82

본 연구에서 제시한 방법은 Section 1.3에서 언급한 기존의 변동성 기반 알고리즘, 자기상관성 기반 알고리즘, 마코프 기반 알고리즘과는 달리, 심박간격 데이터의 변동성 군집화 현상을 모형화 함으로써 심방세동을 탐지하였다. 변동성 군집화 모형은 심박간격 데이터의 자기상관성과 심방세동 시 변동성의 변화를 동시에 고려할 수 있어, 기존 모형과 비교했을 때 심방세동 시 심박간격 데이터의 특성을 보다 잘 설명한 것으로 판단된다.

4. 결과

본 연구의 결과를 요약하면 다음과 같다. 본 연구에서는 마코프 국면전환 GARCH(1, 1) 모형을 통해 심박간격 데이터를 바탕으로 심방세동을 진단하는 방법을 제안하였다. 제안하는 방법은 정상 상태와 심방세동 상태 시 심박간격 패턴이 크게 달라지는 점에 착안하여, 정상 상태/심방세동 상태를 각기 다른 GARCH (1, 1) 모형을 통해 모델링함으로써 정상 상태와 심방세동 상태

를 진단하였다. 제안한 방법은 MIT-BIH Atrial Fibrillation database에 속한 records 중 충분한 수의 정상상태, 심방세동상태 심박간격을 포함한 10개의 records를 통해 검증되었다. Accuracy, Sensitivity, Specificity의 세 가지 성능지표에서 평균적으로 90% 이상의 성능을 보였으며, 이는 과거 선행연구에서 제시한 알고리즘의 성능과 비교했을 때 우수하다고 할 수 있다. 이러한 우수한 성능은 심박간격 데이터의 변동성 군집화 현상을 탐지하여 심방세동을 진단하는 것이 효과적이라는 것을 보여준다.

본 연구는 심박간격 데이터를 이용하여 심방세동을 진단하는 것에 초점을 맞추었는데, 이를 확장하여 심박간격 데이터를 통해 여러 종류의 심장질환을 진단하기 위해서는 다중 상태(multi-state)를 고려한 모형설계를 위한 연구가 수행되어야 한다. 구체적으로, 심방세동 질환은 심방이 더욱 급속하게 뛰는 심방조동이라는 질환과 유사한데, 본 연구에서 제시한 알고리즘을 다중상태를 고려한 모형으로 확장하여 적용한다면 이를 적절히 진단할 수 있을 것으로 기대된다.

참고문헌

- Cammarota, C. and Rogora, E. (2005), Independence and symbolic independence of non-stationary heartbeat series during atrial fibrillation, *Physica a-Statistical Mechanics and Its Applications*, **353**, 323-335.
- Cerutti, S., Mainardi, L., Porta, A., and Bianchi, A. (1997), Analysis of the dynamics of RR interval series for the detection of atrial fibrillation episodes, *Computers in Cardiology 1997*, IEEE, 77-80.
- Cho, J.-G. (1999), Management of atrial fibrillation, *Korean Circulation Journal*, **29**(4), 440-447.
- Dahlquist, M. and Gray, S. F. (2000), Regime switching and interest rates in the European monetary system, *Journal of International Economics*, **50**(2), 399-419.
- Dovancescu, S. and Babaeizadeh, S. (2015), Automated home monitoring of atrial fibrillation in heart failure patients, *2015 Computing in Cardiology Conference (CinC)*, IEEE, 261-264.
- Engle, R. (2001), GARCH 101 : The use of ARCH/GARCH models in applied econometrics, *Journal of Economic Perspectives*, **15**(4), 157-168.
- Goldberger, A., Amaral, L., Glass, L., Hausdorff, J., Ivanov, P., Mark, R., Mietus, J., Moody, G., Peng, C.-K., and Stanley, E. (2000), Physiobank, Physiobank, and Physionet components of a new research resource for complex physiologic signals, *Circulation*, **101**(23), e215-e220.
- Gray, S. F. (1996), Modeling the conditional distribution of interest rates as a regime-switching process, *Journal of Financial Economics*, **42**(1), 27-62.
- Hamilton, J. D. and Susmel, R. (1994), Autoregressive conditional heteroskedasticity and changes in regime, *Journal of Econometrics*, **64**(1), 307-333.
- Hargittai, S. (2014), Is it possible to detect atrial fibrillation by simply using RR intervals? *Computing in Cardiology Conference (CinC)*, 2014, IEEE, 897-900.
- Huang, C., Ye, S., Chen, H., Li, D., He, F., and Tu, Y. (2011), A novel method for detection of the transition between atrial fibrillation and sinus rhythm, *IEEE Transactions on Biomedical Engineering*, **58**(4), 1113-1119.
- Ieva, F., Paganoni, A. M., and Zanini, P. (2013), Detection of structural changes in tachogram series for the diagnosis of atrial fibrillation events, *Computational and Mathematical Methods in Medicine*.
- Juri, M. (2005), Forecasting stock market volatility with regime-switching GARCH models, *Studies in Nonlinear Dynamics and Econometrics*, **9**(4), 1-42.
- Kelwade, J. and Salankar, S. (2016), Radial basis function neural network for prediction of cardiac arrhythmias based on heart rate time series, *2016 IEEE First International Conference on Control, Measurement and Instrumentation (CMI)*, IEEE, 454-458.
- Kim, J.-S. (2011), Antithrombotic management in atrial fibrillation, *Journal of Korean Heart Rhythm Society*, **12**(3), 8-11.
- Klaassen, F. (2002), Improving GARCH volatility forecasts with regime-switching GARCH, *In Advances in Markov-Switching Models*, 223-254.
- Larburu, N., Lopetegi, T., and Romero, I. (2011), Comparative study of algorithms for atrial fibrillation detection, *Computing in Cardiology*, **38**, 265-268.
- Leite, A., Rocha, A. P., and Silva, M. E. (2013), Beyond long memory in heart rate variability : An approach based on fractionally integrated autoregressive moving average time series models with conditional heteroscedasticity, *Chaos*, **23**(2), 023103-1-023103-10.
- Linker, D. T. (2016), Accurate, automated detection of atrial fibrillation in ambulatory recordings, *Cardiovascular engineering and technology*, **7**(2), 182-189.
- Logan, B. and Healey, J. (2005), Robust detection of atrial fibrillation for a long term telemonitoring system, *Computers in Cardiology*, IEEE, 619-622.
- Mabrouki, R., Khaddoumi, B., and Sayadi, M. (2014), Nonlinear statistical methods for atrial fibrillation detection on electrocardiogram, *Electrical Sciences and Technologies in Maghreb (CISTEM)*, 2014 International Conference on, IEEE, 1-6.
- Moody, G. B. and Mark, R. G. (1983), A new method for detecting atrial fibrillation using RR intervals, *Computers in Cardiology*, **10**, 227-230.
- Oster, J. and Clifford, G. D. (2013), An artificial model of the electrocardiogram during paroxysmal atrial fibrillation, *Computers in Cardiology*, **40**, 539-542.
- Shin, H.-Y., Lee, J.-Y., Song, J., Lee, S., Lee, J., Lim, B., Kim, H., and Huh, S. (2016), Cause-of-death statistics in the republic of korea, *Journal of the Korean Medical Association*, **59**(3), 221-232.
- Tateno, K. and Glass, L. (2001), Automatic detection of atrial fibrillation using the coefficient of variation and density histograms of RR and Δ RR intervals. *Medical and Biological Engineering and Computing*, **39**(6), 664-671.
- Yoo, J. S., Kim, J. B., and Lee, J. W. (2013), Surgical treatment of atrial fibrillation. *Journal of Korean Medical Association*, **56**(9), 805-816.
- Young, B., Brodnick, D., and Spaulding, R. (1999), A comparative study of a hidden Markov model detector for atrial fibrillation, In *Neural Networks for Signal Processing IX, Proceedings of the 1999 IEEE Signal Processing Society Workshop.*, IEEE, 468-476.
- Zhou, X., Ding, H., Ung, B., Pickwell-MacPherson, E., and Zhang, Y. (2014), Automatic online detection of atrial fibrillation based on symbolic dynamics and Shannon entropy, *Biomedical Engineering Online*, **13**(1), 13:18, 1-18.