

Türkiye'de Cinsiyete göre Obezite Öncesi Yüzdeler Dağılımının Yapay Sinir Ağı ve Zaman Serileri ile Tahmini

Halil ÇOLAK¹, Emre ÇOLAK^{2*}

Öz

Obezite, artan aşırı kilolu birey oranları nedeniyle Türkiye'de önemli bir halk sağlığı sorunu teşkil etmektedir. Ancak bu sorun, sağlıklı beslenme alışkanlıklarının teşvik edilmesi, düzenli fiziksel aktivitenin desteklenmesi ve toplumsal farkındalığın artırılması gibi önlemlerle etkili bir şekilde ele alınabilir. Bu hedefe ulaşmak kolektif bir çaba ve ortak bir vizyon gerektirecektir. Obezite için alınacak tedbirlerin etkin olabilmesi açısından, obezite öncesi dönemin bilinmesi büyük önem taşımaktadır. Makine öğrenmesinin avantajlarından bir tanesi de geleceği tahmin etmesidir. Yapılan bu çalışmada Türkiye'de cinsiyete göre obezite öncesi yüzdeler dağılım tahminleri yapılmış ve 2023 ile 2030 yılları arasındaki veriler tahmin edilmiştir. Bunun için Levenberg-Marquardt (LM) algoritması, Bayesian Regularization (BR) algoritması, ARIMA model ve Holt-Winters (HW) yöntemi kullanılmıştır. Çıkan sonuçlara göre Türkiye'de cinsiyete göre obezite öncesi yüzdeler dağılımının 2030 yılında kadınlarda LM'e göre %32,79 değerinde erkeklerde ise ARIMA modelin %42,73 değerinde olacağı tahminlendi.

Anahtar Kelimeler: Obezite öncesi, Levenberg-Marquardt, Bayesian Regularization, ARIMA, Holt-Winters

Estimation of Prevalence Distribution of Pre-obesity by Gender in Türkiye Using Artificial Neural Networks and Time Series Analysis

Abstract

Obesity is an important public health problem in Türkiye due to the increasing proportion of overweight individuals. However, this problem can be effectively addressed through measures such as promoting healthy eating habits, supporting regular physical activity, and raising public awareness. Achieving this goal will require a collective effort and a common vision. For the measures to be taken for obesity to be effective, it is of great importance to know the pre-obesity period. One of the advantages of machine learning is that it predicts the future. In this study, the pre-obesity percentage distribution of obesity in Türkiye by gender was estimated and the data between 2023 and 2030 were estimated. For this purpose, the Levenberg-Marquardt (LM) algorithm, Bayesian Regularisation (BR) algorithm, ARIMA model, and Holt-Winters (HW) method were used. According to the results, the pre-obesity percentage distribution by gender in Türkiye in 2030 was estimated to be 32.79% for women according to LM, and 42.73% for men according to the ARIMA model.

Keywords: Pre-obesity, Levenberg-Marquardt, Bayesian Regularization, ARIMA, Holt-Winters

¹Giresun Üniversitesi, Spor Bilimleri Fakültesi, Beden Eğitimi ve Spor Bölümü, Giresun, Türkiye, halil.colak@giresun.edu.tr

²Giresun Üniversitesi, Fen Bilimleri Enstitüsü, Enerji Sistemleri Mühendisliği A.B.D., Giresun, Türkiye, emre.colak@giresun.edu.tr

*Sorumlu Yazar/Corresponding Author

Geliş/Received: 21.03.2024

Kabul/Accepted: 26.07.2024

Yayın/Published: 15.09.2024

1. Giriş

Obezite kronik ve çok faktörlü bir hastalıktır. Ciddi sağlık ve ekonomik sonuçları olan küresel bir salgın haline gelmiştir (Busebee, Ghusn, Cifuentes, & Acosta, 2023). Obezite aşırı toplam yağ birikimi ve anormal dağılımlı lokalize yağ artışından kaynaklanan kronik metabolik bozukluklar olarak tanımlanır (Wei et al., 2022). Obezite temel olarak tüketilen kalori miktarı ile harcanan enerji miktarı arasındaki dengesizlikten kaynaklanmaktadır (Baer, Dalton, Blundell, Finlayson, & Hu, 2023). Dünya genelinde bir milyardan fazla insan aşırı kilolu olup, 650 milyondan fazla yetişkin, 340 milyondan fazla çocuk ve ergen obez olarak sınıflandırılmaktadır ("World Health Organization Obesity and Overweight.," 2011). Türkiye'de 2019 yılında 15 yaş ve üzeri kadınların %24,8'i obez olarak sınıflandırılırken, bu oran erkeklerde ise %17,3'tür (Pekkurnaz, 2023). Obezitenin neden olduğu insülin direnci, yağlı karaciğer hastalığı, kalp krizi ve hiperlipidemi gibi metabolik hastalıklarla bağlantılıdır ve halk sağlığı için önemli bir tehdit oluşturmaktadır (Jiang, Tian, Yang, Jia, & Shu, 2024).

Teknolojinin gelişmesi insanlığa bazı kolaylıklar getirirken, fiziksel hareketliliği etkileyen birtakım olumsuzlukları da beraberinde getirmiştir. Sık araba ve asansör kullanımı gibi kolaylıklar fiziksel hareketsizliğe yol açmış ve obezite gibi birçok hastalığa neden olmuştur (Çolak, Kale, & Cihan, 2003). Düzenli fiziksel aktivite, obezitenin önlenmesinde önemli bir rol oynamaktadır (Janssen et al., 2005). Obezite hastalarında fiziksel aktivite düzeylerinin ve beslenme davranışlarının iyileştirilmesinin sağlık açısından faydalarını destekleyen önemli kanıtlar da bulunmaktadır (Ross & Bradshaw, 2009). Artan fiziksel aktivite düzeylerinin, kilo kaybı olmasa bile obezite sorunu olan bireylerde kardiyometabolik sağlıkta iyileşmelere yol açabileceğini göstermiştir (Elagizi, Kachur, Carbone, Lavie, & Blair, 2020). Türkiye'de obezite, koroner kalp ve damar hastalıkları günümüzün en başta gelen sağlık sorunları biridir [7]. Son 10 yılda Türkiye'de obezite öncesi ve obezite oranları önemli ölçüde artarak %17,9'a yükselmiştir. Bu artış, 2008'de %47,6 olan oranın 2019'da %56,1'e ulaşmasıyla belirginleşmiştir (Benli, Acar, & Bas, 2024). Obezite, genel sağlığı etkileyen karmaşık, kronik bir hastalıktır (Pauchet-Traversat et al., 2023). Bu sebeple ileri yıllar obezite ile ilgili çalışma, fizibilite yapmak için obezite öncesi dönemin tahminlenmesi önemlidir ve makine öğrenimi bu açıdan araştırma süreçlerini tamamlamak için umut verici fırsatlar sağlayabilmektedir (Eisbach, Mai, & Hertel, 2024).

Makine öğrenimi, karmaşık veriler için kullanışlıdır (Henriques & Sadorsky, 2023). Bir tahmin yöntemi olan yapay sinir ağları (YSA), insan zihninin nörolojik işlevlerini ve beynin mantıksal sistemlerini taklit etmek için tasarlanmıştır. Birbirine bağlı nöronlardan oluşurlar ve makine öğrenimi için kullanılırlar (Sarwar, Aziz, & Tiwari, 2023). Otoresif hareketli ortalamalar (ARIMA) modeli tüm zaman serisi yöntemleri arasında doğrusal modellerin uyarlanabilirliği nedeniyle zaman serisi

yöntemlerinin en yaygın olanıdır (Tarmanini, Sarma, Gezeğin, & Ozgonenel, 2023). Diğer zaman serisi yöntemi olan Holt-Winters yöntemi ise kübik üstel düzeltme, mevsimsel özellikleri kullanarak doğrusal eğilimlere, periyodik dalgalanmalara sahip ve durağan olmayan tek sütunlu serileri tahmin etmek için kullanılan bir yöntemdir (Wang, He, Chen, & Jia, 2024).

Literatür taramalarında ise Türkiye’de obezite veya obezitenin tetiklediği hastalıklara yapılan tahmin yöntemleri çalışmaları mevcuttur. Sözmen vd., (2015) Türkiye’nin 2025 yılındaki diyabet prevalansı tahmin etmek için yaptıkları çalışmada obezite veri parametreleri ile Microsoft Excel programında model oluşturup tahminde bulundular. Danacı vd., (2023) makine öğrenimi metotları ile obezite düzeylerini tahmin ettiler ve bu düzeye göre belirli bir sınıflandırma yaptılar. Bunun için karar ağacı algoritmasını ve aşırı gradyan artırma algoritmasını tercih ettiler. Çelik vd., (2021) 2021 yılında obezite düzey tahminleri için YSA ve makine öğrenme yöntemlerini kullandılar. YSA için R^2 değerini 0,9652, destek vektör makinelerinde R^2 değerini 0,978 ve karar ağacı algoritması (torbalı ağaç) R^2 değerini 0,9540 olarak elde ettiler. Özcan vd., (2019) obezitenin neden olduğu hastalıklardan biri olan kalp ve damar hastalıklarının tahmini için destek vektör makineleri ile YSA’yı tercih ettiler. YSA ile R^2 değerini 0,8333, destek vektör makinelerinin R^2 değerini ise 0,9167 olarak buldular.

Obezite ve obezitenin neden oldukları hastalıkların belirlenmesi için obezite öncesi dönemin mutlak bilinmesi gerekmektedir. Bunun için yapılan tahminler oldukça önemlidir. Obezite öncesi dönemin tahmini ile bu hastalıklar önlenmektedir. Bu çalışmanın amacı Türkiye’de cinsiyete göre obezite öncesi yüzdeler dağılımlarının gelecek yıllara yönelik tahmin edilmesidir. Bu çalışmadaki tahminler ile Türkiye’de bilim adamlarının ve politika yapıcılarının (siyasetçilerin) ileri yıllar için yapılacak olan sağlık alanındaki çalışmalara yardımcı olacağı yazarlar tarafından düşünülmektedir.

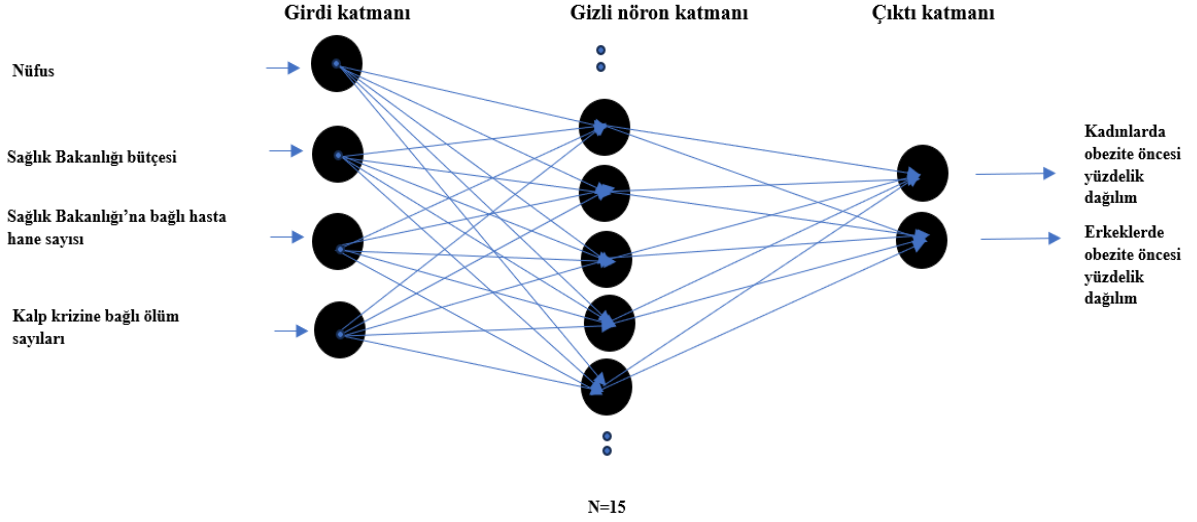
2. Teorik Metot

2.1. Yapay Sinir Ağları

Yapay sinir ağları (YSA), insan beyni gibi öğrenerek yeni bilgiler üretmek, oluşturmak ve keşfetmek üzere tasarlanmış bilgisayar sistemleridir. YSA'nın yapısını oluşturan üç bileşen vardır: nöron, bağlantılar ve öğrenme algoritması. Nöron, YSA'nın ana işlem elemanıdır (Şenol, Dereli, & Özbilgin, 2021). Yapay sinir ağları (YSA) veriler tarafından yönlendirilir ve belirli bir dağılım gerektirmez. Sonuç olarak, doğrusal olmayan fonksiyonlara yaklaşabilir ve girdi-çıkış ilişkisinin hesaplanmasının zor olduğu problemleri çözebilirler (Salih et al., 2022). YSA daha fazla tahmin ve tahmin doğruluğuna sahiptir bu yönden diğer makine öğrenme yöntemlerine göre avantajlıdır (Jani, Mishra, & Sahoo, 2017). Yapay sinir ağları, biyolojik sinir sistemine benzer bir yapıya sahip, paralel olarak bağlanmış basit elemanlardan oluşur. Ağın işlevi, bu unsurlar arasındaki büyük ölçekli

bağlantılar tarafından oluşturulur. Belirli bir işlevi yerine getirmek için ağ, belirli bir girdiye yanıt olarak elemanlar arasındaki bağlantıların ağırlık değerleri ayarlanarak eğitilir (Şenol, 2021). YSA'lar, belirli bir girdiye yanıt olarak parametreler arasındaki bağlantıların ağırlık değerlerine göre eğitilir ve buna göre bir çıktı üretir (Çolak & Şenol). Levenberg-Marquardt (LM) yöntemi genellikle büyük boyutlu en küçük kareler problemlerini çözmek için kullanılır. LM algoritması, Gauss-Newton yöntemini iyileştirmek için bir düzenleme stratejisine dayanmaktadır. Gauss-Newton yönteminin her iterasyonunda doğrusal en küçük kareler problemi çözülmelidir. LM algoritması ayrıca yön hesaplamasını kolaylaştıran bir düzenleme parametresi ekler. Bu nedenle, LM algoritmasının her iterasyonunda, adım veya adımın yönünü hesaplamak için bir doğrusal denklem sistemi çözülmelidir (Krejić, Malaspina, & Swaenen, 2023). Bayesian Regularization algoritmasının (BR) genellikle bir problemin çözümünü sabit bir nokta olarak tahmin edilen frekans yaklaşımının aksine, parametreler üzerinde tam bir dağılım kullanarak belirsizliği tahmin etmektir (Pomponi, Scardapane, & Uncini, 2021). Türkiye'de cinsiyete göre obezite öncesi yüzdeleri dağılımlarının 2023-2030 yılları arasında tahmin edilmesi amacıyla kullanılan modeller, 4-15-2 mimari ağlar üzerinde eğitilmiştir (Şekil1). Bu çalışmada, girdi değişkenleri olarak nüfus, Sağlık Bakanlığı Bütçesi, Sağlık Bakanlığı'na bağlı hasta hane sayıları ve kalp krizine bağlı ölüm sayılarının verileri tercih edilmiştir. Bu amaçla, 2014-2022 yılları arasındaki veriler kullanılmıştır. Farklı denemeler sonucunda, en iyi sonuçları verdiği belirlenen gizli nöron sayısı 15 olarak belirlenmiştir. Çıktı değişkenleri olarak ise kadın ve erkek obezite öncesi veri yüzdeleri kullanılmıştır ve bu veriler için 2014, 2016, 2019 ve 2022 yıllarındaki veriler kullanılmıştır. 2015, 2017, 2018, 2020 ve 2021 yıllarındaki veriler Türkiye İstatistik Kurumu (TÜİK) ("Türkiye İstatistik Kurumu (TÜİK) ", 2024) 'te yayınlanmadığı için bu yıllara ait veriler bir önceki yılın verileriyle eşit kabul edilmiştir. Yapay sinir ağı modelleri için LM algoritması ile BR algoritmaları tercih edilmiş ve kümelenme oranları %60 eğitim, %20 doğrulama ve %20 test olarak belirlenmiştir. Bu sayılar deneme yanılma yöntemi ile belirlenmiştir. Ancak deneme yanılma, her katmandaki gizli katmanların ve nöronların sayısını seçmek için yaygın bir yaklaşım olmasına rağmen, mutlaka en etkili veya verimli yöntem değildir (Zhang, Patuwo, & Hu, 1998). Yapılan model ve tahminler için MATLAB (R2019a) programı tercih edilmiştir.

Çalışma da kullanılan girdi parametrelerine ait veriler ve hedef parametrelerine ait veriler Tablo 1 ve Tablo 2' de sunulmuştur.



Şekil 1. Yapay sinir ağı mimarisi.

Tablo 1. YSA modellerine ait girdi parametreleri verileri.

Nüfus (10^6)	Sağlık Bakanlığı bütçesi (10^9)	Sağlık Bakanlığı'na bağlı hasta hane sayısı	Kalp krizine bağlı ölüm sayısı (10^3)
77,6959	18,43	866	43,077
78,74105	20,12	865	45,131
79,81487	25,28	876	47,527
80,81053	31,97	879	47,066
82,00388	37,57	889	45,442
83,1550	48,44	895	44,248
83,61436	58,88	900	51,909
84,68027	77,62	908	55,845
85,27955	116,04	915	53,347

Tablo 2. YSA modellerine ait hedef parametreleri verileri.

Kadınlarda obezite öncesi yüzdelik dağılım	Erkeklerde obezite öncesi yüzdelik dağılım
29,3	38,2
29,3	38,2
30,1	38,6
30,1	38,6
30,1	38,6
30,4	39,7
30,4	39,7
30,4	39,7
30,9	40,4

2.1.1. Duyarlılık Analizleri

Türkiye’de cinsiyete göre obezite öncesi yüzdeler dağılımlarının tahminleri için yapılan YSA modellerinde girdi parametrelerinin çıktı parametrelerini ne kadar etkilediğini bulmak için girdi parametrelerine duyarlılık analizi uygulandı. Duyarlılık analizi olarak Garson algoritması ile Yoon algoritması tercih edildi. Garson algoritması, YSA modelinin giriş ve çıkış katmanları arasındaki ağırlıkları çıkararak giriş değişkenlerinin etkisini veya göreceli katkısını hesaplar ve Denklem 1’de formülü verilmiştir (al-Swaidani & al-Hajeh, 2023). Denklem 2’de ise yer alan Yoon algoritması ise bir girdi değişkenindeki değişimin diğerlerine oranıdır (da Costa, de Lima, & Barbosa, 2021).

$$DA(GARSON)(\%)_{ik} = \frac{\sum_{j=1}^m (|W_{ij}| / \sum_{i=1}^n |W_{ij}|) \times |W_{jk}|}{\sum_{i=1}^n \{ \sum_{j=1}^m (|W_{ij}| / \sum_{i=1}^n |W_{ij}|) \times |W_{jk}| \}} \times 100 \quad (1)$$

$$DA(YOON)(\%)_{ik} = \frac{\sum_{j=1}^h W_{ij} v_{jk}}{\sum_{i=1}^m | \sum_{i=1}^h W_{ij} v_{jk} |} \times 100 \quad (2)$$

2.2. Zaman Serileri

2.2.1. Otoregresif Entegre Hareketli Ortalama (ARIMA) Modeli

Otoregresif Entegre Hareketli Ortalama (ARIMA) Modeli, kendi gecikme terimini ve Y_t değişkeninin rastgele hata terimini dahil ederek bir zaman serisi verisinin davranışını tanımlamak için kullanılır. Bu, değişkenlerin açıklanmasına ve belirli bir matematiksel model kullanılarak gelecekteki sonuçların tahmin edilmesine yardımcı olur (Şenol, Çakır, Bianco, & Görgün, 2024). ARIMA modeli, ARIMA (p, d, q) modelini elde etmek için otomatik regresyon, fark ve farklı derecelerde hareketli ortalamaların bir kombinasyonunu kullanma avantajına sahiptir. Bu model, zaman serisini uydururken zaman serisinin çeşitli bilgi türlerini ifade eder ve uygun parametrelerin seçilmesiyle doğru tahminler yapılmasına olanak tanır (Li & Li, 2017). ARIMA (p, d, q) olarak ifade edilebilmektedir. Burada, 'p' otoregresif süreçlerin sırasını, 'd' farkın sırasını ve 'q' hareketli ortalama sürecinin sırasını temsil eder. Otoregresif süreç, korelasyon katsayısı ile temsil edilen AR fonksiyonunu hesaplamak için mevcut ve önceki verilerin kullanılmasını içerir. Benzer şekilde, hareketli ortalama (MA) süreci de MA fonksiyonunu hesaplamak için mevcut ve önceki hataları kullanmayı içerir. Bu, mevcut veriler ile hatalar arasındaki ilişki incelenerek yapılır (Conejo, Plazas, Espinola, & Molina, 2005). Denklem 3’te ARIMA’nın genel formülü yer almaktadır.

$$Y_t = C + \Phi_1 * Y_{t-1} + \dots + \Phi_p * Y_{t-p} + \theta_1 * e_{t-1} + \dots + \theta_q * e_{t-q} \quad (3)$$

2.2.2. Holt-Winters Yöntemi

Zaman serisi verileri hem trend hem de mevsimsel faktörleri bir araya getiren Holt-Winters (HW) yöntemi kullanılarak tahmin edilebilir. Parametrelerin değerleri hakkında bilinçli bir tahminde bulunmak için geçmiş veriler ve optimizasyon yöntemlerinin bir karışımını kullanılır (Pleños, 2022). Denklem 4'te yer alan HW formülünde L_t verinin seviyesini ifade ederken, T_t trendi, S_t ise mevsimsel bileşeni, F_{t+k} ise önümüzdeki k dönem için tahminleri ifade eder (Rashidi, Keshavarz, Pazarı, Safahieh, & Samimi, 2022).

$$F_{t+k} = (L_t + kT_t)S_{t-m+k} \quad (4)$$

2.3. Model Hata Performans Ölçütleri

Türkiye'nin cinsiyete göre obezite öncesi yüzdeler dağılımlarını tahmin etmek için kullanılan yöntem modellerinin hata performans ölçütleri için MSE, RMSE, SSE, MAPE ve R^2 kullanılmıştır

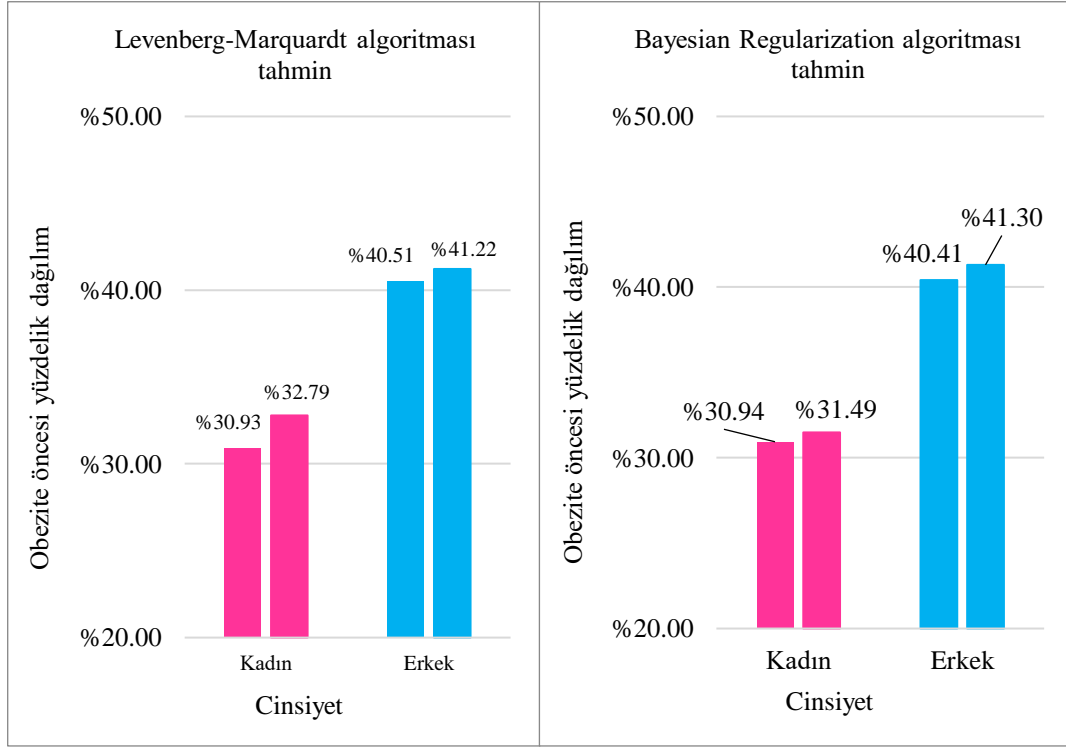
3. Sonuçlar ve Tartışma

3.1. Türkiye'de obezite öncesi yüzdeler dağılımının YSA ile tahmin edilmesi

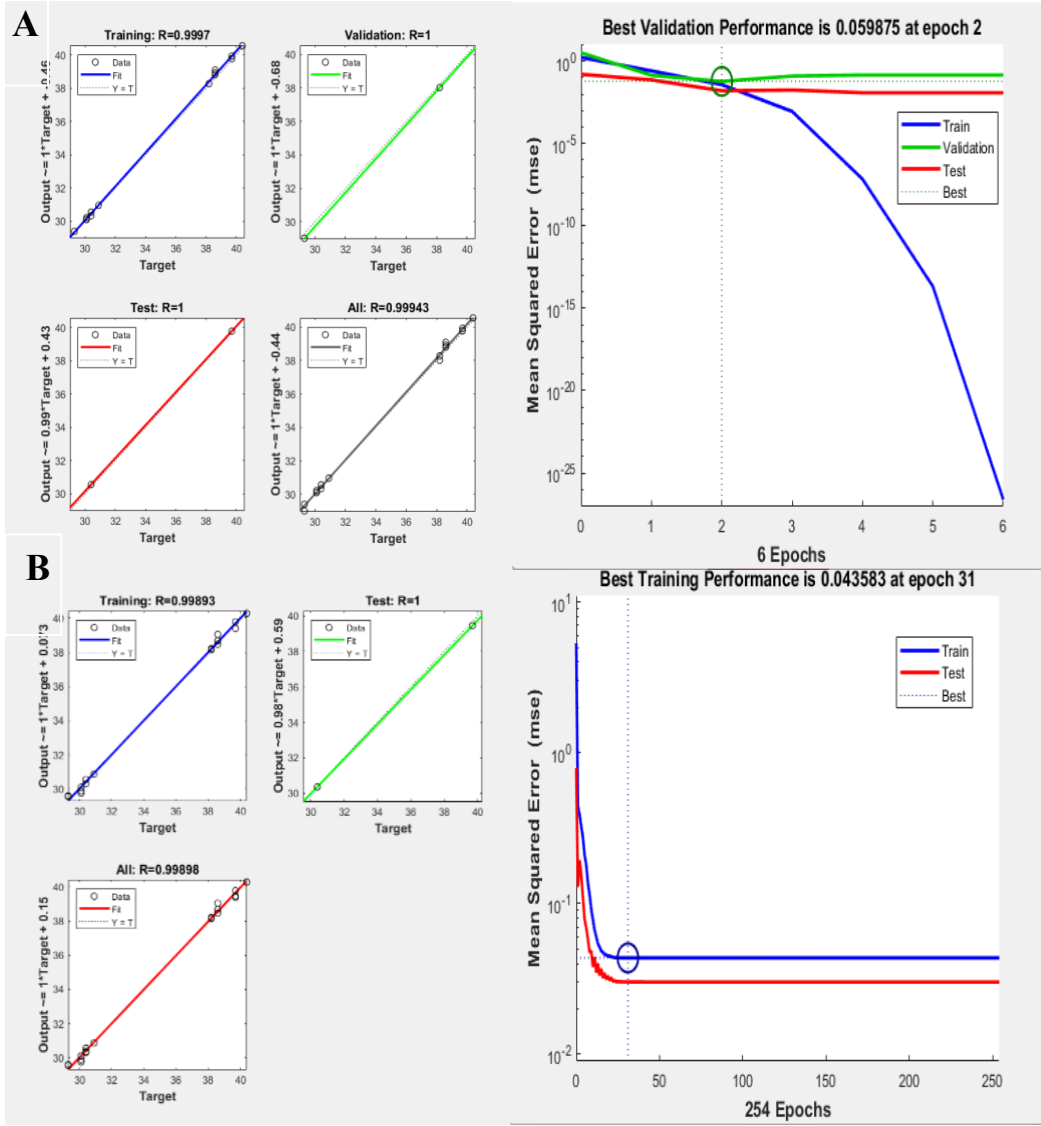
Doğrusal olmayan kareler sorunlarını çözmek ve makine öğreniminde aşırı uyum sorununu çözmek için LM algoritması ve BR algoritması kullanılmaktadır (Marcos & Planklang, 2024). LM algoritması, doğrusal olmayan en küçük kareler problemlerine yönelik önde gelen yöntemlerden biridir (Martínez, 2024). BR algoritması, standart geri yayılım ağlarından daha sağlamdır ve uzun çapraz doğrulama ihtiyacını azaltır veya ortadan kaldırmaktadır (Burden & Winkler, 2009). Türkiye'de obezite öncesi yüzdeler dağılımının LM algoritmasıyla tahmini, 2030 yılında kadınlar yaklaşık olarak %32,79, erkekler ise %41,22 olarak belirlenmiştir ($R^2 = 0,9994$). Benzer şekilde, BR algoritmasıyla yapılan tahminlere göre, 2030 yılında kadınlarda obezite öncesi yüzdeler dağılımı %31,48 iken erkeklerde bu oran %41,30 olarak öngörülmüştür ($R^2 = 0,9989$).

Değerler arasında kıyaslama yapıldığında, 2022 yılına göre kadınlarda LM algoritmasına göre %1,89 artış olduğu görülmüşken, BR algoritmasına göre bu artış yaklaşık %0,59 olarak gerçekleşecektir. Erkeklerin obezite öncesi yüzdeler dağılımı ise LM algoritmasıyla 2030 yılında %0,8202 artarken, BR algoritmasına göre bu artışın %0,9039 olacağı tespit edilmiştir (Şekil 2).

Algoritmalara ait regresyon ve MSE grafikleri Şekil 3'te sunulmuştur. Bu sonuçlara göre, genel regresyon performansının en etkili algoritmanın LM algoritması olduğu belirlenmiştir. Ayrıca, LM algoritmasının 6 iterasyon boyunca en düşük MSE değerine 2. iterasyonda sahip olduğu ve tahmin değerlerinin bu iterasyonlara dayandığı gözlemlenmiştir. BR algoritmasında ise, 254 iterasyon boyunca en düşük MSE değerinin 31. iterasyonda elde edildiği ve tahmin sonuçlarının bu değerlere göre belirlendiği görülmüştür.



Şekil 2. Algoritmaların cinsiyete göre tahmin grafikleri.

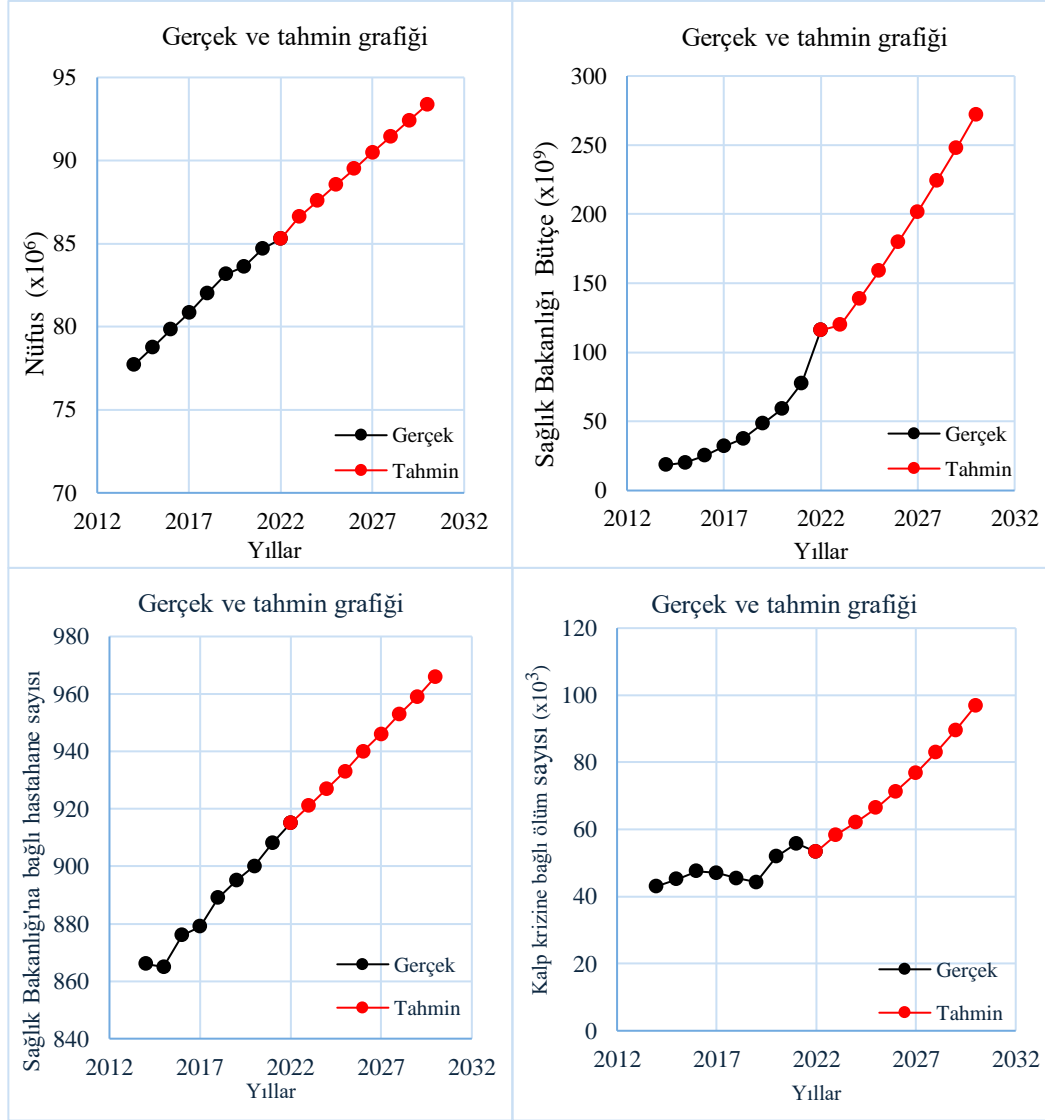


Şekil 3. Levenberg Marquardt algoritması (A) ve Bayesian Regularization algoritmasının (B) regresyon ve MSE grafikleri.

Algoritma çıktı parametrelerinin (kadın ve erkek obezite öncesi yüzdelik dağılımının) 2023 yılı ile 2030 yılları arasındaki tahminlerinin belirlenmesi için 4 adet girdi parametrelerine eğri uydurma yöntemi uygulanmıştır. Bu işlem için R^2 değeri yüksek olan fonksiyonlar tercih edilmiştir ve Tablo 3'te değerler sunulmuştur. Eğri uydurma yöntemi ile girdi parametrelerinin 2023 ve 2030 yılları arasındaki değerleri Şekil 4'te verilmiştir. Bu değerlere göre çıktı parametrelerinin tahminlerine ulaşılmıştır.

Tablo 3. Girdi parametrelerine uygulanan eğri uydurma yönteminin değer tablosu.


Parametre	Fonksiyon	Derece	R ²
Nüfus	Polynomial	1	0,9081
Sağlık Bakanlığı bütçe	Power	1	0,9035
Sağlık Bakanlığı'na bağlı hastahane sayısı	Polynomial	1	0,9848
Kalp krizine bağlı ölüm sayısı	Power	2	0,7098

**Şekil 4.** Girdi parametrelerinin eğri uydurma yöntemi ile tahmin grafikleri.

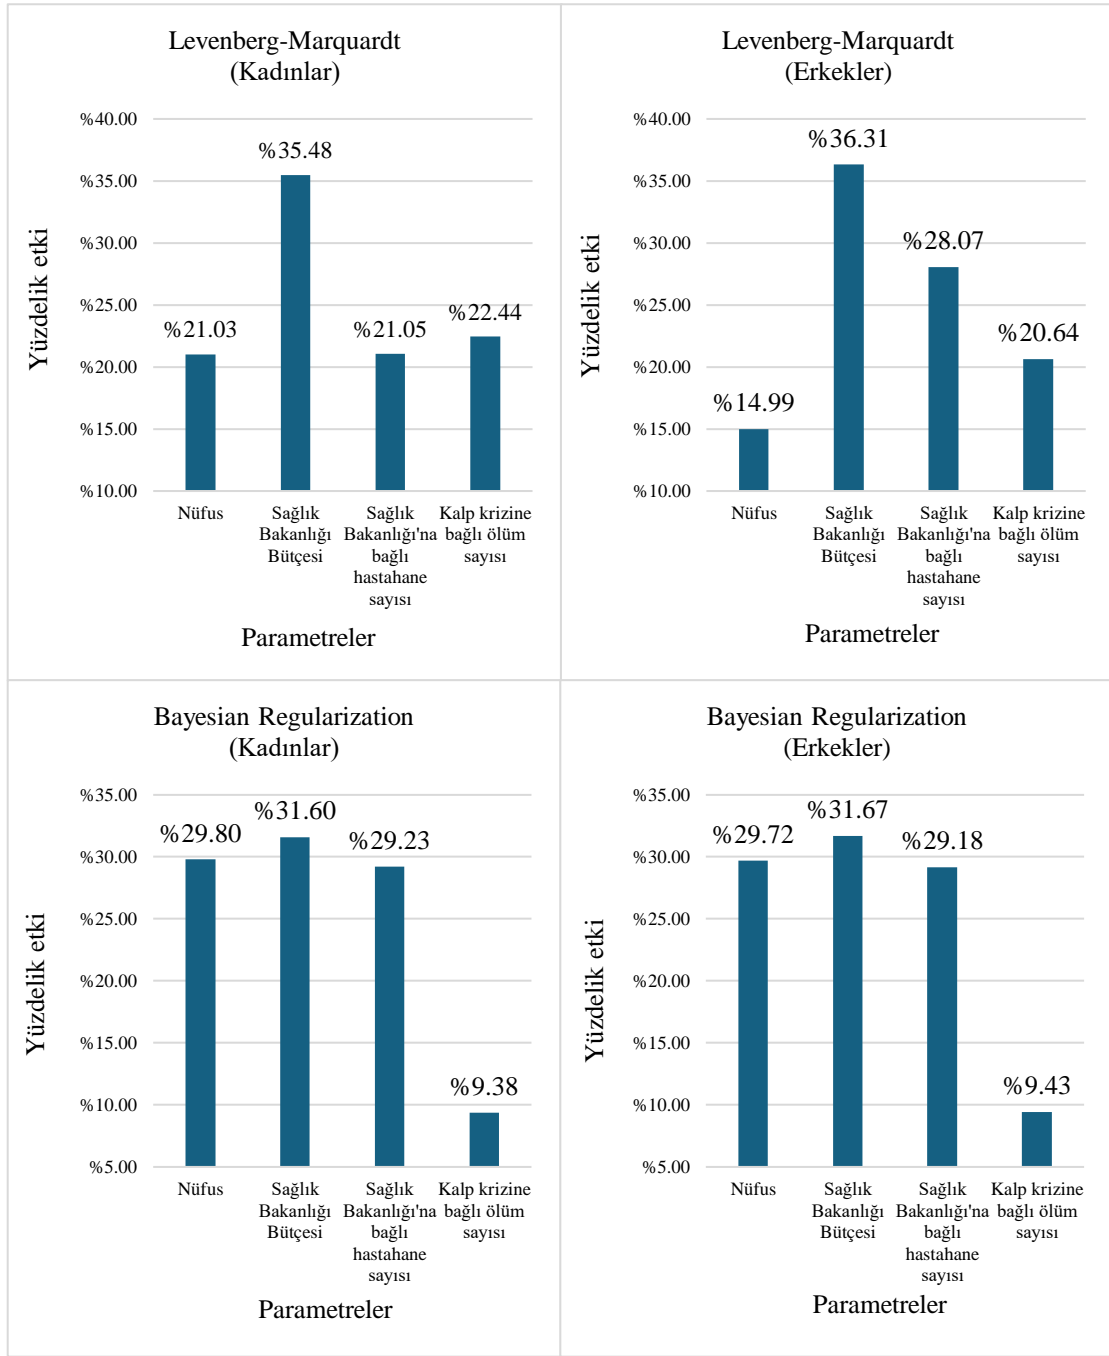
3.1.1. Duyarlılık Analizleri

Türkiye'nin cinsiyete göre obezite öncesi yüzdeler dağılımlarının tahmini için YSA ile oluşturulan modellerde kullanılan çıktı parametrelerinin üzerindeki etkiyi belirlemek için girdi parametrelerine duyarlılık analizi yapılmıştır. Duyarlılık analizlerini belirlemek için Garson algoritması ile Yoon algoritması tercih edildi. LM için Garson algoritmasına göre kadınların obezite öncesi yüzdeler dağılımını en çok etkileyen parametre Sağlık Bakanlığı Bütçesi olurken erkeklerin

obezite öncesi yüzdeler dağılımında da aynı benzer sonuç elde edildi. Kadınların obezite öncesi yüzdeler dağılımını en az etkileyen parametre ise Sağlık Bakanlığı'na bağlı hasta hane sayısı iken, erkeklerin obezite öncesi yüzdeler dağılımını etkileyen en az parametre ise nüfus olarak bulundu. LM için Yoon algoritmasında ise hem kadınların hem de erkeklerin obezite öncesi yüzdeler dağılımını etkileyen parametreler Garson algoritması ile benzerlik göstermiştir. BR için Garson algoritmasında ise kadınların obezite öncesi yüzdeler dağılımını en çok etkileyen parametre nüfustur. En az etkileyen parametre ise kalp krizine bağlı ölüm sayısı olmuştur. Erkeklerin obezite öncesi yüzdeler dağılımını en çok etkileyen parametre Sağlık Bakanlığı Bütçesi iken çıktı parametresini en az etkileyen girdi parametresi kalp krizine bağlı ölüm sayısı olmuştur. BR için Yoon algoritmasıyla yapılan duyarlılık analizinde kadınların obezite öncesi yüzdeler dağılımını en fazla etki eden parametre Sağlık Bakanlığı Bütçesi, en az etki eden parametre ise kalp krizine bağlı ölüm sayısı oldu. Erkeklerde ise bu analiz kadınların obezite öncesi yüzdeler dağılımı ile benzer sonuçlara ulaşıldı (Şekil 5 ve Şekil 6).



Şekil 5. YSA algoritmalarının Garson ile duyarlılık analizi.

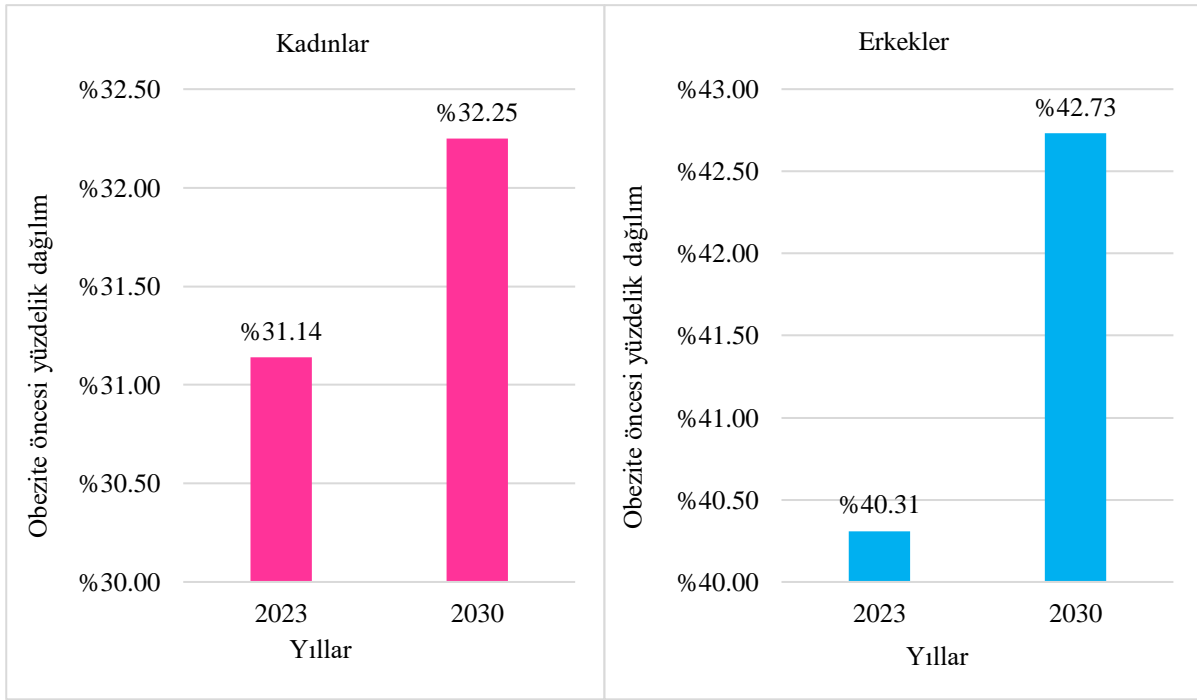


Şekil 6. YSA algoritmalarının Yoon ile duyarlılık analizi.

3.2. Türkiye’de obezite öncesi yüzdelerinin ARIMA ile tahmin edilmesi

Türkiye’de cinsiyete göre obezite öncesi yüzdelerinin 2030 yılına kadar tahmini için bir başka tahmin yöntemi olan zaman serisi ARIMA modeli kullanıldı. ARIMA modeli, zaman serisi analizleri içinde en güvenilir yöntemlerden biridir. ARIMA, otoregresif ve hareketli ortalama modellerinin faydalarını birleştiren, doğrusallaştırma nedeniyle doğrusal olmayan ve karmaşık olan verileri tahmin eden doğrusal bir regresyon modelidir [32]. SPSS 23 programı sayesinde 2014-2022 yılları arasındaki cinsiyete göre obezite öncesi yüzdelerinin verileri ile yıl-obezite öncesi


yüzdeler dağılım grafiği çizdirildi. ACF ve PACF grafiklerine bakılarak hem kadınlar hem de erkeklerin obezite öncesi yüzdeler dağılımının tahmini için ARIMA modelin p, d ve q sayıları belirlendi ve en uygun modelin (5, 1, 1) olduğu saptandı. Buna göre yapılan tahminlerde 2030 yılında kadınlarda obezite öncesi yüzdeler dağılımının 2022 yılına göre %1,35 artacağı, erkeklerde bu değerin %2,33 artacağı gözlenmiştir. 2023-2030 yılları arası yapılan tahminlerde veri setlerinin obezite öncesi yüzdeler dağılım ortalaması kadınlarda %31,71 iken erkeklerde bu değer %41,50 olarak hesaplandı. Kadınlarda ve erkeklerde obezite öncesi yüzdeler dağılım tahmin verileri Şekil 7’de verilmiştir.



Şekil 7. ARIMA modelin cinsiyete göre tahmin grafikleri.

3.3. Türkiye’de obezite öncesi yüzdeler dağılımının Holt- Winters ile tahmin edilmesi

Türkiye’de cinsiyete göre obezite öncesi dağılımının 2030 yılına kadar tahmini için bir başka yöntem olan Holt-Winters (HW) yöntemi kullanılmıştır. HW yöntemi en popüler, basit, koruyucu, kısa vadeli zaman serisinin tahmin yöntemlerindedir (Rumbe, Hamasha, & Al Mashaqbeh, 2024). HW yöntemine göre yapılan tahminlerde 2030 yılında kadınlarda obezite öncesi yüzdeler dağılımının 2022 yılına göre %1,32 artacağı, erkeklerde bu değerin %1,94 artacağı bulundu. 2023-2030 yılları arası yapılan tahminlerde veri setlerinin obezite öncesi yüzdeler dağılım ortalaması kadınlarda %31,60 erkeklerde ise bu değer %41,36 olduğu saptandı. Şekil 8’de kadınlarda ve erkeklerde obezite öncesi yüzdeler dağılım tahmin verileri sunulmuştur.



Şekil 8. Holt-Winters yönteminin cinsiyete göre tahmin grafikleri.

3.4. Model performanslarının hata ölçümleri

Türkiye'nin cinsiyete göre obezite öncesi yüzdeleri dağılımının 2023 ile 2030 yılları arasındaki tahminlerini bulmak için YSA'nın LM ve BR algoritmaları, ARIMA model ve HW yöntemi ile oluşturulan modellerin hataları bulundu. Hata ölçümleri için MSE, RMSE, SSE, MAPE ve R^2 'ye göre saptandı ve Tablo 4 ile Tablo 5'te sunuldu.

Tablo 4. Kadınlar için tahmin yöntemlerinin model performans hata ölçümleri.


Modeller/Ölçütler	MSE	RMSE	SSE	MAPE	R^2
LM	0,019	0,138	0,170	0,362	0,9223
BR	0,040	0,200	0,359	0,540	0,8360
ARIMA	0,390	0,624	3,504	0,460	0,7310
HW	0,051	0,225	0,456	0,534	0,8480

Tablo 5. Erkekler için tahmin yöntemlerinin model performans hata ölçümleri.

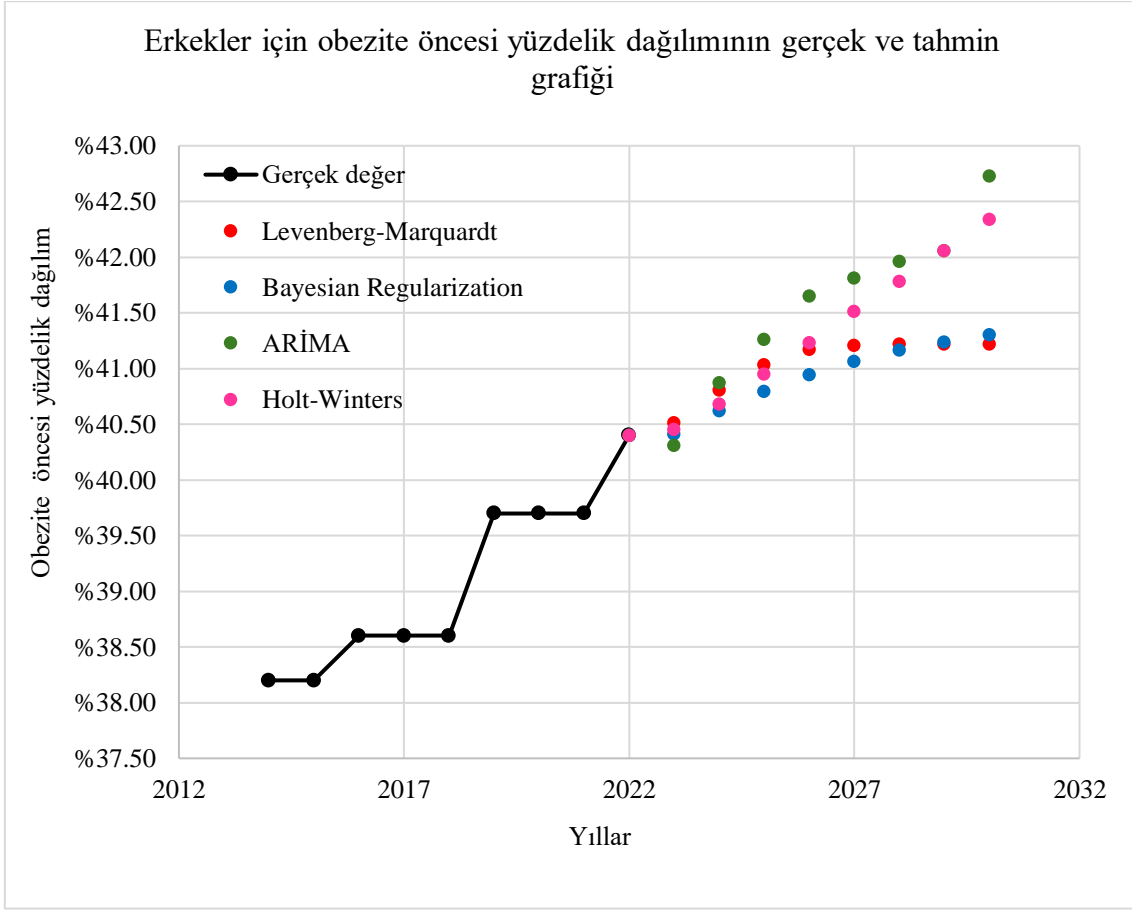
Modeller/Ölçütler	MSE	RMSE	SSE	MAPE	R^2
LM	0,057	0,239	0,516	0,518	0,8994
BR	0,044	0,210	0,399	0,414	0,9223
ARIMA	0,449	0,670	4,040	0,460	0,9000
HW	0,082	0,287	0,741	0,554	0,8880

3.5. Türkiye’de obezite öncesi yüzdeler için yapılan tahminlerin kıyaslamalı analizi

Türkiye’nin cinsiyete göre obezite öncesi yüzdeler dağılımının 2023 ile 2030 yılları arasındaki tahminleri için LM, BR, ARIMA ve HW yöntemleri tercih edildi. Kadınlara göre 2022 yılından 2030 yılına kadar ki en fazla obezite öncesi yüzdeler tahmin veren yöntem LM algoritması iken erkeklerde en fazla obezite öncesi yüzdeler tahmini veren yöntem ARIMA oldu. 2022 yılından 2030 yılına kadar ki en az obezite öncesi yüzdeler tahmin veren yöntem kadınlarda BR algoritması olarak saptandı. Erkeklerde ise en az tahmin yapan yöntem LM olarak elde edildi. Şekil 9 ve Şekil 10’da kadınlar ile erkeklerin gerçek obezite öncesi yüzdeler dağılımları ile 2023-2030 yılları arasındaki tahminleri verilmiştir.



Şekil 9. Kadınlar için obezite öncesi yüzdeler dağılımının gerçek ve tahmin değer grafiği.



Şekil 10. Erkekler için obezite öncesi yüzdeler dağılımının gerçek ve tahmin değer grafiği.

4. Sonuçlar

Obezite, son yıllarda aşırı kilo oranlarındaki önemli artış nedeniyle Türkiye'de halk sağlığı açısından giderek artan bir endişe kaynağı haline gelmiştir. Bu sorunun eğitim, farkındalık ve politika değişikliklerini içeren dengeli bir yaklaşımla ele alınması önemlidir. Bu eğilimle mücadele etmek için bireysel, toplumsal ve politik düzeylerde önlemler alınmalıdır. Sağlık kurumları, hükümet, eğitim kurumları ve sivil toplum kuruluşları arasında iş birliği ve koordinasyon yoluyla obeziteyle mücadele için etkili stratejiler geliştirilmelidir.

Çalışmada kullanılan YSA ve ARIMA, yüksek doğruluk ve esneklikleri ile dikkat çekmektedir. YSA'nın veri örüntülerini tanıma ve karmaşık ilişkileri modelleme kapasitesi, tahmin doğruluğunu artırmıştır. Zaman serisi modelleri ise trend analizi ve öngöründe güvenilir sonuçlar sunmuştur. Tahminlere göre, Türkiye'de cinsiyete göre obezite öncesi yüzdeler dağılımının 2030 yılında kadınlarda LM modeline göre %32,79, erkeklerde ise ARIMA modeline göre %42,73 olacağı bulunmuştur.

Ancak, çalışmanın bazı sınırlamaları bulunmaktadır. Veri eksiklikleri, modellerin varsayımlarındaki kısıtlamalar ve kullanılan veri setlerinin sınırlı kapsamı, sonuçların

genellenebilirliğini etkileyebilir. Veri eksiklikleri, tahminlerin doğruluğunu sınırlayan önemli bir faktördür. Ayrıca, model varsayımları, gerçek dünyadaki karmaşık etkileşimleri tam olarak yansıtamayabilir.

Bu sonuçlara göre obeziteyle mücadele için alınacak önlemler arasında sağlıklı beslenme alışkanlıklarının teşvik edilmesi, düzenli fiziksel aktivitenin desteklenmesi, beslenme ve yaşam tarzı konusunda farkındalığın artırılması, okul kantinlerinde sağlıklı seçeneklerin sunulması ve reklamlar yoluyla besin değeri düşük ürünlerin tüketiminin azaltılması yer almalıdır.

Sonuç olarak, obezitenin önlenmesi ve kontrol altına alınması için toplumsal bir çaba gerekmektedir. Sağlık hizmetlerinin yanı sıra eğitim, çevresel değişiklikler ve politika düzenlemeleri gibi alanlarda etkili müdahaleler yapılmalıdır. Ancak bu zorluğun üstesinden gelmek için toplumun tüm kesimlerinin katılımı ve desteği önemlidir. Obezite ile mücadelede ortak bir vizyon ve kararlılıkla Türkiye'de obez birey sayısı azaltılabilir ve toplum sağlığında olumlu bir değişim yaşanabilir.

Yazarların Katkısı

Tüm yazarlar çalışmaya eşit katkıda bulunmuştur.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

Kaynaklar

- al-Swaidani, A. M., & al-Hajeh, T. (2023). Estimation of GPA at Undergraduate Level using MLR and ANN at Arab International University During the Syrian Crisis: A Case Study. *Open Education Studies*, 5(1), 20220197.
- Baer, D. J., Dalton, M., Blundell, J., Finlayson, G., & Hu, F. B. (2023). Nuts, energy balance and body weight. *Nutrients*, 15(5), 1162.
- Benli, M., Acar, Y., & Bas, S. (2024). Testing obesity Kuznets curve for Türkiye. *Obesity Medicine*, 100537.
- Burden, F., & Winkler, D. (2009). Bayesian regularization of neural networks. *Artificial neural networks: methods and applications*, 23-42.
- Busebee, B., Ghush, W., Cifuentes, L., & Acosta, A. (2023). *Obesity: A review of pathophysiology and classification*. Paper presented at the Mayo Clinic Proceedings.

- Celik, Y., Guney, S., & Dengiz, B. (2021). *Obesity level estimation based on machine learning methods and artificial neural networks*. Paper presented at the 2021 44th International Conference on Telecommunications and Signal Processing (TSP).
- Conejo, A. J., Plazas, M. A., Espinola, R., & Molina, A. B. (2005). Day-ahead electricity price forecasting using the wavelet transform and ARIMA models. *IEEE transactions on power systems*, 20(2), 1035-1042.
- Çolak, H., Kale, R., & Cihan, H. (2003). Yoğunlaştırılmış Yürüyüş ve Jogging Programının Yüksek Dansiteli Lipoproteinler (HDL) ve Düşük Dansiteli Lipoproteinler (LDL) Üzerine Olan Etkisi. *Spormetre Beden Eğitimi ve Spor Bilimleri Dergisi*, 1(1), 69-76.
- Çolak, H., & Şenol, H. *Türkiye'nin Lisanslı Sporcu Sayısının Yapay Sinir Ağları ile 2030 Yılına Kadar Tahmini: Spor Bilimleri Alanında Akademik Değerlendirmeler-7* (2023).
- da Costa, N. L., de Lima, M. D., & Barbosa, R. (2021). Evaluation of feature selection methods based on artificial neural network weights. *Expert Systems with Applications*, 168, 114312.
- Danacı, Ç., Derya, A., & Tuncer, S. A. (2023). Komşuluk Bileşen Analizi Tabanlı Makine Öğrenimi Yöntemleri ile Obezite Seviyelerinin Tahmini. *Fırat Üniversitesi Mühendislik Bilimleri Dergisi*, 35(2), 433-442.
- Eisbach, S., Mai, O., & Hertel, G. (2024). Combining theoretical modelling and machine learning approaches: The case of teamwork effects on individual effort expenditure. *New Ideas in Psychology*, 73, 101077.
- Elagizi, A., Kachur, S., Carbone, S., Lavie, C. J., & Blair, S. N. (2020). A review of obesity, physical activity, and cardiovascular disease. *Current obesity reports*, 9, 571-581.
- Henriques, I., & Sadorsky, P. (2023). Forecasting rare earth stock prices with machine learning. *Resources Policy*, 86, 104248.
- Jani, D., Mishra, M., & Sahoo, P. K. (2017). Application of artificial neural network for predicting performance of solid desiccant cooling systems—A review. *Renewable and Sustainable Energy Reviews*, 80, 352-366.
- Janssen, I., Katzmarzyk, P. T., Srinivasan, S. R., Chen, W., Malina, R. M., Bouchard, C., & Berenson, G. S. (2005). Combined influence of body mass index and waist circumference on coronary artery disease risk factors among children and adolescents. *Pediatrics*, 115(6), 1623-1630.
- Jiang, L.-y., Tian, J., Yang, Y.-n., Jia, S.-h., & Shu, Q. (2024). Acupuncture for obesity and related diseases: insight for regulating neural circuit. *Journal of Integrative Medicine*.
- Krejić, N., Malaspina, G., & Swaenen, L. (2023). A split Levenberg-Marquardt method for large-scale sparse problems. *Computational Optimization and Applications*, 85(1), 147-179.
- Li, S., & Li, R. (2017). Comparison of forecasting energy consumption in Shandong, China Using the ARIMA model, GM model, and ARIMA-GM model. *Sustainability*, 9(7), 1181.
- Marcos, F. L., & Plangklang, B. (2024). A high accurate user-friendly energy audit platform of a university building using ANN Bayesian regularization and Levenberg-Marquardt algorithm. *Energy Reports*, 11, 2220-2235.
- Martínez, J. (2024). Levenberg-marquardt revisited and parameter tuning of river regression models. *Computational and Applied Mathematics*, 43(1), 14.
- Ozcan, İ., Tasar, B., Tatar, A. B., & Yakut, O. (2019). Destek vektör makinasi algoritması ile kalp hastalıklarının tahmini. *Computer Science*, 4(2), 74-79.
- Pauchet-Traversat, A.-F., Berrebi, S., Brugère, S., Cancel, A., Communal, D., Constantin, A., . . . Gauthier, C. (2023). Surpoids et obésité de l'adulte: 14 messages clés pour améliorer les pratiques: Overweight and obesity in adults: 14 key messages to improve practices. *Nutrition Clinique et Métabolisme*, 37(2), 2S58-52S61.
- Pekkurnaz, D. (2023). Causal effect of obesity on the probability of employment in women in Turkey. *Economics & Human Biology*, 51, 101301.
- Pleños, M. (2022). Time series forecasting using holt-winters exponential smoothing: Application to abaca fiber data. *Zeszyty Naukowe SGGW w Warszawie-Problemy Rolnictwa Światowego*, 22(2), 17-29.
- Pomponi, J., Scardapane, S., & Uncini, A. (2021). Bayesian neural networks with maximum mean discrepancy regularization. *Neurocomputing*, 453, 428-437.
- Rashidi, M. H., Keshavarz, S., Pazari, P., Safahieh, N., & Samimi, A. (2022). Modeling the accuracy of traffic crash prediction models. *IATSS research*, 46(3), 345-352.
- Ross, R., & Bradshaw, A. J. (2009). The future of obesity reduction: beyond weight loss. *Nature Reviews Endocrinology*, 5(6), 319-325.
- Rumbe, G., Hamasha, M., & Al Mashaqbeh, S. (2024). A comparison of Holts-Winter and Artificial Neural Network approach in forecasting: A case study for tent manufacturing industry. *Results in Engineering*, 21, 101899.

- Salih, S. O., Bezenchek, A., Moramarco, S., De Iuliis, M., Stanev, D., Fanti, I., . . . Gialloreti, L. E. (2022). Forecasting causes of death in Northern Iraq using neural network. *Journal of Statistical Theory and Applications*, 21(2), 58-77.
- Sarwar, S., Aziz, G., & Tiwari, A. K. (2023). Implication of machine learning techniques to forecast the electricity price and carbon emission: Evidence from a hot region. *Geoscience Frontiers*, 101647.
- Sözmen, K., Unal, B., Capewell, S., Critchley, J., & O'Flaherty, M. (2015). Estimating diabetes prevalence in Turkey in 2025 with and without possible interventions to reduce obesity and smoking prevalence, using a modelling approach. *International journal of public health*, 60, 13-21.
- Şenol, H. (2021). Methane yield prediction of ultrasonic pretreated sewage sludge by means of an artificial neural network. *Energy*, 215, 119173.
- Şenol, H., Çakır, İ. T., Bianco, F., & Görgün, E. (2024). Improved methane production from ultrasonically-pretreated secondary sedimentation tank sludge and new model proposal: Time series (ARIMA). *Bioresource technology*, 391, 129866.
- Şenol, H., Dereli, M. A., & Özbilgin, F. (2021). Investigation of the distribution of bovine manure-based biomethane potential using an artificial neural network in Turkey to 2030. *Renewable and Sustainable Energy Reviews*, 149, 111338.
- Tarmanini, C., Sarma, N., Gezeşin, C., & Ozgonenel, O. (2023). Short term load forecasting based on ARIMA and ANN approaches. *Energy Reports*, 9, 550-557.
- Türkiye İstatistik Kurumu (TÜİK) (2024). Retrieved from www.tuik.gov.tr
- Wang, W., He, N., Chen, M., & Jia, P. (2024). Freight Rate Index Forecasting with Prophet Model based on Multi-dimensional Significant Events. *Expert Systems with Applications*, 123451.
- Wei, C., Liu, L., Liu, R., Dai, W., Cui, W., & Li, D. (2022). Association between the phytochemical index and overweight/obesity: a meta-analysis. *Nutrients*, 14(7), 1429.
- World Health Organization Obesity and Overweight. (2011). Retrieved from <https://www.who.int/>
- Zhang, G., Patuwo, B. E., & Hu, M. Y. (1998). Forecasting with artificial neural networks:: The state of the art. *International journal of forecasting*, 14(1), 35-62.