



Aktüerya Derneği

İstatistikçiler Dergisi: İstatistik & Aktüerya

Journal of Statisticians: Statistics and Actuarial Sciences

IDIA 12, 2019, 1, 15-31

Geliş/Received:14.01.2019, Kabul/Accepted: 19.05.2019

www.istatistikciler.org

Araştırma Makalesi / Research Article

Bayesci model ortalaması yöntemi: İstihdam oranı üzerine bir uygulama

Atilla Yardımcı

Türkiye Odalar ve Borsalar Birliği

Dumlupınar Bulvarı No: 252

06530-Çankaya, Ankara, Türkiye

atilla.yardimci@tobb.org.tr

orcid.org/0000-0003-3521-2452

Öz

Bu çalışmada, model belirsizliğini azaltmak, modelde yer alan bağımsız değişkenlerin katkıları ile önem düzeylerinin belirlenmesi amacıyla kullanılan, Bayesci model ortalaması yöntemi açıklanmıştır. Ayrıca Ocak 2007-Ağustos 2018 ayları arasındaki sektörel kapasite kullanım oranı verisi yardımıyla, istihdam oranını etkileyen imalat sektörlerinin belirlenmesi için Bayesci model ortalaması yöntemi kullanılmıştır. Yapılan analizler sonucunda istihdam oranı üzerinde en etkili olan sektörlerin içeceklerin imalatı, tekstil ürünlerinin imalatı, diğer metalik olmayan mineral ürünlerin imalatı ile mobilya imalatı sektörleri olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: Bayesci model ortalaması, istihdam oranı, kapasite kullanım oranı, model belirsizliği.

Abstract

Bayesian model average method: An application on employment rate

In this study, Bayesian model averaging method, which is used to decrease the model uncertainty and to determine the importance levels of the independent variables in the model, was explained. In addition, with the help of sectoral capacity utilization rate data between January 2007 and August 2018, the Bayesian model average method was used to determine the manufacturing sectors that affect the employment rate. As a result of the analyzes, it is concluded that the sectors that are the most effective on the employment rate are the manufacture of beverages, the manufacture of textiles, the production of other non-metallic mineral products and the furniture manufacturing sectors.

Keywords: Bayesian model averaging, employment rate, the capacity utilization rate, model uncertainty

1. Giriş

Regresyon analizlerinde geniş bir model havuzundan çeşitli ölçütlere göre “tek bir” en iyi modele ulaşılması ve en az açıklayıcı özelliği olan değişkenlerin modelden elenmesi amaçlanmaktadır. En iyi model seçildikten sonra, bu modelin gerçek veriyi üreten süreç olduğu varsayılarak tahminlerde bulunmaktadır. Ancak tek bir modelin seçilmesi, bazı belirsizliklerin dikkate alınmadığı anlamına geldiğinden yanıltıcı sonuçların elde edilmesine neden olabilir [1, 2]. Ayrıca en iyi modelin tanımlandığı

varsayılsa bile yalnızca “en iyi” tek bir modele ait sonuçlarının sunulması, “ikinci en iyi” modelin sonuçlarının dikkate alınmaması model belirsizliğini ortaya çıkarmaktadır. Bunun yanında seçilen bu model gerçekten en iyi olsa bile az da olsa en iyi olmama olasılığının varlığı model belirsizliğini ortaya çıkaracaktır. Model seçimindeki belirsizliğin azaltılması için farklı model yapılarından gelen tahminlerin, belli bir değere göre ağırlıklandırılarak ortalamalarının alınarak birleştirilmesi, alternatif bir yaklaşım olarak önerilmektedir [3].

Model ortalaması yaklaşımının, birkaç modelin sonuçlarını tek bir tahmin kümesinde birleştirerek, model belirsizliğini de dikkate alan bir yöntem olduğu Banner ve Higgs [4] tarafından ifade edilmektedir. Model ortalamaları yöntemleri, klasik ve Bayesci olmak üzere ikiye ayrılmaktadır. Son yıllarda birçok farklı alanda Bayesci model ortalaması (BMO) yöntemini kullanan çalışmaların sayısı oldukça artmıştır. Bijak [5] uluslararası göç tahmininde, Kabir vd. [6] su şebekesinin arızalanma oranlarının tahmin edilmesinde BMO yöntemlerini kullanmışlardır. Mohsen vd [7] tarafından 1996-2013 yılları arasında 24 gelişmekte olan ülke için BMO kullanılarak ihracat bileşenleri incelenmiştir. İsveç tüketici fiyat endeksinin tahmin edilmesi için Jacobson ve Karlsson [8] tarafından BMO yaklaşımı kullanılmıştır. Schneider ve Yavuz [9] çalışmalarında BMO yöntemini kullanarak Amerika Birleşik Devletleri’nde eyalet düzeyinde ölüm oranları arasındaki değişimleri incelemişlerdir. Cheng [10] ebeveynlerin süt satın alırken tercihlerindeki etkileri BMO yöntemini kullanarak araştırmıştır.

Literatür incelemesi sonucunda ağırlıklı olarak işsizlik oranları ve kapasite kullanım oranları üzerine yoğunlaşan çalışmalar olmasına karşın, istihdam oranı üzerinde daha az durulduğu görülmüştür. Belton ve Cebula [11] yaptıkları çalışma ile kapasite kullanım ve işsizlik oranlarının enflasyon oranı üzerindeki etkilerini araştırmışlardır. Altuntepe ve Güner [12] tarafından sanayi, tarım ve hizmetler sektöründe ki büyüme oranları, kapasite kullanım oranları ile sabit sermaye yatırımlarının, toplam istihdam üzerindeki etkisi analiz edilmiştir. Geyikçi [13] tarafından yapılan çalışmada turizm tesislerinin doluluk oranı ile istihdam arasında çift yönlü nedensellik ilişkisi tespit etmiştir. Durmuş ve Akbulut [14] çalışmalarında 1980-2016 yılları arasında Türkiye’de büyüme rakamları ile istihdam oranları arasındaki ilişkiyi incelemişlerdir.

Bu çalışmada model belirsizliğini gidermek, modelde yer alan bağımsız değişkenlerin katkıları ve önem düzeylerinin belirlenmesi amacıyla, Bayesci model ortalaması yöntemi kullanılmıştır. Bununla birlikte istihdam oranı üzerinde, kapasite kullanım oranları dikkate alındığında, hangi sektörlerin etkili olduğu incelenmiş ve bu sektörlerin içerdiği alt sektörler dikkate alınarak bazı tespitler yapılmıştır. Çalışma kapsamında Bayesci model ortalaması yöntemi açıklanarak, Nace Rev 2.0 sektör sınıflamasına bağlı olarak Ocak 2007- Ağustos 2018 dönemi dikkate alınarak, istihdam oranı üzerindeki sektör etkileri incelenmiştir.

2. Bayesci Model Ortalaması

Bayes teoremi, bir deneyin olası sonuçlarından biri biliniyor iken bu sonucun nasıl ortaya çıktığını araştırmaya yarayan bir teoremdir. A_1, A_2, \dots, A_n olayları n tane ayrık ve S örneklem uzayını kapsayıcı olaylar, B olayı da yine S örneklem uzayının bir elemanı olsun. B bilindiğinde A_i olayının ortaya çıkış olasılığı Bayes teoremi kullanılarak,

$$p(A_i|B) = \frac{p(B|A_i)p(A_i)}{\sum_{i=1}^n p(B|A_i)p(A_i)} \quad (1)$$

biçiminde ifade edilir [15]. Bayesci istatistik genel olarak, sadece örneklem bilgilerine değil eldeki tüm bilgilere bağlı olarak istatistiksel çıkarımların yapılabileceğini öne süren bir yaklaşım olarak tanımlanmaktadır. Bayesci istatistikte, hesaplamalarda örneklem bilgisinin yanında araştırmacının sahip olduğu bilgi, daha önce benzer araştırmalardan elde edilmiş sonuçlar ya da konunun özelliklerine göre geçerli olan kurallar analizlere dahil edilmektedir. Dahil edilen tüm bu bilgilere önsel bilgi adı verilmektedir. Önsel bilgilerin Bayesci süreçlerde kullanılabilmesi için olasılık ya da dağılım biçiminde

tanımlanması gerekmektedir. Önsel bilgi/olasılık ile örneklem (deneyden elde edilen) bilgilerinin bileşiminden sonsal bilgiler/olasılıklar elde edilmektedir [16].

Regresyon analizlerinde, model seçiminden sonra, bu seçimin ne kadar doğru olduğu konusu önemli olmaktadır. Bu nedenle; modellerin çeşitli kriterlere göre sıralanması ve seçilen modelin diğer aday modellerden daha iyi olup olmadığının incelenmesi gerekmektedir. Klasik yaklaşımlarda farklı seçim kriterlerine göre yapılan sıralamalar sonucunda, farklı modeller seçilebileceğinden en iyi modelin belirlenmesinde belirsizlik durumu oluşmaktadır. BMO yöntemi, belirsizliğin açıklanmasına yönelik olarak, çıkarımları tek bir modele bağlı kalmadan, birden fazla modelin dahil edildiği model kümesini kullanarak yapmaktadır. Böylece kullanılan bu model kümesinde yer alan her bir model, sonuç üzerinde kendi açıklama gücü kadar katkıda bulunmaktadır [17, 18]. BMO yönteminde modellerin açıklama güçleri sahip oldukları sonsal olasılıklar ile ölçüldüğünden, olası tüm modeller sonsal olasılıkları ile ağırlıklandırılarak ortalamaya dahil edilmekte ve böylece model belirsizliği giderilmeye çalışılmaktadır [6]. Ayrıca olası tüm modeller sahip oldukları sonsal olasılıklarına göre sıralanarak tek bir modelin tercih edilmesi gereken durumlarda belirsizlik, olasılık biçiminde ifade edilerek somutlaştırılmaktadır [5, 7, 19]. Bunun yanında; açıklayıcı değişkenlerin bağımlı değişken üzerindeki muhtemel etkilerinin belirlenmesi istendiğinde de BMO yöntemleri kullanılmaktadır [20]. BMO yöntemleri kullanılarak sağlanan yararlar aşağıda kısaca özetlenmiştir.

- BMO yöntemleri kullanılarak aynı anda çok sayıda açıklayıcı değişkenin birlikte incelenmesi, her bir değişkenin gerçek modelde yer alma olasılığı (sonsal dahil olma olasılığı) ve sonsal model olasılıkları ile model ortalamalarının hesaplanması mümkün olmaktadır [21].
- Değişkenlerin sahip olduğu sonsal dahil olma olasılıkları tek bir en iyi model seçilmesi gerektiği durumlarda hangi değişkenlerin seçilmesi gerektiği konusunda yol gösterici olmaktadır. Genellikle 0.50 ve üstü olasılığa sahip değişkenler modelde yer alabilirler, bunun yanında uygulamada 0.66 ve üstü tercih edilmektedir [9].
- Araştırmacıyı sadece tek modeli tercih etmeye zorlamamakta, konuyla ilgili farklı araştırmacıların oluşturdukları modellerin de çalışmaya dahil edilmesine imkan vermektedir. Böylece sadece bir modelin seçimine dayanan yöntem ve analizlerin aksine, belirsizlik kavramını dikkate almaktadır [2].
- BMO yaklaşımının uygulanması için incelenen modeller kümesinin ortak bir yapıda olması gerekmemektedir. Başka bir deyişle modeller aynı niceliği tahmin etmek şartıyla, tamamen farklı yöntemlerden/yaklaşımlardan türetilebilir ve birbirlerinden tamamen bağımsız biçimde katkıda bulunabilirler [3].

2.1. Sonsal olasılıklar

Araştırmada p adet bağımsız değişken varsa, $k = 2^p$ adet olası alt model vardır. $M = \{M_1, \dots, M_k\}$ tüm olası alt modeller kümesinden, M_j modelinin dikkate alındığı ve $\theta_j \sim (\beta_j, \sigma^2)$ 'nin M_j modelinin parametreleri olduğu varsayalım. Eşitlik (1) ile ifade edilen Bayes teoremi kullanılarak, D veri kümesi için M_j modelinin seçilmesine karşılık gelen sonsal olasılık;

$$p(M_j | D) = \frac{p(D|M_j)p(M_j)}{\sum_{i=1}^k p(D|M_i)p(M_i)} = \frac{p(D|M_j)p(M_j)}{p(D)} \quad (2)$$

$$p(D|M_j) = \int p(D|\theta_j, M_j) p(\theta_j|M_j) d\theta_j \quad (3)$$

eşitlikleri ile tanımlanır. Burada (2) eşitliği; M_j modelinin marjinal olabilirliği diğer bir deyişle M_j modelini ortaya çıkaran verilerin olasılığıdır. Ayrıca θ_j ; j modelinin parametre vektörü, $p(\theta_j|M_j)$; M_j

modelindeki θ_j parametrelerinin önsel olasılığı, $p(D|\theta_j, M_j)$; M_j modelinin olabilirlik fonksiyonu, $p(M_j)$; j modelinin doğru model olmasına yönelik belirlenen önsel olasılıktır [2, 6]. Eşitlik (2)'deki payda sabit olduğundan genellikle göz ardı edilerek,

$$p(M_j|D) \propto p(D|M_j)p(M_j) \quad (4)$$

biçiminde yeniden yazılabilir. (4) ifadesi Bayesci istatistiğin temeli olan örneklem bilgisi ile önsel bilginin j 'inci model için birleştirilmiş hali olup, sonsal model olasılığı (PMP) olarak adlandırılmaktadır [18]. PMP'lerin toplamı bir olduğundan, en yüksek PMP değerine sahip modelin, gerçek model olma olasılığının diğerlerine göre daha güçlü olduğu söylenebilir [22]. Ayrıca hesaplanan PMP değerleri model kümesindeki belirsizlik derecesinin incelenmesinde de kullanılabilir [4]. Bunun yanında tek bir modelin öne çıkmadığı durumlarda, yüksek olasılıklı birkaç model seçilerek ortalamalarının alınmasının, model belirsizliğini hesaba katmanın bir yolu olduğu Clyde ve George [23] tarafından ifade edilmiştir. Model parametre katsayılarının ağırlıklı sonsal dağılımı k olası tüm alt model sayısı olmak üzere;

$$p(\beta|D) = \sum_{j=1}^k p(\beta_j|M_j, D)p(M_j|D) \quad (5)$$

eşitliği ile tanımlanır. Eğer parametrelerin nokta tahmini ile ilgileniliyorsa, (5) dağılımının beklenen değeri;

$$E(\beta|D) = \sum_{j=1}^k E(\beta_j|M_j, D)p(M_j|D) \quad (6)$$

biçiminde hesaplanır. Burada $E(\beta|D)$; katsayıların ortalama değeri, $E(\beta_j|M_j, D)$; M_j modelindeki β katsayılarının tahminidir. Benzer biçimde varyans;

$$V(\beta|D) = \sum_{j=1}^k V(\beta_j|M_j, D)p(M_j|D) + \sum_{j=1}^k (E(\beta_j|M_j, D) - E(\beta|D))^2 p(M_j|D) \quad (7)$$

eşitliği ile tanımlanır [24]. Böylece sonsal beklenen değer ve varyans her bir modelin birinci ve ikinci momentleri olup, modelin sonsal olasılığı ile ağırlıklandırılmıştır.

Herhangi bir m değişkeninin modelde bulunma olasılığı, sonsal dahil olma olasılığı (PIP) olarak adlandırılmakta ve (4) ifadesinden yararlanılarak bu değişkeni içeren tüm modellerin sonsal olasılıklarının toplamı alınarak;

$$PIP_m = \sum_{j=1}^k p(M_j|\beta_m \neq 0, D) \quad (8)$$

eşitliği ile hesaplanmaktadır. Yüksek PIP değerine sahip değişkenlerin büyük bir olasılıkla seçilecek model/lerde yer alacağı söylenebilir. Böylece m açıklayıcı değişkenin, bağımlı değişken üzerinde anlamlı bir etkisinin olduğu anlaşılır. Uygulamada genellikle PIP değeri 0.50'den küçük ise dikkate alınan değişkenin modelde yer almaması, 0.50 ile 0.75 arasında düşük, 0.75 ile 0.95 arasında güçlü tercih seviyeleri olduğu, 0.95 ile 1.00 arasında ise kesin olarak modelde yer alması gerektiği belirtilmektedir [25].

Modelde bulunan değişkenlere ait parametre tahminlerinin işaretlerine ait olasılıklar;

$$p(\beta_m \geq 0|D) = \sum_{j=1}^k p(\beta_{j,m}|M_j, D)p(M_j|D) \quad (9)$$

biçiminde hesaplanmaktadır. Bire yakın değerler m değişkeninin yer aldığı modellerin büyük çoğunluğunda pozitif, sıfıra yakın değerler ise negatif işaretli olduğunu ifade eder [24].

Model belirsizliğinin giderilmesi için BMO yöntemlerinin kullanılmasında aşağıda açıklanan üç temel noktada zorluklar bulunmaktadır [2, 15, 17, 26, 27].

1. Bağımsız değişkenlerin sayısının çok olması durumunda, (3) eşitliğinde verilen integralin analitik çözümü güç olabilir. Bu nedenle, integralin çözümünde Laplace veya Monte Carlo tekniklerinin kullanılması gerekebilir.
2. Olası tüm modellerden oluşan model uzayının çok büyük olması, her bir modelin hesaplamaya katılmasını zorlaştırmaktadır. Bu amaçla BMO uygulanmadan önce model uzayında sonsal olasılığı yüksek modellerden oluşan bir alt küme Monte Carlo Markov Zinciri (MCMC), Occam penceresi ve stokastik aramalı değişken seçimi yöntemleri kullanılarak belirlenir ve çalışma bu küme üzerinden yapılır.
3. Model uzayında yer alan modellerin her birinin geçerli model olduklarına yönelik $p(M_j)$ önsel model olasılıklarının belirlenmesi zor olmaktadır.

Yukarıda sıralanan zorluklar, son yıllarda geliştirilen yazılımlar ve bilgisayarların hesaplama kapasitelerindeki artışlar sonucunda aşılmaya başlanmış ve araştırmacıların bilgi birikimlerinden bağımsız olarak, BMO yöntemlerinin farklı konulardaki araştırmalarda kullanılması mümkün olmuştur.

2.2. Sonsal model olasılıklarının hesaplanması

BMO yöntemlerinin uygulanmasında (3) eşitliğinde yer alan integralin hesaplanma zorluğu ile değişken sayısının çok olması durumunda tüm olası modellerin hesaplamaya dahil edilmesi amacıyla, MCMC ve Occam penceresi yöntemlerinden yararlanılır.

Parametre uzayında rasgele yürüyüş oluşturup hedeflenen sonsal dağılıma yakınsaması MCMC yaklaşımının temel amacını oluşturmaktadır [28]. MCMC tekniklerinin uygulanmasında, öncelikle sonsal dağılımdan ya da buna yakın özellikteki dağılımdan örneklem alınmakta ve bu örneklem yardımıyla sonsal özellikler hesaplanmaktadır. MCMC yaklaşımlarında sonsal dağılıma yakınsamak amacıyla türetilen parametre değerleri, önceki değere bağlı olmaktadır. Bu amaçla örnekleme, markov geçiş fonksiyonu (dağılımı) adı verilen dağılımdan yapılmaktadır [29]. Böylece BMO yönteminin uygulanması için ihtiyaç duyulan muhtemel modellerin kümesi elde edilmiş olur. Hedeflenen sonsal dağılımın elde edilmesi amacıyla, geçiş dağılımından örneklem alınması ve bunun işlenmesi için Metropolis-Hasting algoritması ve Gibbs örnekleme yöntemleri kullanılmaktadır. Bu makalede çalışmanın amacına uygun olması nedeniyle, Metropolis-Hasting algoritması kullanıldığından, bu yöntem aşağıda açıklanmıştır [30].

1. Herhangi bir t başlangıç modeli seçilir.
2. Geçiş dağılımından yeni j modeli türetilerek zincirin yeni olası değişim değeri belirlenir.
3. t ve j modelleri için Eşitlik (4) ile gösterilen PMP değerleri kullanılarak;

$$p_{t,j} = \text{enk} \left\{ 1, \frac{p(M_j|D)}{p(M_t|D)} \right\} \quad (10)$$

oranı ile hesaplanır ve yeni modele geçilip geçilmeyeceği test edilir. Bunun sonucunda eğer $p_{t,j} \geq 1$ ise M_j modeline, $p_{t,j} < 1$ ise M_t modelinde kalınmaya devam edilir.

4. Tekrar sayısı bir arttırılarak, yakınsaklık sağlanana kadar adım 2 'ye gidilir.

Bu şekilde, her bir modelin tercih edilme sayısı, sonsal model olasılıklarının dağılımına yakınlaşacağından Monte Carlo hesaplama teknikleri ile istenen kestirimler yapılabilir. Gerçek sonsal dağılıma yakınlaşmanın kalitesi tekrar sayısına bağlıdır. Metropolis-Hasting algoritmasının başlangıç adımlarında, genellikle yüksek PMP'lere sahip modeller tercih edilmeyeceğinden, yanıklar olarak adlandırılan ilk tekrar kümesi hesaplamalardan çıkarılır [31].

2.3. Önsel bilgilerin belirlenmesi

BMO yöntemlerini kullanmak için model ve parametreler için ayrı ayrı önsel bilgilerin tanımlanması gerekmektedir.

2.3.1. Önsel model olasılıkları

Eşitlik (4)'de yer alan $p(M_j)$ önsel model olasılığının belirlenmesinde iki yaklaşım bulunmaktadır. Eğer olası 2^P adet model arasından, bazı modellerin diğerlerine göre tercih edilmesi yönünde bir bilgi ya da fikir yoksa, tüm modellerin eşit derecede önceliğe sahip olduğu varsayımı yapılabilir [2]. Bu durumda tüm modellere eşit şans vermek amacıyla, her bir modele $1/2^P$ önsel olasılığı atanabilir. Ancak herhangi bir model veya değişkenin önem dereceleri hakkında önceden bilgi ya da beklenti varsa önsel model olasılığı;

$$p(M_j) = \prod_{i=1}^P w_i^{y_{ij}} (1 - w_i)^{1-y_{ij}} \quad (11)$$

biçiminde ifade edilebilir [32]. Burada $w_i \in [0,1]$ olmakta ve y_{ij} ; i inci değişkenin, j inci modele dahil edilip edilmeyeceği yönündeki önsel beklentiye ifade eden gösterge (1 ise dahil edilir, 0 ise edilmez), w_i ise i inci değişkenin modellerde bulunmasına yönelik önsel olasılığı ifade etmektedir. Böylece i inci değişkenin model de yer almasına yönelik önsel olasılık; değişkenin modelde olmasına yönelik önsel olasılık düzeyi w_i ve yer aldığı gösteren y_{ij} değerlerinin birlikte belirlenmesi ile tanımlanır. Önsel olarak i inci değişkenin tüm modellerde yer alması yönünde güçlü bir beklenti varsa $w_i=1$ alınarak önsel model olasılığı $p(M_j) = 1$ olacaktır. Uygulamada genellikle i inci değişkenin modelde bulunmasına yönelik tarafsız beklenti olduğu varsayımı ile $w_i=1/2$ alındığından, önsel model olasılığı $p(M_j) = 1/2^P$ biçiminde tekdüze dağılımı olacaktır [24]. Önsel model olasılıkları için tekdüze dağılımın yanında, uygulamada binomial veya beta-binomial yapısındaki önsellerde sıklıkla kullanılmaktadır.

2.3.2. Model parametre önselleri

Regresyon parametreleri için önsel dağılımların tanımlanması amacıyla çeşitli yaklaşımlar bulunmaktadır. Bu yaklaşımlardan ilki modellerde bulunan parametreler için önceden yeterli bilgiye sahip olunmadığı durumlarda uygun olmayan önsellerin kullanılmasıdır. Bu önsellerin kullanılması durumunda sonsal model olasılıkları örneklem bilgisine daha fazla ağırlık vereceğinden, küçük boyutlu modellerin sonsal olasılıkları daha yüksek olacaktır [26]. BMO yönteminde, normal doğrusal regresyon modelleri için genellikle Zellner [33] tarafından önerilen g-önseli kullanılmaktadır. Bu önsel yapısında, modelde bulunan değişkenlerin katsayıları hakkında yeterli bilgi olmadığından ortalama sıfır alınmakta ancak varyans için önceden bir miktar bilgi olduğu varsayımı yapılmakta ve β_{jm} için önsel;

$$\beta_{jm} | \sigma^2, M_j, g \sim N \left(0, \sigma^2 g (X_j' X_j)^{-1} \right) \quad (12)$$

normal dağılımı ile ifade edilmektedir. Burada, j inci modele ait $X_j' X_j$ matrisinin hesaplanması için örneklem verileri kullanılmaktadır. σ^2 değeri tüm modeller için ortak olmakta ve genellikle önsel dağılımı;

$$p(\sigma) \sim \sigma^{-1} \quad (13)$$

biçiminde tanımlanmaktadır [18, 24]. g değeri, verilerden elde edilen önsel varyansa ne kadar ağırlık verildiğini ifade ettiğinden, sıfıra yakın belirlenmesi önsel bilginin zayıf olduğunu, bire yakın belirlenmesi veriler ile önsele aynı ağırlığın verildiği anlamına gelmektedir. Buna karşın büyük g değerleri ile verilere daha çok ağırlık verileceğinden parametre katsayıları en küçük kareler kestirim değerlerine yaklaşacaktır [21]. Önsel beklenti inancının ölçüsünü yansıtan g değerinin belirlenmesi için önerilen bazı yaklaşımlar aşağıda özetlenmiştir.

- Birim Bilgi Önseli (UIP) : Kass ve Wasserman [34] tarafından önerilmiş ve N gözlem sayısı olmak üzere $g=N$ olarak alınmıştır.
- Risk Şişme Kriteri (RIC) : Foster ve George [35] tarafından $g=p^2$ alınması önerilmiştir.
- Kıyaslama Önseli (BRIC): Fernandez vd. [36] tarafından UIP ve RIC önsellerinin birleşiminden $g=enb(N, p^2)$ olarak tanımlanmıştır. Ayrıca yine aynı yazarlar tarafından Hannan-Quinn (HQ) önseli $g=\log(N)$ biçiminde önerilmiştir.
- Hiper g (Hyper-g): Liang vd. [37] tarafından g 'nin sabit bir değer yerine,

$$\frac{g}{g+1} \sim \text{Beta} \left(1, \frac{a}{2} - 1 \right) \quad a \in (2,4) \quad (14)$$

biçiminde ifade edilen Beta dağılımı yardımıyla tanımlanabileceği gösterilmiştir. hyper-g seçeneği güncelleme yapılmasına izin verdiğinden bazı araştırmacılar tarafından tercih edilmektedir [24].

Model parametreleri için seçilecek önseller, konunun ve araştırmacının bilgi düzeyine bağlı olarak farklı olacaktır. Ayrıca seçilen önsel yapının nedenlerinin çok fazla eleştiri almayacak biçimde ortaya konması gerekliliği unutulmamalıdır.

3. Veri, yöntem ve temel analizler

BMO yöntemi kullanılarak, sektörel kapasite kullanım oranlarının istihdam oranı üzerindeki etkileri, doğrusal regresyon modeli ile incelenmiştir. Çalışma kapsamında yapılan veri ön incelemeleri ve analizlerde R veri analizi yazılımının 3.5.1 sürümü, BMO yönteminin uygulanması için BMS paketi kullanılmıştır. Çalışmada kullanılan veri, "Resmî İstatistik Programı" kapsamında Türkiye Cumhuriyeti Merkez Bankası (TCMB) ve Türkiye İstatistik Kurumu (TÜİK) tarafından açıklanan, 2007 yılı Ocak ile 2018 Ağustos dönemi arasındaki istatistiklerden yararlanılarak elde edilmiştir.

3.1. Kapasite kullanım oranı ve istihdam oranı

Kapasite kullanım oranı (KKO), bir imalatçının ya da bir ülkenin belirli bir dönemde yaptığı üretimin, toplam kapasiteye oranı olarak tanımlanmaktadır [38]. Üretim gücünün bir göstergesi olarak ifade edilebilen KKO’nda artış eğilimi gözleniyorsa, imalat sektöründe üretim miktarında yükselme olduğu, aksi durum varsa üretimde düşüş eğilimi olduğu anlaşılır. Öncü gösterge niteliğinde olan KKO, TCMB tarafından her ay imalat sektöründe faaliyet gösteren işyerlerine gönderilen anketlerden hesaplanmaktadır. Anketin uygulandığı ay için toplanan veri, imalat sektörünün geneli ve alt sektörleri için ayrı ayrı hesaplanıp yayınlanmaktadır. NACE Rev.2 sektör sınıflamasına göre derlenen veriler toplam, sektör grupları ve alt sektörler bazında açıklanmaktadır. Bu çalışmada kullanılan ve Çizelge 1’de açıklamaları verilen alt sektörler için veri, TCMB elektronik veri dağıtım sistemi (EVDS) üzerinden alınmıştır. Veri analizi yazılımında sektör kodlarının başına (K) harfi eklenerek çözümlenmeler yapılmıştır.

TÜİK tarafından yapılan hane halkı işgücü araştırması kapsamında istihdam; “işbaşımda olanlar ve işbaşımda olmayanlar grubuna dahil olan kurumsal olmayan çalışma çağındaki nüfus” biçiminde tanımlanmaktadır. İstihdam oranı (IO) ise; “istihdamın kurumsal olmayan çalışma çağındaki nüfus içindeki oranı” olarak ifade edilmektedir. Kurumsal olmayan çalışma çağındaki nüfus; üniversite yurtları, yetiştirme yurtları (yetimhane), huzurevi, özel nitelikteki hastahane, hapisane, kışla vb. yerlerde ikamet edenler dışında kalan 15 ve daha yukarı yaştaki nüfus biçiminde tanımlanmıştır [39]. Anket referans dönemi; sonuçların açıklandığı ay, öncesi ve sonrasındaki ayları kapsayacak biçimdedir. Örneğin Şubat 2018 dönemi haber bülteninde açıklanan sonuçlar; 2018 yılının Ocak, Şubat ve Mart aylarını, Mart 2018 dönemi de Şubat, Mart ve Nisan aylarını kapsayacaktır. Modelin tahmin edilmesinden önce verilerin dönemsellik farklılıklarından dolayı uyumlaştırılması, zamana bağlı olduklarından dolayı da durağanlık kontrollerinin yapılması gerekmektedir.

Çizelge 1. NACE Rev.2’ye göre alt sektörler


Kodu	Sektör Açıklaması
10	Gıda ürünlerinin imalatı
11	İçeceklerin imalatı
12	Tütün ürünleri imalatı
13	Tekstil ürünlerinin imalatı
14	Giyim eşyalarının imalatı
15	Deri ve ilgili ürünlerin imalatı
16	Ağaç, ağaç ürünleri ve mantar ürünleri imalatı (mobilya hariç); saz, saman ve benzeri malzemelerden örülerek yapılan eşyaların imalatı
17	Kağıt ve kağıt ürünlerinin imalatı
18	Kayıtlı medyanın basılması ve çoğaltılması
19	Kok kömürü ve rafine edilmiş petrol ürünleri imalatı
20	Kimyasalların ve kimyasal ürünlerin imalatı
21	Temel eczacılık ürünlerinin ve eczacılığa ilişkin malzemelerin imalatı
22	Kauçuk ve plastik ürünlerin imalatı
23	Diğer metalik olmayan mineral ürünlerin imalatı
24	Ana metal sanayii
25	Fabrikasyon metal ürünleri imalatı (makine ve teçhizat hariç)
26	Bilgisayarların, elektronik ve optik ürünlerin imalatı
27	Elektrikli teçhizat imalatı
28	Başka yerde sınıflandırılmamış makine ve ekipman imalatı
29	Motorlu kara taşıtı, treyler (römork) ve yarı treyler (yarı römork) imalatı
30	Diğer ulaşım araçlarının imalatı
31	Mobilya imalatı
32	Diğer imalatlar
33	Makine ve ekipmanların kurulumu ve onarımı

3.2. Veri uyumlaştırılması ve doğrusal regresyon analizi

Model de bağımlı değişken olarak yer alan IO'na ait referans dönemlerinin üç ayı kapsamı nedeniyle bağımsız değişken olan KKO'nun da buna uygun hale getirilmesi gerekmektedir. Bu amaçla KKO verisinin 2007 yılının 1. ayından başlamak üzere önce ve sonraki ayları kapsayacak biçimde üçer aylık ortalamaları alınmıştır. Böylece IO ile KKO değişkenleri arasındaki dönemsel farklılık giderilmiştir. Çalışma kapsamında IO üzerinde etkili olan sektörlerin belirlenmesi temel amaç olmakla birlikte, elde edilecek sonuçlardan daha anlaşılabilir yorumlar yapılabilmesi amacıyla, aylar arasındaki değişim miktarı hesaplanarak analizde kullanılacak veri setine ulaşılmıştır. IO üzerinde KKO'nun etkisini araştırmak üzere 24 açıklayıcı değişkenden oluşan ve tam model olarak adlandırılan çoklu doğrusal regresyon modeli, β_0 sabit değer olmak üzere;

$$IO = \beta_0 + \beta_1 K10 + \beta_2 K11 + \dots + \beta_{24} K33 + \varepsilon \quad (15)$$

biçiminde yazılabilir. Burada IO, istihdam oranlarının bir önceki aydan farkı alınmış bağımlı değişken, K10,..., K33 sektör bazında kapasite kullanım oranlarının bir önceki aydan farkı alınmış $p \times 1$ boyutlu bağımsız değişken vektörü, $\beta_1, \dots, \beta_{24}$; $p \times 1$ boyutlu bilinmeyen katsayılar vektörü; $\varepsilon \sim N(0, \sigma^2)$ olan yanlış vektörüdür. Doğrusal regresyon modelinde yer alan değişkenlerin durağanlığının test edilmesi amacıyla Augmented Dickey-Fuller birim kök testi uygulanmış ve değişkenlerin durağan olduğu, birim kök içermediği görülmüştür. Değişkenlerin durağanlık kontrollerinden sonra çoklubağlantı içerip içermedikleri için ilişki matrisi ve VIF değerleri incelenmiştir. Şekil 1' de verilen ilişki matrisinin grafiksel gösteriminden görülebileceği gibi bağımsız değişkenler arasında yüksek dereceli ilişkilerin olmadığı anlaşılmıştır. Çizelge 2'de VIF ve Eşitlik (15) için tam model parametre kestirim değerleri özetlenmiştir.



Şekil 1. Değişkenlerin Korelasyon Grafiği

Tam modele ait düzeltilmiş $R^2=0.5534$ değeri; bağımlı değişken olan IO'daki değişimin %55.34'lük kısmının model de yer alan bağımsız değişkenler tarafından açıklandığı, geri kalanının ise hata terimi aracılığı ile modele dahil edilmeyen diğer değişkenlerce açıklandığı anlamına gelmekle birlikte, modelin bütünsel olarak anlamlı olduğu söylenebilir. Bunun yanında; Çizelge 2'de verilen VIF değerlerinin 10'dan küçük olması nedeni ile bağımsız değişkenler arasında çoklubağlantı olmadığı görülmüştür [7]. Ayrıca Çizelge 2'de tam model üzerinden uygulanan adımsal değişken seçimi yöntemine göre belirlenen değişkenler ve katsayıları da özetlenmiştir. Buna göre K11(içeceklerin imalatı), K13 (tekstil ürünlerinin imalatı), K23 (diğer metalik olmayan mineral ürünlerin imalatı), K28 (başka yerde sınıflandırılmamış makine ve ekipman imalatı) ve K31 (mobilya imalatı) değişkenlerinden oluşan model, en iyi alt model olarak belirlenmiştir. Bu modelin düzeltilmiş $R^2=0.5301$ değeri tam modele göre çok az düşük olmakla birlikte aralarında çok fark bulunmamaktadır. Bu nedenle 24 yerine 5 bağımsız değişken kullanılarak IO'daki değişimin %53.01'lik kısmı açıklanabilmektedir. Benzer biçimde model de yer alan değişkenlerin katsayıları ve standart sapmaları da tam modele oldukça yakın elde edilmiştir.

Çizelge 2. Tam model kestirimi, VIF değerleri ve adımsal seçim sonuçları

Değişken	Tam Model Kestirimi				Adımsal Seçim Sonuçları		
	Katsayı	Std. Sapma	p	VIF	Katsayı	Std. Sapma	p
Sabit	-0.0611	0.0350			-0.0624	0.0357	
* K10	-0.0801	0.0270	0.0036	1.6706			
* K11	0.0341	0.0079	0.0000	1.5690	0.0318	0.0074	0.0000
K12	0.0011	0.0063	0.8654	1.4243			
* K13	0.0810	0.0306	0.0093	1.7318	0.0908	0.0265	0.0008
K14	-0.0256	0.0309	0.4081	1.7288			
K15	-0.0187	0.0181	0.3026	1.3048			
K16	0.0032	0.0200	0.8716	1.7886			
K17	0.0021	0.0212	0.9199	1.2885			
K18	0.0289	0.0202	0.1550	1.6039			
K19	0.0006	0.0057	0.9232	1.4108			
K20	0.0201	0.0135	0.1399	1.8372			
* K21	0.0298	0.0142	0.0388	1.2936			
K22	0.0259	0.0238	0.2798	1.9289			
* K23	0.0768	0.0219	0.0006	2.1491	0.0677	0.0193	0.0006
K24	-0.0285	0.0162	0.0807	1.3968			
K25	-0.0169	0.0271	0.5351	1.9201			
K26	0.0035	0.0102	0.7299	1.2742			
K27	0.0166	0.0204	0.4166	1.5213			
* K28	0.0349	0.0162	0.0328	1.4343	0.0374	0.0148	0.0124
K29	0.0144	0.0106	0.1757	1.7568			
K30	0.0066	0.0127	0.6042	1.3023			
* K31	0.0496	0.0183	0.0077	1.8098	0.0565	0.0152	0.0004
K32	-0.0112	0.0073	0.1310	1.3576			
K33	0.0002	0.0059	0.9787	1.4436			
R ² =0.5534; MSE=0.4075; F=8.074					R ² =0.5301; MSE=0.418; F=31.91		

* 0.05 yanılma düzeyinde anlamlıdır

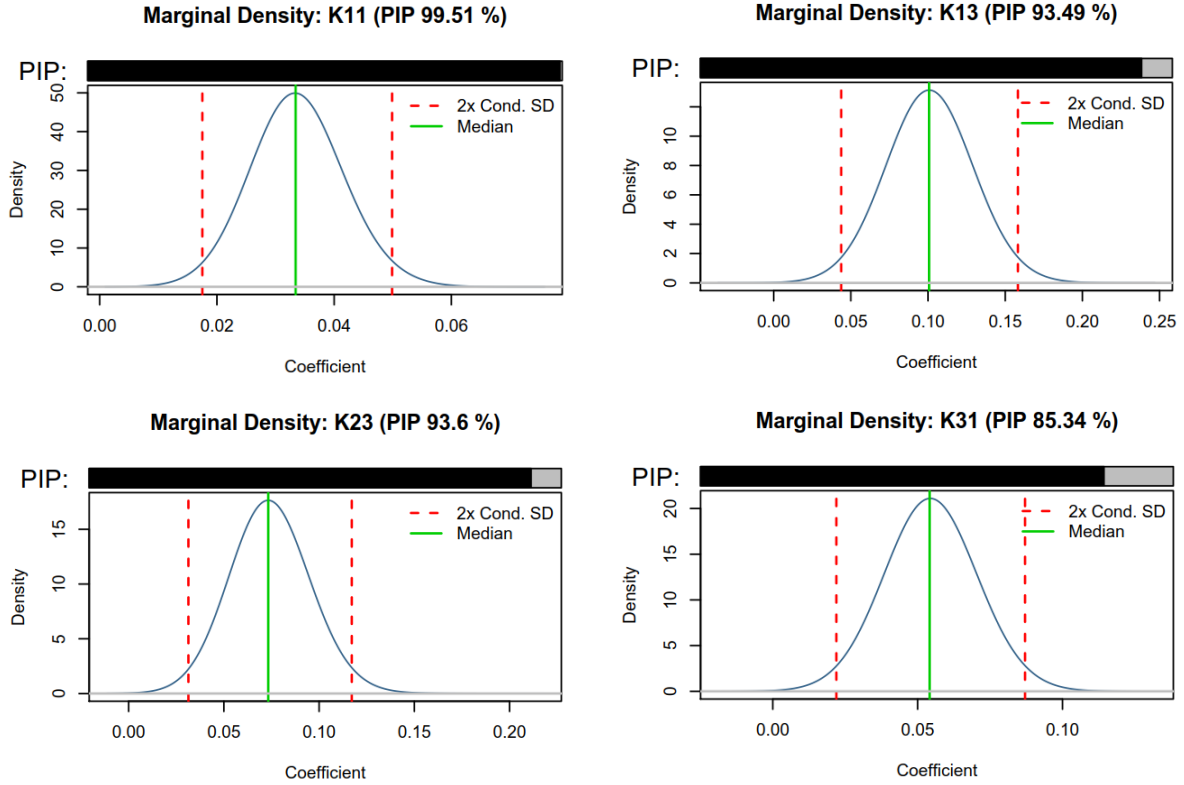
3.3. Bayesci model ortalaması sonuçları

Modelde bulunma olasılığı ile IO'yu açıklama oranı yüksek değişkenlerin belirlenmesi ve yüksek sonsal olasılıklı modellerin seçilmesi amacıyla, BMO yönteminin uygulanması için R 3.5.1 üzerinde çalışan BMS paketinin 0.3.4 sürümü kullanılmıştır. BMO'nun uygulanması için gerekli olan önsel bilgiler; model için beta-binomial, parametreler için $g=UIP$ kullanılmış, ilk yanma değeri 50,000, tekrar sayısı ise 100,000 olarak tanımlanmış, olası model sayısı $2^{24}=16,777,216$ olduğundan MCMC yaklaşımına dayanan Metropolis Hasting algoritması kullanılmıştır. Çizelge 3'de özetlenen BMO sonuçlarına göre Kesim 2.1'deki Eşitlik (8) ile verilen ve değişkenlerin modele dahil olma sonsal olasılıklarını ifade eden PIP sütununa bakıldığında, $PIP>0.50$ değerine sahip olan K11 (içeceklerin imalatı), K23 (diğer metalik olmayan mineral ürünlerin imalatı) K13 (tekstil ürünlerinin imalatı) ve K31 (mobilya imalatı) değişkenlerinin, IO üzerinde en etkili değişkenler olduğu ve bu nedenle, mutlaka modelde bulunmaları gerektiği görülmektedir.

Çizelge 3'de verilen sonsal ortalama ile sonsal standart sapma değerleri, bu modeller de yer alan değişkenlerin ortalama parametre kestirimleri ile standart sapmalarına karşılık gelmektedir. Sonsal ortalama sütununda sıfıra yakın değerlere sahip olan değişkenlerin, PIP sütununda da düşük olasılığa sahip olduğu görülmektedir. Sonsal işaret olasılığı sütunundaki değerler ise BMO hesaplamalarına dahil edilen modellerde, sonsal ortalamanın pozitif işaretli olmasının olasılığını ifade etmektedir. Olasılık değerinin 1 olması işaretin kesinlikle pozitif, 0 olması kesinlikle negatif olacağı anlamına gelmektedir. Böylece modele dahil edilen PIP değeri %50'den büyük olan ilk dört değişkenin pozitif işaretli olma olasılıklarının kesin olduğu söylenebilir. Benzer biçimde bu dört değişkenin marjinal yoğunluk dağılımlarının verildiği Şekil 2'de görüldüğü gibi değişken katsayılarının sıfır değerini alma olasılıkları çok düşüktür.

Çizelge 3. Bayesci model ortalaması özet sonuçları (PIP'e göre sıralı)

Değişkenler	PIP	Sonsal Ortalama	Sonsal Std. Sapma	Sonsal İşaret Olasılığı
K11	0.9900	0.0333	0.0088	1.0000
K23	0.9350	0.0700	0.0280	1.0000
K13	0.9261	0.0932	0.0383	1.0000
K31	0.8296	0.0452	0.0253	1.0000
K28	0.3954	0.0152	0.0212	1.0000
K10	0.1486	-0.0066	0.0185	0.0000
K29	0.1163	0.0019	0.0063	1.0000
K32	0.1103	-0.0013	0.0044	0.0016
K22	0.0966	0.0036	0.0134	1.0000
K20	0.0931	0.0016	0.0063	1.0000
K18	0.0887	0.0027	0.0105	1.0000
K27	0.0783	0.0022	0.0097	1.0000
K12	0.0735	0.0006	0.0025	0.9992
K24	0.0610	-0.0013	0.0064	0.0011
K21	0.0589	0.0010	0.0051	1.0000
K15	0.0527	-0.0011	0.0062	0.0051
K16	0.0508	0.0009	0.0059	0.9890
K19	0.0473	0.0002	0.0015	0.9994
K30	0.0420	0.0004	0.0033	1.0000
K14	0.0396	0.0005	0.0063	0.8960
K26	0.0348	0.0001	0.0019	0.8467
K33	0.0343	-0.0001	0.0012	0.0233
K17	0.0323	-0.0001	0.0038	0.1833
K25	0.0293	0.0002	0.0044	0.7999
Sabit terim	1.0000	-0.0624		



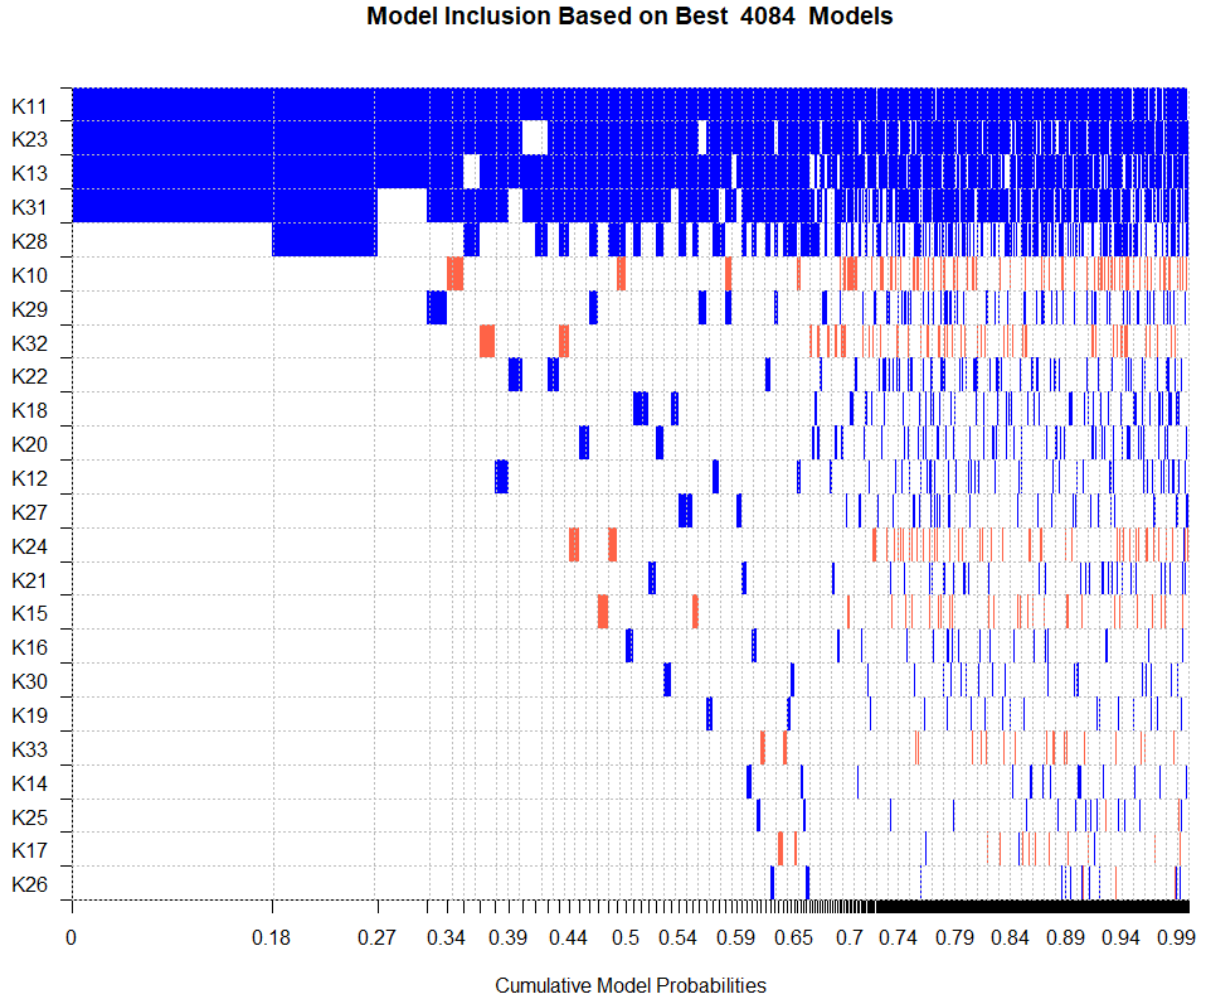
Şekil 2. PIP değeri %50'de büyük olan katsayıların marjinal yoğunluk grafikleri

Çizelge 4. En iyi 5 Modelde bulunan değişkenler, katsayıları ve modellerin sonsal olasılıkları *

Değişkenler	Model I		Model II		Model III		Model IV		Model V	
	Son. Ort.	St.Sap	Son. Ort.	St.Sap	Son. Ort.	St.Sap	Son. Ort.	St.Sap	Son. Ort.	St.Sap
K10									-0.0379	0.0227
K11	0.0339	0.0074	0.0316	0.0073	0.0352	0.0077	0.0354	0.0074	0.0341	0.0074
K13	0.1052	0.0262	0.0902	0.0263	0.1148	0.0271	0.0974	0.0263	0.1089	0.0260
K23	0.0729	0.0194	0.0672	0.0190	0.0904	0.0194	0.0633	0.0199	0.0791	0.0195
K28			0.0371	0.0146						
K29							0.0155	0.0089		
K31	0.0516	0.0153	0.0561	0.0151			0.0529	0.0152	0.0539	0.0152
PMP	0.1793		0.0939		0.0444		0.0175		0.0154	

* Çizelgede yer almayan değişkenler sonsal olasılığı en yüksek ilk 5 modelde yer almamaktadır.

Çizelge 4'de en iyi ilk beş model, bu modellerde yer alan değişkenler ve katsayılarının sonsal ortalaması ile model sonsal olasılıkları verilmiştir. Çizelgede en yüksek sonsal model olasılığı PMP=0.1793 olarak bulunmuştur. Şekil 3'de değişkenlerin, modele katılması durumundaki birikimli sonsal model olasılıkları gösterilmektedir. Kırmızı renkler negatif işaretli, mavi renkler pozitif işaretli katsayılara, beyaz renkler ise değişkenin modele dahil edilmediği anlamına gelmektedir. Şekilden görülebileceği gibi K11, K23, K13 ve K31'den oluşan model, Çizelge 4'deki Model I'e karşılık gelmekte ve sonsal olasılığı 0.1793 olarak bulunmuştur. K28 değişkeninin Model I'e eklenmesi ile 0.0939 sonsal olasılığına sahip Model II elde edilir. Benzer biçimde Model III'de şekil üzerinden görülebileceği gibi Model I'den K31 değişkeninin çıkarılmasıyla oluşmakta ve sonsal olasılığı da 0.044 olarak hesaplanmıştır.



Şekil 3. Değişkenlerin modele dahil olma durumu grafiği

4. Sonuç ve öneriler

Aylık istihdam oranı üzerinde, sektörel kapasite kullanım oranlarının etkisinin BMO yöntemi kullanılarak incelendiği bu çalışma sonucunda, dört sektörün diğerlerine göre daha etkili olduğu görülmüştür. Bu sektörler içeceklerin imalatı (K11), diğer metalik olmayan mineral ürünlerin imalatı (K23), tekstil ürünlerinin imalatı (K13), mobilya imalatı (K31) biçiminde sıralanmıştır. Bu değişkenlerin bulunduğu modelin sahip olduğu %17.93 oranındaki sonsal model olasılığı aslında %82.07 oranında bir belirsizliğin olduğunu ifade etmektedir. Modelin sahip olduğu bu belirsizlik oranı tam modelde yer alan 24 adet bağımsız değişken haricinde de başka açıklayıcı değişkenlerin katkısına ihtiyaç duyulduğu biçimde yorumlanabilir. BMO yöntemi ile tüm değişkenlerin modele katkılarının belirlenmesi, en iyi modelin sahip olduğu sonsal olasılığın hesaplanması ile belirsizlik miktarının bilinerek yorumlar yapılması mümkün olmaktadır. Buna bağlı olarak BMO yöntemi sonucunda K11, K13, K23 ve K31 bağımsız değişkenlerinin sonsal dahil olma olasılıklarının yüksek olması, bu değişkenlerden kaynaklanan belirsizlik miktarının çok az olduğu anlamına gelmektedir. BMO sonucunda değişkenlerin modele katkılarının, sahip oldukları sonsal dahil olma olasılığına bağlı olduğu dikkate alınarak oluşan model;

$$IO = -0.0624 + \dots + 0.0333K11 + \dots + 0.0932K13 + \dots + 0.07K23 + \dots + 0.0431K31 + \dots - 0.0001K33 \quad (16)$$

biçiminde ifade edilir. Çalışmada kullanılan veriler bir önceki aya göre farkı yansıttığından, tüm sektörlerde kapasite kullanım oranında bir değişim olmasa bile sabit terim dikkate alındığında, istihdam oranının bir önceki aya göre 0.0624 kadar azalacağı söylenebilir. Benzer biçimde, Çizelge 3'deki BMO sonucuna göre oluşturulan ve Eşitlik (16) ile verilen model de yer alan tüm sektörlerde 1 puanlık artışın, IO üzerinde toplamda 0.1999 kadar artış yapacağını söylemek mümkündür.

BMO yöntemine göre değişkenlerin modelde yer alma olasılıkları, aynı zamanda bu değişkenlerin IO üzerindeki etkilerini de ortaya koymaktadır. IO üzerinde en etkili sektörün K11(içeceklerin imalatı) sektörü olduğu görülmüştür. Daha sonra sırasıyla K23 (diğer metalik olmayan mineral ürünlerin imalatı) K13 (tekstil ürünlerinin imalatı) ve K31 (mobilya imalatı) sektörlerinin IO üzerinde etkili oldukları görülmektedir. BMO yöntemine göre seçenек modeller arasında yer alan Model II'de bu sektörlerle ek olarak K28 (başka yerde sınıflandırılmamış makine ve ekipman imalatı) sektörü de yer almıştır.

TÜİK tarafından açıklanan istihdam oranları içinde sektörel ayırım bulunmadığından, BMO yöntemine göre oluşturulan modelde yer alan sektörler hakkında sağlıklı yorum yapılması zor olmakla birlikte, modelde yer alma olasılıkları en yüksek olan ilk dört sektörün alt kırılımları EK-de verilmiştir. Bunun yanında; K11 (içeceklerin imalatı) sektörünün %99 olasılıkla model de yer alması dikkat çekicidir. İçecek imalatları sektörünün alt kırılımlarına bakıldığında, bu sektörün hizmet sektörü ile doğrudan ilişkili olduğunu söylemek yanlış olmayacaktır.

Modelde yüksek sonsal olasılıklara sahip değişkenler açısından K13 (tekstil ürünlerinin imalatı) ve K23 (diğer metalik olmayan mineral ürünlerin imalatı) sektörlerine ait katsayıların (sonsal ortalamaların) , diğerlerine göre yüksek olması, bu sektörlerdeki KKO değişimlerinin IO üzerinde daha etkili olduğu anlamına gelmektedir. Tekstil ürünlerinin imalatı sektöründe yer alan 13.10, 13.20 ve 13.30 alt sektörlerinin ara malı imalatı grubunda yer alması, bunların üretimindeki artışın ilişkili olduğu diğer imalat sektörlerinde de istihdam arttırıcı etki yarattığı söylenebilir. Benzer biçimde ara malı imalatı grubunda yer alan K23 (diğer metalik olmayan mineral ürünlerin imalatı) sektöründe cam, porselen ve seramik gibi maddelerin üretimi yanında, özellikle inşaat sektöründe yoğun olarak kullanılan başta çimento, kireç, alçı olmak üzere mermer işlenmesi ve bitirilmesi konularında yapılan üretimin istihdam üzerinde etkili olduğu düşünülmektedir. Bunun yanında inşaat sektörü emek yoğun özelliği ve diğer sektörlerle olan ilişkisi dolayısıyla K23'de meydana gelen KKO'nun da ki artışın, istihdama yansıma kabiliyetinin yüksek olduğu bilinmektedir. Son olarak K31 (mobilya imalatı) sektörüne bakıldığında büro, mağaza, mutfak mobilyaları ile yatak imalatı alt sektörlerinin, konut ve inşaat sektöründeki gelişmelerden etkilenmiş olabileceğini söylemek yanlış olmayacaktır. Ayrıca; yine bu sektöründe ilişkili olduğu hizmet sektörlerini tetiklediği söylenebilir. Yukarıda yapılan tüm bu yorumlar yanında bu çalışmada, IO üzerinde sadece imalat sektörünün etkisine yoğunlaşıldığından hizmet, tarım, madencilik gibi sektörlerdeki istihdam dinamiklerinin de dikkate alınmasında yarar vardır.

EK: Sonsal dahil olma olasılığı en yüksek sektörler ve alt sektörleri

Sektör	Alt sektörler
11 - İçeceklerin imalatı	11.01 Alkollü içeceklerin damıtılması, arıtılması ve harmanlanması
	11.02 Üzümünden şarap imalatı
	11.03 Elma şarabı ve diğer meyve şaraplarının imalatı
	11.04 Diğer damıtılmamış mayalı içeceklerin imalatı
	11.05 Bira imalatı
	11.06 Malt imalatı
	11.07 Alkolsüz içeceklerin imalatı; maden sularının ve diğer şişelenmiş suların üretimi
13 – Tekstil ürünleri imalatı	13.10 Tekstil elyafının hazırlanması ve bükülmesi
	13.20 Dokuma
	13.30 Tekstil ürünlerinin bitirilmesi
	13.91 Örgü (triko) veya tığ işi (kroşe) kumaşların imalatı
	13.92 Giyim eşyası dışındaki tamamlanmış tekstil ürünlerinin imalatı
	13.93 Halı ve kilim imalatı
	13.94 Halat, urgan, kınnap ve ağ imalatı
	13.95 Dokusuz kumaşların ve dokusuz kumaştan yapılan ürünlerin imalatı, giyim eşyası hariç
	13.96 Diğer teknik ve endüstriyel tekstillerin imalatı
13.99 Başka yerde sınıflandırılmamış diğer tekstillerin imalatı	
23 - Diğer metalik olmayan mineral ürünlerin imalatı	23.11 Düz cam imalatı
	23.12 Düz camın şekillendirilmesi ve işlenmesi
	23.13 Çukur cam imalatı
	23.14 Cam elyafı imalatı
	23.19 Diğer camların imalatı ve işlenmesi (teknik amaçlı cam eşyalar dahil)
	23.20 Ateşe dayanıklı (refrakter) ürünlerin imalatı
	23.31 Seramik karo ve kaldırım taşları imalatı
	23.32 Fırınlanmış kilden tuğla, karo ve inşaat malzemeleri imalatı
	23.41 Seramik ev ve süs eşyaları imalatı
	23.42 Seramik sıhhi ürünlerin imalatı
	23.43 Seramik yalıtkanların (izolatörlerin) ve yalıtkan bağlantı parçalarının imalatı
	23.44 Diğer teknik seramik ürünlerin imalatı
	23.49 Başka yerde sınıflandırılmamış diğer seramik ürünlerin imalatı
	23.51 Çimento imalatı
	23.52 Kireç ve alçı imalatı
	23.61 İnşaat amaçlı beton ürünlerin imalatı
	23.62 İnşaat amaçlı alçı ürünlerin imalatı
	23.63 Hazır beton imalatı
	23.64 Toz harç imalatı
	23.65 Lif ve çimento karışımli ürünlerin imalatı
23.69 Beton, alçı ve çimentodan yapılmış diğer ürünlerin imalatı	
23.70 Taş ve mermerin kesilmesi, şekil verilmesi ve bitirilmesi	
23.91 Aşındırıcı ürünlerin imalatı	
23.99 Başka yerde sınıflandırılmamış metalik olmayan diğer mineral ürünlerin imalatı	
31 - Mobilya imalatı	31.00 Koltuk, sandalye, tabure, bank ve benzeri oturaklar (takımlar hariç) ile bunların parçaları ve mobilya parçaları (CPA 31.00)
	31.01 Büro ve mağaza mobilyaları imalatı
	31.02 Mutfak mobilyalarının imalatı
	31.03 Yatak imalatı
	31.09 Diğer mobilyaların imalatı

Kaynaklar

- [1] Raftery, Adrian E., (1995), "Bayesian Model Selection in Social Research", *Sociological Methodology*, 25,111-163.
- [2] Hoeting, Jennifer A., Madigan David, Raftery Adrian E., T. Volinsky Chris, (1999), "Bayesian Model Averaging: A Tutorial", *Statistical Science*, 14(4), 382–417.
- [3] Gibbons, J.M., Cox G.M., Wood A.T.A., Craigon J., Ramsden S.J., Tarsitano D., Crout N.M.J., (2008), "Applying Bayesian Model Averaging to Mechanistic Models: An Example and Comparison Of Methods", *Environmental Modelling & Software*, 23, 973-985.
- [4] Banner, Katharine M., Higgs Megan vd., (2017), "Considerations for Assessing Model Averaging of Regression Coefficients" *Ecological Applications*, 27 (1), 78–93.
- [5] Bijak, Jakob, (2006), "Bayesian Model Averaging in Forecasting International Migration", *European Population Conference 2006*. Liverpool, United Kingdom, 21–24 June.
- [6] Kabir, Golam, Tesfamariam Solomon, Sadiq Rehan, (2016), "Bayesian Model Averaging For The Prediction Of Water Main Failure For Small To Large Canadian Municipalities" , *Canadian Journal of Civil Engineering*, 43, 233–240.
- [7] Mohsen, Mehrara, Samaneh Sejjani, Abbas Rezaazadeh Karsalari, (2017), "Determinants Of High-Tech Export in Developing Countries Based On Bayesian Model Averaging", *Zb. rad. Ekon. fak. Rij.*, 35 (1), 199-215,
- [8] Jacobson, Tor & Karlsson Sune, (2002), "Finding Good Predictors for Inflation: A Bayesian Model Averaging Approach", *Sveriges Riksbank Working Paper Series*, 138.
- [9] Schneider, Markus P.A. & Yaşar Yavuz, (2016), "Is İnequality Deadly and For Whom? A Bayesian Model Averaging Analysis", *The Social Science Journal*, 53 (3), 357-370.
- [10] Cheng, Yingzhe, (2016), "What Affects Parents' Choice of Milk? An Application of Bayesian Model Averaging.", *Electronic Theses and Dissertations*, University of New Mexico.
- [11] Belton, Willie & Cebula Richard, (2010), "Capacity Utilization Rates and Unemployment Rates: Are They Complements or Substitutes in Warning About Future Inflation? ", *Applied Economics*, 32 (12),1521-1532.
- [12] Altuntepe, Nihat & Güner Tuğba, (2013), "Türkiye’de İstihdam-Büyüme İlişkisinin Analizi (1988-2011)", *Uluslararası Alanya İşletme Fakültesi Dergisi*, 5 (1), 73-84.
- [13] Geyikçi, Umut Burak, (2017), "Turizm Tesislerinin Doluluk Oranları ve Tarım Dışı İstihdam Rakamlarının Bist Turizm Endeksi Üzerine Etkisinin Nedensellik ve Eşbütünleşme İle Analizi", *Akademik Bakış Dergisi*, 64, 573-585.
- [14] Durmuş, Savaş & Akbulut Hülya, (2017), "Türkiye Ekonomisinde İstihdam Yaratmayan Büyüme Sorunsalı", *Hukuk ve İktisat Araştırmaları Dergisi*, 9 (2), 91-100.
- [15] Lee, M. Peter, (1989), *Bayesian Statistics: An introduction*, Oxford University Press.
- [16] Yardımcı, A & Erar, A., (1995), "Bazı Yanlı Kestirim Yöntemleri Üzerine Bir Benzetim Çalışması ", *Hacettepe Fen ve Mühendislik Bilimleri Dergisi*, 16, 215-231.
- [17] Clyde, Merlise A.,(1999),"Bayesian Model Averaging and Model Search Strategies", *Bayesian Statistics 6*, 157-185.
- [18] Hasan, İftekar, Horvath Roman, Mares Jan., (2016), "What Type of Finance Matters for Growth? : Bayesian Model Averaging Evidence", *Policy Research Working Paper*; No. 7645. World Bank, Washington, DC.
- [19] Posada, David & Buckley Thomas R.; (2004), "Model Selection and Model Averaging in Phylogenetics: Advantages of Akaike Information Criterion and Bayesian Approaches Over Likelihood Ratio Tests", *Systematic Biology*, 53 (5), 793–808.
- [20] Montgomery, Jacob M. & Nyhan Brendan,(2010), "Bayesian Model Averaging: Theoretical Developments and Practical Applications"; *Political Analysis*, 18 ,245–270.
- [21] Horvarth, Roman, (2011), "Research & Development and Growth: A Bayesian Model Averaging Analysis", *Economic Modelling*, 28, 2669–2673.
- [22] Wit, Ernst, Heuvel Edwin van den, Romeijn Jan-Willem, (2012), "All Models Are Wrong...: An Introduction To Model Uncertainty", *Statistica Neerlandica*, 66 (3), 217–236.
- [23] Clyde, Merlise & George Edward I., (2004), "Model Uncertainty", *Statistical Science*, 19 (1), 81–94.
- [24] Mares, Jan, (2014), "Finance and Growth: A Bayesian Model Averaging Evidence", Master Thesis, Charles University in Prague Faculty of Social Sciences Institute of Economic Studies.
- [25] Viallefont, Valerie, Raftery Adrian E., Richardson Sylvia, (2001), "Variable Selection and Bayesian Model Averaging in Case-Control Studies", *Statistics In Medicine*, 20, 3215-3230.
- [26] Benito, Moral Enrique, (2015), "Model Averaging in Economics: An Overview", *Journal of Economic Surveys*, 29 (1), 46–75.

- [27] Candolo C., Davison A. C., Demétrio C. G. B., (2003), "A Note on Model Uncertainty in Linear Regression", *The Statistician*, 52 (2), 165–177.
- [28] Carlin, B.P.& Chib S., (1995), "Bayesian Model Choice Via Markov Chain Monte Carlo Methods", *J. R. Statist. Soc. B*, 57 (3), 473–484.
- [29] George, E. I. & McCulloch R. E.,(1997), "Approaches for Bayesian Variable Selection", *Statistica Sinica*,7, 339-373.
- [30] Yardımcı, A, (2000) "Doğrusal regresyonda değişken seçimine Bayes yaklaşımlarının karşılaştırılması", Doktora Tezi (yayınlanmamış), *Hacettepe Üniversitesi Fen Bilimleri Enstitüsü*, Ankara
- [31] Zeugner, Stefan & Feldkircher Martin, (2015), "Bayesian Model Averaging Employing Fixed and Flexible Priors: The BMS Package for R", *Journal of Statistical Software*, 68 (4), 1-37.
- [32] George, E. I. & McCulloch, R. E., (1993), "Variable Selection Via Gibbs Sampling", *Journal of the American Statistical Association*, 88, 881-889.
- [33] Zellner, Arnold, (1986), "On Assessing Prior Distributions and Bayesian Regression Analysis With g-Prior Distributions", *Bayesian inference and decision techniques: Essays in Honor of Bruno De Finetti*, 6,233–243.
- [34] Kass, Robert & Wasserman Larry, (1995), "A Reference Bayesian Test for Nested Hypotheses and its Relationship to the Schwarz Criterion", *Journal of the American Statistical Association*, 90 (431),928-934.
- [35] Foster, P. & George E. I., (1994), "The Risk Inflation Criterion For Multiple Regression", *The Annals of Statistics*, 22, 1947-1975.
- [36] Fernandez, C., Ley, E., and Steel, M. F. (2001). "Benchmark Priors for Bayesian Model Averaging", *Journal of Econometrics*, 100, 381–427.
- [37] Liang, Feng, Paulo Rui, Molina German, Clyde Merlise A, O Berger Jim, (2008), "Mixtures of g Priors for Bayesian Variable Selection", *Journal of the American Statistical Association*, 103 (481), 410-423,
- [38] Abdioglu, Zehra, (2013), "Türkiye için Enflasyonu Hızlandırmayan Kapasite Kullanım Oranı Tahmini", *Journal of Yasar University*, 8 (31), 5296-5323.
- [39] TÜİK, "Hanehalkı İşgücü Araştırması Hakkında Genel Açıklama", http://www.tuik.gov.tr/HbGetir.do?id=27688&tb_id=10 , erişim tarihi: 24.05.2018