

Sıcaklık Verisi Olmadan Kısa Dönem Yük Tahmini İçin Yapay Zeka Tabanlı Melez Yapılar

Artificial Intelligence Based Hybrid Structures for Short-Term Load Forecasting Without Temperature Data

İdil IŞIKLI ESENER, Tolga YÜKSEL, Mehmet KURBAN

Elektrik-Elektronik Mühendisliği Bölümü, Mühendislik Fakültesi
Bilecik Şeyh Edebali Üniversitesi

idil.isikli@bilecik.edu.tr, tolga.yuksel@bilecik.edu.tr, mehmet.kurban@bilecik.edu.tr

Özet

Elektrik enerji sistem planlamasının ilk adımı olan yük tahmini, elektrik enerjisinin ekonomik üretim ve dağıtımının gerçekleştirilebilmesi ve elektrik enerji fiyatlandırması konularında büyük önem taşımaktadır. Bu çalışmada, sıcaklık verisi kullanmadan Türkiye geneli için 24 saatlik yük tahmini amaçlanmıştır. Bu amaçla, Yapay Sinir Ağları (YSA), Dalgacık Dönüşümü (DD) ve YSA, DD ve Radyal Tabanlı Fonksiyon Sinir Ağları (RTF SA), Görgül Kip Ayrışımı (GKA) ve RTF SA olmak üzere dört yapı oluşturulmuştur. Her bir yapı için tahmin hata yüzdeleri, ortalama günlük Ortalama Mutlak Yüzdelik Hata (MAPE), maksimum günlük MAPE olarak hesaplanmış ve tüm MAPE değerleri için yapılar arasında bir karşılaştırılma yapılmıştır.

Abstract

Load forecasting, as the first step of power system planning, is of great importance in economic electric power generation and distribution and energy pricing. In this study, Turkey's 24-hour-ahead load forecasting without meteorological data is aimed. For this purpose, four structures, Artificial Neural Networks (ANN), Wavelet Transform (WT) and ANN, WT and Radial Basis Function Neural Network (RBF NN), Empirical Mode Decomposition (EMD) and RBF NN are constructed. For each of the structures, forecast error percentages are computed as average daily Mean Absolute Percentage Error (MAPE) and maximum MAPE and all MAPE values are compared between the proposed structures.

1. Giriş

Güç Sistem planlamasının ilk adımı olan yük tahmini ile elektrik enerjisinin ekonomik üretim ve dağıtımının gerçekleştirilebilmesi ve elektrik enerji fiyatlandırması amaçlanmaktadır. Yük tahmini, yapıldığı zaman aralığına göre kısa dönem, orta dönem ve uzun dönem yük tahmini olmak üzere üçe ayrılmaktadır. Çalışmada ele alınan kısa dönem yük tahmini (KDYT) ile saatlik-günlük tahmin yapılmaya çalışılır ve güç santralleri arasında yük paylaşımı ve jeneratörlerin devreye girip çıkma zamanlarının belirlenmesi amaçlanır[1]. Yük tahmininde kullanılan yöntemler genel olarak analitik yöntemler ve yapay zekâ yöntemleri olarak

sınıflandırılmaktadır. Analitik yöntemler, normal şartlarda iyi çalışırken, hava değişimlerine, sosyolojik ve ekonomik değişimlere ve tatil günlerindeki enerji talebi değişimlerine doyurucu sonuçlar verememektedir. Bu nedenle, yapay zekâ yöntemleri önem kazanmıştır. Yapay sinir ağları (YSA), bulanık mantık, destek vektör makineleri (DVM), genetik algoritma (GA), parçacık sürü optimizasyonu (PSO), karınca kolonisi optimizasyonu (KKO) tabanlı yöntemler yük tahmini için kullanılan yapay zekâ yöntemleri arasındadır. Bunların yanı sıra birden fazla yapay zekâ yönteminin, birden fazla analitik yöntemin ya da analitik yöntemler ve yapay zekâ yöntemlerinin birlikte kullanıldığı melez yöntemler de yük tahmini amacı ile kullanılmaktadır.

Yük talebi, bağımsız değişken olarak adlandırılan meteorolojik, sosyolojik, ekonomik ve demografik koşullara göre değişkenlik gösterir. Bu nedenle, tahmin çalışmasında kullanılan veriler seçilirken bağımsız değişkenler de göz önünde bulundurulmalıdır. Literatürdeki birçok çalışmada özellikle bağımsız değişken olarak sıcaklık kullanılırken nem, yağış, rüzgâr gibi hava verilerinin kullanıldığı çalışmalar da mevcuttur. Yapılan çalışmalarda genel olarak bölgesel yük tahminine odaklanılmıştır.

Bu çalışmada, TEİAŞ'tan alınan 2009-2010 yılları Türkiye geneli saatlik yük verileri kullanılarak, 2009-2010 yıllarına ait 24 saatlik yük tahmininde bulunulmuştur. Literatürde yer alan KDYT çalışmaları genel olarak bölgesel olarak gerçekleştirildiğinden sıcaklık verisi kullanılmıştır. Ancak geniş ölçekli ülke geneli tahmin çalışmaları için bir sıcaklık verisinden bahsetmenin zorluğundan dolayı bu çalışmada bağımsız değişken kullanılmamış, yalnızca geçmiş yük verileri dikkate alınmıştır. Çalışma, Yapay Sinir Ağları (YSA), Dalgacık Dönüşümü ve Yapay Sinir Ağları (DD ve YSA), Dalgacık Dönüşümü ve Radyal Tabanlı Fonksiyon Sinir Ağları (DD ve RTF SA), Görgül Kip Ayrışımı ve Radyal Tabanlı Fonksiyon Sinir Ağları (GKA ve RTF SA) olmak üzere dört melez yapı ile gerçekleştirilmiş ve yapıların hata yüzdeleri karşılaştırılmıştır. Hata yüzdeleri ortalama mutlak yüzdelik hata (MAPE) olarak hesaplanmıştır.

Bildiri şu şekilde düzenlenmiştir: Bölüm 2'de KDYT ile ilgili yapılmış literatür çalışmaları özetlenmiştir. Bölüm 3'te GKA ve oluşturulan yapılara yer verilmiştir. Veri kümesi seçimi ve tahmin regülasyonu için önerilen yaklaşım Bölüm 4'te ve benzetim çalışmaları Bölüm 5'da verilmiştir. Son olarak, Bölüm 6'da çalışmada oluşturulan yapılar karşılaştırılmıştır.

2. Literatür Özeti

Literatürde kısa dönem yük tahmini ile ilgili yapılmış çalışmalara bakıldığında yapay zekâ yöntemlerinin sıklıkla kullanıldığı görülmektedir. Azadeh ve arkadaşları, yapay sinir ağları ile 2003-2005 yılları için İran geneli 1 saatlik ve 24 saatlik yük tahmininde bulunmuşlardır [2]. Çalışmada bağımsız değişken olarak sıcaklık kullanılırken her mevsim için ayrı bir ağ oluşturulmuştur. Osman ve arkadaşları, YSA ve çoklu regresyon analizi kullanarak yaptıkları Mısır ülke geneli 2004 yılı saatlik yük tahmini çalışmasında ilkbahar ve yaz ayları için bir ağ, sonbahar ve kış ayları için başka bir ağ oluşturmuşlardır [3]. Gao ve Tsoukalas, yalnızca yük verisi kullanarak YSA ve dalgacık dönüşümünü melezleştirerek 24 saatlik yük tahmininde bulunmuşlardır [4]. Gontar ve Hatziaargyriou, Crete-İtalya için, bağımsız değişken kullanmadan RTF sinir ağları ile 48 saatlik yük tahmininde bulunmuşlardır [5]. Dongxiao ve Jie, 17.11.2009 gününe ait 24 saatlik yük tahmini çalışmasını RTF sinir ağları ile yapmışlardır [6]. Lu ve Zhou, Çin'in bir ili için RTF sinir ağları ile yük ve hava verileri kullanarak yaptıkları 24 saatlik yük tahmini çalışmasında ağ parametrelerini PSO ile belirlemişlerdir [7]. Bir başka çalışmada, dalgacık dönüşümü, RTF sinir ağları, zaman serileri analizi ve bulanık sinir ağları ile melezlenmiş ve Kanada'nın bir bölgesi için 24 ve 168 saatlik yük tahmininde bulunulmuştur [8]. Jain ve Satish, saatlik yük ve sıcaklık verisi kullanarak DVM ile 24 saatlik yük tahmininde bulunmuşlardır [9]. Kim ve arkadaşları Kore geneli 1996-1997 yılları özel günlerine ait saatlik yük tahminini YSA ve bulanık mantık ile gerçekleştirmişlerdir [10]. Song ve arkadaşları, aynı çalışmayı 20 yıllık veri kullanarak bulanık doğrusal regresyon yöntemi ile yapmışlardır [11]. ARIMA modelleme, AR modelleme, temel bileşen analizi (PCA), Holt-Winters üstel yumuşatma, benzer gün yöntemi gibi analitik yöntemler ile yapılmış kısa dönem yük tahmini çalışmaları da literatürde yer almaktadır [12-13]. Zu ve arkadaşları, GKA ve DVM yöntemlerini birlikte kullanarak HuBei, Çin için 20 Haziran 2005 gününe dair 24


saatlik yük tahmininde bulunmuşlardır ancak eğitim seti ile ilgili açık bilgi verilmemiştir [14]. Çalışmada yük verileri GKA ile Öz Kip Fonksiyonlarına (ÖKF) ayrıştırılmıştır. Her bir ÖKF'ye sıcaklık verileri de eklenerek farklı DVM modelleri uygulanarak tahmin sonuçları elde edilmiştir.

3. Görgül Kip Ayrışımı ve Oluşturulan Yapılar

Tahmin çalışması için YSA, DD ve YSA, DD ve RTF SA, GKA ve RTF SA olmak üzere dört yapı oluşturulmuştur ve bu yapılara dair blok diyagram Şekil 1'de gösterilmiştir. Yapılarda kullanılan YSA, DD ve RTF SA ile ilgili literatürde birçok ayrıntılı inceleme bulunmaktadır ve burada yer verilmemiştir [15-18]. GKA ise tanımlanan bu yöntemlere göre daha yeni ve kullanımı yavaş yavaş yaygınlaşan bir yöntemdir. Bu sebeple bu bölümde GKA aşamaları anlatılmıştır.

GKA, var olan sinyali alçak (trend) ve yüksek (detay) frekans bileşenlerine ayrıştırmada dalgacık dönüşümüne alternatif olarak geliştirilen ve herhangi bir analitik denklemle tanımlanamayan bir sinyal ayrıştırma yöntemidir. [19]. Ayrışım, durma ölçütü sağlanana kadar devam etmektedir ve bu tanımlı hariç dalgacık dönüşümü ile benzerlik göstermektedir. Durma ölçütü olarak ayrılmış sinyale ait maksimum ve minimum noktaları kullanılmakta, ayrılmış sinyallerin maksimum ve minimum noktaları hesaplanmadığında dönüşümün durma ölçütü sağlanmış olmaktadır. Ayrışım ile elde edilen yüksek frekans bileşenleri, sinyalin öz kip fonksiyonları (ÖKF) olarak adlandırılmaktadır. GKA aşağıdaki adımlar izlenerek gerçekleştirilmektedir [19]:

- $x(t)$ sinyalindeki tüm yerel ekstremum (maksimum ve minimum) noktalar bulunur.
- Bulunan üst ve alt ekstremum noktaları ara değerlendirme ile birleştirilerek bir üst zarf ($e_{mak}(t)$) ve bir alt zarf ($e_{min}(t)$) elde edilir.
- Alt ve üst zarfların ortalaması alınarak $m(t)$ ortalama sinyali elde edilir.



Şekil 1: Önerilen yapıların blok diyagramı

$$m(t) = \frac{e_{min}(t) + e_{mak}(t)}{2} \quad (1)$$

iv. $d(t)$ detay sinyali (4)'den elde edilir.


$$d(t) = x(t) - m(t) \quad (2)$$

v. Durma kriteri sağlanana kadar $d(t)$ sinyaline ilk dört adım uygulanır.

Şekil 1'de verilen yapıların eğitime ve çalışmasına dair ayrıntılar izleyen bölümlerde verilmiştir.

3.1. YSA

Uygulama için tek gizli katmanlı, sıfır hata hedefli bir ileri beslemeli-geri yayımlı sinir ağı kullanılmıştır. Oluşturulan YSA yapısı ile Şekil 2'de belirtilen eğitim veri kümesi kullanılarak eğitim gerçekleştirilmiş ve giriş olarak verilen 72 saatlik yük verisine göre tahmin gününe dair 24 saatlik tahmin sonuçları elde edilmiştir. Burada g tahmini yapılacak gündür. Giriş ve çıkış katmanlarındaki nöron sayısı sırasıyla giriş ve çıkış sayısına eşittir. Gizli katman nöron sayısı deneme yanılma ile 10 olarak seçilmiştir. YSA yapısı doğrudan tahmin sonucunu vermektedir.



Şekil 2: Sinir ağı eğitimi şeması.

3.2. DD ve YSA

YSA yapısı fonksiyon yakınsama problemlerinde iyi başarımlı göstermektedir, ancak giriş verileri birbirine yakın değerlerde olduğunda yakınsama problemi zorlaşmaktadır. Diğer taraftan, dalgacık dönüşümü, zaman alanında verilen sinyali frekans bileşenlerine ayırarak giriş uzayını genişletir; böylece YSA daha iyi yakınsama yapabilir. Bu nedenle, daha iyi tahmin sonuçları elde edebilmek için aynı eğitim giriş veri kümesi "db2" dalgacığı ile 5. seviyede alçak ve yüksek frekans bileşenlerine ayrılmış ve katsayıları elde edilmiştir. Oluşturulan YSA yapısı, bu katsayılarla eğitilmiş ve eğitim sonucunda elde edilen katsayılar "db2" dalgacığı ile yeniden yapılandırılarak tahmin yapılmıştır.

3.3. DD ve RTF SA

Durağan olmayan problemlerin çözümünde RTF SA'nın YSA'ya göre daha doğru sonuçlar verdiği bilinmektedir [20]. Bu nedenle dalgacık tekniği ile elde edilen alçak ve yüksek frekanslı katsayılar RTF SA eğitimi kullanılmış ve eğitim

sonuçları yine aynı dönüşümle yeniden yapılandırılarak tahmin yapılmıştır. RTF sinir ağı yayılım sabiti 1 alınmıştır.

3.4. GKA ve RTF SA

Bu yapıda RTF SA, görgül kip ayrışımı ile birlikte kullanılmıştır. İlk olarak, giriş verisi GKA ile öz kip fonksiyonlarına ayrıştırılmıştır. Öz kip fonksiyonları ile eğitilen RTF SA'ya Şekil 1'de belirtilen giriş veri kümesi uygulanmış, çıkışta tekrar ters GKA ile tahmin gününe dair 24 saatlik tahmin sonuçları elde edilmiştir.

4. Veri Kümesi Seçimi ve Tahmin Hatası Düzeltimi

Yük talebi, değişen meteorolojik, ekonomik, sosyolojik ve demografik koşullar karşısında değişkenlik gösterir. Bu çalışmada ise bu tip veriler olmadan, oluşturulan tüm yapılar için tahmin gününün öncesindeki 3 günün sadece saatlik yük verileri giriş olarak kullanılmıştır. Çalışmada amaçlanan bu bağımsız değişkenler olmadan da kabul edilebilir tahmin seviyesine ulaşabilmektir.

Literatürde yük tahmini ile ilgili yapılmış çalışmalar ekonomik ve demografik koşulların çoğunlukla uzun dönem, sıcaklığın ise kısa dönem yük tahmini çalışmalarında kullanıldığını göstermektedir. Ancak, ülke geneli yük tahmini gibi büyük ölçekli çalışmalarda etkin bir ortalama sıcaklık verisi elde etmenin ve kullanımının zorluğu nedeniyle, bu çalışmada sadece geçmiş yıllarda ait yük verileri kullanılmıştır.

Tahmini etkileyen bir başka önemli etken ise sosyolojik koşullardır. Örneğin, Türkiye için yerel tatil günleri olarak adlandırılacak yılbaşı tatili, ulusal ve dini bayram tatillerine ait yük talep eğrileri normal gün olarak adlandırılacak diğer günlere göre oldukça farklı karakteristik göstermektedir. Bu nedenle, yerel tatil günleri ve normal günler için tek bir model oluşturmak oldukça zordur. Bu çalışmada, yerel tatil günlerine ait geçmiş yük tüketim verileri tahmin gününün bir hafta öncesi ve bir hafta sonrası haftalık yük tüketim verileri esas alınarak normal gün karakteristiğine indirgenmiş ve bu günlere dair tahmin sonuçları hata hesabına katılmamıştır.

Geçmiş yük verisi incelendiğinde bir günlük yük tüketiminin çoğunlukla öncesindeki iki haftanın yük tüketimi ile değiştiği öngörülebilir. Bu nedenle, SA eğitimi giriş olarak tahmin gününün öncesindeki 3 günün bir hafta öncesindeki ve iki hafta öncesindeki günlerin saatlik yük verileri, çıkış olarak da tahmin günün bir hafta öncesi ve iki hafta öncesindeki günlerin saatlik yük verileri kullanılmıştır. Ağ eğitimi Şekil 2'te ayrıntılı olarak gösterilmiştir.

Literatürde yapılan çalışmalar yük talebinin mevsimsel olarak değiştiğini göstermektedir [2-3, 5, 8, 12-13]. Bunun yanında, yük tüketimi haftalık olarak değişmektedir. Geçmiş yük verisi incelendiğinde, yük tüketiminin son iki haftanın haftalık yük tüketimlerinin belirlediği bir oranda değiştiği görülmektedir. Bu nedenle çalışmada, daha düşük hata yüzdesine sahip tahmin sonuçları elde edebilmek adına yük tahmininde bir regülasyon önerilmiştir. Regüleri yük tahmini, regülesiz tahmin sonuçlarına haftalık yük tüketimi değişim oranı eklenerek gerçekleştirilmiştir. Haftalık yük tüketimi (HT), haftalık yük tüketimi değişim oranı (ΔHT) ve regüleri yük tahmini (RYT) ifadeleri sırasıyla (3), (4) ve (5)'te verilmiştir:

$$HT = \sum_{g=1}^7 \sum_{s=1}^{24} ST_s^g \quad (3)$$

$$\Delta HT = \frac{BHHT}{IHHT} \quad (4)$$

$$RYT = RZYT + (\Delta HT - 1) \cdot RZYT \quad (5)$$

Eşitliklerdeki ST , g , s , $BHHT$, $IHHT$ ve $RZYT$ terimleri sırasıyla saatlik yük tüketimi, gün endeksi, saat endeksi, tahmin gününün bir hafta öncesi haftalık tüketimi, tahmin gününün iki hafta öncesi haftalık tüketimi ve regülesiz yük tahminini temsil etmektedir.

5. Benzetim Çalışmaları

Çalışmada önerilen yapıların başarımını denemek amacıyla TEİAŞ'tan elde edilen Türkiye geneli 1 Aralık 2008-31 Aralık 2010 arası saatlik yük verisi veriler kullanılarak 2009-2010 yılları Türkiye geneli 24 saatlik yük tahmini yapılmıştır. Oluşturulan yapıların uygulanmasında MATLAB *Neural Networks Toolbox*, *Wavelet Toolbox* ve *emd* olarak tanımlı alt program kullanılmıştır [16,18-19].

Tahmin hataları MAPE olarak hesaplanmıştır. Yerel tatil günlerine ait tahmin sonuçları hata hesabına katılmamıştır. Oluşturulan her bir yapı için ortalama günlük MAPE ve günlük maksimum MAPE hesaplanmış ve karşılaştırılmıştır. Günlük MAPE ve ortalama günlük MAPE sırasıyla (6) ve (7)'de gösterildiği gibi hesaplanmıştır:

$$\text{Günlük MAPE} = \frac{1}{24} \cdot 100 \sum_{s=1}^{24} \frac{|(\text{tahmin})_s - (\text{gerçek})_s|}{(\text{gerçek})_s} \quad (6)$$

$$\text{Ortalama Günlük MAPE} = \frac{1}{G} \cdot \sum_{i=1}^G (\text{Günlük MAPE}) \quad (7)$$

(7)'deki G terimi normal gün (yerel tatil günleri dışındaki tüm günler) sayısıdır.

Çizelge 1 ve Çizelge 2'de sırasıyla 2009 ve 2010 yılları için regüleli-regülesiz ortalama günlük ve maksimum günlük MAPE değerleri verilmiştir. Çizelgelerde koyu olarak belirtilmiş değerler, en düşük hata yüzdelerini veren yapıları göstermektedir.

2009 yılı için en düşük ortalama günlük MAPE değerini regülesiz tahmin çalışmasında DD ve RTF SA, regüleli tahmin çalışmasında GKA ve RTF SA yapısı vermiştir. Regüleli yük tahmini hata yüzdeleri genel olarak regülesiz yük tahmini sonuçlarına göre daha düşük çıkarken DD ve RTF SA için bu durumun tersi geçerlidir.

Maksimum günlük MAPE değerlerine bakıldığında, her iki tahmin çalışmasında da en düşük hata yüzdesini yine DD ve RTF SA yapısı vermiştir. Maksimum günlük MAPE için regüleli yük tahmini hata yüzdeleri, regülesiz yük tahmini yüzdelerine göre daha yüksek çıkmıştır.

2010 yılı için en düşük ortalama günlük MAPE değerini regülesiz tahmin çalışmasında DD ve RTF sinir ağı yapısı, regüleli tahmin çalışmasında ise GKA ve RTF sinir ağı yapısı vermiştir. Regüleli yük tahmini hata yüzdeleri genel olarak regülesiz yük tahmini sonuçlarına göre daha düşük çıkarken DD ve RTF SA yapısı için bu durumun tersi geçerlidir.

Maksimum günlük MAPE değerlerine bakıldığında, regülesiz tahmin çalışmasında da en düşük hata yüzdesini YSA yapısı, regüleli tahmin çalışmasında ise GKA ve RTF sinir ağı yapısı vermiştir. Regüleli yük tahmini hata yüzdeleri genel

Çizelge 1: 2009 yılı MAPE değerleri


2009	YSA	DD ve YSA	DD ve RTF SA	GKA ve RTF SA
Ortalama Günlük MAPE (Regülesiz)	3.6735	3.7296	2.8955	3.5155
Maksimum Günlük MAPE (Regülesiz)	10.9531	15.7200	10.1784	12.4950
Ortalama Günlük MAPE (Regüleli)	3.3279	3.3459	2.9340	2.6686
Maksimum Günlük MAPE (Regüleli)	11.9370	20.4328	11.5731	12.7550

Çizelge 2: 2010 yılı MAPE değerleri

2010	YSA	DD ve YSA	DD ve RTF SA	GKA ve RTF SA
Ortalama Günlük MAPE (Regülesiz)	3.8104	4.1859	2.9919	3.6346
Maksimum Günlük MAPE (Regülesiz)	9.5459	15.2228	9.7173	11.1660
Ortalama Günlük MAPE (Regüleli)	3.3983	3.5704	3.0351	2.6424
Maksimum Günlük MAPE (Regüleli)	9.1770	14.8118	13.9602	8.1421

olarak regülesiz yük tahmini sonuçlarına göre daha düşük çıkarken DD ve RTF SA yapısı için bu durumun tersi geçerlidir.


Hata sonuçları doğrultusunda en iyi tahmini veren yapı olan DD ve RTF SA yapısına ait regülesiz yük tahmini ortalama günlük MAPE hata grafiği 2009-2010 yılları yerel tatil günleri dahil tüm günleri için Şekil 3'te gösterilmiştir.




Şekil 3: DD ve RTF SA ile 2009-2010 yılları regülesiz tahmin MAPE değerleri

Benzetim çalışmaları 2009-2010 yılları tüm günleri için gerçekleştirilmiş ve 12 Mayıs 2009 Salı günü için örneklenmiştir. Bu güne ait gerçek yük eğrisi tüm yapılar ile

elde edilmiş regüledi ve regülesiz tahmin eğrileri birlikte sırasıyla Şekil 6 ve Şekil 7'de gösterilmiştir. Her iki tahmin çalışması için Dalgacık Dönüşümü ve RTF sinir ağı yapılarında elde edilen hata yüzdesi şekillerin altında belirtilmiştir.



Şekil 6: 12 Mayıs 2009 günü regülesiz tahmin eğrileri ve gerçek yük eğrisi (MAPE-DD ve RTF SA= 1,2423).



Şekil 7: 12 Mayıs 2009 günü regüledi tahmin eğrileri ve gerçek yük eğrisi (MAPE-DD ve RTF SA= 1,9122).

6. Sonuçlar

Bu çalışmada sıcaklık verisi kullanmadan Türkiye geneli 24 saatlik yük tahmini için YSA, DD ve YSA, DD ve RTF SA, GKA ve RTF SA yapıları oluşturulmuş ve gerçekleştirilmiştir. Ek olarak, hata yüzdesini azaltmak için, tahmin günü öncesindeki son iki haftanın saatlik yük verileri kullanılarak yapılan bir regülasyon hesabı tanımlanmıştır.

DD ve GKA, sinyali bileşenlerine ayırıp giriş uzayını genişlettiğinden YSA ve RTF SA yapılarına daha iyi yakınsama kabiliyeti katmıştır. Nöronların başlangıç ağırlıkları rastgele verildiğinden, YSA yapısının her simülasyon sonucunda farklı sonuçlar vermektedir.

Oluşturulan tüm yapılar sıcaklık verisi kullanmadan MAPE olarak kabul edilebilir hata yüzdeslerinde tahmin sonuçları vermiştir. Bu hata sonuçlarına göre hem ortalama günlük MAPE, hem de maksimum günlük MAPE açısından DD ve RTF SA ve GKA ve RTF SA yapılarının daha iyi yük tahminçileri olduğu görülmektedir.

7. Kaynaklar

[1] A. Khotanzad, R. Afkhami-Rohani, T. L. Lu, A. Abaye, M. Davis ve D. J. Maratukulam, "ANNSTLF- A Neural Network-Based Electric Load Forecasting System", *IEEE Transactions on Neural Networks*, Cilt. 8, No. 4, s. 835-846, 1997.

[2] A. Azadeh, S. F. Ghadrei ve B. Pourvalikhan Nokhandan, "Short Term Load Forecasting by ANN", *Hybrid Intelligent Models and Applications*, s. 39-43, 2009.

[3] Z. H. Osman, M. L. Awad ve T. K. Mahmoud, "Neural Network Based Approach for Short-Term Load Forecasting", *Power Systems Conference and Exposition*, 2009.

[4] R. Gao ve L. H. Tsoukalas, "Neural-Wavelet Methodology for Load Forecasting", *Journal of Intelligent and Robotic Systems*, Cilt. 31, s. 149-157, 2001.

[5] Z. Gontar, ve N. Hatziaargyriou, "Short Term Load Forecasting with Radial Basis Function Network", *IEEE Porto Power Tech. Conference*, 2001.

[6] N. Dongxiao, ve T. Jie, "Improved RBF network Applied to Short-Term Load Forecasting", *ICSESS 2011*, 2011, s. 864-867.

[7] N. Lu ve J. Zhou, "Particle Swarm Optimization-Based RBF Neural Network Load Forecasting Model", *APPEEC 2009*.

[8] A. S. Pandey, D. Singh ve S. K. Sinha, "Intelligent Hybrid Wavelet Models for Short-Term Load Forecasting", *IEEE Transactions on Power Systems*, Cilt. 25, No. 3, s. 1266-1273, 2010.

[9] A. Jain ve B. Satish, "Integrated Architecture for Short-Term Load Forecasting using Support Vector Machines", *NAPS'08*, 2008, s. 1-8.

[10] K. H. Kim, H. S. Youn ve Y. C. Kang, "Short-Term Load Forecasting for Special Days in Anomalous Load Conditions Using Neural Networks and Fuzzy Inference Method", *IEEE Transactions on Power Systems*, Cilt. 15, No. 2, s. 559-565, 2000.

[11] K. B. Song, Y. S. Back, D. H. Hong ve G. Jang, "Short-Term Load Forecasting for the Holidays Using Linear Regression Method", *IEEE Transactions on Power Systems*, Cilt. 20, No. 1, s. 96-101, 2005.

[12] J. W. Taylor ve P. E. McSharry, "Short-Term Load Forecasting Methods: An Evaluation Based On European Data", *IEEE Transactions on Power Systems*, Cilt. 22, No. 4, s. 2213-2219, 2007.

[13] Y. Chen, P. B. Luh, C. Guan, Y. Zhao, L. D. Michel, M. A. Coolbeth, P. B. Friedland ve S. J. Rourke, "Short-Term Load Forecasting: Similar Day-Based Wavelet Neural Networks", *IEEE Transactions on Power Systems*, Cilt. 25, No. 1, s. 322-330, 2010.

[14] Z. Zhu, Y. Sun ve H. Li, "Hybrid of EMD and SVMs for Short-Term Load Forecasting", *ICCA 2007*, s. 1044-1047, 2007.

[15] Arı, N., Özen, Ş. ve Çolak, Ö. H., *Dalgacık Teorisi (Wavelet) Matlab Uygulamaları İle*, Palme Yayıncılık, 2008.

[16] MATLAB Wavelet Toolbox User Guide, Mathworks.

[17] Sağiroğlu Ş., Beşdok, E. ve Erler, M., *Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları*, Ufuk Yayıncılık, 2003.

[18] Beale, M. H., Hagan, M. T. ve Demuth, H. B., *Neural Network Toolbox 7 User's Guide*, MathWorks, 2010.

[19] G. Rilling, P. Flandrin ve P. Gonçalvès, "On Empirical Mode Decomposition and Its Algorithms", *NSIP-03*, 2003.

[20] Soliman, S. A. ve Al-Kandari, A. M., *Electrical Load Forecasting: Modeling and Model Construction*, Butterworth-Heinemann, 2010.