



Araştırma Makalesi

Koşullu Otoresif Bayes Model Yaklaşımı ile Türkiye Deprem Verilerinin Mekânsal Analizi

Leyla BAKACAK KARABENLİ^{*1}, Serpil AKTAŞ ALTUNAY¹

¹*Hacettepe Üniversitesi, İstatistik Bölümü, 06800, Ankara, Türkiye*

* yazışılan yazar e-posta: leylabakacak@hacettepe.edu.tr

(Alınış / Received: 16.08.2021, Kabul / Accepted: 07.03.2022, Yayımlanma / Published: 27.05.2022)

Öz: Mekânsal veri türlerinden birisi olan alansal verilerde gözlem değerleri mekâna bağlı olarak değiştiği için gözlem değerleri arasında mekânsal otokorelasyon ortaya çıkar. Mekânsal modellerde mekân bilgisinin modele katılabilmesi için alanların ilişkilerini tanımlayan komşuluk matrisinin oluşturulması gerekir. Bu nedenle mekânsal otokorelasyonu dikkate alan modellerin kullanımı son yıllarda yaygınlaşmıştır. Genelleştirilmiş Doğrusal Modeller (GDM), mekânsal otokorelasyonun modellenmesinde yetersiz kalmaktadır. Koşullu Otoresif Bayes (CARBayes) modeli ile daha önceden deprem verilerinin modellenmesi ile ilgili bir çalışma yapılmamıştır. Bu yüzden, bu çalışmada 2016 yılında Türkiye’de meydana gelen deprem sayıları kullanılarak CARBayes modelinin kullanımı önerilmiştir. CARBayes modeli Genelleştirilmiş Doğrusal Mekânsal Model (GDMM) formundadır. Verilerde alansal birim olarak “iller” alınmış ve komşuluk matrisleri oluşturulurken idari bölünüş sınırları dikkate alınmıştır. Oluşturulan komşuluk matrisi üzerinden kurulan permütasyon testi sonucunda deprem sayılarında mekânsal ilişki çıkmıştır. Bu yüzden, deprem sayıları ile ortalama deprem büyüklüğü arasındaki ilişki için GDMM’de mekân bilgisi komşuluk matrisi yardımı ile rastgele etki olarak modele eklenmiştir. Böylece artıklardaki otokorelasyon problemi çözülmüş ve tahmin değerleri elde edilmiştir. Tahmin değerlerinden yararlanılarak bir risk değeri hesaplanmış ve haritalandırma aracılığıyla riskli iller belirlenmiştir.

Anahtar kelimeler: Mekânsal modeller, Genelleştirilmiş Doğrusal Mekânsal Modeller, CARBayes, Türkiye deprem verileri

Spatial Analysis of Turkey Earthquake Data with Conditional Autoregressive Bayesian Model Approach

Abstract: Since the observation values in (spatial) areal data, which is one of the spatial data types, change depending on the space, spatial autocorrelation occurs between the observation values. In spatial models, in order for the spatial information to be included in the model, the neighborhood matrix, which defines the relations of the areas, must be created. For this reason, the use of models that take into account spatial autocorrelation has become widespread in recent years. Generalized Linear Models (GLM) are insufficient in modeling spatial autocorrelation. There is no previous study which has been done on modeling earthquake data with the Conditional Autoregressive Bayes (CARBayes) model. Therefore, in this study, the use of CARBayes model has been proposed by using the number of earthquakes occurred in Turkey in 2016. The CARBayes model is in the form of the Generalized Linear Spatial Model (GLSM). In the data set, “provinces” are taken as the spatial unit and administrative division boundaries are taken into account while creating neighborhood matrices. As a result of the permutation test established on the created neighborhood matrix, a spatial relationship is found in the earthquake numbers. Therefore, for the relationship between the number of earthquakes and the average

earthquake size, the spatial information in GLSM is added to the model as a random effect with the help of the neighborhood matrix. Thus, the autocorrelation problem in residuals was solved and the predicted values were obtained. A risk value was calculated by using the estimated values and risky provinces were determined by mapping.

Key words: Spatial models, Generalized Linear Spatial Models, CARBayes, Turkey earthquake data

1. Giriş

Mekânsal veri tanımı haritada konumu tanımlanan verilerdir ve harita özelliği (feature), destek (support) ve öznitelik (attribute) olmak üzere üç bileşenden oluşur [1,2]. Harita özelliği, verinin haritada nasıl bir şekle sahip olduğunu tanımlar. Bu bağlamda veriler, nokta, çizgi, poligon veya grid olarak tanımlanabilir. Noktasal veriler, elektrik direği, ağaç veya otobüs durağı gibi haritada yalnızca bir nokta ile ifade edilen verilerdir. Çizgisel veriler, yol veya nehir gibi birbirine bağlanmış noktalardan oluşan verilerdir. Çizgilerle çevrelenmiş kapalı bir alan oluşturan veriler ise poligon tipli veriler olarak adlandırılır ve iller, ülkeler veya göller bu tip verilere örnek olarak verilebilir. Grid olarak tanımlanan veriler ise belirli bir düzen oluşturan noktalar veya hücrelerden meydana gelmektedir. Bu tip verilere dijital resimler, hava fotoğrafları veya uydu görüntüleri örnek verilebilir.

Mekânsal verilerin diğer bir parçası olan destek, verilerdeki her bir özniteliğin şekli, boyutu ve yönü ile ilişkilidir. En küçük destek olarak, nokta desenli verilerin boyutu sıfır, şekli ve yönü bulunmamaktadır. Çizgisel veriler, belirli bir uzunluğa ve yöne sahiptir. Alansal veriler ise belirli bir alana ve sınıra sahiptir.

Mekânsal verilerin öznitelikleri, harita detayına bağlı olarak ölçülen değerlerdir. Örneğin, her bir hava gözlem istasyonundan elde edilen ozon, partiküler madde veya sülfür dioksit gibi maddelerin ölçümleri, noktasal verilerden elde edilen öznitelik verilerini oluşturur. Bir gölün tuzluluk, derinlik veya sıcaklık gibi ölçümleri ise alansal verilere ait öznitelige örnek olarak verilebilir [3-5].

Mekânsal alansal veriler, çokgen olarak adlandırılacak birbiriyle örtüşmeyen belirli bir sınır içerisinde gözlenmiş veriler olarak da ifade edilebilir. Mekânsal analizde, sayısal verilerin yanı sıra alan olarak tanımlanabilen mekân bilgisinin kullanılması için mekânsal otokorelasyonun hesaplanması ve bu bilginin modele katılması gerekir. Çünkü mekânsal otokorelasyona sahip birbirine yakın alanların gözlem değerlerinin mekân bilgisinden dolayı benzer özellikler göstermesi beklenir. Burada mekânsal yakınlık kavramından yola çıkarak ve otokorelasyonun hesaplanabilmesi için komşuluk kavramı ortaya çıkmaktadır. Bu komşuluk ilişkisini gösteren matris, eşit bir ağırlık ya da mekânsal bağımlılığa bağlı olarak farklı ağırlıklandırma da yapılarak tanımlanabilir [5]. Böylece mekân bilgisinin komşuluk matrisi ile modele dahil edildiği ve alanlar arası otokorelasyonun rastgele etkiler ile ifade edildiği koşullu otoregresif türü modeller mekânsal verilerin analizinde kullanılabilecek bir model olarak ortaya çıkmaktadır [6-8].

Seçim bölgeleri gibi bitişik mekânsal birimlerle ilgili veri modellemesi, tarımsal alan denemeleri, görüntü analizi, coğrafi analiz veya hastalıkların haritalandırılması gibi alanlarda sıkça karşılaşılan bir durumdur. Bu uygulamalardaki bağımlı değişkenler mekânsal bağımlılık gösterir. Yani birbirine yakın birimlerden elde edilen gözlemler, birbirine uzak olanlara göre daha benzer olma eğilimi gösterir. Bu tarz verilerde, gözlem değerleri arasındaki mekânsal otokorelasyonu modellemek için çeşitli istatistiksel modeller geliştirilmiştir [9-12].

Mekânsal modeller birçok alanda kullanıldığı gibi çok önemli bir uygulama alanı da deprem uygulamalarıdır. Schiappapietra ve Douglas [13] 2016-2017 İtalya deprem verileri için mekânsal otokorelasyon modelini uygulamışlardır. Mai ve Beroza [14]

mekânsal verileri üzerine bir yöntem geliştirmişlerdir. Jayaram and Baker [15,16] sismik hareketleri analiz eden mekânsal yöntemler kullanmışlardır. Lavallée vd. [17] mekânsal değişim için Levy dağılımını kullanarak dört farklı noktadaki deprem verileri için olasılıksal bir model geliştirmişlerdir. Ogata ve Katsura [18] deprem büyüklüğü verilerine ait mekânsal model önermişlerdir. Sokolov vd. [19] Taywan deprem verileri için yer hareketleri ilişkilerini dikkate alan mekânsal bir çözümleme yapmışlardır. Goda ve Hong [20] çalışmalarında Kaliforniya kayıtlarından yararlanarak zayıf yer hareketlerine ilişkin mekânsal ilişkileri incelemişler ve bunu sismik tehlike ve sismik risk değerlendirmelerinde kullanmışlardır. Goda ve Atkinson [21] mekânsal olarak ilişkili yer hareketleri parametreleri için bir model geliştirmişler ve bu modelin sismik tehlike ve sismik risk değerlendirmelerinde kullanılabileceğini göstermişlerdir.

Bu çalışmada, 01.01.2016 – 31.12.2016 tarihleri arasında Türkiye'nin 81 ilinde meydana gelen deprem sayıları olarak toplanan veriler bir koşullu otoregresif bayes model ile analiz edilmiştir [22]. Veriler üzerinden modelleme ve risk haritalandırılması yapılmıştır. Rastgele etkinin modelde yer aldığı koşullu otoregresif modeli ile deprem sayıları ve deprem büyüklüğü arasındaki ilişki incelenmiştir. Model sonucunda elde edilen kestirilmiş değerler üzerinden her ile ait risk değerleri hesaplanmış ve risk haritalaması yapılmıştır. Bunun yanı sıra, mekân bilgisinin tanımlanmasında farklı komşuluk matrisi kullanımının parametre tahminine etkisini görmek için iki farklı matris kullanılmış ve analizler tekrarlı olarak incelenmiştir. Deprem sayılarının modellenmesinde Poisson dağılımı varsayımı altında Genelleştirilmiş Doğrusal Modeller (GDM) ile artıklarda mekânsal bilginin etkisi yer aldığından bu modellerin kullanımının uygun olmadığı gözlenmiştir. Daha önceden koşullu otoregresif bayes model ile deprem verilerinin modellenmesi ile ilgili bir çalışma yapılmamıştır. Bu nedenle, deprem sayıları ve deprem büyüklüğü arasındaki ilişkinin incelenmesinde rasgele etkinin modelde yer aldığı Leroux et. al. [23] tarafından önerilen koşullu otoregresif modelinin kullanımı önerilmiştir.

2. Materyal ve Metot

Mekânsal olarak yapılandırılmış modellerin analizinde doğrusal model yaklaşımı kullanıldığında artıklarda mekânsal bağımlılık söz konusu olmaktadır. Artıklardaki mekânsal otokorelasyon için en yaygın çözümlerden biri Bayesci hiyerarşik modellerdir. Bu modellerde, mekânsal ilişkili rastgele etki kümesi yer almakta ve model farklı düzeylerle ifade edilmektedir. Bu bağlamda, alansal verilerde var olabilecek mekânsal otokorelasyon hiyerarşinin ikinci düzeyinde bir dizi rastgele etkiyle modellenir. Böylece, Bayesci hiyerarşinin her bir düzeyi farklı değişim kaynaklarını açıklamak için kullanılır. Modelde açıklayıcı değişkenlerin yanı sıra komşuluk bilgisinin de rastgele etkiler ile modele katılmasıyla daha tutarlı tahmin değerleri elde edilir. Genelleştirilmiş Doğrusal Mekânsal Modellerdeki (GDMM) bu rastgele etkiler genellikle Markov koşullu otoregresif önsel dağılım ile temsil edilir [3].

2.1 Koşullu otoregresif bayes model

Koşullu otoregresif modeller (Conditional Autoregressive Models, CAR Models), çalışma bölgesinde bulunan alanlar arası otokorelasyonu rastgele etkiler üzerinden yakalayan GDMM'dir. Bu modelde komşu alanlar mekânsal modellenirken komşu olmayan alanlar koşullu bağımsız olarak modellenir. Rastgele etkiler genellikle K tek değişkenli koşullu dağılımlar kümesi olarak tanımlanmaktadır, $\phi_{-k} = (\phi_1, \dots, \phi_{k-1}, \phi_{k+1}, \dots, \phi_K)$.

Bağımlı değişkendeki mekânsal değişim, açıklayıcı değişken matrisi $X = (X_1, \dots, X_K)$ ve mekânsal bileşen $\psi = (\psi_1, \dots, \psi_K)$ tarafından modellenir. Mekânsal bileşen, açıklayıcı değişkenlerin etkisinden sonra artıklarda kalabilecek mekânsal

otokorelasyonu ayrıştırmak için modele dahil edilir. Her alansal birim için açıklayıcı değişken vektörü, $X_k = (1, x_{k1}, \dots, x_{kp})$ olarak tanımlanır ve vektördeki 1 sabit terimi ifade eder.

Leroux et al. [23] tarafından mekânsal otokorelasyon parametresi de dahil edilen sadece tek bir rastgele etki kümesi içeren bir model öne sürülmüştür. Parametrelere ait önseller Denklem 1’de verildiği gibidir.

$$\begin{aligned} \psi_k &= \phi_k \\ \phi_k | \phi_{-k}, \mathbf{W}, \tau^2, \rho &\sim N \left(\frac{\rho \sum_{j=1}^K w_{kj} \phi_j}{\rho \sum_{j=1}^K w_{kj} + 1 - \rho}; \frac{\tau^2}{\rho \sum_{j=1}^K w_{kj} + 1 - \rho} \right) \\ \tau^2 &\sim \text{Ters Gamma}(a; b) \\ \rho &\sim \text{Düzgün}(0; 1) \end{aligned} \quad (1)$$

Burada $\mathbf{W} = [w_{kj}]_{K \times K}$, elemanları w_{kj} olan komşuluk matrisidir. \mathbf{W} matrisinin k. ve j. elemanı w_{kj} , k. ve j. alanları arasındaki mekânsal yakınlığı nicelleştirmekte ve tüm alan üzerinde komşuluk yapısını tanımlamaktadır. Böylece, K tane alanın birbirine göre mekânsal olarak nasıl konumlandığını gösteren $K \times K$ boyutlu bir matris elde edilir. τ^2 varyans parametresidir ve parametreleri a ve b olan ters Gamma dağılımına sahip bir rastlantı değişkenidir. ρ ise mekânsal otokorelasyon parametresidir ve düzgün dağılıma sahiptir.

- $\rho = 1$ olması güçlü mekânsal bağımlılığa karşılık gelir.
- $\rho = 0$ ise bağımsızlığı ifade etmektedir ve $\phi_k \sim N(0, \tau^2)$ dağılımına sahip olur.

Bu modelin çözümlenmesi için Lee [24] R programındaki CARBayes paketini geliştirmiştir. Bu paket, Gibbs örneklemesinin içinde Metropolis-Hasting adımlarını kullanan Markov zinciri Monte Carlo (MCMC) benzetimine dayanmaktadır.

Parametre tahminleri için aralıklar, %95 güven aralığı yerine %95 güvenirlilik aralığı (credible interval) olarak adlandırılır ve parametrenin tahmin edilen aralığa düşmesi olasılığı %95’tir şeklinde yorumlanır.

2.2 Moran’ın I istatistiği

Veride var olabilecek mekânsal otokorelasyon için kullanılan testlerden birisi Moran’ın I istatistiğidir. Moran’ın I istatistiği, herhangi X ve Y rastlantı değişkenlerinin gözlenen değerleri arasındaki ilişkiyi ölçen Pearson korelasyon katsayısına benzeyen bir ölçüttür. Yani Moran I , bir anlamda mekânsal ağırlıklı bir Pearson korelasyon katsayısı olarak değerlendirilebilir. $y = (y_1, \dots, y_K)$, K tane lokasyonda ölçülen veriler olsun. Moran’ın I istatistiği Denklem 2’de verildiği gibi, y_k ’nın yakınlarındaki yerlerde kendisiyle ilişkilendirilip ilişkilendirilmediğini test etmek için kullanılmaktadır.

$$I = \frac{K \sum_{k=1}^K \sum_{j=1}^K w_{kj} (y_k - \bar{y})(y_j - \bar{y})}{\left(\sum_{k=1}^K \sum_{j=1}^K w_{kj} \right) \left(\sum_{k=1}^K (y_k - \bar{y})^2 \right)}, \quad k = 1, \dots, K, j = 1, \dots, K \quad (2)$$

Burada y_k ve y_j , sırasıyla k. ve j. alana ait gözlem değeri, \bar{y} bağımlı değişkenin ortalaması, $\bar{y} = \frac{\sum_{k=1}^K y_i}{K}$; w_{kj} ise k. ve j. alanlar arasındaki bağlantının mekânsal ağırlığıdır.

Moran'ın I istatistiği korelasyon katsayısı gibi -1 ile 1 arasında değer almaktadır.

- $I = -1$ ise güçlü negatif otokorelasyon vardır. Uzayda birbirine yakın olan veri kümeleri farklı değerler almaktadır.
- $I = 0$, bağımsızlığı yani mekânsal otokorelasyonun olmadığını ifade eder.
- $I = 1$, güçlü pozitif otokorelasyon varlığını göstermektedir. Uzayda birbirine yakın olan veri kümeleri benzer değerler almaktadır.

Mekânsal otokorelasyonun önem kontrolü hipotez testi ile değerlendirilebilir. “ H_0 :Verilerde mekânsal ilişki yoktur.” hipotezini test etmek için Moran'ın I istatistiği kullanılır ve anlamlılık değeri (p) değeri permütasyon testi yardımıyla hesaplanabilir [24].

3. Bulgular

Bu çalışmada, 01.01.2016 – 31.12.2016 tarihleri arasında Türkiye'nin 81 ilinde meydana gelen deprem sayıları için modelleme ve risk haritalandırılması yapılmıştır. Bu bağlamda, modelde kullanılacak bağımlı değişken, her bir ilde meydana gelen depremlerin büyüklüğü 2'den büyük olan deprem sayılarıdır. Açıklayıcı değişken ise her il için büyüklüğü 2'den büyük olan depremlerin ortalama deprem büyüklüğüdür. Veriler, Boğaziçi Üniversitesi Kandilli Rasathanesi BDTİM deprem sorgulama sisteminden sarsıntı türü sadece deprem seçilerek 26-45 boylam ve 35-42 enlemleri arasında kalan bölgeye göre elde edilmiştir [25].

Deprem sayılarının modellemesinde Poisson dağılımı varsayımı altında geliştirilmiş doğrusal modeller kullanıldığında artıklarda mekânsal bilgi kalmaktadır. Bu nedenle rastgele etkinin modelde yer aldığı Leroux et. al [23] koşullu otoregresif modeli ile deprem sayıları ve deprem büyüklüğü arasındaki ilişki incelenmiştir. Ayrıca, farklı komşuluk matrislerinin kullanımının parametre tahminlerinde yaratacağı etki ve farklı etkilerin olması durumunda hangisinin daha başarılı açıklama oranına sahip olacağı araştırılmak istenmiştir. Bu nedenle, ikili bağlantı matrisi ve genel standartlaştırılmış matris olmak üzere iki farklı komşuluk matrisi üzerinden analizler tekrarlanmıştır. Analizler sonucunda elde edilen kestirilmiş değerler üzerinden her ilde ait risk değerleri hesaplanmış ve risk haritalaması yapılmıştır. Çözümlemeler CARBayes paketi üzerinden R programında gerçekleştirilmiştir [26].

CARBayes paketi, Lee [24] tarafından alansal veriler için tek değişkenli ve çok değişkenli mekânsal geliştirilmiş doğrusal karma modellerin uygulamasını içerir. İstatistiksel yazılım programı R için bir eklenti paketidir ve R arşivinden ücretsiz olarak indirilebilir. Paket, 3.0.0 ve daha yüksek sürüm gerektirmekte ve çeşitli paketlere bağlı olarak çalışmaktadır [22]. Bu paketlerden birisi olan “shapefiles”, mekân bilgisinin analizde kullanılması amacı ile *shapefile* yani mekân bilgisinin bulunduğu dosyanın R programına aktarılması için kullanılır. Bu *shapefile* dosyasında, alanların coğrafi koordinatları, yüz ölçümleri gibi bilgiler dbf, shp ve shx uzantılı dosyalarda yer almaktadır. Mekânsal analizde komşuluk matrisinin yaratılması veya mekânsal otokorelasyonun varlığının kontrolü için testlerin yapılması amacıyla **sp** ve **spdep** paketlerinden yararlanır. Kestirilmiş değerlerin ve artıkların mekânsal haritalarının çıkarılması için **mapproj** paketi kullanılır. Ayrıca, **ggplot2** ve **rgeos** paketleri haritalandırmada kullanılan diğer yardımcı paketlerdir.

Model tanımlaması yaparken örneklem sayısı, yakma periyodu ve inceltme (thinning) miktarının tanımlanması gerekir. Yakma periyodu, başlangıç değeri etkisinin azaltılması için zincirin başlangıç bölümünün atılması olarak ifade edilebilir. Böylece, sonsal çıkarımlar için iyi örneklem kullanılmış olur. İnceltme ise örneklemdeki bağımlılığı yani otokorelasyonu azaltmak için kullanılır.

Paket kapsamında oluşturulan modeller sonunda elde edilen çıktılar aşağıda tanımlanmıştır.

Çıktı tablosunda, sonsal medyan değeri, %95 güvenirlilik aralığı, üretilen örneklem sayısı, Markov zincirleri için kabul edilme oranları ve bu zincirlerin yakınsaklığının kontrolü için Geweke değerleri yer almaktadır.

Geweke [27] tarafından geliştirilen bu değer, Markov zincirinin ilk ve son bölümünün karşılaştırılmasına dayanan bir skordur. Zincirin başından ve sonundan yüzde kaçlık bir karşılaştırma yapılacağı ile ilgili varsayılan değerler, sırasıyla %10 ve %50 olarak belirlenmiştir. Eğer ortalamalar birbirine yakın ise zincir yakınsaktır. Geweke değerinin skor testi olmasından ötürü, -1,96 ile 1,96 arasında yer alan test istatistikleri yakınsamayı ifade ederken, daha aşırı değerler yakınsama eksikliğini işaret etmektedir. Zincirlerin yakınsama durumunun kontrol edilebilmesi için diğer bir yol ise parametrelerin iz ve olasılık yoğunluk fonksiyonu grafiğinin incelenmesidir. Eğer iz grafiğinde herhangi bir trend veya büyük dalgalanma yok ise yakınsama gerçekleşmiş ve hedef dağılıma ulaşılmıştır.

Model sonucunda her bir alan için sonsal medyan değerine bağlı olarak kestirilmiş değerler elde edilir. Model artıkları ise “response”, “Pearson” ve “deviance” olarak üç farklı şekilde elde edilir. Çıktıdan elde edilen artık matrisinde her satır bir veri noktasını ifade ederken her sütunda üç farklı artık tipi yer almaktadır.

Model bilgi kriteri olarak, etkin parametre sayısı ile birlikte sapma bilgi kriteri (Deviance Information Criterion, DIC), Watanabe-Akaike bilgi kriteri (WAIC), LMPL (Log Marginal Predictive Likelihood) ve açıklanan sapma yüzdesi (percentage deviance explained, p.d.e) verilir. En uygun model, DIC ve WAIC değerlerini minimum, LMPL’yi maksimum yapan modeldir.

Çalışmada kullanılan veriler için bağımlı ve açıklayıcı değişken için tanımlayıcı istatistikler Tablo 1’de verildiği gibidir. 2016 yılında meydana gelen depremler içerisinde, Kırklareli, Sinop ve Zonguldak’ta büyüklüğü 2’den büyük olan deprem meydana gelmediği için minimum deprem sayısı ve büyüklüğü 0 olarak tanımlanmıştır. En çok deprem olan il ise büyüklüğü 2’den büyük olan 669 deprem ile Manisa ili olmuştur. Ortalama deprem sayısı 62 ve deprem büyüklüğü 2,3 olarak elde edilmiştir. Poisson dağılımının özelliklerinden biri olan ortalama ve varyans değerlerinin eşit olması durumu burada sağlanamamış, varyans değerinin ortalama dan büyük olmasından dolayı aşırı yayılım durumu söz konusu olmaktadır. Literatürde bu durumda negatif binom dağılımına dayalı analizler yapılmıştır fakat GDMM aşırı yayılım durumunu çözmekte ve Poisson dağılımlı olarak modellenmesine izin vermektedir [28]. Ayrıca çalışma kapsamında Leroux modelinin simetrik olma koşulunu sağlayan iki komşuluk matrisi (ikili bağlantı matrisi ve genel standartlaştırılmış matris) kullanılmış ve karşılaştırması yapılmıştır.

Tablo 1. Tanımlayıcı istatistikler

	Minimum	Maksimum	Ortalama	Varyans
Deprem Sayısı	0	669	62	10027,2
Ortalama Deprem Büyüklüğü	0	2,7	2,3	0,2

Modellemede mekânsal bağımlılığın varlığının testi için artıklarının kontrol edilmesi gerekir. Bu test için ilk önce komşuluk matrisinin tanımlanması gerekir. İdari bölünüşlere göre her bir il, alansal bir birim oluşturmaktadır. Mekânsal bağımlılık, birbirine komşu olan iller tarafından açıklanır ve her il için komşuluk listesi oluşturulur. Örneğin, Ankara ilinin komşuluk listesinde, Çankırı, Kırıkkale, Kırşehir, Aksaray, Konya, Eskişehir ve Bolu bulunmaktadır. İkili tanımlı komşuluk matrisi oluşturulurken de Ankara ilinin komşuluk listesinde bulunan illere 1 ($w_{kj} = 1$), bulunmayanlara 0 ($w_{kj} = 0$) değeri atanır. Komşuluk matrisi tanımından gelen, Ankara kendisinin komşusu olamayacağı için $w_{kk} = 0$ değeri atanır. 81 il için oluşturulan 81×81 boyutlu simetrik komşuluk matrisi, ortak sınıra sahip olma durumuna göre w_{kj} değerleri üzerinden Tablo 2’deki gibi tanımlanmıştır.

Tablo 2. Sınır paylaşma durumuna göre ikili bağlantı matrisi (W_1)

	Adana	...	Ankara	Konya	Düzce
Adana	0	.	0	.	.	.	0	.	.	.	0
⋮
Ankara	0	.	0	.	.	.	1	.	.	.	0
⋮
⋮
Konya	0	.	1	.	.	.	0	.	.	.	0
⋮
Niğde	1	.	0	.	.	.	1	.	.	.	0
⋮
⋮
Düzce	0	.	0	.	.	.	0	.	.	.	0

81×81

İller arasında deprem sayıları bakımından otokorelasyon varlığının testi için bağımlı değişken üzerinden “ H_0 : Verilerde mekânsal ilişki yoktur.” şeklindeki yokluk hipotezi permütasyon testi ile test edilmiştir. Bağımlı değişken için W_1 komşuluk matrisi altında Tablo 3’teki otokorelasyon testi sonucu incelendiğinde, iller arasında deprem sayıları bakımından %5 anlamlılık düzeyinde mekânsal ilişki bulunmaktadır ($p < 0,05$). Ayrıca, Moran’ın I istatistiğinin yaklaşık olarak 0,23 gelmesinden dolayı alanlar arasında pozitif bir ilişki olduğu da söylenebilir. Yani her bir ildeki gözlem değerleri o alanın mekân bilgisine bağlı olarak değişmektedir.

Tablo 3. Bağımlı değişken için W_1 matrisi komşuluğunda otokorelasyon testi

Moran’ın I istatistiği	p değeri
0,227	0,0016

Genelleştirilmiş doğrusal mekânsal modellere geçmeden önce, Poisson dağılımı altında veriye genelleştirilmiş doğrusal model uygulaması yapılmış ve artıklarda mekânsal otokorelasyon bulunduğu sonucuna ulaşılmıştır ($Moran'ın I = 0,231$; $p = 0,0013$). Bu tür mekânsal bağımlılığın olduğu verilerin modellenmesinde klasik Genelleştirilmiş Doğrusal Modeller (GDM) yetersiz kalmaktadır. Böylece Genelleştirilmiş Doğrusal Mekânsal Modeller (GDMM) önem kazanmaktadır ve çözümlerler GDMM üzerinden yapılmalıdır. Bu yüzden W_1 komşuluk matrisi altında deprem sayısı ile ortalama deprem büyüklüğü arasındaki ilişkiyi incelemek için Leroux koşullu otoregresif modeli kurularak parametre tahminleri elde edilmiş ve risk haritası oluşturulmuştur.

Deprem sayılarının analizinde, Eşitlik (1)’de önselleri tanımlanan Leroux koşullu otoregresif modeli kullanılmıştır. Model, R programında tanımlanırken S.CARleroux() fonksiyonu ile 100.000 örneklem üretilmiş ve yakma periyodu olarak zincirin ilk 20.000’i analizden çıkarılmıştır. Böylece, 80.000 örneklem üzerinden analiz yapılmıştır. W_1 komşuluk matrisi altında kurulan Leroux modeli ve parametreler için tanımlanan önsel dağılımlar aşağıda verilmiştir.

$$Y_k \sim \text{Poisson}(\mu_k), k = 1, \dots, 81$$

$$\ln(\mu_k) = \beta_0 + \beta_1 * \text{ortalama deprem büyüklüğü} + \phi_k$$

$$\phi_k | \phi_{-k}, \mathbf{W}_1, \tau^2, \rho \sim N \left(\frac{\rho \sum_{j=1}^{81} w_{kj} \phi_j}{\rho \sum_{j=1}^{81} w_{kj} + 1 - \rho}; \frac{\tau^2}{\rho \sum_{j=1}^{81} w_{kj} + 1 - \rho} \right)$$

$$v^2 \sim \text{Ters Gamma}(1; 0,01)$$

$$\rho \sim \text{Düzgün}(0; 1)$$

Tablo 4'te \mathbf{W}_1 matrisi kullanılan Poisson GDMM artıklarının sonucu incelendiğinde, mekân bilgisinin model tarafından açıklandığı ve artıkların mekân bilgisinden bağımsız olduğu sonucuna ulaşılır ($p > 0,05$).

Tablo 4. Poisson GDMM artıkları için otokorelasyon testi (\mathbf{W}_1)

Moran'ın I istatistiği	p değeri
0,009	0,336


Parametre tahminlerine geçmeden önce Markov zincirlerinin yakınsaklığına bakmak için Geweke değerleri incelenir. Açıklayıcı değişken ortalama deprem büyüklüğü ve diğer parametrelere ait zincirlerden elde edilen Geweke değerleri (-1,96; 1,96) sınırları içerisinde kaldığı için yakınsama gerçekleşmiştir. (Tablo 5). Yakınsamaya görsel bir alternatif sağlaması açısından parametrelere ait iz grafikleri incelendiğinde, bu grafiklerde herhangi bir trende rastlanmadığı için yakınsaklığın sağlandığı sonucuna ulaşılabilir (Şekil 1-3).

Tablo 5. Poisson GDMM (\mathbf{W}_1)


Parametre	Medyan	%95 güvenirlilik aralığı		Geweke değerleri
		%2,5	%97,5	
β_0	-7,088	-9,305	-4,318	0,2
β_1	4,380	3,225	5,308	-0,2
τ^2	3,465	2,011	6,065	-0,3
ρ	0,336	0,087	0,729	-0,2

Ortalama deprem büyüklüğünün katsayısı olan β_1 , olasılık yoğunluk fonksiyonu grafiğinde sıfırdan büyük değer aldığı için ve bu yüzden güvenirlilik aralığı sıfırı içermediği için bu parametre anlamlıdır. Ayrıca, bağımlı değişken üzerinde pozitif bir etkiye sahiptir.

Şekil 2'de verilen otokorelasyon iz grafiği incelendiğinde, MCMC örnekleme geniş aralıkta çeşitli değerler alarak belirli bir ortalama etrafında rastlantısal gezinebildiği için yakınsamanın gerçekleştiği sonucuna ulaşılmıştır. Ayrıca, olasılık yoğunluk fonksiyonu grafiğinde ρ parametresine ait sonsal ortalama değerinin sıfırdan büyük olması ve %95 güvenirlilik aralığının sıfırı kapsamamasından dolayı anlamlı ve pozitif bir otokorelasyon parametresi olduğu sonucuna ulaşılır.




(a)




(b)

Şekil 1. β_0 (a) ve β_1 (b) için iz ve olasılık yoğunluk fonksiyonu grafiği (W_1)



Şekil 2. Otokorelasyon parametresi ρ için iz ve olasılık yoğunluk fonksiyonu grafiği (W_1)



Şekil 3. Varyans parametresi τ^2 için iz ve olasılık yoğunluk fonksiyonu grafiği (W_1)

Poisson log-doğrusal mekânsal modelin uygulanmasında, bağımlı değişkenin ortalaması üzerinden model kurulurken \log bağ fonksiyonu kullanıldığı için parametre tahminleri yapılırken test sonucunda elde edilen değerlerin üstelinin alınması gerekir (Tablo 6).

Tablo 6. Üstel Poisson GDMM (W_1)

	Parametre	Medyan	%95 güvenirlilik aralığı	
			%2,5	%97,5
Sabit Terim	e^{β_0}	0,008	9,09e-05	0,013
Ortalama Deprem Büyüklüğü	e^{β_1}	79,838	25,151	201,945
	e^{τ^2}	31,983	7,471	430,781
	e^{ρ}	1,399	1,091	2,073

DIC=1178,635; p.d.e=88,48

β_1 'in tahmini medyan değeri pozitif geldiği için her bir ilde meydana gelen büyüklüğü 2'den büyük olan depremlerin ortalama büyüklükleri arttıkça, o ilde meydana gelen deprem sayısı da artmaktadır. Parametrelerin anlamlılıklarını test etmek için %95 güvenirlilik aralıkları incelendiğinde, bütün parametrelerin anlamlı olduğu sonucuna ulaşılır. Ayrıca modelin açıklanabilirlik oranı (p.d.e) yaklaşık olarak %88'dir.


Risk haritalarının oluşturulmasında, modellerin hem açıklayıcı değişkenlere yer vermesi hem de alansal birimler arasındaki mekân bilgisinin komşuluk matrisi ile modele katılıyor olması daha tutarlı sonuçlara neden olmaktadır. Bu yüzden, Poisson GDMM'sinden elde edilen kestirilmiş değerlerin beklenen deprem sayısına bölümünden risk değerleri tahmin edilmektedir.

$$\text{Risk} = \frac{\text{Kestirilmiş değer}}{\text{Beklenen değer}} = \frac{\hat{Y}_k}{E_k}, k = 1, \dots, K \quad (3)$$

Her bir ilde meydana gelebilecek beklenen deprem sayıları şu şekilde hesaplanmıştır;

- 2016 yılında her bir ilde meydana gelen deprem sayıları ve toplam deprem sayısı (A) elde edilmiş.
- 2016 yılında her bir ilde meydana gelen büyüklüğü 2'den büyük olan deprem sayıları ve büyüklüğü 2'den büyük olan toplam deprem sayısı (B) elde edilmiş.
- $\frac{B}{A}$ oranı ile, 2016 yılında meydana gelen depremlerde, büyüklüğü 2'den büyük olanlar için bir oran elde edilmiş.
- Bu oranın her bir ilde meydana gelen deprem sayıları ile çarpımından elde edilen sayılar, o iller için büyüklüğü 2'den büyük olan beklenen deprem sayısını ifade etmektedir.


Eşitlik (3)'te verilen risk formülüne göre her bir il için elde edilen risk ölçümlerinin haritası Şekil 4'de verilmiştir. Haritalandırma **RColorBrewer** paketinde mavi rengi derecelendirme vermesi açısından farklı tonlarına göre seçilmiştir. Etiketle var olduğu üzere rengin açıktan koyuya doğru gitmesi riskin veya olasılığın arttığı anlamına gelmektedir.



Şekil 4. 2016 yılında meydana gelen büyüklüğü 2'den fazla olan depremlerin riski (W_1)

Kırklareli (1), Zonguldak (2) ve Sinop (3) illerinde 2016 yılında çok fazla deprem olmadığı için bu alanların renkleri çok açık bir mavi renge sahiptir. Başka bir deyişle risksiz alanlar olarak adlandırılır. İzmir (4), Uşak (5), Bartın (6), Erzurum (7) ve Van (8) illeri birinci dereceden riskli iller olarak ifade edilebilir. 2016 yılında bu alanlarda beklenenden daha fazla deprem olmuştur. İkinci dereceden riskli grupta ise Ordu (9), Rize (10), Ardahan (11) ve Ağrı (12) illeri yer almaktadır.

Risk haritasına alternatif olarak riskin belirli bir değerden büyük olduğu durumlar için sonsal olasılık haritası yapılabilir. Şekil 5'te verilen, riski 1'den büyük olan depremlerin yüksek olasılığı doğu illerinde gözlenmektedir. İç Anadolu bölgesi, nispeten az riskli bölge olarak tanımlanabilir. Ülkenin batı tarafında yer alan İzmir (1), Uşak (2) ve Balıkesir (3), bu bölgede deprem riski yüksek alanlar olarak değerlendirilebilir.



Şekil 5. Riski 1'den büyük olan depremlerin sonsal olasılıkları (W_1)

İkinci bir komşuluk matrisi olarak genel standartlaştırılmış matris elde edilmiştir (Tablo 7). Bu komşuluk matrisi oluşturulurken bütün illerin komşuluk listesi kullanılarak, tüm alansal birimler arasındaki toplam bağlantı sayısı elde edilir. Burada toplam bağlantı sayısı 398'dir. Çalışma bölgesinde 81 tane il yani alansal birim bulunmaktadır. Böylece, genel standartlaştırılmış bu matrisin ağırlıkları toplam alan sayısının toplam bağlantı sayısına oranından,

$$w_{kj} = \frac{\text{Toplam Alan Sayısı}}{\text{Toplam Bağlantı Sayısı}} = \frac{81}{398} \cong 0,203$$

şeklinde elde edilir.

Tablo 7. Genel standartlaştırılmış matris (W_2)

	Adana	...	Ankara	Konya	Düzce
Adana	0	.	0	.	.	.	0	.	.	.	0
...
Ankara	0	.	0	.	.	.	0,203	.	.	.	0
...
...
Konya	0	.	0,203	.	.	.	0	.	.	.	0
...
Niğde	0,203	.	0	.	.	.	0,203	.	.	.	0
...
...
Düzce	0	.	0	.	.	.	0	.	.	.	0

81x81

Komşuluk matrisinin elde edilmesinden sonra, bağımlı değişken için W_2 komşuluk matrisi altında otokorelasyon testi yapılır (Tablo 8). Test sonucunda yine mekânsal bir bağımlılığın söz konusu olduğu görülmektedir ($p < 0,05$). Bu yüzden bu komşuluk matrisi altında tekrar bir Leroux modeli kurularak parametre tahminleri yorumlanıp risk haritası oluşturulmuştur.

Tablo 8. Bağımlı değişken için W_2 matrisi komşuluğunda otokorelasyon testi

Moran'ın I istatistiği	p değeri
0,227	0,0015

Burada kurulan Leroux modeli ve parametreler için tanımlanan önsel dağılımlar ilk oluşturulan Leroux modeli ile aynı olmakla birlikte sadece komşuluk matrisi olarak W_2 kullanılmıştır.

$$\phi_k | \phi_{-k}, W_2, \tau^2, \rho \sim N \left(\frac{\rho \sum_{j=1}^{81} w_{kj} \phi_j}{\rho \sum_{j=1}^{81} w_{kj} + 1 - \rho}; \frac{\tau^2}{\rho \sum_{j=1}^{81} w_{kj} + 1 - \rho} \right)$$

Modelin yorumlamasına geçebilmek için artıklarda mekânsal otokorelasyon olup olmadığının testi yapılır. Tablo 9'da belirtilen test sonucuna göre model mekân bilgisini açıklamakta ve artıklarda herhangi bir mekânsal bağımlılık söz konusu olmamaktadır.

Tablo 9. Poisson GDMM artıkları için otokorelasyon testi (W_2)

Moran'ın I istatistiği	p değeri
-0,031	0,6825

Parametre tahminlerine geçmeden önce Markov zincirlerinin yakınsaklığına bakmak için Geweke değerleri incelenir (Tablo 10). Bütün parametreler için bu değerler, (-1,96; 1,96) aralığına düştüğü için zincirlerde yakınsama gerçekleşmiştir (Ek 1). Zincirlerin yakınsaması gerçekleştiği için ve artıklarda mekânsal otokorelasyon bulunmadığı için parametre tahminlerine Tablo 10 değerlerinin üsteli alınarak geçilebilir (Tablo 11).

Tablo 10. Poisson GDMM (W_2)

Parametre	Medyan	%95 güvenirlilik aralığı		Geweke değerleri
		%2,5	%97,5	
β_0	-2,913	-5,824	-0,490	-0,6
β_1	2,631	1,613	3,8539	0,6
τ^2	1,412	0,998	2,049	-1,3
ρ	0,643	0,234	0,909	-0,3


Parametre tahminlerinin güvenilirlik aralığına bakıldığında bütün parametreler Poisson GDMM’de anlamlı bir etkiye sahiptir. W_1 matrisinden elde edilen modelin sonuçlarına paralel olarak, ortalama deprem büyüklüğü arttıkça alanlardaki deprem sayısı da artmaktadır (Tablo 11). Modelin açıklanabilirlik oranı ise yaklaşık olarak %91’dir.

Tablo 11. Üstel Poisson GDMM (W_2)

	Parametre	Medyan	%95 güvenilirlik aralığı	
			%2,5	%97,5
Sabit Terim	e^{β_0}	0,054	0,003	0,612
Ortalama Deprem Büyüklüğü	e^{β_1}	13,887	5,018	47,176
	e^{τ^2}	4,104	2,713	7,764
	e^{ρ}	1,902	1,263	2,483


DIC=893,415; p.d.e=91,93

Genel standartlaştırılmış komşuluk matrisi dahilinde kurulan modelden elde edilen risk tahminleri Şekil 6’da verilmiştir. W_1 matrisi dahilinde elde edilen risk haritasında olduğu gibi Uşak (1), Bartın (2) ve Ordu (3) riskli iller arasındadır. Balıkesir (4) ise W_2 matrisi öncülüğünde kurulan modelde yüksek riske sahiptir. Ayrıca kıyı doğu illerinde riskli alanlar da mevcuttur.



Şekil 6. 2016 yılında meydana gelen büyüklüğü 2’den fazla olan depremlerin riski (W_2)

Şekil 7’de verilen riski 1’den büyük olanların haritalaması incelendiğinde, genel anlamda doğuda bulunan illerin olasılıkları yüksek çıkmıştır. Ayrıca ülkenin kuzeyinde de bu yüksek deprem riski mevcuttur. Ülkenin İç Anadolu ve güney kesimi, W_1 ’den elde edilen model sonuçlarına kıyasla daha çok risk taşıdığı anlamına gelmektedir. Batı kesimlerinde daha önceki haritalarda olduğu Balıkesir (1), İzmir (2), Uşak (3) ve ayrıca Bursa (4) yüksek deprem riski olan alanlar olarak tanımlanır.



Şekil 7. Riski 1’den büyük olan depremlerin sonsal olasılıkları riski (W_2)

4. Sonuç ve Yorum

Mekânsal veri türlerinden birisi olan alansal verilerde gözlem değerleri mekâna bağlı olarak değiştiği için gözlem değerleri arasında mekânsal otokorelasyon oluşmaktadır. Mekânsal modellemede mekân bilgisinin modele katılabilmesi için alanların ilişkilerini tanımlayan komşuluk matrisinin oluşturulması gerekir. Klasik GDM'ler bu tip verileri modellemede yetersiz kaldığından mekânsal otokorelasyonu dikkate alan modellerin kullanımı son yıllarda yaygınlaşmıştır. Uygulamada ise bağımlı değişken üzerinden mekânsal otokorelasyon testi yapıldığında mekânsal ilişkinin var olduğu sonucuna ulaşılmıştır ve deprem sayılarını modellemek için GDMM'ler tercih edilmiştir.

Bu çalışmada, 2016 yılında Türkiye'de meydana gelen büyüklüğü 2'den büyük olan deprem sayıları kullanılarak CARBayes modeli ile çözümlene yapılması önerilmiştir. Alansal birim olarak "iller" alınmış ve komşuluk matrisleri oluşturulurken idari bölünüş sınırları dikkate alınmıştır. Ayrıca, farklı komşuluk matrislerinin kullanımının parametre tahminine etkisini incelemek amacıyla iki ayrı komşuluk matrisi tanımlanmıştır. Birincisi ikili bağlantı matrisi, ikincisi ise genel standartlaştırılmış matristir. Veride genel mekânsal otokorelasyon testi için Moran'ın I istatistiği kullanılmıştır. Oluşturulan her iki komşuluk matrisi üzerinden kurulan permütasyon testi sonucunda deprem sayılarında mekânsal ilişki çıkmıştır. Bu yüzden, deprem sayıları ile ortalama deprem büyüklüğü arasındaki ilişki için model kurulurken GDMM kullanılmıştır. GDMM'de mekân bilgisi komşuluk matrisi yardımı ile rastgele etki olarak modele eklenmiştir.

GDMM'lerde, komşu alanlardaki veriler mekânsal olarak modellenirken, komşu olmayan alanlar koşullu bağımsız olarak modellenmektedir. Böylece rastgele etkiler, koşullu otoregresif önsel dağılımları ile temsil edilmiştir. CAR modelleri arasında teorik ve pratik anlamda güzel sonuçlar veren Leroux modeli parametre tahminleri ve risk haritalaması için kullanılmıştır. Parametre tahminleri, Bayesci yaklaşımla elde edilmiştir.

İkili tanımlı komşuluk matrisi üzerinden kurulan Leroux modelinin zincirlerinde yakınsama gerçekleşmiş ve parametre tahminleri anlamlı bulunmuştur. Modelden elde edilen artıklarda mekânsal bağımlılığa rastlanmamıştır. Bu yüzden model yorumuna geçerek, büyüklüğü 2'den büyük olan depremlerde, büyüklük arttıkça deprem sayısı da artmaktadır. Modelden elde edilen kestirilmiş değerlerin beklenen deprem sayısına oranıyla risk haritası oluşturulmuştur. Çok az sayıda deprem olması nedeniyle Kırklareli, Zonguldak ve Sinop risksiz alanlar olarak tanımlanmıştır. İzmir, Uşak, Bartın, Erzurum ve Van'da beklenenden daha fazla deprem olduğu için riski yüksek alanlar olduğu sonucuna ulaşılmıştır. Bu illeri daha sonra Ordu, Rize, Ardahan ve Ağrı takip etmiştir. Ayrıca riski birden büyük alanlar için sonsal olasılık haritası yapılmıştır. Bu haritada doğu illerindeki yüksek risk oranı yoğun bir şekilde gözlenmiştir. İç Anadolu bölgesi az riskli bölge olarak tanımlanırken, İzmir, Uşak ve Balıkesir batı bölgesinde birden büyük riske sahip olma olasılığı yüksek iller olarak ifade edilebilir.

Genel standartlaştırılmış komşuluk matrisi ile kurulan modelde zincirlerin yakınsaması sağlandıktan sonra artıklar mekânsal otokorelasyon testine sokulduğunda mekânsal bağımlılığa rastlanmamıştır. Diğer modelde olduğu gibi bu modelde de parametreler anlamlı gelmiş ve ortalama deprem büyüklüğü ile deprem sayısı arasında aynı yönlü bir ilişki olduğu sonucuna ulaşılmıştır. Bu modelde elde edilen risk haritasında, kıyı doğu illerinin yanı sıra Balıkesir, Uşak, Bartın ve Ordu riskli iller olarak değerlendirilmiştir. Riski 1'den büyük olanların sonsal olasılık haritası incelendiğinde, doğu illerinde yüksek oran gözlenmiştir. Batı tarafta ise Balıkesir, İzmir ve Uşak birden büyük risk olasılığı yüksek iller olarak değerlendirilmiştir.

Uygulamada kullanılan iki komşuluk matrisi ile elde edilen Leroux modeli sonuçları incelendiğinde, ortalama deprem büyüklüğü ile deprem sayısı arasında aynı yönlü bir

ilişki olduğu sonucuna ulaşılmıştır. Risk haritaları incelendiğinde ise küçük farklılıklara rağmen riskli alanlar için büyük ölçüde benzer sonuçlar elde edilmiştir.

Araştırmacıların Katkı Oranı Beyanı

Leyla Bakacak Karabenli: Araştırma, Metodoloji, Görselleştirme

Serpil Aktaş Altunay: Kavramsallaştırma, İnceleme ve Düzenleme, Denetim/Gözlem/Tavsiye

Destek ve Teşekkür Beyanı

Bu çalışma Leyla BAKACAK'ın yüksek lisans tezinden türetilmiştir.

Çatışma Beyanı

Bu çalışmanın yazarları olarak herhangi bir çatışma beyanımız bulunmadığını bildiririz.

Etik Kurul Onayı ve/veya Aydınlatılmış Onam Bilgileri

Bu çalışmanın yazarları olarak herhangi bir etik kurul onayı ve/veya aydınlatılmış onam bilgileri beyanımız bulunmadığını bildiririz.


Kaynakça

- [1] N. Cressie, *Statistics for Spatial Data*, Revised Edition, John Wiley & Sons, New York, 1993.
- [2] R. P. Haining, *Spatial Data Analysis: Theory and Practice*, Cambridge University Press, Cambridge, 2003.
- [3] O. Schabenberger and C. A. Gotway, *Statistical Methods for Spatial Data Analysis*, Chapman & Hall/CRC, Boca Raton/London, 2005.
- [4] S. R. Bivand, E. Pebesma, and V. Gomez-Rubio, *Applied Spatial Data Analysis with R*, Second Edition, Springer, 2013.
- [5] A. D. Cliff and J. K. Ord, *Spatial Processes: Models and Applications*, Pion, London, 1981.
- [6] D. Griffith, "What is spatial autocorrelation?," *L'Espace géographique*, 21, 265–280, 1992.
- [7] Y. Chun and D. A. Griffith, *Spatial Statistics & Geostatistics*, Sage, Thousand Oaks, CA, 2013.
- [8] A. D. Cliff and J. K. Ord, *Spatial Autocorrelation*, Pion, London, 1973.
- [9] M. D. Ward and K. S. Gleditsch, *Spatial regression models*, Sage, Thousand Oaks, CA, 2008.
- [10] R. Haining, *Spatial Data Analysis in the Social and Environmental Sciences*, Cambridge University Press, Cambridge, 1990.
- [11] T. C. Bailey and A. C. Gatrell, *Interactive Spatial Data Analysis*, England, Addison Wesley Longman, 1995.
- [12] W. Kissling and G. Carl, "Spatial autocorrelation and the selection of simultaneous autoregressive models," *Global Ecol. Biogeogr.*, 17, 59–71, 2008.
- [13] E. Schiappapietra and J. Douglas, "Modelling the spatial correlation of earthquake ground motion: Insights from the literature, data from the 2016–2017 Central Italy earthquake sequence and ground-motion simulations," *Earth-Sci. Rev.*, Volume 203, 103139, 2020.
- [14] P. M. Mai and G. C. Beroza, "A spatial random field model to characterize complexity in earthquake slip," *J. Geophys. Res.*, 107(B11), 2308, 2002.
- [15] N. Jayaram and J. W. Baker, "Considering spatial correlation in mixed-effects regression, and impact on ground-motion models," *Bull. Seismol. Soc. Am.*, 100(6), 3295-3303, 2011.
- [16] N. Jayaram and J. W. Baker, "Correlation model for spatially distributed round-motion intensities," *Earthquake Engng Struct. Dyn.*, 38:1687–1708, 2009.
- [17] D. Lavallée, P. Liu, and R. J. Archuleta, "Stochastic model of heterogeneity in earthquake slip spatial distributions," *Geophys. J. Int.*, Volume 165(2), 622–640, 2006.
- [18] Y. Ogata and K. Katsura, "Analysis of temporal and spatial heterogeneity of magnitude frequency distribution inferred from earthquake catalogues," *Geophys. J. Int.*, 113(3), 727–738, 1993.
- [19] V. Sokolov, F. Wenzel, J. Wen-Yu, and W. Kuo-Liang, "Uncertainty and Spatial Correlation of Earthquake Ground Motion in Taiwan," *Terr. Atmos. Ocean. Sci.*, 21(6), 905-921, 2010.
- [20] K. Goda and H. P. Hong, "Spatial correlation of peak ground motions and response spectra," *Bull. Seismol. Soc. Am.*, 98, 354-365, 2008.
- [21] K. Goda and G. M. Atkinson "Probabilistic characterization of spatially correlated response spectra for earthquakes in Japan", *Bull. Seismol. Soc. Am.*, 99, 3003-3020, 2009.
- [22] L. Bakacak, "Genelleştirilmiş doğrusal mekansal modellere koşullu otoregresif model yaklaşımı," Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, Hacettepe Üniversitesi, Ankara, Türkiye, 2018.
- [23] B. Leroux, X. Lei, and N. Breslow, *Estimation of disease rates in small areas: a new mixed model for spatial dependence*, *Statistical models in epidemiology, the environment and clinical trials*, New York, Springer-Verlag, 135–78, 1999.
- [24] D. Lee, "CARBayes: An R Package for Bayesian Spatial Modeling with Conditional Autoregressive Priors," *J. Stat. Softw.*, Volume 55, Issue 13, 2013.


- [25] B.Ü. KRDAE Bölgesel Deprem-Tsunami İzleme ve Değerlendirme Merkezi, Available: <http://www.koeri.boun.edu.tr/sismo/zeqdb/>.
- [26] R Core Team (2013). R: A language and environment for statistical computing. R Foundation for Statistical Computing, Vienna, Austria. Available: <http://www.R-project.org/>.
- [27] J. Geweke, "Evaluating the accuracy of sampling-based approaches to the calculation of posterior moments," *In Bayesian Statistics*, University Press, 169-193, 1992.
- [28] P. McCullagh and J. A. Nelder, *Generalized Linear Models*, Second Edition, New York, Chapman & Hall, 1989.

Ek


Ek 1:



Şekil 8. β_0 (a) ve β_1 (b) için iz ve olasılık yoğunluk fonksiyonu grafiği (W_2)



Şekil 9. Otokorelasyon parametresi ρ için iz ve olasılık yoğunluk fonksiyonu grafiği (W_2)



Şekil 10. Varyans parametresi τ^2 için iz ve olasılık yoğunluk fonksiyonu grafiği (W_2)