

Bayesci Yapısal Eşitlik Modellerinde Yakma Periyodu, Thin Kavramlarının İterasyon ve Otokorelasyona'a Etkilerinin Bir Model Üzerinde İncelenmesi

Sanem Şehribanoğlu , Hayrettin Okut

Yüzüncü Yıl Üniversitesi İstatistik Bölümü, Van

Yüzüncü Yıl Üniversitesi Biyometri ve Genetik ABD, Van

e-posta: sanem@yyu.edu.tr

Geliş Tarihi:01.12.2014; Kabul Tarihi:09.03.2015

Özet

Son yıllarda Bayesci yaklaşımların kullanımındaki esneklik Yapısal Eşitlik Modelleri (YEM)'de Monte Carlo Markov Zincir(MCMC) yöntemlerinin daha sık kullanılmasına neden olmuştur. MCMC yöntemlerinde çekilen örneklemeler arasındaki otokorelasyon, sonsal dağılıma yakınsayıp yakınsamadığının belirlenmesi ve zincirin sonlandırılması önemli konular arasındadır. Bu çalışma kapsamında MCMC yöntemlerinden olan Gibbs Örnekleme ile elde edilen bir Bayesci Yapısal Eşitlik Model sonuçlarına ait parametre tahmin değerleri kullanılmıştır. Bu parametre tahminleri için üretilen değerler başlangıç değerlerinin etkisinden kurtulabilmesi için yakma periyodu, bağımsızlığı içinde thin uygulamalarının iterasyonlar ve otokorelasyon üzerinde etkileri incelenmiştir. Çalışma sonunda yakma periyodu ve thin uygulamalarının etkili olduğu gösterilmiştir.

Anahtar kelimeler

Bayesci Yapısal Eşitlik Modelleri; Thin; Yakma periyodu; İterasyon.

Effects of Burn-In and Thinning Methods on Iteration and Autocorrelation in a Model System of Bayesian Structural Equation Models

Abstract

The flexibility of the Bayesian approach has recently led to a more common use of Monte Carlo Markov Chain (MCMC) methods in Structural Equation Modeling. Some important issues regarding the MCMC methods are autocorrelation between the samples, whether they converge to a posterior distribution or not, and the termination of the chain. In this study, the predicted values of the parameters were used, based on the data of a Bayesian Structural Equation Model obtained by Gibbs Sampling as one of the MCMC methods. Burn-in method was utilized for overcoming the effects of the original parameters on the predicted values and thinning method was used for the independence of these predictions. The effects of burn-in and thinning methods were evaluated and it is concluded that these methods were very effective on iteration and autocorrelation.

Keywords

Bayesian Structural Equation Model; Thining; Burn-in; Iteration

1.Giriş

Klasik YEM'de parametre tahminleri için genellikle en yüksek olabilirlik (ML) yöntemi kullanılarak nokta tahminlemesi, asimptotik güven sınırları ve test istatistikleri kullanılır. Bayesci yaklaşım da ise parametreler için tam sonsal dağılım yardımıyla

gizil (latent) değişkenler MCMC tarafından tahmin edilir (Palomo vd., 2007).

Bayes yöntemi, sonsal dağılımların elde edilmesinde MCMC algoritmalarından yararlanır. MCMC, rastgele yürüyüş simülasyonu ile parametre değerlerini çekmek için bir dizi koşullu dağılım kullanılır. Bu koşullu dağılımlar sayesinde bileşik

© Afyon Kocatepe Üniversitesi

sonsal dağılıma yakınsayan bir dağılım elde edilmeye çalışılır (Gelman ve Rubin, 1996; Muthén ve Asparouhov, 2010). MCMC'nin en önemli avantajı, örneklemelerde asimtotik normaliteye ihtiyaç duymaması ve küçük örneklemelerde güvenilir sonuçlar vermesidir (Congdon, 2001; Palomo vd., 2007; Lee ve Song, 2004; Yang ve Dunson, 2010).

1.1.Yakma Periyodu Nedir ve Neden Uygulanır?

MCMC yöntemlerinde çekilen örneklemelerin sonsal dağılıma yakınsayıp yakınsamadığının belirlenmesi ve zincirin durdurulması önemli konulardan biridir. Markov zincirinin başlangıç değerlerinin (initial values) belirlenmesinde, araştırmacı deneyimlerini göz önünde tutarak bir başlangıç değeri atayabileceği gibi, ML yönteminden elde edilen dağılımın mod değerine yakın bir değer de alabilir. Simülasyonun ilk adımlarında başlangıç değerinin etkileri görülse de ilerleyen adımlarda zincirin başlangıç değerinin etkilerinden kurtulması beklenir (Gill, 2002).

Markov zincirinde, teorik olarak sonsuz iterasyon sayısı ile çalışılırsa ($n \rightarrow \infty$) başlangıç değerinin etkisinden kurtulur. Ancak pratikte böyle bir şeyden bahsetmek mümkün değildir. Uygulamada, belli bir tekrarlama sayısından sonra zincirin yakınsaması beklenir. Böylece parametrelerin daha uygun tahminleme yapmak için başlangıç değerinin etkisinde olan bölüm zincirden çıkarılır. Yakma periyodu olarak isimlendirilen bu işlemin amacı, başlangıç değerinin etkisinde olan bölümün analizden çıkarılarak, sonsal değerler üzerindeki etkisini minimize etmektir (Congdon, 2003; Gill, 2002; SAS, 2009).

Başlangıç değerinin etkisinden kurtulmak ve yakınsamanın gerçekleşmesi için gerekli olan tekrarlama sayısını belirlemede kesinleşmiş yöntemler bulunmamaktadır. Gilks vd. (1996)'e göre örnekleme ait grafiği incelemek zincir uzunluğuna karar vermede etkili bir yöntemdir.

1.2.Thin Kavramı Nedir?

Uzun süren simülasyon çalışmalarında elde edilen verileri depolamak bir sorun haline gelebilir. İterasyondaki yüksek otokorelasyon, yakınsamanın yavaş gerçekleşmesi, çok sayıda eşzamanlı zincir çalıştırılması ve çok boyutluluk bu sorunlara neden olabilmektedir. Yakınsamanın yavaş gerçekleşmesi Monte Carlo standart hatasının (MC Error) yanlış sonuçlar üretmesine neden olabilir (Gill, 2002). Bu sorunları gidermek için thin yöntemine başvurulur.

Markov zincirinin tümü kullanıldığı takdirde, her zaman daha hassas sonsal tahminler elde edildiği belirtilmiştir (SAS, 2009; SAS, 2006). Ancak tüm Markov zincirinin kullanılmadığı durumlarda; k'cı iterasyon örnekleme olarak isimlendirilen yöntem kullanılır. Thin olarak da bilinen bu yöntem, Markov sürecinin bütünlüğünü korur ve depolama taleplerini azaltarak sadece tahmin kalitesini artırmayı amaçlar. Zinciri hızlandırmaya veya yakınsamaya yardımcı olmaz. Bu yöntem, bağımsızlığı sağlamak için her sıranın k.cı itersayonda elde edilen değerini örnekleme alır. Zincir içindeki değerler arasındaki ilişki azalır ve zincir sonsal dağılımda kullanılmak üzere güvenilir hale gelir (Gill, 2002; Gelfand, 2000; SAS, 2006).

1.3.Yakınsama ve Otokorelasyon

Bayes tabanlı simülasyon çalışmalarında Markov zincirinin istenen sonsal dağılıma ulaşım ulaşımadığını incelemek için yakınsama diagnostikleri geliştirilmiştir. Bunlardan biride Potansiyel Ölçek Azalma tahminidir (EPSR). Bu yöntem farklı başlangıç değerlerinden oluşan çok sayıda dizilerin simülasyonlarını temel alır. Tahmin edilecek her bir parametre değeri n uzunluğundaki k. zincirin tahmini olarak tanımlanır (Gelman, 1996). Yakınsama, Gelman-Rubin diagnostiği kullanılarak elde edilir (Muthén ve Asparouhov 2010; Lee, 2007) . Gelman-Rubin diagnostiği, farklı başlangıç değerleri olan iki ya da daha fazla paralel zincir arasındaki varyansları karşılaştırır. Temelde klasik varyans analizine dayanan bu yöntem, her bir değişken için zincir

varyansları arasındaki karşılaştırmaları dikkate alır (Ntzoufras, 2009).

Yakınsama'nın değerlendirilmesi için başka bir yöntem olarak MC hatalarına bakılır. Markov zincirinden elde edilen sonsal standart sapma ile MC hata değerleri karşılaştırılır. Bu karşılaştırma sonucunda MC hata, sonsal ortalama değerlerinden küçük ise sonsal ortalama tahmini yüksek duyarlılıkta tahmin edilmiştir denir. İterasyon sayısını arttırmak çoğunlukla MC hatayı düşürür (Ntzoufras, 2009). Thumb Kuralı olarak da bilinen, ilgili parametreye ait MC hata değerinin, standart sapma değerinin %5'inden küçük olması istenir (Spiegelhalter vd., 2003 ; Bugs, 2012).

Modeldeki parametreler arasında yüksek korelasyon olması durumunda Gibbs Örnekleme'nin tüm parametrelere ait sonsal dağılımlarını ortaya koyması yavaş olacaktır (Grynaviski, 2003). Modelde otokorelasyonu incelediğimizde, her bir zincir için örneklemeler arasındaki bağımlılık ölçülmektedir. Yakınsama hızı, koşullu dağılımların karmaşıklığına da bağlı olmasının yanı sıra yavaş yakınsama hızı, zincirin bağımlı (örneğin otokorelasyonun büyük) olduğu anlamına gelir (SAS, 2009). Otokorelasyon seviyesi, zincirdeki gecikme (lag) sayısı arttıkça azalacaktır.

Otokorelasyonların izlenmesi, düşük ya da yüksek değerlerin ayrı ayrı hızlı veya yavaş yakınsamayı göstermesi sebebiyle çok kullanışlıdır. Yakınsama problemi bulunmayan zincirler için, otokorelasyon katsayılarının küçük olması beklenir (Ntzoufras, 2009).

İz (Trace Plot) ve geçmiş (history) grafikleri de iterasyonun yakınsama değerlendirmesinde kullanıcılar için yararlı yöntemler arasındadır. Modelin kaçınıcı iterasyonda yakınsayacağı, başlangıç değerinin değerlendirilmesi, yakma periyodu sayısını arttırmaya gerek olup olmadığı gibi bilgileri elde etmemizi sağlarlar. Grafiklerdeki uzun süreli iniş ve çıkışlar, yakınsamanın yavaş olduğu bilgisini verir (SAS, 2009). Ntzoufras (2009)'a göre,

otokorelasyon ve iz grafikleri yakınsamayı izleyebilmek için kullanılan basit ve hızlı yöntemlerdir.

2. Materyal ve Metot

Bu çalışmanın veri seti kırmızı et tüketim alışkanlığı konusunda likert ölçekli 25 sorudan oluşmaktadır. Yüzüncü yıl üniversitesinde 2012-2013 yılları arasında okumakta olan 403 öğrenciye uygulanmış olan çalışmanın kuramsal modelinde; Bireysel Düşünce, Ailesel Görüş ve Tüketimde Sağlık Yaklaşımı olarak belirlenen faktörler arasındaki ilişki WinBUGS programı yardımıyla incelenmiştir (Şehribanoğlu, 2012). Çalışmamıza ait modeller sırasıyla yazılacak olursa,

y_i , ölçülebilen (içsel ve dışsal) gözlemler vektörü, ω , gözlenemeyen değişkenler matrisi, $\Omega = (\omega_1, \dots, \omega_h)$,

$\omega_{\eta_i} = \eta_i$ içsel gözlenemeyen değişken vektörü,

$\omega_{\xi_i} = \xi_i$ dışsal gözlenemeyen değişken vektörü, δ , boyutlu rassal hata vektörüdür.

$$y_i = \Lambda \omega_i + \varepsilon_i \quad (1)$$

$$\eta_i = B \eta_i + \Gamma \xi_i + \delta_i \quad (2)$$

$M = [B \ \Gamma]$ regresyon katsayılar matrisidir. η ve ξ arasındaki nedensel etkileri gösterir. Yapısal modelimiz $\eta_i = M \omega_i + \delta_i$ gibi yazılabilir. Değişkenlere ait dağılımlar, sırasıyla, $\varepsilon_i \sim N(0, \Psi_\varepsilon)$, $\delta_i \sim N(0, \Psi_\delta)$, $\omega_i \sim N(0, \Sigma_w)$ dir. Ψ_ε ölçümsel hataların, Ψ_δ yapısal hataların ve Φ gözlenemeyen dışsal değişkenlere ait varyans-kovaryans matrisidir. Λ , ölçülebilen modelin regresyon katsayılarının matrisi, Σ_w ise ω 'nin kovaryans matrisidir.

Modellere ait θ bilinmeyen vektörünü $\Lambda, \Psi_\varepsilon, \Phi, \Psi_\delta, M$ kabul edersek, koşullu dağılımlar aşağıdaki biçimde yazılabilir.

İçsel gizil değişkenler,

$$p(\Lambda, \Psi_\varepsilon, \Omega, M, \Psi_\delta, \Phi | Y) \quad (3)$$

$$\propto p(Y | \Lambda, \Psi_\varepsilon, \Omega, M, \Psi_\delta, \Phi) p(\Lambda, \Psi_\varepsilon, \Omega, M, \Psi_\delta, \Phi)$$

$$p(\Lambda, \Psi_\varepsilon, M, \Psi_\delta, \Phi | Y, \Omega) \propto [p(Y | \Lambda, \Psi_\varepsilon, \Omega) p(\Lambda, \Psi_\varepsilon)] [p(\Omega | M, \Psi_\delta, \Phi) p(M, \Psi_\delta, \Phi)] \quad (4)$$

Parametrelere ait sonsal dağılım aşağıdaki gibi

yazılabilir,

$$p(\theta | y, x, \eta, \xi) \propto [p(\theta_x) p(x_i | \xi_i, \theta)] [p(\theta_y) p(y_i | \eta_i, \theta)] [p(\theta_\eta) p(\eta_i | \xi_i, \theta)] [p(\theta_\xi) p(\xi_i | \theta)] \quad (5)$$

(Stokes-Riner, 2009)

Aynı şekilde YEM modeline ait içsel ve dışsal değişkenlere ait koşullu sonsal dağılımlar sırasıyla;

$$p(\eta_i | v_y, \Lambda_y, \Psi_\varepsilon, (I - B)^{-1}(\alpha + \Gamma \xi_i), \Omega_\eta, y_i) \propto p(y_i; v_y + \Lambda_y \eta_i, \Psi_\varepsilon) p(\eta_i; (I - B)^{-1}(\alpha + \Gamma \xi_i), \Omega_\eta) \quad (6)$$

ve

$$p(\xi_i | \eta_i, \Omega_\xi, v_x, \Lambda_x, \Psi_\delta, \alpha, B, \Gamma, \Omega_\xi, \mu_\varepsilon, x_i) \propto p(x_i; v_x + \Lambda_x \xi_i, \Psi_\delta) p(\eta_i; \alpha + B \eta_i + \Gamma \xi_i, \Omega_\xi) p(\xi_i; \mu_\xi, \Omega_\xi) \quad (7)$$

olacak şekilde yazılır (Dunson vd., 2005) . YEM'e ait parametrelerin Gibbs örnekleme yöntemiyle elde edilmesi ile ilgili ayrıntılı bilgi Şehribanoğlu ve Okut , 2013 tarafından verilmiştir .

Bu çalışma da $y_{ik} \sim N(\mu_{ik}, \Psi_k)$ olan modele ait dağılım bilgileri Tablo 1 ve Tablo 2 gibi atanmıştır.

Tablo 1. Uygulamada kullanılmak üzere belirlen parametrelere ilişkin önsel dağılımlar I

	Dağılım Bilgisi	Önsel Dağılım Bilgisi
Sabit vektörler	$\alpha \sim N(0, I)$	$\alpha \sim N(0.0, 1.0)$
ξ gözlenemeyen	$\xi_i = (\xi_{i1}, \xi_{i2})^T$	$\xi_i \sim N(0, \Phi)$
Φ	$\Phi \sim IW [v_0, V_0]$	$\Phi \sim IW [v_0, 6]$
Ölçümsel modellere ait hata	$\varepsilon_{ik} \sim N(0, \Psi_{\varepsilon k})$	
$\Psi_{\varepsilon k} = \text{diag}(\psi_{\varepsilon 1}, \dots, \psi_{\varepsilon 11})$	$\Psi_{\varepsilon k}^{-1} \sim \text{Gamma}(\alpha_{0\varepsilon k}, \beta_{0\varepsilon k})$	$\Psi_{\varepsilon k}^{-1} \sim \text{Gamma}(0.01, 0.01)$
Lambda faktör yüklerine	$\Lambda_k \sim N(\Lambda_{0k}, \Psi_{\varepsilon k})$	$\Lambda_{0k} = 0.0$

Tablo 2. Uygulamada kullanılmak üzere belirlen parametrelere ilişkin önsel dağılımlar II

	Dağılım Bilgisi	Önsel Dağılım Bilgisi
η	$\eta_i \sim N(v_i, \Psi_\delta)$	
Ψ_δ	$\Psi_\delta^{-1} \sim \text{Gamma}(\alpha_{0\delta}, \beta_{0\delta})$	$\Psi_\delta^{-1} \sim \text{Gamma}(0.01, 0.01)$
Regresyon katsayıları	$\Gamma \sim N(\Gamma_0, \Psi_\delta)$	$\Gamma_0 = 0.0$

Bu çalışmada yakma periyodu, thin ve iterasyon sayılarının model üzerindeki etkilerini görebilmek amacıyla modelimize ait sorunların gözlemlendiği lambda değerleri verilmiştir.

Modelimizde farklı önsellerle çalışan zincirlerin durumunu gözlemleyebilmek için dört adet zincir oluşturulmasına karar verilmiştir (Tablo 3). Birinci ve ikinci (lamda parametrelerine 1 değeri atanmış) zincirde bilgi sahibi olmadığımız düşüncesinden hareket ederek bilgi vermeyen önseller seçilmiştir.

LISREL programında klasik tahminleme yöntemi ile elde ettiğimiz değerleri ve analizlere başlamadan önce çalıştırılan birinci zincirden (thin=5, Yakma periyodu =1000 olmak üzere 10.000 iterasyon) elde edilen sonuçlar hiperönseller olarak sırasıyla üçüncü ve dördüncü zincirlere atanmıştır.

Seçilen bu zincirlerin durumunu incelemek ve yöntem bölümünde anlatılan yakınsama ve otokorelasyonu etkileyen durumların modelimiz üzerindeki etkilerini gözlemleyebilmek için farklı

iterasyon, thin ve yakma periyotlarından oluşan dört uygulama yapılmasına karar verilmiş olup bu uygulamaların detayları Tablo 4’ de verilmiştir.

Tablo 3. Zincirler ve önsel değerleri

Zincirler	Önsel Değerler
1.Zincir	lam=c(0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0, 0.0),
2.Zincir	lam=c(1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0, 1.0),
3.Zincir	lam=c(0.96,0.98,1.12,1.09,1.42,1.28,0.55,0.87)
4.Zincir	lam = c(0.943, 0.971, 1.327, 1.162, 1.424, 1.089 ,0.562 ,0.963),

Tablo 4. Çalışmada kullanılan uygulamalar

	İterasyon	Thin	Yakma Per.	Üretilen Örn. Sayısı
Uyg. I	5000	-	-	5.000
Uyg. II	10000	4	-	2.500
Uyg. III	15000	-	1000	14.000
Uyg. IV	25000	4	1000	6.000

3.Bulgular

Uygulamalara ait MC hata değerleri sırasıyla aşağıda verilmiş olup (Tablo 5, Tablo 6, Tablo 7 ve Tablo 8) MC hata değerinin standart hata değerinden küçük olmadığı durumlar koyu renkli olarak belirtilmiştir.

Tablo 5. Birinci uygulamaya ait Mc Hata değerleri

	1 Zincir	2 Zincir	3 Zincir	4 Zincir	1-4 Zincir Ortalaması
lam[B2]	0.005	0.006	0.006	0.005	0.003
lam[B3]	0.006	0.007	0.006	0.005	0.003
lam[B4]	0.006	0.007	0.006	0.005	0.003
lam[B5]	0.006	0.007	0.006	0.005	0.003
lam[B22]	0.007	0.007	0.007	0.006	0.003
lam[B23]	0.015	0.015	0.015	0.011	0.007
lam[B18]	0.007	0.006	0.006	0.007	0.003
lam[B19]	0.007	0.007	0.006	0.007	0.003

Tablo 5’ de elde edilen değerlere bakıldığında farklı önseller ile çalışmış olmanın MC hata değerlerini ortadan kaldırmadığı görülmektedir.

Tablo 6. İkinci uygulamaya ait Mc Hata değerleri

	1 Zincir	2 Zincir	3 Zincir	4 Zincir	1-4 Zincir Ortalaması
lam[B2]	0.003	0.003	0.003	0.003	0.002
lam[B3]	0.003	0.004	0.003	0.003	0.002
lam[B4]	0.003	0.003	0.003	0.003	0.001
lam[B5]	0.003	0.004	0.003	0.003	0.002
lam[B22]	0.004	0.004	0.004	0.004	0.002
lam[B23]	0.007	0.008	0.006	0.008	0.004
lam[B18]	0.003	0.002	0.003	0.003	0.001
lam[B19]	0.003	0.003	0.003	0.003	0.001

Tablo 5 ve Tablo 6 değerlerini karşılaştırdığımız zaman, Tablo 6’da üretilen örnek sayısının az olmasına rağmen thin uygulamasının MC hata değerlerini düşürdüğü fark edilmiştir.

Tablo 7. Üçüncü uygulamaya ait Mc Hata değerleri

	1 Zincir	2 Zincir	3 Zincir	4 Zincir	1-4 Zincir Ortalaması
lam[B2]	0.003	0.003	0.003	0.003	0.002
lam[B3]	0.003	0.003	0.004	0.004	0.002
lam[B4]	0.003	0.003	0.003	0.003	0.002
lam[B5]	0.003	0.003	0.003	0.004	0.002
lam[B22]	0.004	0.005	0.004	0.005	0.002
lam[B23]	0.009	0.010	0.012	0.010	0.005
lam[B18]	0.003	0.003	0.004	0.003	0.002
lam[B19]	0.004	0.004	0.004	0.004	0.002

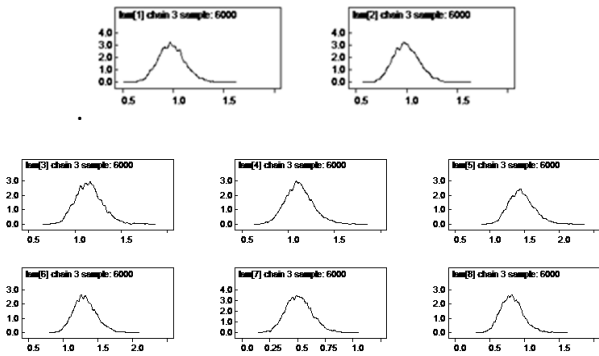
Tablo 7 değerlerine bakıldığında ise lam[B23] dışındaki tüm parametrelere ait MC hata değerlerinin azaldığı dikkatimizi çekmiştir.

Tablo 8. Dördüncü uygulamaya ait Mc Hata değerleri

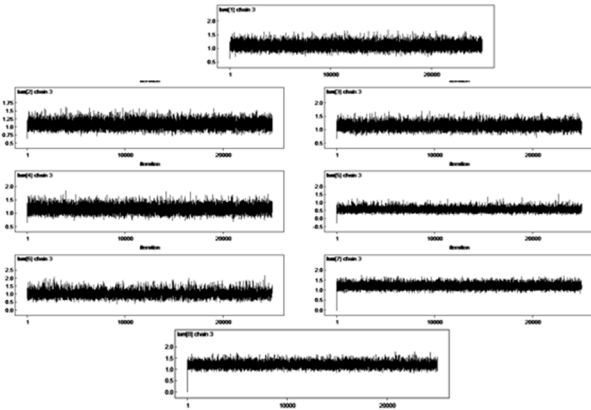
	1 Zincir	2 Zincir	3 Zincir	4 Zincir	1-4 Zincir Ortalaması
lam[B2]	0.002	0.002	0.002	0.002	0.001
lam[B3]	0.002	0.002	0.002	0.002	0.001
lam[B4]	0.002	0.002	0.002	0.002	0.001
lam[B5]	0.002	0.002	0.002	0.002	0.001
lam[B22]	0.002	0.002	0.003	0.002	0.001
lam[B23]	0.004	0.005	0.005	0.004	0.002
lam[B18]	0.002	0.001	0.002	0.002	0.001

lam[B19] 0.002 0.002 0.002 0.002 0.001

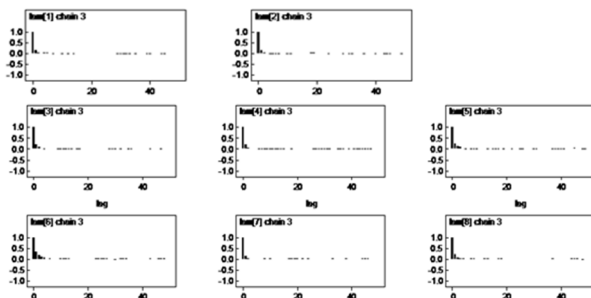
Tablo 8’de MC hata değerleri incelendiğinde, tüm değerlerin beklenildiği şekilde küçük değerlere ulaştığı görülmüştür. Modelimize ait MC hata değerlerinin, yukarıda değinilen teorik koşulları sağlamasından dolayı, modelin hem yakınsama hem de otokorelasyon sorunları yaşamadığı sonucuna varılmıştır. Şekil 1’de verilen modelimize ilişkin kernel yoğunluk fonksiyonları da bu sonucu destekleyen görsel bilgiler sunmaktadır. Ancak yakınsama ve otokorelasyon sorunlarının olmadığı görüşünün kanıtlanabilmesi için modele ait grafiklerin de incelenmesi gerekmektedir (Şekil 2 ve Şekil 3).



Şekil 1. Üçüncü zincir’e ait Kernel grafikleri



Şekil 2. Üçüncü zincir’e ait history grafikleri



Şekil 3. Üçüncü zincir’e ait otokorelasyon grafikleri Geçmiş grafikleri (Şekil.2) incelendiğinde parametrelerin yakınsamayı kolaylıkla sağladığı görülmüştür. Aynı şekilde otokorelasyon grafikleri (Şekil.3) her bir parametre için otokorelasyonun olmadığını ve otokorelasyondan ne zaman kurtuldukları bilgisini vermiştir.

4.Sonuç

Uygulamalar incelendiğinde, iterasyon sayılarının artırılması modelimize ait türetilen verilerde otokorelasyonu gidermekte etkili olduğu ancak tüm otokorelasyonu ortadan kaldırmadığı görülmektedir. Yakma periyodu uygulamasının bu çalışmamızda yakınsama konusunda çok fazla etkili olmadığı görülmüştür. Bu durum yakma periyodu mantığının çalışmadığını değil, Şekil 2’ye ait geçmiş grafiklerinde de görüldüğü üzere modelimizin hızlı bir şekilde atanan başlangıç değerinden kurtulduğu anlamına gelmektedir. Thin uygulamasının birbirinden bağımsız değerler üretilmesi sırasında aralarında gecikme sayılarının oluşmasına izin vermediği yani otokorelasyonu yok ettiği ve bu sayede yakınsamanın daha hızlı olduğu sonucuna varmamızı sağlamıştır.

Her dört uygulamada da zincir ortalama değerlerinde (1-4 Zincir Ortalaması) MC hataya ait sorunlar yaşanmadığı görülmektedir. Bu da bize iterasyon sayısını arttırmanın MC hata değerini düşürdüğü bilgisini vermektedir.

Kaynaklar

Congdon, P., 2001. Applied Bayesian Modeling. John Wiley & Sons, London, UK, 478.

Dunson, D.,B. and Herring, A.,H.,2005. Bayesian latent variable models for mixed discrete outcomes. *Biostatistics*, **6**, 11-25.

Gelfand, A.,E.,2000. Gibbs Sampling. *Journal of the American Statistical Association*, **95** (452), 1300-1304.

Gelman, A. and Rubin D.,B.,1996. Markov Chain Monte Carlo methods in Biostatistics. *Statistical Methods in*

Medical Research, 5(4),339-355.

Gelman, A., 1996. Markov Chain Monte Carlo in Practice. W.R. Gilks and S. Richardson, D.J. Spiegelhalter (Editörler), Chapman and Hall, 131-143.

Gilks, W.,R., Richardson S. and Spiegelhalter D.J., 1996. Markov Chain Monte Carlo in Practice. Chapman and Hall, London. 486.

Gill, J., 2002. Bayesian Methods (A social and behavioral sciences approach). Chapman & Hall/CRC Statistics in the Social and Behavioral Sciences, USA, 655.

Lee, S. and Song, X., 2004. Evaluation of the Bayesian and Maximum Likelihood approaches in analyzing Structural Equation Models with small sample sizes, *Multivariate Behavioral Research*, 39(4),653-686.

Lee, S., 2007. Structural Equation Modeling: A Bayesian Approach. John Wiley & Sons, London,UK,458.

Ntzoufras, I., 2009. Bayesian Modelling Using WinBUGS. John Wiley & Sons, New Jersey, 520 .

Palomo, J., Dunson, D., B. and Bollen, K., 2007. Handbook of Computing and Statistics with Applications. S.Y. Lee (Editör), Elsevier, 163-188.

Şehribanoğlu,S., 2012. Yapısal Eşitlik Modellerinde Parametre Tahmininde Gibbs Örneklemesi. Doktora Tezi, Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü, Van, 140.

Şehribanoğlu,S. ve Okut, H., 2013. Bayesci Yapısal Eşitlik Modellerinde Parametre Tahminlemesi. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 18 (1-2), 17-22.

Stokes-Riner,A., 2009. Residual Diagnostic Methods for Bayesian Structural Equation Models. University of Rochester, School of Medicine and Dentistry. Dept. of Biostatistics and Computational Biology, Doktora Tezi, New York, 94.

Yang, M. and Dunson, D.,B., 2010. Bayesian semiparametric Structural Equation Models with latent variables, *Psychometrika*, 75 , 675-693.

1-Bugs, 2012. Tutorial. <http://mathstat.helsinki.fi/openbugs/Manuals/Tutorial.html> (16.01.2012).

2-Grynaviski, J., 2003. ABSLec13 - MCMC Diagnostics. <http://home.uchicago.edu/~grynav/bayes/ABSLec13.ppt> (22.01.2012).

3-Muthén, B. and Asparouhov, T., 2010. Bayesian SEM:A more exible representation of substantive theory. <http://www.statmodel.com/download/BSEMFINAL10212011.pdf> (15.05.2011).

4-Muthén, L. and Muthén, B., 2010. Mplus,Statistical Analysis With Latent Variables User's Guide.Mplus User's Guide. <http://www.statmodel.com/download/usersguide/Mplus%20Users%20Guide%20v6.pdf> (01.2012).

5-SAS, 2006. Preliminary capabilities for Bayesian analysis in SAS/STATR Software, <http://support.sas.com/rnd/app/papers/Bayesian.pdf> (01.06.2011).

6-SAS, 2009. SAS/STAT(R) 9.2. User's Guide, <http://support.sas.com/documentation/cdl/en/statug/63033/HTML/default/viewer.htm#statugintrBayessect007.htm> (06.2011).

7-Spiegelhalter, D., Thomas, A., Best, N. and Lunn,D., 2003. WinBUGS Version 1.4. User Manual. Cambridge: Medical Research Council Biostatistics Unit. <http://www.mrc-bsu.cam.ac.uk/bugs/winbugs/manual14.pdf> (06.2011).

internet kaynakları