

Yapay Sinir Ağları Kullanılarak Kısa Dönem Elektrik Yükü Tahmini

Short Term Electric Load Forecasting Using Artificial Neural Networks

Hakan Var¹, Belgin Emre Türkey²

¹Elektrik Mühendisliği Bölümü
İstanbul Teknik Üniversitesi
hakan.vr@gmail.com

²Elektrik Mühendisliği Bölümü
İstanbul Teknik Üniversitesi
turkeyb@itu.edu.tr

Özet

Kısa dönem yük tahminin doğruluğu güç sistemleri için çok önemlidir. Tüketicilere ekonomik, güvenilir ve kaliteli enerji sunmak için, iyi bir yük tahminine dayalı planlama yapılmalıdır. Yük tahmini, geçmişteki koşulların incelenerek gelecekteki durumun tahmin edilmesine dayanır. Etkili bir sistem planlaması için, puant yük ve enerji ihtiyacının tahmin edilmesi gereklidir. Ayrıca doğru yük tahmini elektrik sistemlerinin güvenliğini artırdığı gibi yük tahmini teklif stratejisinde fiyat tahmini için önemli bir gerekliliktir. Başka bir deyişle, yeniden yapılandırılmış elektrik piyasasında, bir üretim şirketinin sistemin yük talebini tahmin etmesi ve piyasa yük tahminine göre bir fiyat belirlemesi gerekmektedir. Bu çalışma ile İstanbul'daki bir bölgenin yapay sinir ağları yöntemi kullanılarak elektrik puant yükü tahmin edilmiştir.

Abstract

Accuracy of short time load forecast is highly important to power systems. To offer economical, reliable and qualified energy solutions, a decent load prediction should be planned. Load forecasting is to estimate future load examining past data. For efficient system planning, peak load and energy requirement should be forecasted. Moreover a correct load forecast increases system reliability and also is an important requirement to the offer strategy of price estimation. In other words, in a reconstructed electricity market, a generating company should forecast load demand and set price in order to market load forecast. In this study, electrical peak load is forecasted by using artificial neural networks method for a region in İstanbul.

1. Giriş

Kısa vadeli yük tahminleri üretim kapasitesinin planlanmasında ve ekonomik kararların alınmasında önemlidir. Doğru yük tahmini ihtiyacı gelecekte enerji ihtiyacındaki dramatik değişimler ve enerjinin daha verimli kullanılması sebebiyle devlet tarafından alınan kararlar ve rekabetçi piyasanın da etkisiyle artacaktır. Bu ortam daha doğru ve hızlı tahminlerde bulunulması, bunun için en doğru

bilgisayar programlarının kullanılmasını zorunlu hale getirmektedir [1].

Yıllardır yük tahminlerinin doğruluğunun iyileştirilmesi sorunu önemli bir araştırma konusu olmuştur. Çeşitli yöntemlerle yük tahminlerinin kendine göre avantajları rapor edilmiştir [1]. Regresyon analizi, istatikselsel metot, yapay sinir ağları, genetik algoritma, yapay sinir ağları gibi yöntemler uzun yıllardır yük tahmininde kullanılmaktadır.

Kısa vadeli yük tahmini çalışmaları ilk olarak Heineman ve arkadaşları tarafından 1960'ların başında başlamıştır ve 1966 yılında yük ve sıcaklık arasındaki ilişki ele alınmıştır. 1971 yılında Lijesen ve Rosing istatikselsel yaklaşım metodu kullanarak yük tahmin sistemini geliştirmişlerdir. 1987 yılında Hegan ve Behr zaman serileri modelini kullanarak tahminde bulunmuşlardır [2]. Zaman serileri yöntemin yük önceki verilere bağlıdır. Regresyon metodu otoregresif hareketli ortalama modelleri [3] ve spektral açılım tekniği [4] gibi yük örnekleri ve sıcaklık örnekleri arasındaki kuvvetli bağıntı arasındaki eğilimi kullanır. Havanın yükü etkileyen değişkenleri önceden belirlenmiş bir fonksiyon ile modellenir. Otoregresif hareketli ortalama, lineer regresyon, stokastik zaman serisi, ve genel üstel düzleştirme gibi istatistiksel yöntemler değişkenler arasında doğrusal ilişki kuran bilgisayar programlarının kullanımını gerektirir. Fakat bunları doğrusal ve durağan olmayan saatlik yük değişimleri arasındaki ilişkiyi sınırlandırmaktadır.

1990 yılından itibaren araştırmacılar kısa dönem yük tahminleri için istatikselsel yaklaşım dışında yapay zeka uygulamaları alanına yönelmeye başlamışlardır[2]. Yapay sinir ağları, bulanık sinir ağları, uzman sistemler gibi yapay zeka uygulamaları doğrusal olmayan büyük veri kümeleri ile başa çıkmak için uygulanmıştır. Sinir ağları farklı ağ tipleri kurmadaki esnekliği ile kısa dönem yük tahmini alanındaki araştırmacılar tarafından büyük ilgi görmüştür. 1991 yılında Park ve arkadaşları kısa dönem yük tahmini için yapay sinir ağlarını kullanmayı seçen ilk grupta yer alıyordu [5]. Bazı araştırmacılar kısa dönem yük tahminin hibrit metodu kullanarak yapmaktaydı. Buna 1995 yılında Srinivasan ve arkadaşlarının yaptığı bulanık mantık ve sinir ağı metotlarını içeren çalışma örnek gösterilebilir [6].

Yapay sinir ağları öğrenme algoritmaları sayesinde eğitilerek doğrusal olmayan giriş değişkenleri kullanarak daha iyi sonuçlar verebilir [7]. Sinir ağları ile tahminde, bulanık sinir ve diğer tahmin metodlarının da kullanıldığı geniş bir literatür taraması yapıldı ve yükün sıcaklıkla güçlü bir bağlantısının olduğu not edildi. Fakat gelecekteki sıcaklık değerleri bilinmediği için yük tahmini tahmin edilen sıcaklık değerleri kullanılarak yapılmıştır [2]. Yapay sinir ağları kısa dönem yük tahmincisi (ANNSTLF) literatüre uygun ve gerçek dünyada test edilir yük tahmincilerinden sadece bir tanesidir [1]. ANNSTLF 'ın önemli bir özelliği de ağ yapısı ile aynı ülkenin çeşitli bölgelerinde farklı boyuttaki tahminler için kullanılabilir olmasıdır.

2. Yapay Sinir Ağları

Yapay sinir ağları (YSA) insan beyninin sinir hücrelerinden oluşmuş katmanlı ve bağlantılı yapısını fonksiyonlarıyla beraber sayısal dünyaya modellenmesidir. Yapay sinir ağları, sınıflandırma, örüntü, tanıma ve tahmin gibi birçok alanda kullanılmaktadır.

Yapay sinir ağı; deneyime dayalı bilgiyi depolama ve bu bilgiyi kullanıma yönelik doğal bir eğilim içinde olan yoğun paralel dağıtılmış bir işlemcidir. Yapay sinir ağları iki açıdan insan beynine benzemektedir: Bilgi ağ tarafından bir öğrenme süreci vasıtasıyla elde edilmektedir ve sinir hücreleri arasında sinaptik ağırlık olarak adlandırılan bağlar bilgiyi depolamakta kullanılmaktadır [8].

YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ihtiyaç duymadan doğrusal ve doğrusal olmayan modellemeyi sağlayabilmektedir. Bu sebeple yapay sinir ağları, tahmin aracı olarak diğer yöntemlere göre daha genel ve esnekler [9].

2.1. Yapay Sinir Ağları' nın Özellikleri

2.1.1. Doğrusal Olmama

YSA problemin çözümünde kullandığı aktivasyon fonksiyonu sayesinde doğrusal ya da doğrusal olmayan modellemeyi gerçekleştirebilmektedir.

2.1.2. Öğrenme

İnsan beynindeki sinir ağının yapısının taklit edilmesiyle geliştirilen yapay sinir ağı, veri yapısı ile hedef arasındaki bilinmeyen ilişkileri ortaya çıkarmaktadır.

2.1.3. Genelleme

Yapay sinir ağı veriler ile hedefler arasındaki gizli ilişkileri ortaya çıkardıktan sonra öğrenmiş olduğu ağ yapısını yeni verilere uygulayabilmektedir.

2.1.4. Uygulanabilirlik

Daha önce herhangi bir problem için uyarlanmış olan YSA, farklı bir problem için yeniden uyarlanabilir.


2.1.5. Hata Toleransı

Yapay sinir ağı, paralel dağılmış yapay sinir hücrelerinin birbiriyle bağlanması sonucu oluşmuştur. Ağı eğitimi için kullanılan verilerde herhangi bir yanlışlık olduğunda bu yanlışlık bütün ağa dağıldığı için sonuç üzerine etkisi

azaltılmış olur. Bu sebeple YSA' nın hata hoşgörüsü diğer yöntemlere göre daha fazladır.

2.2. Yapay Sinir Ağının Çalışma Algoritması

Yapay sinir ağlarının algoritmasını tanıttak olursak, sinir hücreleri girdi ve çıktılar arasındaki bağıntıyı kurabilmek için genellikle birden çok katman halinde dizilmişlerdir. İlk katman genellikle giriş katmanıdır. Çıkış katmanı ise son katmandır. Aradaki diğer katmanlar ise ara katman ya da gizli katman olarak adlandırılır. Bir ağda birden fazla gizli katman bulunabilir [10].



Şekil 1:Yapay Sinir Ağına Genel Bir Örnek

Giriş katmanı, veri gruplarının ağı sunulduğu terminalerdir. Bu tabakadaki nöron sayısı giriş veri sayısı kadardır ve her bir giriş nöronu bir veri alır. Buradaki veri işlenmeden bir sonraki tabaka olan gizli tabakaya geçer. Ağırlıklar, bir yapay sinir hücresine gelen bilgilerin, hücre önündeki önemini ve etkisini gösteren bileşendir. Her bir girişin kendine ait bir ağırlığı vardır. Bir ağırlığın değerinin büyük ya da küçük olması, o girişin yapay sinir ağı için önemli ya da önemsiz olduğunu göstermez. Ağırlıklar değişken ya da sabit değerler olabilir. Gizli katman, ağı temel işlevini gören tabakadır. Bazı uygulamalarda ağda birden fazla gizli katman bulunabilir. Gizli tabaka sayısı ve gizli tabakadaki nöron sayısı probleme göre değişir. Bu tabaka girdi tabakasından alıp ağırlıklarıyla çarptığı veriyi probleme uygun bir fonksiyonla işleyerek bir sonraki tabakaya iletir. Toplama fonksiyonu, bir hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın olanı ağırlıklı toplamı bulmaktır. Burada her gelen girdi değeri kendi ağırlığı ile çarpılarak toplanır. Böylece ağa gelen net girdi bulunmuş olur. Yapay sinir hücresinin bir başka önemli bileşeni de aktivasyon fonksiyonudur. Bu fonksiyon, toplama fonksiyonundan gelen bilgileri çıktıya dönüştürür. Aktivasyon fonksiyonu, eşik fonksiyonu olarak da adlandırılır. Toplama fonksiyonuna benzer bir şekilde, bu fonksiyonda da çıktıyı hesaplamının değişik metodolojileri vardır ve proses elemanlarının hepsinin aynı aktivasyon fonksiyonunu kullanma zorunluluğu yoktur. İlgilenen problemin çeşidini ve kullanılan ağ yapısına göre farklı fonksiyonlar tercih edilebilir. Genellikle aktivasyon

fonksiyonu olarak; doğrusal fonksiyon, basamak fonksiyonu, sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu kullanılmaktadır [11]. Çıktı katmanı, ağı en uç katmanıdır. Saklı tabakadan aldığı veriyi ağı kullandığı fonksiyonla işleyerek çıktısını verir. Çıkış tabakasındaki nöron sayısı, ağı sunulan her verinin çıkış sayısındaki kadardır. Bu tabakadan elde edilen değerler YSA’ dan var olan problem için çıkan sonuç değerleridir [12]. Sinir ağı tek katmanlı ya da çok katmanlı olarak sınıflandırılırlar. Katman sayısı belirlenirken girdi birimi katman olarak sayılmaz, çünkü bular üzerinde hiçbir hesaplama işlemi yapılmaz. Bir ağı içindeki katman sayısı nöronları bağlayan ağırlıklı bağlantı sayısına eşittir [13].

3. Örnek Bölge için Yük Tahmini

Yapay sinir ağlarında, ağı giriş ve çıkışlarına belirli ön işlem adımları uy-gulayarak yapay sinir ağına sunulan verilerin eğitimi daha verimli hale getirilebilir. Ağı giriş işlem fonksiyonları, ağı kullanımını daha iyi bir forma dönüştürür. Normalleştirme işlemi ham verilere uygulanarak ve bu verilerin eğitim için uygun veri setinin hazırlanmasına etkisi vardır. Yapay sinir ağların eğitimi, ham veri setine normalizasyon yöntemi uygulanmadan çok yavaş olabilir. Normal-leştirme işlemlerinde farklı teknikler kullanılabilir. Literatürde birçok veri nor-malizasyon çeşidi vardır. Bunlar; Min kuralı, Max kuralı, Medyan, Sigmoid ve Z-Score gibi kurallar olarak sıralanabilir [14].

$$x' = 0.8 * \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} + 0.1 \quad (1)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

$x_{\min}$ = Girdi seti içindeki en küçük değeri,

$x_{\max}$ = Girdi seti içindeki en büyük değeri, ifade etmektedir.


Bu çalışmada min – max normalizasyonu en iyi sonucu vermiştir ve değerler bu normalizasyon ile 0,1 ile 0,9 arasına indirgenmiştir. Veri setindeki dağılımın düzelenmesiyle ağı performansı artmış olup, daha doğru tahminlerin yapılmasına olanak sağlanmıştır.

Tahmin MATLAB adlı bilgisayar programında yapılmıştır. Yapay sinir ağına veri kümesi olarak saat, sıcaklık, nem ve hedeften bir hafta önceki yük değeri seçilmiştir. Tahminde kurulan ağı netfit, tek gizli katmanlı, gizli katman aktivasyon fonksiyonu sigmoid ve çıktı katmanı aktivasyon fonksiyonu ise özdeşlik fonksiyonu olarak seçilmiştir. Ağı için gizli katmandaki nöron sayısını belirlemek için performans kodu yazılmış ve performans olarak hata oranlarının kareleri (MSE) karşılaştırılmıştır ve MSE’ a göre uygun nöron sayısı belirlenmiştir. Ağı kurulumunda Levenberg – Marquardt geri yayılım algoritması (trainlm) diğer optimizasyon algoritmalarından daha hızlı ve daha iyi sonuç verdiği için, optimizasyon algoritması olarak seçilmiştir.

Yapay sinir ağına verilerin %70’ i eğitim, %15’ i değer ve %15’ i de test için ayrılmıştır. Ayrıca Tek gizli katmanlı yapay sinir ağı en iyi performansına 28 gizli nöron ile 100 iterasyon sonucu ulaşılmıştır. Uygun ağı seçimi yapılırken gizli katman sayısı, aktivasyon fonksiyonu, optimizasyon algoritması, gizli nöron sayısı, iterasyon sayısı ve ağı girilen


verilerin eğitim, değer ve test oranları çok fazla deneme yapılarak bulunmuştur.

Ağı eğitildikten sonra 13-19 Ocak 2014 tarihleri arasındaki yük tahmini aşağıdaki gibidir. Bir haftalık yük değerlerindeki hata oranı Şekil 2’ de verilmiştir.




Şekil 2: Tahmin Edilen ve Gerçek Yük Değerlerinin Karşılaştırılması

Tahmin edilen yükteki ortalama hata değerleri Şekil 3’ teki gibidir.



Şekil 3: Hata Oranı (%)

Hata değeri ise Şekil 4 ‘teki grafikteki gibidir.



Şekil 4: Hata Değerleri

Ağın performansındaki ölçüt ortalama hataların karesi (MSE) iken, yük tahmini yapılırken en iyi sonuç değerlendirmesi ortalama hata oranlarına (MAPE) bakılarak seçilmiştir. MAPE değeri %10'un altında olan modelleri "çok iyi", % 10 ile % 20 arasında olan modelleri "iyi", % 20 ile % 50 arasında olan modelleri "kabul edilebilir" ve % 50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmıştır [15]. MAPE tüm gözlem değerleri için;

$$MAPE = \frac{P_{gerçek} - P_{tahmin}}{P_{gerçek}} * 100 \quad (2)$$

formülü ile bulunur.

Burada $P_{gerçek}$ gerçekte ölçülen yük iken, P_{tahmin} yapay sinir ağı ile tahmin edilen yüküdür.

Sonuç olarak, bölge için yapılan tahminde ortalama Hata (MAPE) %7.5285 ve ortalama hata değeri ise 0.0925 MWh olarak bulunmuştur.

4. Sonuçlar

Seçilen bölgede, güvenilirliği arttırmak, ekonomik enerji üretimi ile besleme yapmak ve gelecek için iyi bir sistem planlamasını yapabilmek için yük tahmini yapılmıştır. Kısa dönem yük tahminlerinde belirleyici faktörler: geçmiş zamana ait elektrik yükü, gün içindeki saat dilimleri, sıcaklık ve nem meteorolojik verilerdir. Bu hedef dahilinde İstanbul'daki bir bölgenin yapay sinir ağı yöntemiyle elektrik yükü saat, sıcaklık, nem geçmiş zamandaki elektrik yükü veri olarak alınarak yük tahmini yapılmıştır. Yapılan tahminin hata analizi yapıldığında kullanılan yapay sinir ağı ile ortalama olarak %7.5285 'luk hata ile tahmin yapılmaktadır.

Ayrıca tahmin edilen değerlerin karakteristiğine bakılırsa gerçek değerlerle örtüştüğü görülmektedir. Grafiklerin bu denli benzer olması tahmin için yapılan uygulamanın doğru olduğu anlaşılmaktadır.

Çalışılan bölgede nüfus yoğunluğunun gün içinde çok değişmesi, veri kümesinin genellikle sıcak havalardan oluşup tahmin yapılan zaman diliminin soğuk havalardan oluşması ve buna

bağlı olarak bölgedeki halkın alışkanlıklarının farklılık göstermesi tahminde dalgalanmalara neden olmuştur. Lewis' in de değerlendirmesini göz önünde bulundurursak yapılan tahminle % 10 hata oranının altına inilmiş ve istenilen amaca ulaşılmıştır.

5. Kaynaklar

- [1] Khotanzad, A., Afkhami-Rohani, R., and Maratukulam, D., ANNSTLFArtificial neural network shortterm load forecastergeneration three, IEEE Trans. on Power Syst., 13, 4, 1413-1422, November, 1998.
- [2] Buhari, M, Adamu S. S., Short-Term Load Forecasting Using Artificial Neural Network, Proceeding of the Int. MultiConference of Engineers and Computer Scientists 2012, Vol 1, IMECS 2012, March 14-16, Hong Kong.
- [3] Khotanzad, A., Afkhami-Rohani, R., and Maratukulam, D., ANNSTLFArtificial neural network shortterm load forecastergeneration three, IEEE Trans. on Power Syst., 13, 4, 1413-1422, Nov. 1998.
- [4] I. Moghram and S. Rahman, "Analysis and evaluation of five short termload forecasting techniques," IEEE Trans. Power Syst., vol. 4, no. 4, pp. 1484-1491, Nov. 1989.
- [5] D. C. Park, M. A. El-Sharkawi, R. J. Marks II, L. E. Atlas, M. J. Damborg. "Electric load forecasting using an artificial neural network ", IEEE Transaction on Power Systems, Vol. 6, no.2, pp. 442-449, May 1991.
- [6] D. Srinivasan, S. S. Tan, C. S. Cheng, Eng Kiat Chan. "Parallel neural network-fuzzy expert system strategy for short-term load forecasting: system implementation and performance evaluation", IEEE Trans. on Power Systems, vol.14, no. 3, pp. 1100-1106, Aug. 1999.
- [7] P. Mandal, T. Senjyu, N. Urasaki, and T. Funabashi, "A neural network based several hour-ahead electric load forecasting using similar days approach," Int. Journal of Electric Power and Energy System, Vol. 28, no. 6, pp. 367-373, July 2006.
- [8] Haykin Simaon, 'Neural Networks: A Comprehensive Foundation', Macmillian College, New York, 1994.
- [9] Zhang G., Patuwo B.E., Hu M.Y., 'Forecasting with Artificial Neural Networks: The State of the Art', International Journal of Forecasting, 1998.
- [10] Yıldız Ö. (2006). Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanımı, Osmangazi Üniversitesi Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Eskişehir.
- [11] Aygören H. , Sarıtaş H, Moralı T.(2012), İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, Uluslararası Alanya İşletme Fakültesi Dergisi, Cilt: 4, Sayı:1, s. 77 – 78.
- [12] Özgen D. (2007). Yapay Sinir Ağları Analizi Ve Türk Finans Piyasaları: İMKB 30 Endeksi Uygulaması, Marmara Üniversitesi Bankacılık ve Sigortacılık Enstitüsü Yüksek Lisans Tezi, İstanbul.
- [13] Ocakoğlu G. (2006). Lojistik Regresyon Analizi Ve Yapay Sinir Ağı Tekniklerinin Sınıflama Özelliklerinin Karşılaştırılması ve Bir Uygulama, Uludağ Üniversitesi Sağlık Bilimleri Enstitüsü Yüksek Lisans Tezi, Bursa.
- [14] Jayalakshmi, T. and A. Santhakumaran; (2011), "Statistical Nor-malization and Back Propagation for Classification", International Journal of Computer Theory and Engineering 3(1), pp. 1793-8201.
- [15] Colin D. LEWIS, Industrial and Business Forecasting Methods, Butterworths Publishing: London, 1982, s. 40