

GENETİK ALGORİTMA İLE EĞİTİLMİŞ DESTEK VEKTÖR REGRESYON KULLANILARAK TÜRKİYE’NİN ELEKTRİK TÜKETİM TAHMİNİ

Doç. Dr. Oğuz KAYNAR*
Yrd. Doç. Dr. A. Gürkan YÜKSEK**
Arş. Gör. Ferhan DEMİRKOPARAN***

ÖZET

Enerji, gelişmekte olan ve endüstrileşen ülkeler için ekonomik kalkınmanın sürdürülebilmesi açısından çok önemli bir faktördür. Elektrik enerjisi de endüstrileşme ve yaşam standardının yükseltilmesi için en önemli enerji formlarından biridir. Enerji bakımından dışa bağımlı bir ülke olan Türkiye’de elektrik tüketiminin modellenmesi ve tahmin edilmesi ayrı bir öneme sahiptir. Bu çalışmada destek vektör regresyon yöntemiyle Türkiye’nin 1975-2014 yılları arası elektrik tüketimi, nüfusu, ithalat, ihracat ve GSYH verileri kullanılarak bir tahmin uygulaması yapılmıştır. DVR parametrelerinin seçiminde genetik algoritma yardımıyla yöntem performansı önemli ölçüde artırılmıştır.

Anahtar Kelimeler: Elektrik tüketimi, Destek vektör regresyon, Genetik algoritma, Tahmin

FORECASTING OF TURKEY’S ELECTRICITY CONSUMPTION USING SUPPORT VECTOR REGRESSION TRAINED WITH GENETIC ALGORITHM

ABSTRACT

Energy is a very important factor in terms of sustaining the economic development for developing and industrialized countries. Electricity is one of the most important forms of energy for industrialization and improvement of living standards. The estimation and modeling of electricity consumption has a special importance in Turkey which is a foreign-dependent country in energy. In this study a forecasting application is made by using Turkey’s electricity consumption, population, import, export and gross domestic product between 1975-2014, employing support vector regression method. By using genetic algorithm to choose the parameters of SVR, the method outperforms significantly.

Keywords: Electricity consumption, Support Vector Regression, Genetic Algorithm, Prediction

* Cumhuriyet Üniversitesi, İİBF, Yönetim Bilişim Sistemleri Bölümü, okaynar@cumhuriyet.edu.tr

** Cumhuriyet Üniversitesi, Müh. Fakültesi, Bilgisayar Mühendisliği Bölümü, agyuksekc@cumhuriyet.edu.tr

*** Cumhuriyet Üniversitesi, İİBF, Yönetim Bilişim Sistemleri Bölümü, fdemirkoparan@cumhuriyet.edu.tr

1. GİRİŞ

Enerji geliřmekte olan ve endüstrileřen ölkeler için ekonomik kalkınmanın sürdürülebilmesi açısından çok önemli bir faktördür. Dünya çapında enerji tüketimi; nüfus artışı, geniş ölçekli endüstrileřmeye verilen önem ve pozitif yöndeki ekonomik büyüme oranlarını sürdürmek gibi nedenlerden dolayı hızla artmaktadır (Bianco vd., 2009). Artan enerji fiyatları, küresel ısınma ve iklim deęişiklikleri, dünya çapında enerji talebindeki artış, hızla tükenen fosil yakıtlara bağımlılık ve artan enerji talebini ticari olarak karşılayacak yeni enerji teknolojilerinin yetersizlięi ölkelerin enerji arz güvenlięi ile ilgili endiře etmesine neden olmaktadır (Küçükali ve Barıř, 2010). Enerji tüketiminin doęru bir şekilde tahmin edilmesi sermaye yatırımlarını, çevre kalitesini, gelir analizini ve pazar araştırma yönetimini etkilerken aynı zamanda arz güvenlięini korumakta ve enerji politikalarının etkin bir şekilde uygulanmasına yardımcı olmaktadır (Economou, 2010).

Enerji, bir ekonomideki talep ve arz üzerinde oldukça etkin rol oynamaktadır. Talep yönünden enerji, tüketicilerin faydalarını maksimize etmeleri için satın aldıkları bir üründür. Arz yönünden ise emek ve sermaye gibi oldukça önemli bir üretim faktörüdür. Ayrıca çoęu üretim ve tüketim faaliyetlerinde temel bir girdi olduęu için ekonomik büyüme ve kalkınmanın gerçekteşmesinde belirleyici bir rolü vardır (Türedi ve Berber, 2007).

Elektrik enerjisi de endüstrileřme ve yaşam standardının yükseltilmesi için en önemli enerji formlarından biridir. Enerjiye paralel olarak dünya çapında elektrik enerjisine olan bağımlılık da giderek artmaktadır. IEA (International Energy Agency)'ya göre orta vadede elektrięin dünyanın toplam enerji talebindeki oranı artacak ve dünyada nihai kullanıcıya yönelik en hızlı büyüyen enerji formu olacaktır (Küçükali ve Barıř, 2010). Ayrıca biliřim ve iletişim teknolojilerinde yaşanan geliřmeler ışığında dijital toplum olma yolunda ilerleyen ölkeler için elektrik, en temel enerji kaynaęı olarak görölmekte ve bilimsel geliřmelerde hayati bir rol oynamaktadır. Türkiye'de elektrik tüketimi de enerji tüketimine paralel olarak hızla artmaktadır. Enerji bakımından dıřa bağımlı bir ölkeler olan Türkiye'deki kararsız ekonominin iç ve dıř politik, ekonomik ve pazar geliřmelerine karşı aşırı hassas yapısına baęlı olarak elektrik tüketiminin kaotik ve doęrusal olmayan bir trend izledięi görölmektedir (Akay ve

Atak, 2007). Bu nedenle Türkiye’de elektrik tüketiminin modellenmesi ve tahmin edilmesi ayrı bir öneme sahiptir.

Literatürde elektrik tüketiminin tahmin edildiği çok sayıda çalışma bulunmaktadır. Gürbüz vd. klasik ve meta-sezgisel tabanlı yapay sinir ağları kullanarak nüfus, GSMH, ithalat ve ihracat gibi ekonomik göstergelerle Türkiye’nin elektrik tüketimini üç farklı senaryo ile tahmin etmişlerdir (Gürbüz vd., 2013). Akay ve Atak Türkiye’nin endüstriyel ve toplam elektrik tüketimini tahmin etmek için çekme mekanizmalı gri tahmin metodunu (GPRM) önermişlerdir (Akay ve Atak, 2007). Hamzaçebi YSA yöntemini kullanarak yaptığı çalışmada Türkiye’nin 2005-2020 yılları arası elektrik tüketimini sektörel bazda tahmin etmiş ve sonuçları Enerji ve Tabii Kaynaklar Bakanlığı’nın kullandığı MAED yöntemi ile karşılaştırmıştır (Hamzaçebi, 2007). Sözen ve Arcaklıoğlu Türkiye’nin net enerji tüketimini tahmin etmek için GSMH, GSYH ve nüfus artışı gibi göstergeleri kullanarak üç farklı YSA modeli oluşturmuşlardır (Sözen ve Arcaklıoğlu, 2007). Toksarı çalışmasında Türkiye’nin enerji talebini tahmin etmek için nüfus, GSYH, ithalat ve ihracat verilerinden yararlandığı bir karınca koloni algoritması sunmuştur (Toksarı, 2007). Kavaklıoğlu vd. Türkiye’deki elektrik tüketimini nüfus, GSYH, ithalat ve ihracat gibi ekonomik göstergelerin bir fonksiyonu olarak modellemiş ve 1975-2007 yılları arası verileri kullanarak 2027 yılına kadar tahmin üretmişlerdir (Kavaklıoğlu vd., 2009). Küçükali ve Barış Türkiye’nin yıllık brüt elektrik talebinin kısa dönem tahminini yapmak için bulanık mantık yönteminden yararlanmışlardır (Küçükali ve Barış, 2010). Azadeh vd. İran tarım sektörünün elektrik tüketim tahminini yapmak için fiyat, katma değer ve müşteri sayısı gibi ekonomik göstergeleri kullanarak birleştirilmiş genetik algoritma (GA) ve yapay sinir ağı (YSA) yaklaşımı önermişlerdir. Sunulan yöntemi klasik zaman serisi yöntemleri ile karşılaştırarak iyi sonuçlar elde ettiklerini belirtmişlerdir (Azadeh vd., 2007). Azadeh vd. bir diğer çalışmalarında İran’ın aylık elektrik tüketimini tahmin etmek için YSA, bilgisayar simülasyonu ve deney tasarımı tabanlı bir yöntem kullanmışlardır (Azadeh vd., 2008). Ekonomou da yine YSA yöntemini kullanarak Yunanistan’ın uzun dönem enerji tüketimini tahmin etmiştir (Ekonomou, 2010). Tso ve Yau Hong Kong’un elektrik tüketim tahmini için klasik regresyon analizine ek olarak YSA ve karar ağaçları kullanarak üç farklı model oluşturmuşlardır. Kullanılan bu iki yöntemin regresyon analizine iyi bir alternatif olduğunu belirtmişlerdir (Tso ve Yau, 2007).

Bianco vd. çalışmalarında uzun dönem tahmin modeli oluşturmak için İtalya'da ekonomik ve demografik değişkenlerin yıllık elektrik tüketimi üzerindeki etkisini incelemişlerdir (Bianco vd., 2009).

Yapılan çalışmalarda tahmin modellerinde girdi olarak geçmiş elektrik tüketim değerleri kullanıldığı gibi nüfus, gayrisafi milli hâsıla, gayrisafi yurtiçi hâsıla, ithalat, ihracat, fiyat, katma değer, müşteri sayısı, CO2 emisyonu, kurulu kapasite, iklim faktörü, sıcaklık ve bağıl nem gibi ekonomik veya ekonomik olmayan göstergelerden de faydalanılmıştır.

Tahmin modelleri arasında son yıllarda Destek Vektör Regresyon (SVR) araştırmacıların yoğun ilgisini çekmektedir. Hu vd. elektrik yükü tahmini yaptıkları çalışmalarında SVR parametrelerini belirlemek için ateşböceği tabanlı memetik algoritma (FA-MA) önermişlerdir. Önerilen yöntem yalnızca iyi bilinen 4 evrimsel algortima ve 3 tahmin modeline göre daha doğru tahminler üretmekle kalmamış, literatürdeki hibrit algoritmalarından da daha iyi performans göstermiştir (Hu vd., 2013). Fan vd. de elektrik yükü tahmini için yeni bir yöntem önermişlerdir. Öncelikle giriş verisini danışmansız olarak kümeledikten sonra her alt kümenin eğitim verisini danışmanlı olarak uydurmak için SVR gruplarını kullanmışlardır (Fan vd., 2008). Hong da yine Tayvan'daki bölgesel elektrik yükünü tahmin ettiği çalışmasında SVR yöntemini kullanmış, SVR parametrelerini belirlemek için de bağıklık algoritmasından yararlanmış (Hong, 2009). Pai vd. çalışmalarında SVR parametrelerini genetik algoritma ile belirlemişlerdir (Pai vd., 2005). Bir diğer çalışmada Hong, SVR parametrelerini belirlemek için kaotik parçacık sürü algoritmasını (CPSO) kullanmış, genetik ve ısıl işlem algoritmalarını kullananlardan daha iyi sonuç aldığını belirtmiştir (Hong, 2009). Bir diğer çalışmada da SVR parametrelerinin belirlenmesinde kaotik karınca koloni algoritması kullanılmıştır (Hong, 2010). Wang vd. elektrik talep tahmininde mevsimsel etkiyi ortadan kaldırmak için giriş verisini düzleştirdikten sonra ϵ -SVR modelinde eğitim seti olarak kullanmış ve tahmin değerleri elde etmişlerdir. Önceden çıkardıkları mevsimsel etkiyi daha sonra göz önüne almış ve tahmin hatalarında hatırı sayılır düşüş olduğunu ifade etmişlerdir (Wang vd., 2009). Kavaklıoğlu çalışmasında Türkiye'nin elektrik tüketim tahminini yapmak için ϵ -SVR metodundan faydalanmıştır. Tüketim fonksiyonunu modellemek için nüfus, GNP, ithalat ve ihracat değişkenleri kullanılmıştır (Kavaklıoğlu, 2011). Türkiye elektrik tüketiminin tahmin edildiği bir diğer çalışmada yine SVR ile yapay sinir

ağları yöntemleri birlikte kullanılmıştır (Oğcu vd., 2012). Kavaklıoğlu yine Türkiye'nin yıllık elektrik tüketimin tahmin ettiği çalışmasında çok değişkenli regresyon yöntemini kullanmış, problemin boyutunu düşürmek ve tahminlerin sağlamlığını arttırmak için tekil değer ayrışması (SVD) metodundan faydalanmıştır (Kavaklıoğlu, 2014).

İyi bir enerji tahmini sadece kapasite genişletme planlamasında düşük maliyetli yatırım yapabilmek için değil aynı zamanda çevresel sorunların izlenmesi, vergilerin ayarlanması ve talep yönetim planlaması yapmak için de önemli ve gereklidir (Akay ve Atak, 2007). Düşük tahminler hayatı ve ekonomiyi felç eden kesintilere yol açarken yüksek tahminler de finansal kaynak israfı anlamına gelen gereksiz ve boşa harcanan kapasite demektir. Ayrıca sağlıklı bir model oluşturabilmek için çıkış değişkenini etkileyen bütün olası değişkenler modele dahil edilmelidir (Kavaklıoğlu vd., 2009). Bazı ekonomik göstergeler ile elektrik tüketimi arasındaki korelasyon ve nedensellik ilişkileri göz önüne alındığında literatürde çok sayıda çalışma olduğu görülür (Abosedra vd., 2009; Altınay ve Karagöl, 2005; Chen vd., 2007; Narayan ve Smyth, 2009; Pao, 2009; Yang, 2000; Yoo, 2006). Bu göstergelerden başlıcaları gayrisafi yurtiçi hasıla ve ekonomik büyümedir.

Elektrik tüketimi ile GSYH arasındaki nedensellik ilişkisini inceleyen çalışmalar, sonuçları bakımından oldukça çeşitlilik göstermektedir. Elde edilen sonuçların çeşitliliği, kullanılan metot, kullanılan veri, incelenen ülkenin gelişmiş veya gelişmekte olan ülke olması, farklı ülkelerin farklı karakteristiklere, örneğin farklı yerel enerji kaynaklarına, farklı siyasi düzenlemelere, farklı kültürlere ve farklı enerji politikalarına sahip olması, elektrik tüketimi kullanım paylarının farklı olması gibi etkenlerden kaynaklanabilmektedir (Abosedra vd., 2009; Chen vd., 2007). Bununla birlikte elektrik tüketimi ile GSYH ve dolayısıyla ekonomik büyüme arasında güçlü bir ilişkinin olduğu bir gerçektir. Elektrik enerjisinin üretim için temel girdi konumunda olduğu düşünülürse GSYH'daki artış elektrik ihtiyacında da artışa neden olur çünkü yapı, imalat ve nakliye gibi endüstriyel sektörlerdeki üretim aktiviteleri yeterli seviyede elektrik kaynağı gerektirir (Chen vd., 2007). Bu nedenle elektrik tüketimi altyapısının kısıtlı olması ekonomik büyümenin önüne geçebilecek bir etken sayılabilir. Elektrik tüketimi sadece ekonomik servetle yakın ilişki içinde olmakla kalmayıp sosyoekonomik kalkınmanın da bir göstergesidir (Altınay ve Karagöl, 2005).

Türkiye Avrupa'nın en büyük ülkelerinden biridir. Yıllık nüfus artışı da %1,6 ile IEA ülkeleri arasında en yüksek orana sahiptir (Sözen ve Arcaklıođlu, 2007). Ekonomik büyüme ve hızlı nüfus artışı ile birlikte enerji talebinde yıldan yıla artış olması ve bu talebin artarak devam etmesi beklenmektedir.

İhracat ve elektrik tüketimi arasındaki nedensellik ilişkisi incelendiğinde eđer elektrik tüketiminden ihracata doğru tek yönlü ilişki varsa elektrik tüketiminin azaltılması farklı alanlara ayrılmış ihracat sektörünün gelişimini engelleyecektir. Diğer yandan eđer ihracattan elektrik tüketimine doğru tek yönlü ilişki varsa veya iki yönde de ilişki yoksa enerji tasarrufu politikalarının ihracatın büyümesi üzerinde olumsuz etki yaratması beklenemez demektir (Narayan ve Smyth, 2009). Türkiye'de enerji kaynaklarının yetersiz olmasından dolayı Türkiye elektrik üretimi için ithal fosil yakıtlara bağımlıdır. Türkiye'de enerji ihtiyacının %60'ı ithal edilerek karşılanmakta ve enerjinin ithalattaki payı her sene artmaktadır (Sözen ve Arcaklıođlu, 2007).

Yapılan çalışmalarda elektrik tüketimi ile GSYH, nüfus, ithalat ve ihracat gibi ekonomik göstergelerin yakından ilişkili olduğu görülmektedir. Bu ilişki göz önüne alınarak bu çalışmada Türkiye'nin 1975-2014 yılları arası elektrik tüketimi, nüfusu, ithalat, ihracat ve GSYH verileri kullanılarak bir tahmin uygulaması yapılmıştır.

2. METODOLOJİ

2.1. Destek Vektör Regresyon

İlk olarak Vapnik (Vapnik, 1995) tarafından ortaya atılan destek vektör regresyon, son yıllarda istatistiksel öğrenme teorisindeki gelişmelere dayanan, veri sınıflandırma ve regresyon için kullanılan güçlü bir makine öğrenmesi tekniğidir. Bir fonksiyonu, genelleştirme hatasının üst sınırını minimize ederek tahmin eden risk minimizasyon prensibi üzerine kurulu olan DVR'nin aşırı öğrenme problemine karşı oldukça dirençli olduğu ve çeşitli zaman serilerinin tahmin problemlerini çözerken eninde sonunda yüksek bir genelleştirme performansı sergilediği gösterilmiştir (Fan vd., 2008). Hataları empirik risk minimizasyonu prensibi ile minimize eden

yapay sinir ağlarının lokal minimuma takılma gibi bazı dezavantajlarını bertaraf eden bir yöntemdir.

DVR'nin çalışma prensibi veriyi daha büyük boyutlu bir özellik uzayına haritalamaktır. DVR'nin öğrenme kabiliyeti özellik uzayının boyutundan bağımsızdır ve bu nedenle iyi performans gösterir (Oğcu vd., 2012).

Verilen bir veri seti için $G = \{(x_i, d_i)\}_{i=1}^N$, x_i giriş vektörü, d_i gerçek değer ve N de toplam veri sayısı olsun. Bu durumda DVR fonksiyonu:

$$y = f(x) = w\psi(x) + b \quad (1)$$

Burada $w\psi(x)$, nonlinear giriş uzayı x 'ten haritalanan özelliktir. Bu yöntemde giriş uzayından özellik uzayına nonlinear kernel fonksiyonların ($\psi(x)$) kullanılmasına izin verilir. w ve b ise ayarlanmış risk fonksiyonunun minimize edilmesi ile tahmin edilen katsayılardır. DVR yöntemi modelin genelleştirme performansının iyi olmasını ve w 'nin mümkün olduğunca düz olmasını ister. Bu yüzden w vektörünün ($\|\cdot\|$) normu her veri noktası için minimize edilmelidir.

$$R(C) = (C/N) \sum_{i=1}^N L_\varepsilon(d_i, y_i) + \frac{\|w\|^2}{2} \quad (2)$$

$$L_\varepsilon(d, y) = \begin{cases} 0, & |d - y| \leq \varepsilon \\ |d - y| - \varepsilon, & \text{aksihalde} \end{cases} \quad (3)$$

Burada C ve ε saptanmış parametrelerdir. $L_\varepsilon(d, y)$, ε -duyarsız kayıp fonksiyonudur. Eğer tahmin edilen değer ε -tüpünde ise kayıp 0 olacaktır. 3. denklemdaki ikinci terim $\frac{\|w\|^2}{2}$, fonksiyonun düzlüğünü hesaplar. C ise empirik risk ile modelin düzlüğü arasındaki ödünleşimi belirler. C ve ε kullanıcının belirlediği parametrelerdir. Bir de gerçek değerle ε tüpünde karşılık gelen sınır değerleri arasındaki uzaklığı ifade eden yapay değişkenler ξ ve ξ^* vardır. Bu durumda 2. Eşitlik şu hale döner:

Aşağıdaki eşitliği;

$$R(w, \xi, \xi^*) = \frac{\|w\|^2}{2} + C \left(\sum_{i=1}^N (\xi_i + \xi_i^*) \right) \quad (4)$$

şu kısıtlarla minimize et;

$$\begin{aligned} w\psi(x_i) + b_i - d_i &\leq \varepsilon + \xi_i^* \\ d_i - w\psi(x_i) &\leq \varepsilon + \xi_i, \quad i=1, 2, \dots, N \\ \xi_i, \xi_i^* &\geq 0 \end{aligned} \quad (5)$$

C parametresi w vektörünün düzlüğü ile ε 'dan büyük hataların cezalandırılması arasındaki dengeyi sağlar. Artık yapılacak iş maliyet fonksiyonunu minimize eden w ve b parametrelerini tahmin etmektir. Kısıtlı optimizasyon problemi temel Lagrangian form ile çözülür:

$$\begin{aligned} L(w, b, \xi, \xi^*, \alpha_i, \alpha_i^*, \beta_i, \beta_i^*) &= \frac{1}{2} \|w\|^2 + C \left(\sum_{i=1}^N (\xi_i + \xi_i^*) \right) - \sum_{i=1}^N \beta_i [w\psi(x_i) + b - d_i + \varepsilon + \xi_i] \\ &- \sum_{i=1}^N \beta_i^* [d_i - w\psi(x_i) - b + \varepsilon + \xi_i^*] - \sum_{i=1}^N (\alpha_i \xi_i + \alpha_i^* \xi_i^*) \end{aligned} \quad (6)$$

Bu eşitlik temel değişkenler w, b, ζ ve ζ^* 'a göre minimize; negatif olmayan Lagrange çarpan değişkenleri α_i , α_i^* , β_i ve β_i^* 'a göre maksimize edilir. Minimumu bulmak için fonksiyonun ayrı ayrı w, b, ζ ve ζ^* 'a göre türevlerinin alınıp 0'a eşitlenmesi gerekir. Son olarak Karush-Kuhn-Tucker şartları regresyona uygulanır. Daha sonra Kernel fonksiyonu iken $K(x_i, x_j) = \psi(x_i)\psi(x_j)$ dual Lagrangian elde edilir:

$$\mathcal{D}(\beta_i, \beta_i^*) = \sum_{i=1}^N d_i (\beta_i - \beta_i^*) - \varepsilon \sum_{i=1}^N (\beta_i + \beta_i^*) - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N (\beta_i - \beta_i^*) (\beta_j - \beta_j^*) K(x_i, x_j) \quad (7)$$

Aşağıdaki kısıtlarla:

$$\begin{aligned} \sum_{i=1}^N (\beta_i - \beta_i^*) &= 0 \\ 0 \leq \beta_i &\leq C, \quad i=1, 2, \dots, N \\ 0 \leq \beta_i^* &\leq C \end{aligned} \quad (8)$$

6. denklemde Lagrange çarpanları $\beta_i * \beta_i^* = 0$ eşitliğini sağlar. Lagrange çarpanları, β_i ve β_i^* hesaplanır ve regresyon hiper düzleminin istenilen optimal ağırlık vektörü aşağıdaki gibidir:

$$w^* = \sum_{i=1}^N (\beta_i - \beta_i^*) \psi(x) \quad (9)$$

Yani regresyon fonksiyonu da şu şekildedir:

$$f(x, \beta, \beta^*) = \sum_{i=1}^{\ell} (\beta_i - \beta_i^*) K(x, x_i) + b \quad (10)$$

Burada $K(x, x_i)$ kernel fonksiyonudur. Kernel değeri; $\psi(x)$ ve $\psi(x_i)$ özellik uzayındaki x ve x_i vektörlerinin iç çarpımlarına eşittir. Genellikle kernel fonksiyonunun en yaygın üç örneği vardır. Polinomial kernel fonksiyonu:

$$K(x_i, x) = (a_1 x_i^T x + a_2)^d \quad (11)$$

Burada d dereceyi, a_1 ve a_2 katsayıları ifade eder. Çok katmanlı algılayıcı kernel fonksiyonu:

$$K(x_i, x) = \tanh(x_i^T x - b) \quad (12)$$

Burada b sabit bir değerdir. Gaussian RBF kernel fonksiyonu:

$$K(x_i, x) = \exp(-\|x_i - x\| / 2\sigma^2) \quad (13)$$

DVR yönteminde en önemli nokta kullanıcının belirlemesi gereken parametrelerin yani ε hata, C sabiti ve σ Gaussian fonksiyonunun genişliğinin optimum şekilde ayarlanmasıdır. Bu üç parametrenin seçimi DVR modelinin performansını doğrudan etkilemektedir (Hong, 2009a). Eğer C değeri çok büyükse (sonsuzaya yaklaşıyorsa) amaç empirik riski minimize etmektir. Büyük ε değeri regresyon tahmin fonksiyonunun daha düz olmasına neden olur. σ parametresi Gaussian fonksiyonunun genişliğini kontrol eder yani bu da eğitim verisindeki x değerlerinin dağılım aralığını yansıtır. Sonuç olarak 3 parametre de farklı yollarla model yapısını etkiler.

C ve ϵ parametresinin seçimi için önerilmiş çok sayıda yöntem mevcuttur. Bunlardan birkaçı, kullanıcı deneyimi ve bilgisine göre seçme, çapraz doğrulama, asimptotik optimizasyon ve çeşitli evrimsel optimizasyon algoritmalarıdır. Bu çalışmada DVR parametrelerinin seçiminde genetik algoritma yöntemi kullanılmıştır.

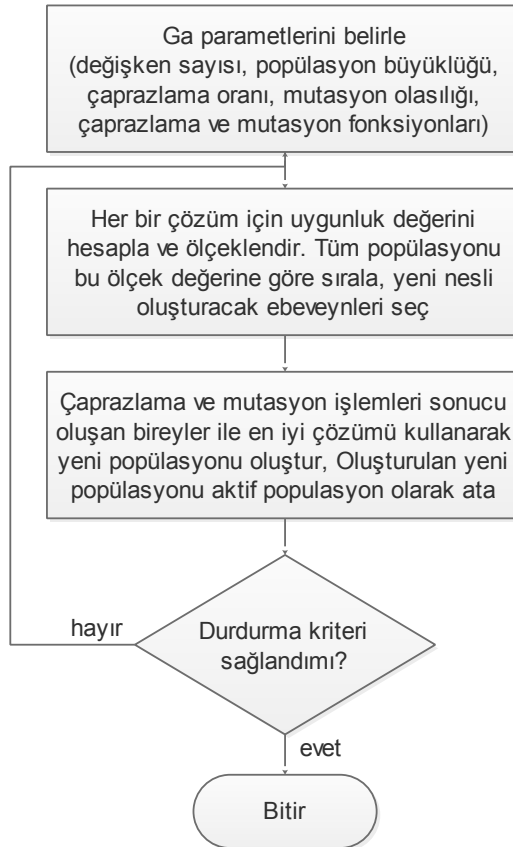
2.2. Genetik Algoritma

Genetik algoritma doğal seleksiyon, çaprazlama ve mutasyon tabanlı, biyolojiden ilham alan global arama optimizasyon tekniğidir (Holland, 1975). Bu yöntemde öncelikle aday çözümlerden oluşan bir popülasyon üretilir ve bu popülasyon belirlenen durdurma kriteri sağlanıncaya kadar seleksiyon, çaprazlama ve mutasyon adı verilen genetik işlemler aracılığı ile güncellenir.

Genetik algoritma (GA) doğal seleksiyon ve evrim teorisini baz alan bir yapay zeka sürecidir. GA daha iyi çözümleri kabul etme sürecinde en iyi olanın hayatta kalması fikrini kullanır. Tek bir çözümü kademeli olarak değiştirmektense bir çözüm popülasyonunu güncelleyerek arama yapması yönüyle geleneksel nanlineer optimizasyon tekniklerinden ayrılır. Klasik optimizasyon algoritmaları iterasyon noktalarının lokal özellikleri ile ilgilendiği için kolayca lokal ekstremum noktasına takılabilirler. Bunun aksine GA sistematik aramaya ek olarak rasgele arama operatörü de kullandığından dolayı lokal minimum veya maksimum noktasına takılması önlenmiş olur. GA'nın akış şeması Şekil 1'de gösterilmiştir. Algoritma optimize edilecek parametrelerin oluşturduğu başlangıç çözümüyle başlar. Problemin durumuna göre her bir parametre ikili bit string, real, ya da permutasyon sıralaması şeklinde kodlanabilir. Probleme ilişkin herhangi bir ip ucu olmadığı durumda başlangıç popülasyonu düzgün dağılmış N adet rastgele çözüm üretilerek oluşturulur. Daha sonra popülasyonda yer alan her bir çözüm için uygunluk (Fitness) değeri hesaplanarak kullanılan ölçek fonksiyonu yardımıyla sıralanır. Uygunluk değeriyle orantılı bir şekilde ebeveynler seçilerek çaprazlama ve mutasyon işlemleri yardımıyla yeni bireyler oluşturulur. Ebeveynlerin seçiminde tekerlek seçimi (roulette wheel selection), turnuva seçimi (tournament selection) yöntemleri kullanılabilir.

En iyi uygunluk değerine sahip çözüm ile çaprazlama ve mutasyon sonucunda oluşan bireyler yeni jenerasyondaki popülasyonu oluştururlar. Kaç tane en iyi çözümün yeni jenerasyona aktarılacağı elitist-count parametresiyle belirlenirken, yeni oluşacak bireylerin ne kadarının çaprazlama sonucunda ne kadarının mutasyon sonucunda üretileceği, çaprazlama oranı (crossover rate) parametresi ile belirlenir. Çaprazlama amacıyla dağınık, tek noktalı ve çok noktalı çaprazlama teknikleri kullanılabilir. Mutasyon işlemi genetik çeşitliği sağlamak amacıyla kromozomdaki her hangi bir gen değerinin belirli bir olasılık dâhilinde değiştirilmesini sağlamaktadır. Böylelikle algoritmanın, çözüm uzayının değişik bölgelerini de araştırarak yerel minimuma takılması engellenir.

Durdurma koşullarından birinin sağlanması durumunda algoritma son bulur. Maksimum iterasyon sayısına erişilmesi, hata toleransının belirtilen bir eşik değerin altında kalması, önceden belirlenen bir zaman aralığının aşılması ya da belirli denemeden sonra performansta bir iyileşme elde edilememesi gibi durumlar sonlandırma kriteri olarak kullanılabilir.



Şekil 1. Genetik algoritma akış şeması

3. UYGULAMA

Bu çalışmada Türkiye'nin 1974-2014 yılları arası yıllık elektrik tüketimi; gayri safi yurtiçi hâsıla, ithalat, ihracat ve nüfus değişkenleri kullanılarak modellenmiştir. Oluşturulan model ve DVR yöntemi kullanılarak bir tahmin uygulaması yapılmıştır. Mevcut verilerin %60'ı eğitim, %40'ı da test verisi olarak kullanılmıştır.

DVR yönteminde kullanıcı tarafından belirlenmesi gereken parametreler olan C cezalandırma, σ Gauss RBF fonksiyonunun genişliği ve ε hata değişkenlerinin optimum değerleri real kodlu genetik algoritma kullanılarak belirlenmiştir. Veriler, farklı ölçek etkilerini gidermek amacıyla öncelikle normalize edilmiştir. Çözüm uzayını sınırlandırmak amacıyla C parametresi; 1-1000 arasında, σ ; 0-1 ve ε parametresi ise 0-0.1 arasında sınırlandırılmıştır.

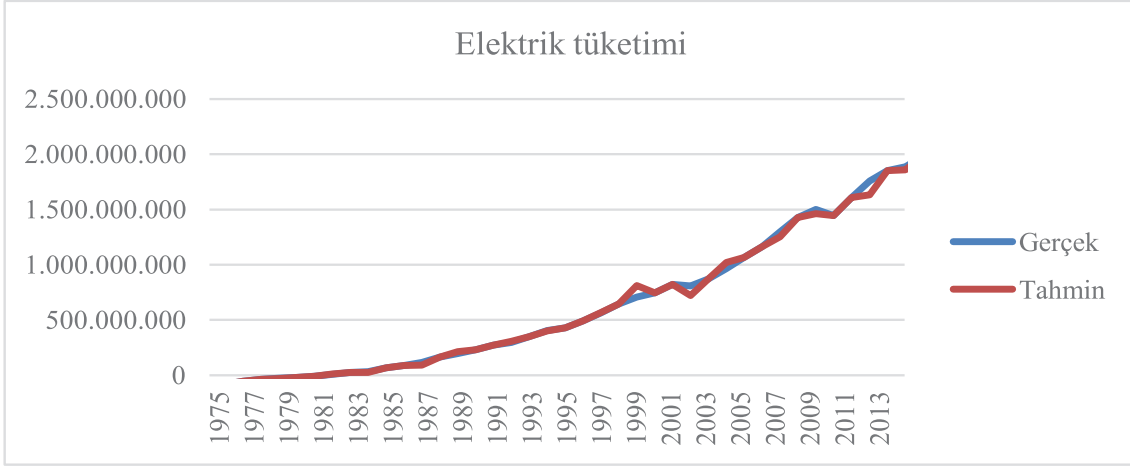
Popülasyon büyüklüğü 50, elit-count 1, çaprazlama oranı 0.7, maksimum iterasyon sayısı 100 olarak belirlenmiştir. Çaprazlama fonksiyonu olarak tek noktalı çaprazlama mutasyon içinse Gauss mutasyon fonksiyonu kullanılmıştır. Genetik algoritma sonucunda $C=103.94$, $\sigma =0.4026$ ve $\varepsilon=0.01$ olarak bulunmuştur. Oluşturulan modelde MAPE hata kriterine göre test verilerinin tahmin hatası % 3.66 modelin genel tahmin hatası da % 1.46 olarak ortaya çıkmaktadır.

Tablo 2 Oluşturulan modelin hata değerleri

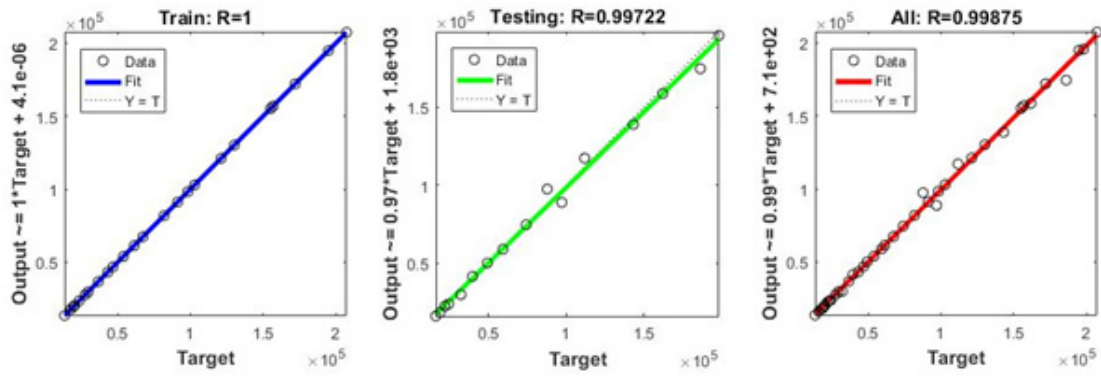
	Test Verisi	Tüm veriler
MAPE	% 3.66	% 1.46

Gerçek elektrik tüketimi ve elde edilen tahmin değerleri aşağıdaki şekilde görülmektedir

Şekil 3'te ise gerçek değerlere karşı tahmin değerleri verilmiştir.



Şekil 2. Gerçek elektrik tüketimi ve tahmin edilen değerler



Şekil 3 Eğitim, test ve tüm veriler için gerçek değerlere karşı tahmin değerleri grafiği

4. SONUÇ

Gelişmekte olan diğer ülkelerde olduğu gibi Türkiye’de de enerji, özellikle de elektrik enerjisi tüketiminin artan bir trend izlediği görülmektedir. Elektrik tüketimi özellikle Türkiye gibi enerji bakımından dışa bağımlı ve dış etkenlere karşı oldukça hassas olan bir ülke için pek çok ekonomik göstergeden etkilenebilmektedir. Bunlardan en önemlileri ithalat, ihracat, gayri safi yurtiçi hasıla ve nüfustur.

Bu çalışmada da adı geçen ekonomik parametreler kullanılarak Türkiye’nin yıllık elektrik tüketimi modellenmiştir. DVR kullanılarak yapılan tahmin uygulamasında elde edilen %3.66 hata performansı bu metodun başarılı bir tahmin yöntemi olduğunu ve sıkça kullanılan klasik regresyon ve yapay sinir ağları yöntemlerine alternatif olarak kullanılabileceğini göstermektedir.

KAYNAKÇA

- Abosedra, S., Dah, A., ve Ghosh, S. (2009) "Electricity consumption and economic growth, the case of Lebanon" *Applied Energy*, 86(4):429-432.
- Akay, D., ve Atak, M. (2007) "Grey prediction with rolling mechanism for electricity demand forecasting of Turkey" *Energy*, 32(9):1670-1675.
- Altınay, G., ve Karagöl, E. (2005) "Electricity consumption and economic growth: evidence from Turkey" *Energy Economics*, 27(6):849-856.
- Azadeh, A., ve Tarverdian, S. (2007) "Integration of genetic algorithm, computer simulation and design of experiments for forecasting electrical energy consumption" *Energy Policy*, 35(10):5229-5241.
- Azadeh, A., Ghaderi, S. F., Tarverdian, S., ve Saberi, M. (2007) "Integration of artificial neural networks and genetic algorithm to predict electrical energy consumption" *Applied Mathematics and Computation*, 186(2):1731-1741.
- Azadeh, A., Ghaderi, S. F., ve Sohrabkhani, S. (2008) "A simulated-based neural network algorithm for forecasting electrical energy consumption in Iran" *Energy Policy*, 36(7):2637-2644.
- Bianco, V., Manca, O., ve Nardini, S. (2009) "Electricity consumption forecasting in Italy using linear regression models" *Energy*, 34(9):1413-1421.
- Chen, S. T., Kuo, H. I., ve Chen, C. C. (2007) "The relationship between GDP and electricity consumption in 10 Asian countries" *Energy Policy*, 35(4):2611-2621.
- Ekonomou, L. (2010) "Greek long-term energy consumption prediction using artificial neural networks" *Energy*, 35(2):512-517.
- Fan, S., Chen, L., ve Lee, W. J. (2008) "Machine learning based switching model for electricity load forecasting" *Energy Conversion and Management*, 49(6):1331-1344.
- Gürbüz, F., Öztürk, C., ve Pardalos, P. (2013) "Prediction of electricity energy consumption of Turkey via artificial bee colony: a case study" *Energy Systems*, 4(3):289-300.

- Hamzaçebi, C. (2007) "Forecasting of Turkey's net electricity energy consumption on sectoral bases" *Energy Policy*, 35(3):2009-2016.
- Holland, J.H. (1975) *Adaption in Natural and Artificial Systems*, University of Michigan Pres, Ann Arbor, MI, 1975.
- Hong, W. C. (2009a) "Electric load forecasting by support vector model" *Applied Mathematical Modelling*, 33(5):2444-2454.
- Hong, W. C. (2009b) "Chaotic particle swarm optimization algorithm in a support vector regression electric load forecasting model" *Energy Conversion and Management*, 50(1):105-117.
- Hong, W. C. (2010) "Application of chaotic ant swarm optimization in electric load forecasting" *Energy Policy*, 38(10):5830-5839.
- Hu, Z., Bao, Y., ve Xiong, T. (2013) "Electricity load forecasting using support vector regression with memetic algorithms" *The Scientific World Journal*.
- Kavaklioglu, K., Ceylan, H., Ozturk, H. K., ve Canyurt, O. E. (2009) "Modeling and prediction of Turkey's electricity consumption using artificial neural networks" *Energy Conversion and Management*, 50(11):2719-2727.
- Kavaklioglu, K. (2011) "Modeling and prediction of Turkey's electricity consumption using Support Vector Regression" *Applied Energy*, 88(1):368-375.
- Kavaklioglu, K. (2014) "Robust electricity consumption modeling of Turkey using singular value decomposition" *International Journal of Electrical Power & Energy Systems*, 54:268-276.
- Kucukali, S., ve Baris, K. (2010) "Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach" *Energy Policy*, 38(5):2438-2445.
- Narayan, P. K., ve Smyth, R. (2009) "Multivariate Granger causality between electricity consumption, exports and GDP: evidence from a panel of Middle Eastern countries" *Energy Policy*, 37(1):229-236.
- Oğcu, G., Demirel, O. F., ve Zaim, S. (2012) "Forecasting electricity

- consumption with neural networks and support vector regression” *Procedia-Social and Behavioral Sciences*, 58:1576-1585.
- Pao, H. T. (2009) “Forecast of electricity consumption and economic growth in Taiwan by state space modeling” *Energy*, 34(11):1779-1791.
- Sözen, A., ve Arcakioğlu, E. (2007) “Prediction of net energy consumption based on economic indicators (GNP and GDP) in Turkey” *Energy policy*, 35(10):4981-4992.
- Toksarı, M. D. (2007) “Ant colony optimization approach to estimate energy demand of Turkey” *Energy Policy*, 35(8):3984-3990.
- Tso, G. K., ve Yau, K. K. (2007) “Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks” *Energy*, 32(9):1761-1768.
- Türedi S., Berber M. (2007) “Enerji Tüketimi ve Ekonomik Büyüme İlişkisi Uzun Dönem Analizi: Türkiye Örneği (1976-2005)”, İkinci Uluslararası İşletme ve Ekonomi Çalıştayı, Giresun, Türkiye.
- Vapnik, V. (1995) *The Nature of Statistic Learning Theory*, Springer-Verlag, New York, 1995.
- Wang, J., Zhu, W., Zhang, W., ve Sun, D. (2009) “A trend fixed on firstly and seasonal adjustment model combined with the ϵ -SVR for short-term forecasting of electricity demand” *Energy Policy*, 37(11):4901-4909.
- Yang, H. Y. (2000) “A note on the causal relationship between energy and GDP in Taiwan” *Energy economics*, 22(3):309-317.
- Yoo, S. H. (2006) “The causal relationship between electricity consumption and economic growth in the ASEAN countries” *Energy policy*, 34(18):3573-3582.