

YAPAY SİNİR AĞLARIYLA HİDROELEKTRİK ENERJİ ÜRETİMİNİN ÇOK DÖNEMLİ TAHMİNİ

MULTI-PERIOD ESTIMATION OF HYDROELECTRIC POWER GENERATION WITH ARTIFICIAL NEURAL NETWORK

Yunus MAKAS¹

Yrd. Doç. Dr. Meltem KARAATLI²

ÖZ

Elektrik enerjisinin depolanamaması arz-talep dengesinin planlanmasını ve yüksek doğruluk dereceli üretim tahmininin önemini artırmaktadır. Yapılacak tahminlerin doğruluğu, yapılan planlama çalışmalarının da geçerliliğini artıracaktır. Bu çalışmada Türkiye'nin en büyük yenilenebilir enerji potansiyeli olan hidroelektrik enerjinin üretim tahmini yapılmıştır.

Çalışma kapsamında Antalya Havzasında bulunan Isparta ili Aksu ilçesi sınırlarındaki Yenice deresinden beslenen bir hidroelektrik santralin 12 aylık elektrik üretimi tahmin edilmiştir. Aylık Ortalama Yağış, Aylık Ortalama Nisbi Nem ve Aylık Ortalama Debi verileri Yapay Sinir Ağlarına (YSA) girdi olarak kullanılmıştır. 2007-2014 tarihleri arasındaki veriler arasındaki ilişki İleri Beslemeli Geri Yayınım Sinir Ağı (İBGYSA) yöntemi ile araştırılmış olup yüksek doğrulukta YSA modeli ile 2015 yılı elektrik üretimi tahmin edilmiştir.

Kurulan modelin hidroelektrik santrallerin aylık üretimlerini başarıyla temsil ettiği ve bir santralin 12 aylık üretim tahmininde başarıyla kullanılabileceği gösterilmiştir. Bu çalışma elektrik enerjisi ihtiyacının arttığı günümüzde, sonraki dönemlere ait üretim tahminleri yapılacak olan çalışmalara öncü niteliğindedir.

Anahtar Kelimeler: Yapay Sinir Ağları, Elektrik Üretimi, Hidroelektrik Santrali, Enerji Tahmini

Jel Kodları: C45 C53 Q47

ABSTRACT

The fact that electricity cannot be stored is increasing the importance of planning the supply-demand balance and estimation of the power generation with high accuracy. The accuracy of the estimations will also increase the validity of the planning. This study has estimated generation of hydroelectric power, Turkey's most potential source for renewable energy.

Within the scope of this study, power generation of a hydroelectric power plant located in Isparta has been estimated for a period of 12 months. Monthly Average Precipitation, Monthly Average Relative Humidity and Monthly Average Flow have been used as input for Artificial Neural Network(ANN). The relationship between the years of 2007-2014 has been researched by Feed Forward Back Propagation Neural Network. Annual hydroelectric power generation in 2015 has been estimated by using Artificial Neural Network(ANN) with high accuracy.

It has been demonstrated that the established model is representing the monthly generation of the hydroelectric power plant in a successful way and it can be used to predict the 12 months generation of a power plant. In today's world, there is an increasing need for electricity power and this study is a pioneer for future studies that will be focusing on the estimations of power generation for the periods ahead.

Keywords: Artificial Neural Network, Electricity Production, Hydroelectric Power Plant, Energy Forecast

Jel Codes: C45 C53 Q47

¹ Süleyman Demirel Üniversitesi, Teknik Bilimler Meslek Yüksekokulu, yunusmakas@sdu.edu.tr

² Süleyman Demirel Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, meltemkaraatli@sdu.edu.tr

1. GİRİŞ

Dünya nüfusunun artması ve teknolojiye yaşanan gelişmeler enerji ihtiyacını artırmaktadır. Enerji üretim, tarım, ulaşım gibi her türlü sektörün başlıca girdisidir. Kolay ulaşılabilir, temiz ve kaliteli olması elektrik enerjisine olan ilgiyi artırmıştır. Fosil enerji kaynaklarının gelecekte tükenerek olması, kolay ulaşılabilir olamaması ve doğaya zarar veriyor olması bakımından ülkeleri yeni ve yenilenebilir enerji kaynakları arayışına yöneltmiştir.

Gün geçtikçe azalan su kaynaklarının verimli şekilde kullanılabilmesi, su kaynaklarının doğru şekilde planlanması ve işletilmesine bağlıdır (Önöz ve Albostan, 2007:196). Hidroelektrik enerji temiz ve yenilenebilir bir enerji kaynağıdır. Hidroelektrik enerjinin birçok ülke tarafından tercih edilme sebepleri; ekonomik olması, teknik ve çevresel faydalarının oluşudur (Huang ve Yan, 2009:1652). Suyun akış enerjisinden faydalanılarak, elektrik enerjisi elde etmek için kurulan santrallere hidroelektrik santrali adı verilir. Hidroelektrik santrallerde suyun akım enerjisi, su türbinler aracılığı sayesinde mekanik enerjiye ve bu mekanik enerjide su türbinlerinin tahrik ettiği generatörler vasıtası ile elektrik enerjisine çevrilmektedir. Üretilen elektrik enerjisi, enerji nakil hatları ile şalt sahaları ve trafo merkezlerine, oradan da tüketicilere dağıtılmaktadır (İnalı vd., 2014:62).

Ülkemizin toplam yerüstü su potansiyeli Devlet Su İşleri (DSİ) verilerine göre brüt yerüstü suyu potansiyeli 193 milyar m³ civarında belirlenmiştir. Ancak günümüz teknik ve ekonomik şartları çerçevesinde, çeşitli maksatlara yönelik olarak tüketilebilecek yerüstü suyu potansiyeli yurt içindeki akarsulardan 95 milyar m³, komşu ülkelere yurdumuza gelen akarsulardan 3 milyar m³ olmak üzere, yılda ortalama toplam 98 milyar m³'tür. 14 milyar m³ olarak belirlenen yeraltı suyu potansiyeli ile birlikte ülkemizin tüketilebilir yerüstü ve yeraltı su potansiyeli yılda ortalama toplam 112 milyar m³ olup, 44 milyar m³'ü kullanılmaktadır (www.dsi.gov.tr/toprak-ve-su-kaynaklari).

Su kaynakları potansiyelinin etkin ve verimli yönetilmesi ancak mevcut su miktarının doğru belirlenmesi ile mümkündür. Bilimsel çalışmalarda karşılaşılan veri yapısındaki belirsizlik ile hidrolojik verilerde de karşılaşılmaktadır. Bu belirsizlik ve hidrometeorolojik analiz için verilerin yetersizliği, su miktarında meydana gelen ani değişikliklerin oluşturduğu problemlere çözüm üretmeyi zorlaştırmaktadır. Bu sebeple, su seviyelerinin modellenmesi, su kaynaklarının gelecekteki potansiyelini belirleme bakımından büyük önem taşımaktadır (Gürer ve Öncü 2011:261-262).

2. ÜRETİM- ELEKTRİK ÜRETİMİ VE TAHMİNİ

İnsanlar var olduğu andan itibaren bir şeyleri üretme çabasındadırlar. Mucuk üretimi, “doğada var olan maddelerin insanların gereksinimlerini karşılayacak ürünler ve hizmetler haline dönüştürülmesi işlemi” olarak tanımlanmaktadır (1987:163). Dünya genelinde 150'den fazla ülke hidroelektrik santralleri kullanmakta (Huang ve Yan, 2009:1652) ve dünyada üretilen tüm elektriğin yaklaşık % 17'si hidroelektrik santrallerde üretilmektedir (tsp-data-portal.org). Hidroelektrik santralde akan suyun türbin kanatlarını döndürmesi ve bu kanatlara bağlı bir milin jeneratörü çevirmesi ile elektrik enerjisi üretilir.

Enerji sorunu, dünyamızın ana gündem maddesi olduğu gibi ülkemiz için de ana gündem maddesidir. Ülkemiz, enerji konusunda büyük oranda dışa bağımlılığından dolayı her yıl milyarlarca dolar ödeyerek enerji ithal etmektedir. Fosil enerji kaynakları bakımından ülke kaynaklarının yetersiz oluşu ülkemizi yeni enerji kaynakları arayışına yöneltmiştir. Konunun uzmanları mevcut enerji kaynaklarının optimal kullanılması için çalışmalar yürütürken bir

yandan da yenilenebilir enerji kaynaklarının artırılması için çözüm arayışındadırlar (Dinçer, 2011:8).

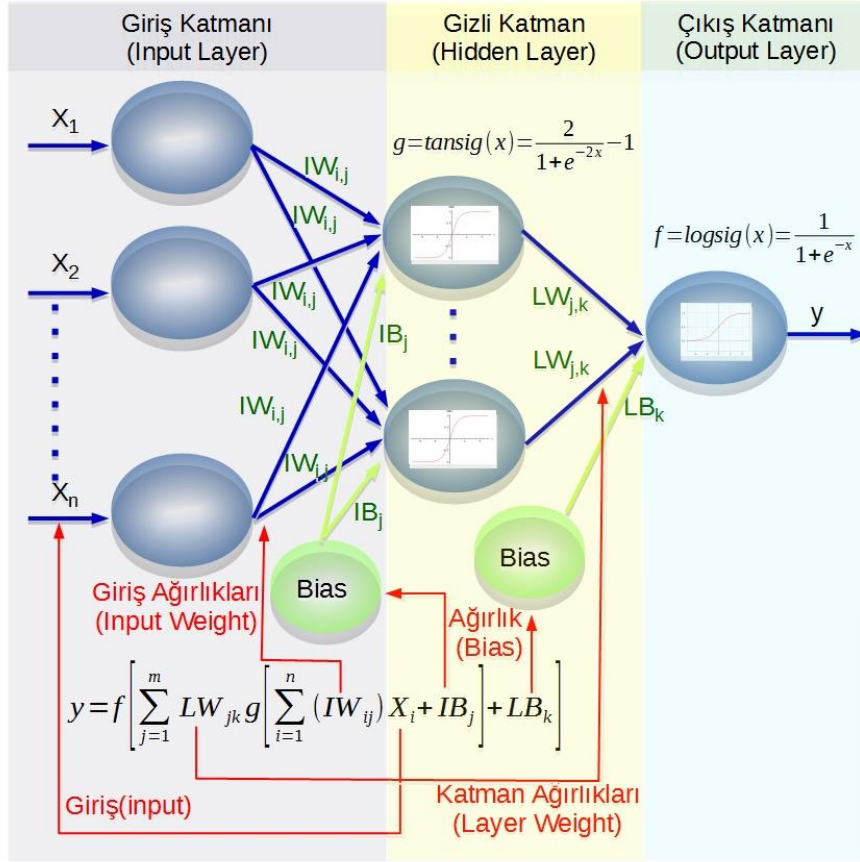
Elektrik enerjisi modern dünyanın vazgeçilmez unsurlarından birisidir. Günümüz ekonomilerinin temel bir girdisi olan elektrik enerjisi, teknolojik ilerlemelerde de büyük öneme sahiptir. Elektrik enerjisi depolanamamasından dolayı üretildiği anda tüketilmesi zorunlu olan bir enerji kaynağıdır. Dolayısıyla elektrik üretimi arz-talep dengesi gözetilerek yapılması zorunluluk arz etmektedir. Bu durum ise talep tahminlerinin önemini artırmaktadır (Akan ve Tak, 2003:21-22).

Tahminleme; üretim, pazarlama ve ekonomi alanında çalışanlar için son derece önemlidir. Geçmiş veriler yardımıyla tahmin yapmak ya da düşük hata payıyla yüksek doğruluk derecesiyle tahminler yapabilmek genellikle çok zordur. Literatürde tahminleme çalışmalarına envanter, enerji, satış, personel planlama, pazarlama, üretim planlama, meteorolojik değişimler ve ekonomik çalışmalarda sıklıkla karşılaşılmaktadır (Aydemir vd., 2014:145).

3. YAPAY SINİR AĞLARI

Biyolojik sinir sitemlerinin esinlenen yapay sinir ağları; girdi verilerini kullanarak öğrenebilen, yeni bir bilgi üretebilen, genelleme yapabilen ve sınıflama yapabilen algoritmalarıdır. YSA ağırlıkları, eğitim ve test kümesindeki bilgiler yardımıyla optimum düzeye getirilmesiyle eğitilmiş olurlar. Eğitilmiş olan YSA yardımıyla yeni bir veri girişi ile yeni bir çıkış tahmini yapılabilir (Zhang vd., 1998:35). İlk YSA modeli, bir sinir hekimi olan McCulloch ile bir matematikçi olan Pitts tarafından 1943 yılında ortaya atılmıştır. McCulloch ve Pitts, insan beyninin hesaplama işlevini modelleyerek, elektrik devreleriyle basit bir sinir ağını gerçekleştirmişlerdir. “Cybernetics” isimli kitabında Wiener, sinirlerin çalışma şekli ve davranış özelliklerini ele almıştır. “Organization of Behavior” isimli kitabında Hebb, öğrenme ile ilgili temel teoriyi ele almıştır. Hebb Kuralı; sinir ağının bağlantı sayısının değiştirilmesi ile ağın öğrenebileceğini öngörmekteydi. 1950’li yıllardan sonra araştırmacılar Hebb Kuralı’ndan esinlenerek YSA’ların hesaplama gücünü artırıcı çalışmalara yönelmişlerdir. YSA’da ki gelişmelerin hızlanması Rosentblatt’in Perceptron’u gerçekleştirmesinden sonra yaşanmıştır. Perceptron, insan beyninin işlevlerini modelleyebilmek için yapılan çalışmalar neticesinde geliştirilen tek katmanlı ve tek çıkışa sahip olan eğitilebilen ilk YSA’dır. Widrow ve Hoff ADALINE ve MADALINE diye adlandırdıkları ağ modellerini geliştirmişlerdir. Basit modellerin ilk eksiklikleri 1963 yılında fark edilmiş olup sonuçların başarıya ulaşması, termodinamikteki teorik yapıların lineer olmayan ağların geliştirilmesinde kullanılması 1980’li yıllara kadar sürmüştür (Elmas, 2007: 26-27).

Çok katmanlı bir yapay sinir ağında (MLP, Multiple Layer Perceptron) giriş katmanı (Input Layer), gizli katman (Hidden Layer) ve çıkış katmanı (Output Layer) olmak üzere üç katman bulunur. Giriş katmanı, çözülmesi istenilen probleme ait verilerin sisteme alındığı katmandır. Gizli katman, giriş katmanından çıkan bilgilerin geldiği katmandır. Problemin yapısına göre nöron sayısı ve katman sayısı değişiklik gösterir. Çıkış katmanı ise gizli katmanda hesaplanan verileri son bir işleme daha tutarak dışarıya aktaran katmandır.



Şekil 1: Çok katmanlı bir YSA genel yapısı.

X =Girdi değerleri(Input)

IW =Giriş katman nöronu ile gizli katman nöronu arasındaki ağırlık (Input Weight)

LW =Gizli katman nöronu ile çıkış katmanı nöronu arasındaki ağırlık (Layer Weight)

IB = gizli nöron için eşik değeri ağırlığı

LB = çıktı nöronu için eşik değeri ağırlığı

y =çıktı değeri(Output)

g = Hiperbolik tanjant sigmoid transfer fonksiyonu(Tansig)

f = Log-sigmoid transfer fonksiyonu(Logsig)

Şekil 1 incelendiğinde, girdi değerlerinin her biri $X_{(i)}$ bir bağlantı ağırlığıyla $IW_{(ij)}$ ile çarpılıp, $IB_{(j)}$ ile toplandıktan sonra transfer fonksiyonuna $g(x)$ ulaştırılır ve transfer fonksiyonu ağırlıklandırılmış veri için gereken çıktıyı hesaplar. Hesaplanan bu çıktı her bir $LW_{(jk)}$ bağlantı ağırlığıyla çarpılıp, $LB_{(k)}$ ile toplandıktan sonra transfer fonksiyonuna $f(x)$ ulaştırılır ve transfer fonksiyonu ağırlıklandırılmış veri için gereken nihai çıktıyı (y) hesaplar.

Günümüzde hemen hemen her alanında başarılı sonuçlar veren YSA'nın tercih edilme sebeplerinin başında; eksik bilgi ile çalışabilmesi, bulunduğu problemlere uyum

sağlayabilmesi, belirsizlikler altında karar verebilmesi, adaptif yapısı ve hatalara karşı toleranslı yapıda olması gelmektedir (Ataseven, 114:2013).

YSA'nın güçlü örüntü tanıma ve doğrusal olmayan ilişkileri öğrenip modelleme yapabilme yetenekleri son yıllarda popülaritesinin artmasının temel nedenlerindedir. Birçok model tabanlı tahmin yöntemleri aksine, YSA daha önce hiç karşılaşmadığı sorulara kabul edilebilir düşük bir hatayla cevap bulabilmekte, bağımlı ve bağımsız değişkenler arasındaki fonksiyonel ilişkiler hakkında herhangi bir kısıtlayıcı varsayımlar olmadan etkili tahmin yapabilmektedir. YSA'ların özelliği, geleceği tahmin etmede etkili bir yöntem olarak kullanılmaktadır (Zhang, 2000: 451; Yavuz ve Deveci, 2013:185).

Öğreticili öğrenme algoritması geri yayılım ağları (Back Propagation Networks-BPN) tahmin çalışmalarında sıklıkla kullanılmaktadır. Standart BPN, ağ ağırlıklarının (weight), performans fonksiyonunun geri yayımlı ilerlediği gradyan iniş algoritmasıdır. Çok sayıda çeşidi olan BPN, newton metodu ve gradyan iniş gibi optimizasyon tekniklerini kullanmaktadır. (Hamzaçebi ve Kutay, 2004:229).

Su kaynakları sistemleri lineer olmayan ve pek çok parametreye sahip karmaşık ilişkilerden oluşur. Bu tür problemler yapay sinir ağları kullanılarak etkili bir şekilde çözülebilir. Ayrıca yapay sinir ağları probleme kolayca adapte olabilmektedir. Hidroloji alanındaki çalışmalarda en yaygın olarak kullanılan yapay sinir ağ mimarisi çok katmanlı geri yayılım algoritmaları beslemeli ağ modelidir (Doğan ve Işık, 2005:4120).

4. LİTERATÜR ARAŞTIRMASI

İnsanoğlu Nil havzasındaki su taşkınlarının hayatı olumsuz etkilemesiyle birlikte akarsuların debilerini tahmin etmeyi hep gerekli görmüştür. Literatür incelendiğinde Yapay sinir ağları yöntemi ile yağış, akım, elektrik üretimi ve elektrik tüketiminin tahminlemesi konusunda yapılmış birçok çalışma bulunmaktadır.

Bugüne kadar YSA modelleri birçok araştırmacı tarafından yağış akış ilişkisini tahmin için (Hsu vd., 1995; Campolo vd., 1999; Alp ve Cıgızoğlu, 2010; Machado vd., 2011; Abrahart vd., 2012) ve baraj havzasının aylık akımlarının tahmini için (Jain vd., 1999; Can, 2012; Ünese, 2015) uygulanmıştır. Bu çalışmalarda kullanılan YSA'ların geleneksel modellere göre daha iyi sonuç verdiği tespit edilmiştir.

Rekabetin arttığı ve kâr marjlarının düştüğü günümüzde ise bir akarsuyun debisini ve hidroelektrik enerji potansiyelini tahmin büyük önem arz etmektedir. YSA ile hidroelektrik santralinin verim ve üretim değerlerinin tahmini konusunda (Coulibaly vd., 2002; Abdulkadir vd., 2012; İnallı vd., 2014) çalışılmışlardır. Ayrıca ileri beslemeli geri yayılım sinir ağları (İBGYSA) ve geri beslemeli yinelemeli yapay sinir ağları (GBYYSA) ile akım tahminleri yaparak akarsuların hidroelektrik enerji potansiyelini (Öncül, 2008; Stokelj vd., 2002), tahmin etmişlerdir.

Ekonomik ve beşeri verilerle Türkiye'nin gelecekteki net enerji tüketiminin YSA ile tahmin edilmesi konusunda (Sözen vd., 2005; Kankal vd., 2011; Es vd., 2014; Yetiş ve Jamshidi, 2014; Uygun, 2015) çalışma yürütmüşlerdir.

Bazı araştırmacılar ise Yapay Sinir ağları ve diğer sezgisel yöntemleri birlikte kullanarak hibrid modeller geliştirmişlerdir. Genetik algoritma yardımıyla parametreleri bulunan YSA modeli ile Türkiye'nin hidroelektrik üretimi ve enerji ithalat tahmin edilmesi (Çınar, 2007), genetik algoritma ve yapay sinir ağlarıyla tarım sektörünün elektrik tüketimini tahmini konusunda (Azadeh vd., 2007) ve hibrid parçacık sürü ve yapay sinir ağı ile debi tahmini

konusunda (Sedki ve Ouazar, 2010; Cheng vd., 2015) çalışmışlardır. Ayrıca bazı araştırmacılar salt genetik algoritma ile elektrik enerjisi tüketiminin tahmin edilmesi konusunda (Öztürk vd., 2005; Yiğit, 2011) çalışmışlardır.

YSA ile bir hidroelektrik santraline ait çok dönemli elektrik enerjisi üretim tahmini konusunda yapılmış bir çalışmaya literatürde karşılaşılmamıştır.

5. UYGULAMA

Bu çalışmada; Isparta ili Aksu ilçesi sınırlarında bulunan Yenice deresinden beslenen bir Hidroelektrik Santralinin 12 aylık elektrik üretimi tahmin edilmeye çalışılmıştır.

Yenice su kaynağından içme suyu ve sulama suyu ihtiyaçları karşılandıktan sonra Zindan Boğazı mevkiinde bulunan regülatör tesisinden takriben 5 km bir tünel ve 14 km lik açık betonarme ‘V’ tipi su kanalı ile Aksu Eğirdir kara yolu güzergahından, çamlık yol mevkiinde bulunan yükleme ve dinlenme havuzuna ulaşan su, bu havuzdan santral binasına kadar yaklaşık 1000 metre cebri boru ile inerek türbinleri çevirmektedir (<http://www.aksuenerji.com.tr/caykotes.aspx>).

Çalışma kapsamında Aksu ilçesinde bulunan 17865 numaralı Otomatik Meteoroloji Gözlem İstasyonu’na ait (OMGİ) Aylık Ortalama Yağış ve Aylık Ortalama Nisbi Nem ile D09A002 numaralı Zindan Boğazı Akış Gözlem İstasyonu’na (AGİ) ait Aylık Ortalama Debi verileri kullanılmıştır. İstasyonlara ait rasat yılları incelendiğinde, bu iki istasyonun veri aralığının aynı olmadığından dolayı kurulacak modele ait rasat yılları her iki istasyona uygun olan 2007-2014 aralığı seçilmiştir.

OMGİ, AGİ ve üretim verileri Microsoft Excel paket programına kaydedilip normalizasyon işlemine tâbi tutulduktan sonra MATLAB paket programına aktarılarak burada işlenmiştir.

Veri kümelerinde değeri olmayan, bilinmeyen değerler olarak adlandırılan eksik veriler, bilimsel araştırmalarda sorunlara sebep olmaktadır. Eksik veriler, değerlerin veri kümesine kayıt yapılamadığı durumlarda ortaya çıkabileceği gibi, gürültülü, aykırı veya tutarsız değerlerin tespit edilmesi sonucu veri setinden çıkarılması gibi durumlarda da oluşabilmektedir (Aydilek, 2013:19).

Bu çalışmada tek değişkenli eksik verilerin tamamlanmasında,

$$\chi_n = (\chi_{n-1} + \chi_{n+1}) / 2 \quad (1)$$

$$\chi_n = \text{Eksik veri dönemi}$$

önceki ve sonraki döneme ait verilerin ortalamasını alma yöntemi (1) kullanılmıştır.

Veri kümesi halinde eksik olan verilerin tamamlanmasında,

$$\chi_n = (\chi_{n-12} + \chi_{n-24} \dots \chi_{n+12} + \chi_{n+24}) / \chi_k \quad (2)$$

$$\chi_n = \text{Eksik veri dönemi}$$

$$\chi_k = \text{Döneme ait eksik olmayan veri âdeti}$$

mevcut döneme ait verilerin aritmetik ortalamasını alma yöntemi (2) kullanılmıştır.

Verilerin ön işleme, eğitim ve test verilerinden oluşan veri setlerinin kurulan YSA’ya uygun biçimde normalize edilmesi demektir. Normalizasyon, YSA’nın başarısını belirleyen etkenlerden biridir.

Yavuz ve Deveci (2013:185) “İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağı Performansına Etkisi” isimli çalışmalarında, hava tahminin doğruluğunu etkileyen faktörlerden birisinin de normalizasyon tekniklerinin olduğunu ifade etmiş ve yaptığı denemelerde D_Min_Max yönteminin gerçeğe yakın sonuçlar verdiğini tespit etmişlerdir.

Öncelikle modelin uygulanması için (3) de ki denklem kullanılarak tüm veriler 0,1 ile 0,9 arasında normalize edilmiştir. Normalizasyon yapılarak veriler boyutsuz hale getirilmiş olur. Bu yöntem için

$$X' = 0.8 * \frac{\chi_i - \chi_{\min}}{\chi_{\max} - \chi_{\min}} + 0.1 \quad (3)$$

X' = Normalize edilmiş veriyi,

$\chi_n = (\chi_{n-1} + \chi_{n+1}) / 2$ = Girdi değerini,

χ_{\min} = Girdi verileri içerisinde yer alan en küçük sayıyı,

χ_{\max} = Girdi verileri içerisinde yer alan en büyük sayıyı,

ifade etmektedir.

5.1. Çalışmada Kullanılan Yapay Sinir Ağı

Bu çalışmada kullanılan YSA modeli, ileri beslemeli geri yayılım ağıdır. Bu ağı tercih edilmesinin nedeni doğrusal modeldeki tahmin başarısının yanında doğrusal olmayan modellerde de başarı gösteriyor olması ve tahmin çalışmalarında yüksek başarılı sonuçlar veriyor olmasıdır.

Bir MLP ağının zaman serisi tahmininde kullanılabilmesi için doğru ağ yapısının kurulması gerekmektedir. Kurulan yapı, ağı kaç katmandan oluşacağını, her katmanda kaç nöron bulunacağını, bu nöronların hangi transfer fonksiyonunu kullanacağı işlemlerini kapsar. Çıkış nöron sayısı tahmin yapılacak dönem sayısına bağlı olarak belirlenir. Giriş nöron sayısı serinin t anındaki değerinin geçmiş kaç gözlemden etkilendiği durumuna göre belirlenir. (Kaynar ve Taşkan, 2009:165).

YSA' da giriş katmanına bağımsız değişkenler, çıktı katmanına da bağımlı değişken denk gelmektedir. YSA tarafından tahmin edilen bu ilişki:

$$Y = f(X_1, X_2, \dots, X_p) \quad (4)$$

şeklinde dir. (4) de gösterilen X' 'ler p sayıda bağımsız değişkeni, Y' 'de bağımlı değişkeni göstermektedir. Zaman dizileri kestirim problemlerinde ise girdiler verinin geçmiş değerlerini, çıktı ise gelecek değeri göstermektedir. Bu durumda fonksiyonel ilişki:

$$Y_{t+1} = f(Y_t, Y_{t+1}, \dots, Y_{t-p}) \quad (5)$$

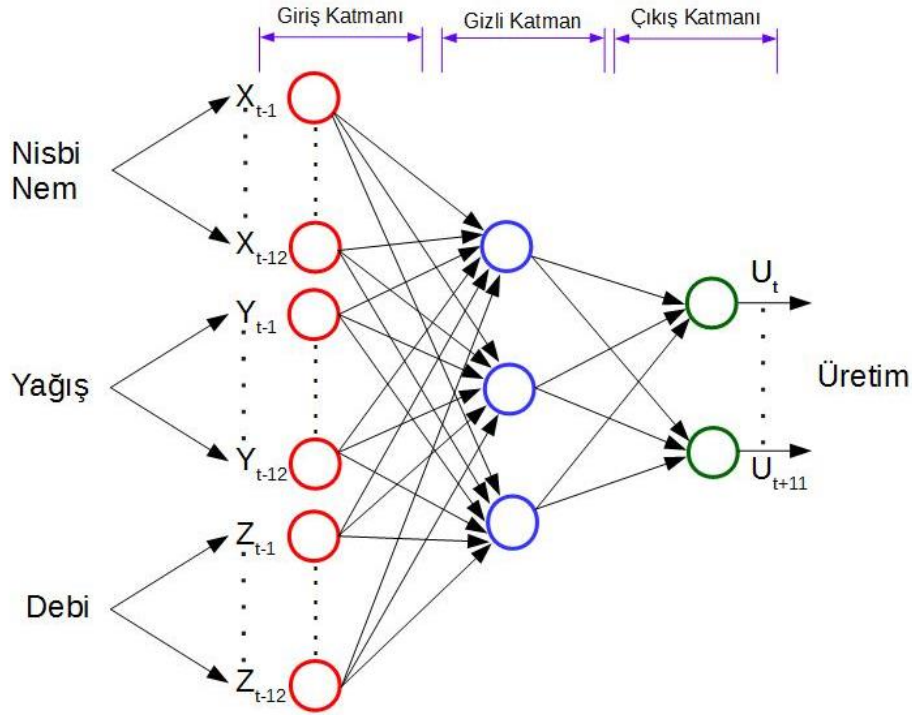
(5) de gösterildiği gibi ifade edilir.

Birden fazla dönemi aynı anda tahmin edebilen YSA modelinin çıktı katmanında birden fazla nöron kullanımıyla direkt olarak çoklu dönem kestirim yapmak mümkündür. Bu yöntem direkt metod olarak adlandırılır. Bu durumda çıktı nöronu sayısı, tahmin edilmek istenen dönem sayısına eşittir. Bu metod da, k adım kestirim için eşitlik (6) deki gibidir (Zhang vd. 1998:46)

$$\begin{aligned} \hat{X}_{t+1} &= f(X_t, X_{t-1}, \dots, X_{t-n}) \\ \hat{X}_{t+2} &= f(X_t, X_{t-1}, \dots, X_{t-n}) \\ &\vdots \\ \hat{X}_{t+k} &= f(X_t, X_{t-1}, \dots, X_{t-n}) \end{aligned} \quad (6)$$

Bu eşitlikte X_t , t anındaki gözlem değerini, \hat{X}_t t zamanında kestirim değerini, f ise YSA fonksiyonunu göstermektedir. Bu çalışmada direkt tahmin metodu kullanılmıştır.

Çalışmada kullanılan YSA modelinin, otuz altı adet girdi ve on iki adet çıktı değişkeni vardır. Model, tek ara katmanlı, ileri beslemeli geri yayımlı (feed forward backpropagation) bir sinir ağıdır. Model Şekil 2’de gösterildiği gibi, girdi katmanında ağı sunulan üç bağımsız değişkenin on iki gecikmesi alınarak otuz altı adet girdi işlemci elemanı, çıktı katmanında ise bağımlı değişkene ait on iki adet çıktı işlemci elemanı bulunmaktadır. Ara katmanda kullanılan nöron sayısı ise üç adettir. Ara katman ile çıktı katmanı için aktivasyon fonksiyonu olarak tanjant sigmoid (tansig) ve eğitim fonksiyonu olarak da trainlm - Levenberg-Marquardt backpropagation seçilmiştir. Bu çalışma için geliştirilen özel algoritmalar yardımıyla giriş sayıları, 1 ile 100 arası gizli katman nöron sayısı ve transfer fonksiyonları taranmıştır. Yapılan bu elli bin civarındaki deneme sonucunda açıklayıcılığı en yüksek olan bu modelde karar kılınmıştır.



Şekil 2: Çalışmada Kullanılan Ağ yapısı

5.2. Çalışmada Kullanılan Hata Ölçütleri

Test aşamasında ağın ürettiği tahmin sonuçları ile gerçek değerlerle karşılaştırılarak modellerinin tahmin doğrulukları Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) istatistiği ile değerlendirilmiştir.

MAPE istatistiğinin hataları yüzde olarak ifade etmesi ve tek başına da bir anlamının oluşu, diğer yöntemlere göre üstünlük sağlamaktadır (Çuhadar, 2013:5287). Matematiksel ifadesi (7) gösterildiği gibidir.

$$MAPE = \frac{1}{T} \sum \left| \frac{y_t - \hat{y}_t}{y_t} \right| * 100 \quad (7)$$

Burada;

y_t = Gerçek gözlem değerleri,

\hat{y}_t = Tahmin edilen değerleri,

T = Tahmin sayısıdır.

Witt ve Witt (1992) çalışmalarında MAPE değeri %10'un altında olan modeller "çok iyi tahmin kabiliyeti olan modeller", %10 ile %20 arasında olan modeller "iyi tahmin kabiliyeti olan modeller", %20 ile %50 arasında ki modelleri "kabul edilebilir tahmin kabiliyeti olan modeller" ve %50'nin üzerinde olan modelleri ise "kötü tahmin kabiliyeti olan modeller" olarak sınıflandırmışlardır.

Hata Kareleri Ortalamasının Karekökü (Root Mean Square Error-RMSE), gerçek değerler ile tahmin değerleri arasındaki hata oranını belirlemek için kullanılmaktadır. RMSE değerinin düşük olması, kurulan modelin tahmin kabiliyetinin yüksek olduğu anlamına gelmektedir. RMSE'nin hesaplanması (8) gösterildiği gibidir (Singh vd., 2009).

$$RMSE = \sqrt{\frac{\sum (y_t - \hat{y}_t)^2}{T}} \quad (8)$$

Literatürde tahmin doğruluk ölçütleri içinde en sık kullanılan Ortalama Hata Kareleri (Mean Square Error-MSE) (9) yöntemidir. Tahmin hatasının varyans toplamlarına ayrıştırılabilmesi özelliği bu ölçütün önemli bir üstünlüğüdür. Bu özellik, bu ölçütün sadece gerçek ve tahminlere ait birleşik dağılımın ikinci momenti ile ilişkili olduğunu göstermektedir (Zhang, 1998:52).

$$MSE = \frac{\sum (y_t - \hat{y}_t)^2}{T} \quad (9)$$

5.3. Yapay Sinir Ağının Eğitimi ve Testi

Eşit aralıklar ile tekrarlanan düzenli değişimlere mevsimlik denir. Mevsimsellik zaman serilerinde gözlenen sorunlardan birisidir. Mevsimsel modellerde, veri setindeki yılların aynı dönemlerine ait değerler arasında ilişki bulunmaktadır (Özer ve İlkdoğan, 2013:15).

Mevsimsel zaman serileri, mevsimlik tekrarlar gösterdiği için bu çalışmada literatürde de önerildiği gibi bağımsız değişkenlerin 12 aylık gecikmesi alınmıştır (Hamzaçebi, 2008:20; Zhang, 2005:506; Tseng vd., 2002:81). Değişkenlerin 12 gecikmeli değerleri kullanıldığı için her bir bağımsız değişken için 12 adet veri kaybı olmuştur. Şekil 2’de gösterilen t birbirini izleyen aynı mevsimsel değerler arasındaki zaman aralığını temsil etmektedir. Aylık zaman serilerinde t=12, üç aylık zaman serilerinde t=4 olarak alınmaktadır.

Ağın öğrenmesi için 2008 ile 2012 dönemine ait 60 aylık veri eğitim verisi olarak ağa girilmiştir. MSE, MAPE, RMSE ve R değerleri Tablo 1’de gösterildiği gibidir. Eğitim veri seti için korelasyon katsayısının yüksek olması ve RMSE, MSE, MAPE değerlerinin düşük olması ağın iyi öğrendiğini kanıtlamıştır.

Eğitim kümesi ağın öğrenmesi için kullanılırken doğrulama kümesi en iyi modelin seçiminde yardımcı olmaktadır. Böylece fazla eğitilmiş bir ağ ile tahminde bulunma riskinin azaltılması mümkündür (Hamzaçebi, 2005:123). 2013 yılına ait veriler doğrulama verisi olarak kullanılmıştır.

Test aşamasında ise bağımsız değişkene ait 2014 yılı verileri ağa gösterilerek 2014 yılı üretim değerlerini tahmin etmesi istenmiştir. Test işlemi MAPE değerinin Tablo 1’de görüldüğü gibi 10% un altına düşürülene kadar sürdürülmüştür. Elde edilen 7,1434% değeri için 2014 yılına ait gerçek değerler ile tahmin değerlerinin grafiği Şekil 3’de gösterilmiştir.

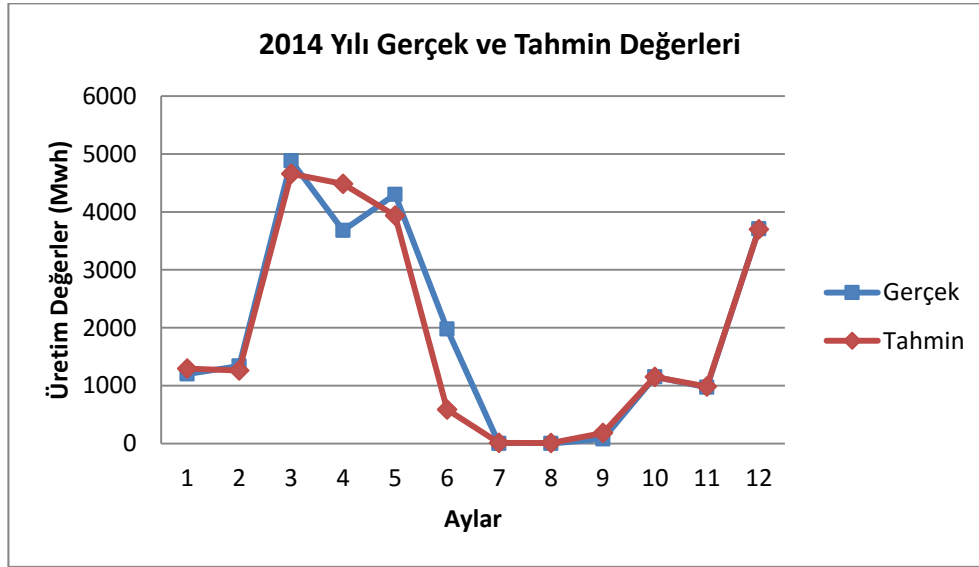
Tablo 1: Öğrenme, Doğrulama ve Test Değerleri İçin Hesaplanan MSE, MAPE, RMSE ve R Değerleri

	2008-2012 Yılı Verileri (Öğrenme)	2013 Yılı Verileri (Doğrulama)	2014 Yılı Verileri (Test)
MSE	0,0038	0,0004	0.0014
MAPE	14,645	8,2172	7,1434
RMSE	0,0622	0,0204	0.0374
R	0.9655	0.9975	0.9614

Elektrik enerjisi günümüzde en çok harcanan ve hayatımızın her alanına girmiş olan enerji çeşididir. Elektrik enerjisinin diğer enerjilere kolaylıkla dönüştürülebilmesi, bu dönüşüm veriminin yüksek olması ve üretildiği yerden kullanılacak yere iletiminin kolay olması tercih sebebidir. Geniş kullanım alanı olan bu temiz enerjinin depolanamamasından dolayı yüksek doğrulukta üretim tahminini önemli hale getirmektedir. Geliştirilen modelin ürettiği tahmin değerlerinin doğruluğu düşük RMSE ve yüksek R katsayısı ile kanıtlanmıştır. Tablo 1’de ki sonuçlar, kurulan YSA modelinin girdi ve çıktı değişkenleri arasındaki ilişkiyi yüksek oranda tanımlayabildiğini ve çıktı değerlerinin yüksek doğrulukla tahmin edebildiğini göstermektedir.

Tablo 2: 2014 Yılı'nın Gerçek Üretim Değeri ve YSA'nın Tahmin Sonucu (Mwh)

GERÇEK	TAHMİN
1200,876	1294,022
1339,428	1260,104
4881,336	4658,607
3679,908	4484,142
4302,318	3936,568
1977,249	586,719
0	11,452
0	8,904
78,279	182,282
1149,253	1149,604
969,247	984,716
3706,639	3697,771



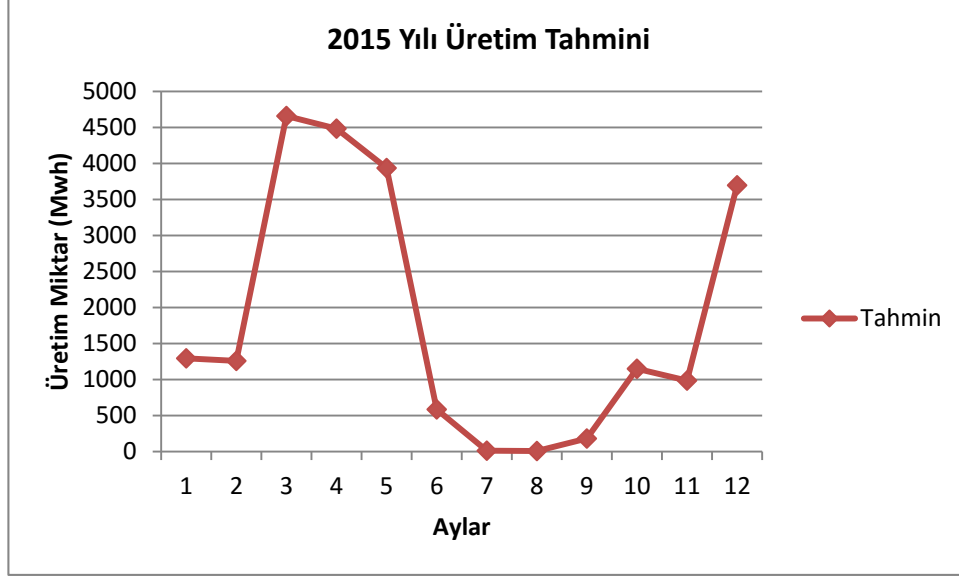
Şekil 3: 2014 Yılına Ait Tahmin Değerleri İle Gerçek Değerlerinin Grafiği

5.4. Kurulan YSA Modeli ile Geleceğe Ait Tahmin Elde Edilmesi

Uygulamanın bu kısmında gelecekte gerçekleşmesi beklenen 2015 yılına ait elektrik üretiminin tahmin edilmesi adımına geçilmiştir. 2015 yılına ait Aylık Ortalama Debi verileri 2016 yılı sonlarına doğru açıklanacaktır. Bu sebepten dolayı 2014 verileri kullanılarak 2015 yılı elektrik üretimi tahmin edilmiştir.

YSA modeline, tahmin yapmak istediğimiz dönemle ilişkili (8)'deki metot da gösterildiği şekilde veri girişleri yapıp, modelden gelecek 12 aylık dönem için tahmin üretmesi

istenmiştir. 2015 yılına ait 12 aylık üretimi 38.438,44 Mwh olarak tahmin edilmiş ve Şekil 4’de gösterilmiştir.



Şekil 4: 2015 Yılı Üretim Tahmini

6. SONUÇLAR

Tahminleme; üretim, pazarlama ve ekonomi alanında çalışanlar için son derece önemlidir. Elektrik enerjisinin depolanamaması, arz-talep dengesinin planlanmasını ve yüksek doğruluk dereceli üretim tahmininin önemini artırmaktadır. Yapılacak tahminlerin doğruluğu, yapılan planlama çalışmalarının da geçerliliğini artıracaktır.

Bu çalışmada, Türkiye'nin en büyük yenilenebilir enerji potansiyeli olan hidroelektrik enerjisinin üretim tahmini yapılmıştır. Akıllı sistem uygulamalarının bir türü olan YSA ile Aksu HES için 2007-2013 yılları arasındaki meteorolojik veriler kullanılarak 2014 yılına ait 12 aylık üretim aktif üretim değeri yüksek doğrulukta ve düşük hatalarla tahmin edilmiştir. Kurulan model test aşamasında başarı ile geçtikten sonra gelecekte gerçekleşmesi beklenen 2015 yılına ait 12 aylık elektrik üretimi tahmin edilmiştir. Bu çalışma diğer hidroelektrik santrallerine de uygulanarak, elektrik piyasasının arz talep dengesi için bir kaynak oluşturması sağlayabilecektir.

KAYNAKÇA

- ABDULKADIR, T. S., SULE, B. F. and SALAMI, A. W. (2012). "Application Of Artificial Neural Network Model To The Management Of Hydropower Reservoirs Along River Niger", Nigeria. *Annals of the Faculty of Engineering Hunedoara*, 10(3): 419-424.
- ABRAHART, R. J., ANCTIL, F., COULIBALY, P., DAWSON, C. W., MOUNT, N. J., SEE, L. M. and WILBY, R. L. (2012). "Two Decades Of Anarchy? Emerging Themes And Outstanding Challenges For Neural Network River Forecasting", *Progress in Physical Geography*, 36(4): 480-513.
- AKAN, Y. ve TAK, S. (2003). "Türkiye Elektrik Enerjisi Ekonometrik Talep Analizi", *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 17(1-2): 21-49.
- ALP, M. ve CİĞİZOĞLU, H. K. (2010). "Farklı Yapay Sinir Ağı Metodları İle Yağış-Akış İlişkisinin Modellenmesi", *İTÜ DERGİSİ/d*, 3(1): 80-88.
- AYDEMİR, E., KARAATLI, M., YILMAZ, G. ve AKSOY, S. (2014). "112 Acil Çağrı Merkezine Gelen Çağrı Sayılarını Belirleyebilmek İçin Bir Yapay Sinir Ağları Tahminleme Modeli Geliştirilmesi", *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 20(5): 145-149.
- AYDILEK, İ. B. (2013). *Veri Kümelerindeki Eksik Değerlerin Yeni Yaklaşımlar Kullanılarak Hesaplanması*, Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Konya.
- AKSU ENERJİ. (2016). <http://www.aksuenerji.com.tr/caykotes.aspx>, 15.03.2015.
- ATASEVEN, B. (2013). "Yapay Sinir Ağları ile Öngörü Modellemesi", *Öneri*, 10 (39), ss. 101-115.
- AZADEH, A., GHADERI, S. F., TARVERDIAN, S. and SABERI, M. (2007). "Integration Of Artificial Neural Networks And Genetic Algorithm To Predict Electrical Energy Consumption", *Applied Mathematics and Computation*, 186(2): 1731-1741.
- CAMPOLO, M., ANDREUSSI, P. and SOLDATI, A. (1999). "River Flood Forecasting With A Neural Network Model". *Water Resour. Res.*, 35(4):1191-1197.
- CAN, M. (2012). *Yapay Sinir Ağları İle Akım Tahmini: Mahmudiye Göleti Örneği*, Doktora, İstanbul Kültür Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- CHENG, C. T., NIU, W. J., FENG, Z. K., SHEN, J. J. and CHAU, K. W. (2015). "Daily Reservoir Runoff Forecasting Method Using Artificial Neural Network Based On Quantum-Behaved Particle Swarm Optimization", *Water*, 7(8):4232-4246.
- ÇINAR, D. (2007). *Hidroelektrik Enerji Üretiminin Hibrid Bir Model İle Tahmini*, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- COULIBALY, P., ANCTIL, F. and BOBÉE, B. (2000). "Neural Network Based Long Term Hydropower Forecasting System", *Computer-Aided Civil and Infrastructure Engineering*, 15(5): 355-364.
- ÇUHADAR, M. (2013). "Türkiye'ye Yönelik Dış Turizm Talebinin Mlp, Rbf Ve Tdnn Yapay Sinir Ağı Mimarileri İle Modellenmesi Ve Tahmini: Karşılaştırmalı Bir Analiz", *Journal of Yaşar University*, 8(31): 5274-5295.
- DEVLET SU İŞLERİ. (2016). <http://www.dsi.gov.tr/toprak-ve-su-kaynaklari>, 16.06.2016

- DİNÇER, F. (2011). "Türkiye’de Güneş Enerjisinden Elektrik Üretimi Potansiyeli-Ekonomik Analizi ve AB Ülkeleri ile Karşılaştırmalı Değerlendirme", KSU Mühendislik Dergisi, 14(1): 8-17.
- DOĞAN, E. ve IŞIK, S. (2005). Sapanca Gölü Günlük Buharlaştırma Miktarının Radyal Temelli Yapay Sinir Ağı Modeli Kullanarak Tahmin Edilmesi, Bilimde Modern Yöntemler Sempozyumu 16-18 Kasım, Kocaeli, 807-814.
- ELMAS, Ç. (2003). Yapay Sinir Ağları, Seçkin Yayıncılık, Ankara.
- ES, H. A., KALENDER, F. Y. ve HAMZAÇEBİ, C. (2014). "Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini", Gazi Üniv. Müh. Mim. Fak. Der, 29(3): 495-504.
- GÜRER, İ. ve ÖNCÜ, M. (2011). Yağış Akış Modellemesi (Ihacres); Konya Kapalı Havzası, Kozanlı Ve Samsam Gölleri Havzası Örneği, II. Su Yapıları Sempozyumu, 16-18 Eylül 2011, Diyarbakır, 261-272
- HAMZAÇEBİ, C. (2005). Geleceği Tahminde Yapay Sinir Ağları İçin Sezgisel Öğrenme Algoritması, Gazi Üniversitesi, Doktora Tezi, Fen Bilimleri Enstitüsü, Ankara.
- HAMZAÇEBİ, C. ve KUTAY, F. (2004). "Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini", Gazi Üniv. Müh. Mim. Fak. Der., 19(3): 227-233.
- HAMZACEBI, C. (2008). "Improving Artificial Neural Networks’ Performance In Seasonal Time Series Forecasting", Information Sciences, 178(23): 4550-4559.
- HSU, K. L., GUPTA, H. V. and SOROOSHIAN, S. (1995). "Artificial Neural Network Modeling Of The Rainfall Runoff Process", Water resources research, 31(10): 2517-2530.
- HUANG, H. and YAN, Z. (2009). "Present Situation And Future Prospect Of Hydropower In China", Renewable and Sustainable Energy Reviews, 13(6):1652-1656.
- İNALLI, K., IŞIK, E. ve DAĞTEKİN, İ. (2014). "Karakaya HES’de Verim Ve Üretim Parametrelerinin Yapay Sinir Ağı İle Tahmini", Dicle Üniversitesi Mühendislik Fakültesi Dergisi, 5(1): 59-68.
- JAIN, S. K., DAS, A. and SRIVASTAVA, D. K. (1999). "Application Of ANN For Reservoir Inflow Prediction And Operation", Journal of Water Resources Planning and Management, 125(5): 263-271.
- KANKAL, M., AKPINAR, A., KÖMÜRÇÜ, M. İ. and ÖZŞAHİN, T. Ş. (2011). "Modeling And Forecasting Of Turkey’s Energy Consumption Using Socio-Economic And Demographic Variables", Applied Energy, 88(5):1927-1939.
- KAYNAR, O. ve TAŞTAN, S. (2009), "Zaman Serisi Analizinde Mlp Yapay Sinir Ağları Ve Arıma Modelinin Karşılaştırılması", Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 33: 161-172.
- MACHADO, F., MINE, M., KAVISKI, E. and FILL, H. (2011). "Monthly Rainfall–Runoff Modelling Using Artificial Neural Networks", Hydrological Sciences Journal–Journal des Sciences Hydrologiques, 56(3): 349-361.
- MUCUK, İ. (1987). Modern İşletmecilik, 3. Baskı, Türkmen Kitapevi, İstanbul.

- OZTURK, H. K., CEYLAN, H., CANYURT, O. E., and HEPBASLI, A. (2005). "Electricity Estimation Using Genetic Algorithm Approach: A Case Study Of Turkey. Energy", 30(7): 1003-1012.
- ÖNCÜL, M., (2008). Aşağı Sakarya Havzasındaki Küçük Akarsuların Yapay Sinir Ağları Yöntemiyle Akım Süreklilik Eğrilerinin Elde Edilerek Enerji Potansiyellerinin Tespiti, Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- ÖNÖZ B. ve ALBOSTAN A. (2007). Hidroelektrik Santral Planlama ve İşletmesinde Yüksek Akımların Mevsimselliğinin Belirlenmesi, TMMOB Türkiye VI. Enerji Sempozyumu – Küresel Enerji Politikaları ve Türkiye Gerçeği, Ankara, 196-206.
- ÖZER, O. O. ve İLKDOĞAN. U. (2013). "Box-Jenkins Modeli Yardımıyla Dünya Pamuk Fiyatının Tahmini", JOTAF/Tekirdağ Ziraat Fakültesi Dergisi, 10(2), 13-20.
- SEDKI, A. and OUAZAR, D. (2010). "Hybrid Particle Swarm and Neural Network Approach For Streamflow Forecasting", Mathematical Modelling of Natural Phenomena, 5(07): 132-138.
- SINGH, K.P., BASANT, A., MALIK, A. and JAIN, G. (2009). "Artificial Neural Network Modeling Of The River Water Quality—A case Study", Ecological Modelling, 220(6), 888-895.
- SOZEN, A., ARCAKLIOGLU, E. and OZKAYMAK, M. (2005). "Modelling Of Turkey's Net Energy Consumption Using Artificial Neural Network", International Journal of Computer Applications in Technology, 22(2-3), 130-136.
- STOKELJ, T., PARAVAN, D. and GOLOB, R. (2002). "Enhanced Artificial Neural Network Inflow Forecasting Algorithm For Run-Of-River Hydropower Plants", Journal of Water Resources Planning and Management, 128(6): 415-423.
- THE SHIFT PROJECT DATA PORTAL. (2016). <http://www.tsp-data-portal.org/Breakdown-of-Electricity-Generation-by-Energy-Source#tspQvChart>, (16.06.2016).
- TSENG, F. M., YU, H. C. and TZENG, G. H. (2002). "Combining Neural Network Model With Seasonal Time Series ARIMA Model", Technological Forecasting and Social Change, 69(1): 71-87.
- UYGUN, İ. (2015). Yapay Sinir Ağları Yardımıyla Enerji Sektöründe Talep Tahmini, Marmara Üniversitesi, Yüksek Lisans Tezi, Sosyal Bilimler Enstitüsü, İstanbul.
- UNES, F., DEMIRCI, M. and KISI, Ö. (2015). "Prediction Of Millers Ferry Dam Reservoir Level In USA Using Artificial Neural Network", Periodica Polytechnica. Civil Engineering, 59(3): 309.
- WITT, S. F. and WITT, C. A. (1992). "Modeling and Forecasting Demand in Tourism", Academic Press, Londra.
- YAVUZ, S. ve DEVECİ, M. (2012). "İstatistiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi", Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, (40): 167-187.
- YETIS, Y. and JAMSHIDI, M. (2014). "Forecasting Of Turkey's Electricity Consumption Using Artificial Neural Network", In World Automation Congress (WAC), 723-728.

- YİĞİT, V. (2011). “Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini”, *International Journal of Engineering*, 3(2): 37-41.
- ZHANG, G. P. (2000). “Neural Networks For Classification: A Survey”, *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 30(4): 451-462.
- ZHANG, G. P. and MIN, Q. (2005). "Neural Network Forecasting For Seasonal And Trend Time Series", *European Journal Of Operational Research*, 160(2): 501-514.
- ZHANG, G. P., PATUWO, B. E. and HU, M. Y. (1998). “Forecasting With Artificial Neural Networks: The State Of The Art”. *International Journal Of Forecasting*, 14(1): 35-62.