

İSTATİKSEL NORMALİZASYON TEKNİKLERİNİN YAPAY SİNİR AĞIN PERFORMANSINA ETKİSİ

Selahattin YAVUZ*
Muhammet DEVECİ**

ÖZ

Son yıllarda, yapay sinir ağları pek çok alanda uygulanan ve üzerinde en çok araştırma yapılan yöntemlerden birisidir. Yapay sinir ağ teknikleri karmaşık ve doğrusal olmayan modellerde etkilidir. YSA araştırmaları; sınıflandırma, optimizasyon, tahmin, şekil tanıma, modelleme ve öğrenme gibi birçok alanda kullanılmaktadır. Bu çalışmada yapay sinir ağlarının genel yapısı ve çalışma mimarisi tanıtılmıştır. Uygulama kısmında yapay sinir ağları ile Adana ili için hava sıcaklık tahmini yapılmıştır. Çeşitli istatistiksel normalizasyon teknikleri öğrenme yöntemleri ile birlikte kullanılmıştır. Sonuç olarak; yapay sinir ağlarının öğrenme ve veri normalizasyon teknikleri ile geleceği tahmin etmede başarıyla kullanılabileceği ortaya konulmuştur.

Anahtar Kavramlar: Normalizasyon, Yapay Sinir Ağları, Tahmin.

THE EFFECT OF STATISTICAL NORMALIZATION TECHNIQUES ON THE PERFORMANCE OF ARTIFICIAL NEURAL NETWORK

ABSTRACT

In recent years, artificial neural networks have been applied in many areas and it is one of the most commonly researched methods. Artificial Neural Network (ANN) techniques are effective for the complex and non-linear models. ANN research techniques are applied to various fields such as classification, optimization, forecasting, recognition, modeling and learning. This paper introduces basic structure and working architecture of artificial neural networks. Weather temperature has been estimated for Adana city with artificial neural networks for the application part. The various statistical normalization techniques used with by combination of learning techniques. As a conclusion, it has been shown that artificial neural networks can be used successfully to estimation future by using data normalization and learning techniques.

Keywords: Normalization, Artificial Neural Networks, Estimation.

* Yrd. Doç. Dr., Erzincan Üniversitesi, İİBF, İşletme Bölümü.

** Arş. Gör. Erzincan Üniversitesi, İİBF, İşletme Bölümü.

Makalenin kabul tarihi: Şubat 2013.

GİRİŞ

İnsan beyni hakkındaki çalışmalar binlerce yıl öncesine dayanır. Modern elektriğin gelişmesi ile birlikte bu konudaki çalışmalar hız kazanmıştır. İlk yapay sinir ağı modeli 1943 yılında, bir sinir hekimi olan Warren McCulloch ile bir matematikçi olan Walter Pitts tarafından gerçekleştirilmiştir. McCulloch ve Pitts, insan beyninin hesaplama yeteneğinden esinlenerek, elektrik devresiyle basit bir sinir ağı modellemiştir. 1948 yılında Wiener "Cybernetics" isimli kitabında sinirlerin çalışması ve davranış özelliklerine değinmiştir. 1949' da ise Hebb "Organization of Behavior" isimli kitabında, öğrenme ile ilgili temel teoriyi ele almıştır (Elmas, 2003: 27).

Yapay sinir ağları, insan beynindeki sinir hücrelerinin (nöron) bilgisayar ortamında matematiksel modellenmiş durumudur. Yapay sinir ağlarında kullanılan öğrenme algoritmaları, klasik bilgisayar algoritmalarından farklıdır. Bu algoritmalar insan beyninin sezgisel gücünü içinde taşırlar. Bu sebeple, birçok bilim dalı yapay sinir ağlarıyla ilgilenmektedir. Genellikle, yapay sinir ağlarıyla oluşturulan modeller zaman serisi analizi, optimizasyon (eniyleme), sınıflandırma, ilişkilendirme veya doğrusal olmayan sistem modellemelerinde kullanılmaktadır (Warner, Misra, 1996: 284-293).

Yapay sinir ağları, insan beyninin özelliklerinden esinlenerek; öğrenme yoluyla yeni bilgiler türetebilme, keşfetme ve oluşturma gibi yetenekleri herhangi bir yardım almadan otomatik olarak gerçekleştirmek amacıyla geliştiren bilgisayar sistemleridir. Bu yeteneklerin gerçekleştirilmesi geleneksel programlama yöntemleriyle çok zordur. Bu nedenle, yapay sinir ağlarını mümkün olmayan olaylar veya programlanması çok zor olan olaylar için geliştirilmiş bilgi işlemeyle ilgilenen bir bilgisayar bilim dalı olduğu söylenebilir (Öztemel, 2003: 29). Bir sinir ağının en temel bileşenin, beynin yapısından esinlenerek geliştirilmelerine karşın, bazı özellikleri beyin ile aynı değildir. Bazı özelliklerinin ise beyinde biyolojik karşılığı yoktur. Bununla birlikte, sinir ağları biyolojik beyinle büyük benzerlikler gösterirler (Elmas, 2003: 30).

Yapay sinir ağları son yıllarda oldukça ilgi gören bir modelleme tekniğidir. Biyolojik sinir sisteminin çalışma düzenini örnek alarak işler. Bir yapay zeka tekniği olan Yapay Sinir Ağı (YSA); veri sıkıştırma, sinyal filtreleme, tanıma, sınıflandırma, analiz, tahminleme ve eniyileme konularında kullanılan etkili bir tekniktir. Geleneksel yöntemler, yanlış sonuçların elde edilmesi riski nedeniyle eksik veya aşırı sapma içeren veriler için uygun değildir. Öte yandan, YSA yaklaşımı ise, verilere bağlı olmayıp; eksik, kısmen hatalı veya aşırı sapmalı verileri değerlendirebilir. Hatta karmaşık ilişkileri öğrenebilir, genellebilir ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilir (Öztemel, 2003: 13-29).

Bu çalışmada Adana ili'nin hava sıcaklık tahmini için kullanılan faktörler; maksimum sıcaklık, minimum sıcaklık, rüzgâr, nem, güneşlenme süresi, açık

yüzey buharlaşması, güneş radyasyonu ve basınçtır. Sıcaklık tahmini için yapay sinir ağları ile tahmin modelleri geliştirilmiş ve geliştirilen modellerin tahmin yeteneği karşılaştırılmıştır. Yapay sinir ağları yaklaşımının klasik istatistiksel yöntemlere göre avantajı, verilerin dağılımıyla ve değişkenlerle ilgili varsayımlara gereksinim duymamasıdır. Yapay sinir ağları, bazı değişkenlere ait eksik verileri de tolare etme özelliğine sahiptir.

Bu çalışmada amaç, yapay sinir ağlarının girdilerine (ham veri setine) farklı normalizasyon metotları uygulayarak bunların performansını ve doğruluk derecesini tartışmaktır. Verinin normalize edilmesinin yapay sinir ağı performansını iyileştireceği literatürde gösterilmiştir (Masters, 1993: 1-12). Diyabet hastaların sınıflandırılmasında farklı istatistiksel normalizasyon teknikleri kullanılarak ağın performansı test edilmiş ve ilginç sonuçlar bulunmuştur (Jayalakshmi, Santhakumaran, 2011: 89-93). Hastaların kuyrukta bekleme süresi tahmini için uygulanan normalizasyon yöntemlerinden elde edilen tahmin sonuçlarının değerlendirilmesi neticesinde, en yüksek tahmin doğruluğunu sağlayan ve gerçek değerlere en yakın sonuçları veren yöntemin, "D_Min_Maks" normalizasyon olduğu görülmüştür (Deveci, 2012: 84-90). Bizim çalışmamızda ise, hava tahmininde farklı normalizasyon teknikleri kullanılarak ağlar eğitilmiş ve bunların sonuçları karşılaştırılmıştır. Bu normalizasyon tekniklerinin neticesinde farklı sonuçlar bulunmuştur.

I. YAPAY SİNİR AĞLARI

İnsan beyin fonksiyonundan esinlenen yapay sinir ağları (YSA), deneme yolu ile öğrenme ve genelleştirme yapabilmektedir. YSA'nın kullanıldığı önemli alanlardan biri de geleceği tahmindir. YSA, veriler arasındaki bilinmeyen ve fark edilmesi güç ilişkileri ortaya çıkartabilir. YSA'nın eğitilebilmesi ve hedef çıktılara ulaşılması için çok sayıda girdi ve girdilere ilişkin çıktı dizisine gereksinim duyulur. YSA, insan beyninin fonksiyonel özelliklerine benzer şekilde,

- Öğrenme,
- Optimizasyon,
- Analiz,
- Sınıflandırma,
- Genelleme,
- İlişkilendirme.

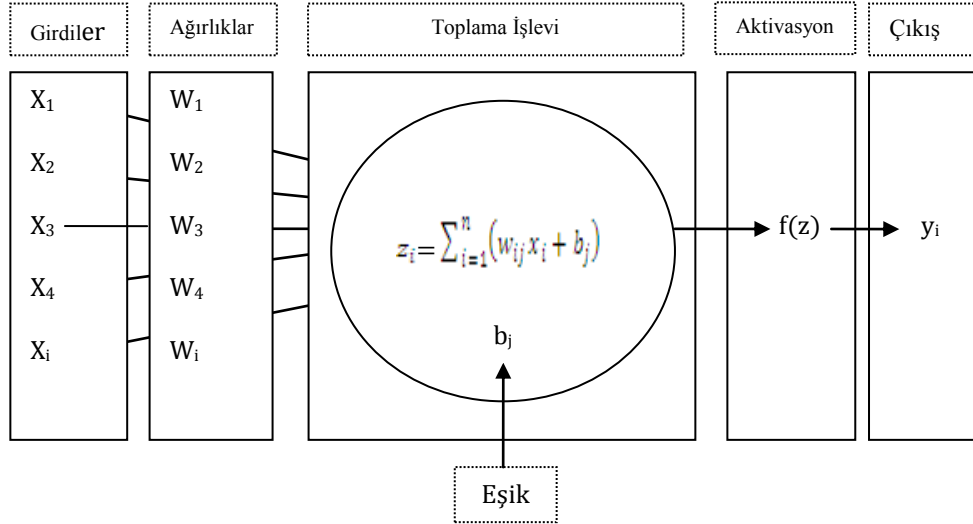
gibi konularda başarılı bir şekilde uygulanmaktadır (Öztemel, 2003:29). YSA günümüzde birçok probleme çözüm üretebilme yeteneğe sahiptir. YSA, girdi ve çıktı değişkenleri arasındaki herhangi bir ön bilgiye ihtiyaç duymadan ve herhangi bir varsayımda bulunmadan doğrusal olmayan modellemeyi sağlayabilmektedir. Ağa, girdi bilgileri ve bu girdilere karşılık gelen çıktı bilgileri verilmekte ve ağın girdi-çıkıtı arasındaki ilişkiyi öğrenmesi sağlamaktadır. Böy-

lece ağın eğitimi gerçekleştirilmektedir. Öğreticili öğrenme olarak adlandırılan bu yöntem, genelde tercih edilen bir yöntemdir.

A. YAPAY SINIR HÜCRESİ

YSA'nın çalışmasına esas teşkil eden en küçük birimler, yapay sinir hücresi ya da işlem elemanı olarak isimlendirilir. En basit yapay sinir hücresi, Şekil 1'de de görüleceği üzere; girdiler, ağırlıklar, toplama (birleştirme) fonksiyonu, aktivasyon (transfer) fonksiyonu ve çıkış olmak üzere beş ana bileşenden oluşmaktadır.

Şekil 1: Yapay Sinir Hücresi



Girdiler x_i sembolüyle gösterilmiştir. Bu girdilerin her biri (1) nolu eşitlikte gösterildiği gibi ağırlık (w_{ij}) ile çarpılır ve eşik değeri (b_j) ile toplanır. Sonra sonucu oluşturmak üzere etkinlik işlevi veya aktivasyon fonksiyonu ile işlem yapıp y_i çıkışı elde edilir.

Girdiler: Bir yapay sinir hücresine dış dünyadan gelen bilgilerdir. Dış dünyadan veya bir önceki katmandan alınan bilgiler giriş olarak yapay sinir hücrelerine gönderilir (Özveren, 2006: 7).

Ağırlıklar: Ağırlıklar bir yapay hücreye gelen bilginin önemini ve nöron üzerindeki etkisini gösterir (Öztemel, 2003: 90). Ağırlıklar ($w_1, w_2, w_3, \dots, w_i$), yapay sinir tarafından alınan girişlerin sinir üzerindeki etkisini belirleyen uygun katsayılarıdır (Elmas, 2003: 35).

Toplam Fonksiyonu: Bu fonksiyon, bir hücreye gelen net girdiyi hesaplar.

$$z_i = \sum_{i=1}^n (w_{ij}x_i + b_j) \quad (1)$$

Toplam fonksiyonu sonucunda elde edilen değer, doğrusal ya da doğrusal olmayan türevlenebilir bir aktivasyon fonksiyonundan geçirilerek işlem elemanının çıktısı hesaplanır. Bu durum (2) nolu eşitlikte gösterilmiştir.

$$y = f(z_i) = f\left(\sum_{i=1}^n (w_{ij}x_i + b_j)\right) \quad (2)$$

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu girdi ve çıktı birimleri arasındaki eğrisel eşleşmeyi sağlar. Aktivasyon fonksiyonunun doğru seçilmesi, ağın performansını önemli derecede etkiler (Hwang, Ding, 1997: 748-757). Genellikle hatayı minimum yapan, günümüzde en yaygın olarak kullanılan Çok Katmanlı Algılayıcı modelinde genel olarak aktivasyon fonksiyonu olan sigmoid fonksiyonu kullanılmaktadır (Oztemel, 2003: 50-51).

Kullanılan aktivasyon fonksiyonuna göre çıktı değeri genellikle $[-1,1]$ veya $[0,1]$ arasındadır. Bu genellikle doğrusal olmayan bir fonksiyondur. Doğrusal olmayan aktivasyon fonksiyonlarının kullanılması yapay sinir ağlarının karmaşık ve çok farklı problemlere uygulanmasını sağlamıştır. En çok kullanılan aktivasyon fonksiyonları sigmoid (3) nolu eşitlikte ve hiperbolik tanjant ise (4) nolu eşitlikte gösterilmiştir.

$$f(z_i) = \frac{1}{1 + e^{-z_i}} \quad (3)$$

$$f(z_i) = \frac{e^{z_i} - e^{-z_i}}{e^{z_i} + e^{-z_i}} \quad (4)$$

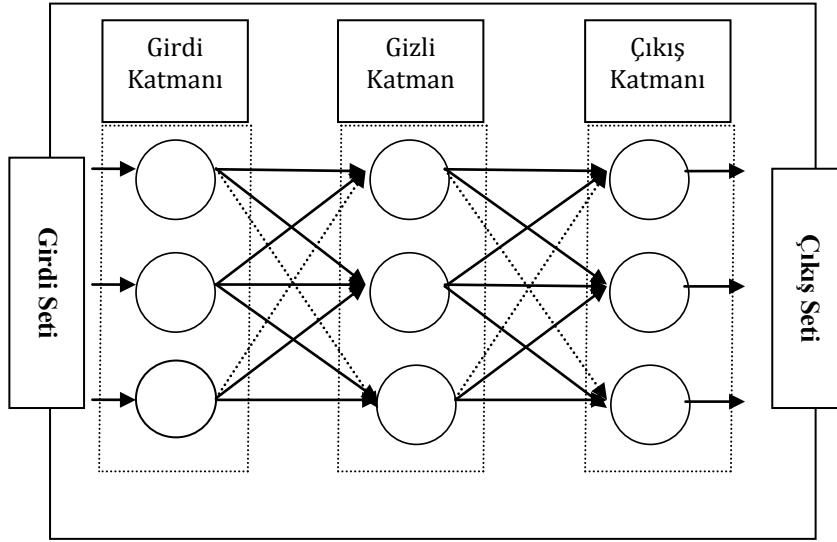
Çıkış İşlevi: Aktivasyon fonksiyonu uygulanmasıyla elde edilen çıktı değeridir.

B. BİR YAPAY SİNİR AĞI'NIN YAPISI

Bir yapay sinir ağı sadece girdi ve çıktı katmanlarından oluşuyorsa tek katmanlı ağıdır. Sadece giriş ve çıkış katmanı olan ağlar, karmaşık işlemleri hesaplama yeteneğinden yoksundurlar. Karmaşık işlevleri hesaplamak için en az bir ara katman olmalıdır (Elmas, 2003: 43-66). Çok katmanlı ağların yapısında ise, girdi, birden fazla gizli ve çıkış katmanı bulunmaktadır. Bu katmanlarda nöron, bağlantılar ve ağırlıklar olmak üzere bileşenler bulunmaktadır. Bu ağla-

rın çalışma prensibi temel olarak iki fazdan oluşmaktadır: eğitim ve test aşamasıdır. Eğitim aşamasında seçilen öğrenme algoritmasına göre ağırlıklar hesaplanır ve bu değerlere göre bir çıktı hesaplanır. Test aşamasında ise ağına görmediği örneklerden faydalanılarak sistem test edilir. Öğrenme algoritması yöntemleri, girdi setine karşılık uygun çıktı seti belirlenmesinde ve ağırları hızlandırmada önemli rol oynamaktadır. Tasarlanan YSA modelinin yapısı ve bileşenleri Şekil 2’de gösterilmiştir.

Şekil 2: Bir Yapay Sinir Ağı




Bir yapay sinir ağında, birbirleriyle bağlantılı sinir hücrelerinin yer aldığı girdi katmanı (input layer), çıktı katmanı (output layer) ve gizli katman (hidden layer) olmak üzere temelde üç katman bulunmaktadır. Girdi katmanı ilk katmandır ve dışarıdan gelen verilerin yapay sinir ağına alınmasını sağlar. Gizli katmanda bulunan nöronların dış ortamla bağlantıları yoktur. Yalnızca girdi katmanından gelen sinyalleri alarak, çıktı katmanına sinyal gönderirler. Son katman çıktı katmanı olarak adlandırılır ve bilgilerin dışarıya iletilmesi işlevini görür. Modeldeki diğer katmanlar ise girdi katmanı ile çıktı katmanı arasında yer alır ve gizli katman olarak adlandırılır.

Öğrenme algoritmalarına göre öğrenme yöntemleri danışmanlı (supervised) ve danışmansız (unsupervised) karma ve takviyeli olmak üzere dört gruba ayrılmıştır. Danışmanlı öğrenmede dışarıdan bir eğiticinin yapay sinir ağına müdahalesi söz konusudur. Eğitime işlemi, sinir ağına giriş ve çıkış bilgileri sunmaktan oluşur. Danışmansız öğrenmede sistemin doğru çıkış hakkında bilgisi yoktur. Danışmansız olarak eğitilebilen ağlar, beklenen ya da hedef çıkış olmadan giriş verilerinin özelliklerine göre ağırlık değerlerini ayarlar. Ağ, eği-


tim sırasında belirlenen bağlantı ağırlıklarını kullanarak görmediği örnekler için çıktılar üretir. Elde edilen çıktılar doğruluk değerleri ağın öğrenmesi hakkında bilgiler verir (Çuhadar vd., 2009: 99-114). YSA, hücrelerin bağlanma biçimlerine göre “ileri beslemeli” ve “geri beslemeli” olmak üzere iki çatı altında sınıflandırılabilir (Slaughter, 2003: 115).

İleri Beslemeli Ağlar: İleri beslemeli yapay sinir ağlarında tersine bir yönelme yoktur. Gelen verilerin ilk önce giriş katmanına daha sonra ara katmana ve çıktı katmanlarına doğru (ileri) aktığı ağ yapısıdır. Bir katmandaki yapay sinir hücreleri bir önceki katmanın yapay sinir hücreleri tarafından beslenir (Özveren, 2006: 9-13). ÇKA ve LVQ (Öğrenmeli Vektör Kuantalama) ileri beslemeli ağlara örnek olarak verilebilir. Şekil 3’te ileri beslemeli nöron ağı yapısı gösterilmiştir.

Şekil 3: İleri Beslemeli Nöron Ağı



Geri Beslemeli Ağlar: Geri beslemeli sinir ağlarında, en az bir hücre sonraki katmanlardaki hücrelerce de beslenir. Veri akışının sadece ileriye doğru değil geriye doğru da olabileceği ağ yapısıdır (Asilkan, Irmak, 2009: 375-391). Şekil 4’te geri beslemeli nöron ağı yapısı gösterilmiştir.

Şekil 4: Geri Beslemeli Nöron Ağı

Günümüzde, belirli amaçlarla ve değişik alanlarda kullanılmaya uygun birçok yapay sinir ağı modeli (MLP, RBF, SOM, ART vb.) geliştirilmiştir.

C. YAPAY SİNİR AĞLARININ GENEL ÖZELLİKLERİ

Yapay sinir ağlarının karakteristik özellikleri, uygulanan ağ modeline göre değişmektedir. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesine olanak tanır. Bu özellikler, yapay sinir ağlarının problemleri çözebilme yeteneğini gösterir. Yapay sinir ağları, aşağıdaki özellikleri veya üstünlükleri nedeniyle birçok alanda uygulanmaktadır (Öztemel, 2003: 31-36):

- Bilginin saklanması sağlar.
- Yapay sinir ağları örnekleri kullanarak öğrenirler.
- Sisteme uygun çözümler sağlamak için ağ tekrar ve tekrar eğitebilir.
- Matematiksel modele ihtiyaç duymazlar.
- Görülmemiş örnekler hakkında bilgi üretebilirler.
- Öğrenme kabiliyeti vardır ve farklı öğrenme algoritmalarıyla öğrenirler.
- Şekil(örüntü) ilişkilendirme ve sınıflandırma yapabilirler.
- Eksik bilgi ile çalışabilmektedirler.
- Görülmemiş örnekler hakkında bilgi üretebilme ve yeni durumlara adapte olmasıdır.

Bu avantajlarına karşılık bazı dezavantajları da vardır. Bunları aşağıdaki gibi ifade edilebilir:

- YSA, probleme uygun ağ yapısını deneme yanılma yolu ile belirler.
- Yapay sinir ağlarının donanım bağımlı çalışmaları önemli bir sorun olarak görülebilir.

- Yapay sinir ağları sadece nümerik (sayısal) veriler ile çalışır.
- Farklı sistemlere uyarlanması zor olabilir.
- Bazı ağlarda ağın parametre değerlerinin öğrenme katsayısı, katman sayısı vb. belirlenmesinde bir kural olmaması diğer bir problemidir.

D. NORMALİZASYON YÖNTEMLERİ

Yapay sinir ağlarında, ağ giriş ve çıkışlarına belirli ön işlem adımları uygulayarak yapay sinir ağına sunulan verilerin eğitimi daha verimli hale getirilebilir. Ağ giriş işlem fonksiyonları, ağ 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. Normalleştirme işlemlerinde farklı teknikler kullanılabilir. Literatürde birçok veri normalizasyon çeşidi vardır. Bunlar; Min kuralı, Max kuralı, Medyan, Sigmoid ve Z-Score gibi kurallar olarak sıralanabilir (Jayalakshmi, Santhakumaran, 2011: 89-93).

ÇKA (Çok Katmanlı Ağ) modelin girdi ve çıktılarının ölçeklendirilmesi (normalizasyon) ağın performansını yakından etkilemektedir. Çünkü normalizasyon, veri setindeki değerlerin dağılımını düzenli hale getirmektedir. YSA girdileri arasında aşırı büyük veya küçük değerler görülebilir. Bunlar yanlışlıkla girdi setine girmiş olabilir. Net girdiler hesaplanırken bu değerler aşırı büyük veya küçük değerlerin doğmasına neden olarak ağı yanlış yönlendirebilirler. Bütün girdilerin belirli aralıkta (çoğunlukla 0-1 aralığında) ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen çok büyük ve küçük şeklindeki değerlerin etkisinin ortadan kalkmasına neden olur. Bazı araştırmacılar ise kendi problemlerine özgü ölçeklendirme yöntemleri geliştirmektedir. Her problem için farklı bir ölçeklendirme yöntemi kullanılabilir. ÇKA ağı tasarımcıları, ellerindeki verileri normalize edecek bir yaklaşımı kendileri belirleyebilir. Bu konuda bir standart koymak doğru olmaz (Öztemel, 2003: 101-102).

Aşağıda bu normalizasyon teknikleri incelenmiş olup, veri setlerinin bir kısmı eğitim ve bir kısmı test serisi olarak yapay sinir ağlarında farklı öğrenme aktivasyonları, gizli katman ve nöron sayıları değiştirilerek incelenmiştir. Test sonucunda elde edilen veriler ile gerçek değer karşılaştırılmıştır. Bu işlemlerin yanında normalizasyon işlemine tabi tutulmadan (ham verilerin) eğitim ve test verilerinin yapay sinir ağına sunulması MAPE ve MSE değerleri de bulunmuştur.

1. İstatiksel veya Z-Score Normalizasyonu

Aynı veri seti üzerindeki bazı değerlerin 0'dan küçük, bazılarının ise daha büyük değerlere sahip olması, veriler arasındaki bu uzaklıkların özellikle uç verilerin sonuçlar üzerinde daha etkin olacağını göstermektedir. Verilerin nor-

malleştirilmesi işlemiyle, eğitim giriş setindeki her bir parametrenin, modelin tahmin işlemine eşit ölçüde katkıda bulunması sağlanır. Her bir değişkene karşı gelen sütunların aritmetik ortalaması ve standart sapması bulunmuştur. Daha sonra, (7) nolu eşitlikte belirtilen formül ile veriler normalleştirilerek, veriler arasındaki uzaklıklar ortadan kaldırılır ve verilerdeki uç noktaları azaltır (Yüksel vd., 2007: 97-112).

$$x' = \frac{x_i - \mu_i}{\sigma_i} \quad (7)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

μ_i = Girdi setinin ortalamasını,

σ_i = Girdi setinin standart sapmasını,

ifade etmektedir.

2. Min-Max Normalizasyonu

Min-Max yöntemi, verileri doğrusal olarak normalize eder. Minimum; bir verinin alabileceği en düşük değer iken, maksimum; verinin alabileceği en yüksek değeri ifade eder. Bir veriyi Min-Max yöntemi ile 0 ile 1 aralığına indirmek için (8) nolu eşitlik kullanılır.

$$x' = \frac{x_i - x_{min}}{x_{max} - x_{min}} \quad (8)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

x_{min} = Girdi seti içerisinde yer alan en küçük sayıyı,

x_{max} = Girdi seti içerisinde yer alan en büyük sayıyı,

ifade etmektedir.

3. Medyan Normalizasyonu

Bu yöntem her girdinin medyan değerini alarak, her örneklem için medyan normalize yöntemini kullanılır. Medyan aşırı sapmalardan etkilenmez (Jayalakshmi ve Santhakumaran, 2011: 89-93). Bu yöntem için (9) nolu eşitlik kullanılır.

$$x' = \frac{x_i}{Median(a_i)} \quad (9)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

α_i = Girdi setinin medyanını,

ifade etmektedir.

4. Sigmoid Normalizasyonu

Sigmoid normalizasyonu fonksiyonu verileri 0 ile 1 veya -1 ile 1 arasında sınıflandırır. Bir kaç tane doğrusal olmayan sigmoid fonksiyon çeşidi vardır. Tanjant sigmoid fonksiyonu süreçleri hızlandırmada iyi bir seçim olabilir (Jayalakshmi ve Santhakumaran, 2011: 89-93). Bu yöntem için (10) nolu eşitlik kullanılır.

$$x' = \frac{e^{x_i} - e^{-x_i}}{e^{x_i} + e^{-x_i}} \quad (10)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

e = doğal logaritma değerini,

ifade etmektedir.

5. D_Min_Max Normalizasyonu

Öncelikle modelin uygulanması için aşağıda verilen denklem ile tüm veriler 0,1 ile 0,9 arasında normalize edilmiştir. Normalizasyon yapılarak veriler boyutsuz hale getirilmiş olur (Doğan vd., 2007: 4119-4131). Bu yöntem için (11) nolu eşitlik kullanılır.

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (11)$$

Bu eşitlikte;

x' = Normalize edilmiş veriyi,

x_i = Girdi değerini,

x_{min} = Girdi seti içerisinde yer alan en küçük sayıyı,

x_{max} = Girdi seti içerisinde yer alan en büyük sayıyı,

ifade etmektedir.

II. UYGULAMA

Bu çalışmada, Adana ilinin hava sıcaklık tahmini modelinin yapay sinir ağlarında kullanılacak normalize edilmiş verilerin sistem performansı üzerinde durulmuş ve model çıktısı olarak günlük ortalama sıcaklık (°C) kullanılmıştır. Bu değişken tahmini için 1990 ile 2011 yılları arasındaki Meteoroloji Genel Müdürlüğünden, Adana ilinin günlük verileri alınmıştır. Bu veriler genel olarak günlük sıralı veriler olarak ağa sunulmuştur. Alınan verilerden bazı değişkenlerin günlük verilerinin eksik olmasından dolayı bu veri grubu eğitim setinden çıkartılmıştır. Alınan günlük verilerden 1990 ile 2004 yılları arasındaki 5500 veri eğitim için kullanılmış olup 2005 ile 2011 yılları arasındaki 1948 günlük veri ise test amaçlı kullanılmıştır. Kurulan modele giriş verileri tarihsel sıralama ile sunularak model eğitilmiştir. Yöntemin uygulanması “Matlab 7.10” bilgisayar programının yapay sinir ağları modülü (Neural Network Toolbox) ile gerçekleştirilmiştir. MATLAB üzerinde kurulan birçok farklı geri yayılım (backpropagation) modeli üzerinde yapılan çok sayıda denemeler sonucunda en elverişli model seçilmiştir.

Çalışmada kullanılan veri setleri için değişik gizli katman sayıları (1-10 arasında) seçilmiş, değişik nöron sayıları (1-20 arasında) ile modeller kurulmuş ve iterasyon sayısı 500 ve 1000 seçilerek eğitim gerçekleştirilmiştir. Daha sonra test için ayrılan veriler ile kurulan tüm modeller test edilmiştir. Test işlemi sonucunda bulunan tahmin değerleri, gerçek değerlerle karşılaştırılarak değişik mimarilere sahip yapay sinir ağı modellerinin tahmin doğrulukları değerlendirilmiştir. YSA girdi parametreleri Tablo 1’de gösterilmiştir.

Tablo 1: YSA Girdi Parametreleri

Ağ Tipi	Feed-Forward Backprop
Eğitim Fonksiyonu	Tranlm
Öğrenme Fonksiyonu	Learngdm
Performans Fonksiyonu	MSE, SSE
Tabaka Sayısı	1 ile 10 arasında
Nöron Sayısı	1 ile 20 arasında
Aktivasyon Fonksiyonu	Tansig, Logsig

Tablo 2’de Meteoroloji Genel Müdürlüğünden alınan 7448 günlük hava sıcaklığı verilerinin bir kısmı ve Tablo 3’te modelde kullanılan parametreler ve kullanılan istatistiksel verilerin bir kısmı verilmiştir.

Tablo 2: Hava Sıcaklığı Verileri

Gün	Günlük Ortalama Rüzgâr	Günlük Ortalama Nem	Günlük Toplam Güneşlenme Süresi	Günlük Açık Yüzey Buharlaşması	Toplam Global Güneş Radyasyonu	Günlük Maksimum Sıcaklık	Günlük Minimum Sıcaklık	Günlük Ortalama Bulutluluk	Basınç	Günlük Ortalama Sıcaklık
1	1,1	67	7,7	0,7	218,95	16,8	2,8	1	1012,7	9,2
2	1,6	64,3	0,3	1	82	12,9	7,2	8	1011,7	10,7
3	1,3	58,3	0,6	1,1	132,9	15,3	8,9	6,3	1006,6	11,8
4	1,5	55,3	4,6	1	176,4	16,8	5,3	8	1008,1	11,1
5	1,7	48	2,8	1,2	124,65	12	4	5,7	1013,5	7,6
6	1,3	33	7,7	1,5	256,8	13,6	2,2	0,3	1021,9	5,6
7	0,8	48,3	7,7	2	248,1	14,2	-1,1	0	1022,4	5
8	1,9	40,7	7,8	1,8	237,9	15	0,2	0,7	1022,7	6,4
9	1,6	35,7	7,7	1,8	255,2	11,9	0,6	0	1023,8	5,2
10	2,3	39	7,3	1,6	238,2	13,5	-1	3	1022,7	7
11	1,2	46	7,8	2,8	250,8	14,4	0,3	0	1027,6	6,6
12	1,1	52,7	7,6	2,2	226,2	16,8	0,2	0,7	1025	7,6
13	1,2	53	7,9	2,2	243,4	19	-0,5	0	1020,5	8,6
14	0,6	53,7	6,2	2,1	227	18	1,4	2,3	1015,4	8,5
15	1,2	63,7	7,7	1,5	249,35	18,8	4,5	2,3	1015,7	9,9
.
.
.
7447	4,3	46	0	8,8	181,2	16,1	8,5	8,7	1013,2	13,1
7448	1	67,7	5,9	5	235,5	17	5,5	5	1013,9	10,6

Tablo 3’de bulunan ilk dokuz parametre, model için girdi parametreleri olup, çıktı olarak günlük ortalama sıcaklık tahmin edilmiştir. Gizli katmanda kullanılan nöron sayısı, öğrenme yöntemleri ve ağ parametreleri değiştirilerek en uygun model bulunmaya çalışılmıştır. Ayrıca, en yakın sonuçların hangi aktivasyon fonksiyonunda elde edilebileceğini belirlemek için de sırasıyla sigmoid (tansig), logistic sigmoid (logsig) aktivasyon fonksiyonları denenmiştir.

Tablo 3: Modelde Kullanılan Parametreler

<i>Parametre</i>	<i>Birim</i>	<i>Değişken Tipi</i>	<i>Ortalama</i>	<i>Standart Sapma</i>	<i>Maksimum</i>	<i>Minimum</i>
Günlük Ortalama Rüzgar	m\sec	Girdi	1,21	0,74	6	0
Günlük Ortalama Nem	%	Girdi	67,86	13,80	97,7	13
Günlük Toplan Güneşlenme Süresi	Saat	Girdi	7,29	3,55	13,3	0
Günlük Açık Yüzey Buharlaşması	mm	Girdi	4,48	2,82	42,9	0
Toplam Global Güneş Radyasyonu	Cal cm ²	Girdi	368,42	158,34	726,15	6,45
Günlük Maksimum Sıcaklık	°C	Girdi	25,51	7,81	43,8	6,2
Günlük Minimum Sıcaklık	°C	Girdi	14,50	7,31	28,7	-3,2
Basınç	hPa	Girdi	3,64	2,89	10	0
Günlük Ortalama Bulutluluk	-	Girdi	1009,98	6,09	1031,9	989
Günlük Ortalama Sıcaklık	°C	Çıktı	19,39	7,48	35	2

Bu çalışmada amaç ham veri setine normalizasyon işlemi uygulayarak ve normalizasyon işlemi uygulamadan ağı eğitilerek sistem performansı ve doğruluk derecesini tartışmaktır. Farklı normalizasyon teknikleri kullanarak ağ eğitilmiş ve bunların sonuçları karşılaştırılmıştır. Özellikle beş farklı normalizasyon işlemi sonucunda ağa gönderilen eğitim ve test setinin üzerinde farklı sonuçlar bulunmuştur. Çalışmada kullanılan her bir veri setinin birimleri farklıdır. Normalizasyon işlemleri bir nevi veri setini aynı birimlere dönüştürmek için uygulanıp, ağ üzerindeki eğitim ve test setinin sistem performansını iyileştirebilir. Ayrıca bu çalışmada, veri setine normalizasyon işlemi uygulanmadan YSA'ya gönderilen ham verilerin gerçeğe yakın sonuçlar verdiği tespit edilmiştir. Matlab 7.10 üzerinde kurulan birçok farklı model denenmiş ve bunun sonucunda en başarılı model seçilmiştir.

A. ÇALIŞMANIN YÖNTEMİ

Çalışmada öncelikle, verilerin yapısına uygun yöntemlerin belirlenebilmesi amacıyla verilerin zaman serisi özellikleri analiz edilerek seriyi etkileyen temel bileşenler incelenmiştir. Veri bileşenlerinin incelenmesinden sonra, 1990 Ocak-2005 Aralık dönemine ait eğitim verileri ile 2006 Ocak - 2011 Kasım yılları arasındaki test verileri yapay sinir ağ modelinde farklı normalizasyon teknikleri

ile Adana iline yönelik günlük hava tahminleri yapılmıştır. Farklı normalizasyon teknikleri ile modelin ürettiği tahmin değerleri, gerçekleşmiş olan hava tahmini ile karşılaştırılarak hangi normalizasyon tekniğinin daha gerçekçi sonuçlar verdiği belirlenmiştir. Uygulanan yöntemlerin tahmin doğruluklarını ve başarısını test etmek için Ortalama Mutlak Yüzde Hata (MAPE, Mean Absolute Percentage Error) ve Hata Kareler Ortalaması (MSE, Mean Square Error) istatistiği yardımıyla değerlendirilmiştir. MAPE istatistiğinin tahmin hatalarını yüzde olarak ifade etmesi nedeni ile tek başına da bir anlamının olması, diğer kriterlere göre üstünlüğü olarak kabul edilmektedir (Çuhadar vd., 2009: 99-114).

Bilindiği gibi tahmin hatası ile tahmin doğruluğu ters orantılıdır. Yani tahmin hatası küçüldükçe modelin doğruluk derecesi artmaktadır. Bu nedenle, farklı tahmin modellerini karşılaştırırken en küçük hata değerine sahip model en iyi model olarak seçilmektedir (Asilkan, Irmak, 2009: 375-391). MAPE ve MSE istatistiğinin matematiksel ifadeleri (5) ve (6) nolu eşitliklerde verilmiştir.

$$MAPE = \frac{\sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{y_i}}{n} 100(\%) \quad (5)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (6)$$

Bu eşitliklerde;

\hat{y}_i = i. dönem için hesaplanan tahmini değer,

y_i = i. dönemde gerçekleşen değer,

n = veri sayısını,

ifade etmektedir.

B. YAPAY SİNİR AĞLARI MODELLERİ DENEME SONUÇLARI

Hava tahmini verilerine istatiksel normalizasyon tekniği ile yapay sinir ağlarının geri yayımlı algoritması uygulanmıştır. Yapay sinir ağların eğitim ve test aşaması için bugünkü verileri kullanırız. Burada amaç, modelin öğrenip öğrenmediğini bugünkü değerler ile test etmektir. Model gerçeğe yakın sonuçlar veriyor ise öğrenme gerçekleşmiştir diyoruz. Daha sonra modeldeki her bir girdi değişkeni için veriler girilir ve gelecek hakkında bilgi sahibi olunur. Çeşitli modellerin MAPE ve MSE sonuçları Tablo 4’de verilmiştir. Ağ eğitimi farklı aktivasyon fonksiyonu, nöron sayısı, gizli katman ve iterasyon sayıları (500 ve 1000) değiştirilerek performansı ölçülmüştür. Tablo 4’de yapay sinir ağları çalıştırılarak elde edilen sonuçların bir kısmı verilmiştir. İterasyon sayısı 500 iken, model iyi sonuç vermediğinden 1000 iterasyonda çalıştırılan modelin sonuçları tabloda yer verilmiştir. Ek olarak Tablo 5’te ise görüldüğü gibi D_Min_Max normalizasyonu diğer metotlardan daha iyi sonuç vermiştir.

Tablo 4: Deney Sonuçları

İstatistik Sonuçları	TANSİG(10,1,9)		TANSİG(10,1,2)		LOGSİG(10,1,9)		LOGSİG(10,1,2)	
	MAPE(%)	MSE	MAPE(%)	MSE	MAPE(%)	MSE	MAPE(%)	MSE
D_Min_Max	5,484	0,001	5,479	0,001	5,480	0,001	5,544	0,001
Z-Score	13,921	0,027	16,562	0,028	17,498	0,029	16,666	0,026
Min_Max	9,070	0,002	8,916	0,001	8,934	0,001	9,064	0,001
Median	6,511	0,004	6,546	0,004	6,542	0,004	6,555	0,004
Sigmoid	28,628	0,194	28,382	0,189	28,048	0,187	27,784	0,184


Aktivasyon fonksiyonu olarak tanjant sigmoid (tansig) ve logaritmik sigmoid (logsig) fonksiyonlarını denemiştir. Örneğin tansig (10, 1, 9) sırasıyla katman sayısı, gizli katman sayısı ve gizli katmandaki nöron sayısını ifade eder.

Tablo 5: En İyi İstatiksel Sonuçlar

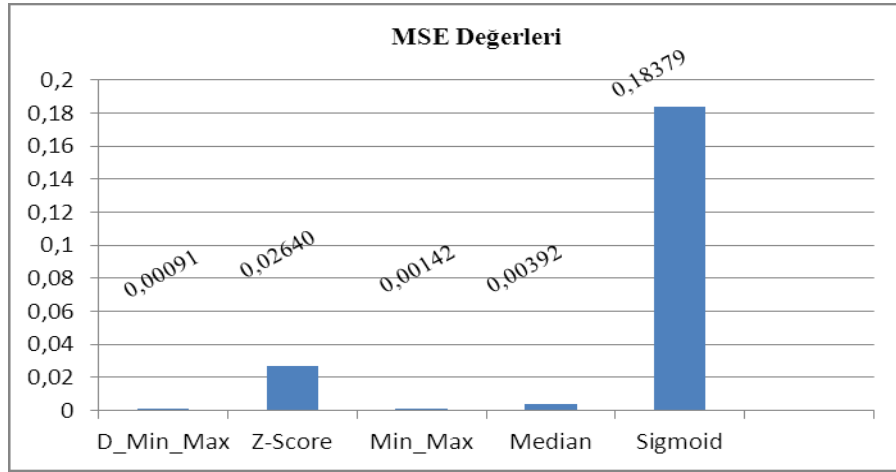
En İyi İstatiksel Sonuçlar	YSA Girdi Parametreleri	MAPE(%)	MSE
D_Min_Max	TANSİG(10,1,2)	5,479	0,001
Z-Score	TANSİG(10,1,9)	13,921	0,027
Min_Max	TANSİG(10,1,2)	8,916	0,001
Median	TANSİG(10,1,9)	6,511	0,004
Sigmoid	LOGSİG(10,1,2)	27,784	0,184

Şekil 5 ve 6'da sırasıyla metod sonuçlarının MAPE ve MSE karşılaştırmaları gösterilmiştir.

Şekil 5: Metot Sonuçlarının MAPE Karşılaştırmaları




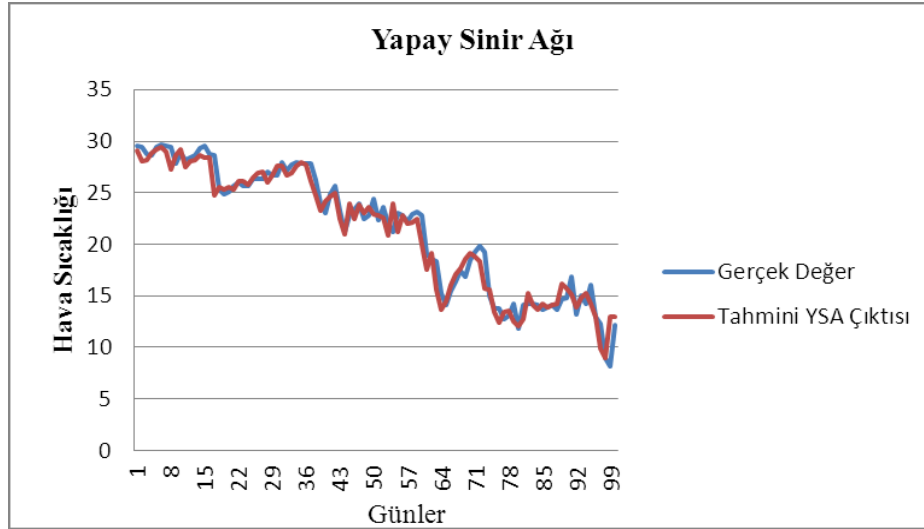
Şekil 6: Metot Sonuçlarının MSE Karşılaştırmaları



YSA girdileri ve çıktıları arasında aşırı büyük veya küçük değerler görülebilir. Net girdiler hesaplanırken bu değerler aşırı büyük veya küçük değerlerin doğmasına neden olarak ağı yanlış yönlendirebilirler (Öztemel, 2003: 81-84). Veri setimizin ölçeklendirme (normalizasyon) yapılmadan da iyi sonuçlar verdiği görülmüştür. Bu sonuç, verilerin düzgün dağıldığının bir göstergesi olabilir. Ham veri seti herhangi bir işleme tabi tutulmadan sistemde eğitilmiş, sonuçları kayıt altına alınmış sonuçlar Tablo 6'da ve gerçek değerler ile tahmini değerlerin karşılaştırılması Şekil 8'de gösterilmiştir. MAPE değeri 6.426 ve MSE değeri de 1.553 bulunmuştur. Şekil 7'de ise görüldüğü gibi oluşan tahmini değerler ile gerçek değerlerin karşılaştırılması verilmiştir.

Tablo 6: İstatiksel Sonuçlar

İstatistik	TANSİG(10,1,9)		TANSİG(10,1,2)		LOGSİG(10,1,9)		LOGSİG(10,1,2)	
	MAPE(%)	MSE	MAPE(%)	MSE	MAPE(%)	MSE	MAPE(%)	MSE
Ham veri	6,426	1,553	7,504	1,889	6,52	2,887	6,475	1,528

Şekil 7: D_Min_Max Metodu Sonucunda Oluşan Gerçek Değerler İle Tahmini Değerlerin Karşılaştırılması**Şekil 8:** Gerçek Değerler İle Tahmin Değerlerin Karşılaştırılması

SONUÇ

Çalışmada, yapay sinir ağları yöntemi ile normalizasyon tekniğinin üzerinde durulmuş ve bir uygulama yapılarak yöntemin işleyişi aydınlatılmaya çalışılmıştır. Literatürdeki istatiksel normalizasyon tekniklerinden faydalanılarak hava tahmini için hangi yöntemin daha iyi sonuç verdiği tartışılmıştır. Çalışma esnasında hava tahminin doğruluğunu etkileyen birçok faktör olduğu görülmüştür. Bunlar normalizasyon teknikleri, ara katman sayısı, ara katmanlardaki nöron sayısı ve iterasyon sayısıdır. Sonuçta bu uygulama için en uygun sonucu elde edilecek şekilde bu faktörlerin değerleri belirlenmiş ve çalışmada sunulmuştur. Normalizasyon tekniklerinden D_Min_Max yöntemi gerçeğe yakın sonuçlar vermiştir.

Sinir ağların doğrusal olmama özelliğini anlamlı kılan yaklaşım, verilerin normalizasyon işlemine tabi tutulmasıdır. Veri setine göre seçilen normalizasyon tekniklerinden biri, ağın performansını doğrudan etkileyecektir. Çünkü normalizasyon, giriş verilerinin transfer edilirken fonksiyonun aktif olan bölgesinden aktarılmasını sağlar. Böylelikle aşırı değerlendirilmiş kümülatif toplamlarının oluşturacağı olumsuzlukların engellenmesi sağlanır (Sağiroğlu vd., 2003: 20-85).

Hava tahmini için istatiksel normalizasyon metodunun uygulama sonucu yapay sinir ağları kullanılarak elde edilen tahmin sonuçları ile ham veri setine herhangi bir işlem uygulanmadan elde edilen tahmin değerlerinden daha iyi performans sergilemişlerdir (Jayalakshmi, Santhakumaran, 2011: 89-93; Deveci, 2012: 84-90). Hava tahmini verileri için uygulanan yöntemlerden elde edilen tahmin sonuçlarının değerlendirilmesi neticesinde, en yüksek tahmin doğruluğunu sağlayan ve gerçek değerlere en yakın sonuçları veren yöntemin, "D_Min_Max Normalizasyon" olduğu görülmüştür. Sonuç olarak hava tahmini doğruluğunun performansını normalizasyon işlemi etkilemektedir.

Elde edilen sonuçlar neticesinde, yapay sinir ağlarının gerçek sonuçlara yakın değerler verdiği ortaya çıkmıştır. Yapay sinir ağları, veriler arasındaki doğrusal olmayan ilişkileri öğrenip genelleme yapabilmekte ve bu sayede daha önce hiç karşılaşmadığı sorulara kabul edilebilir bir hatayla cevap bulabilmektedirler. Bu özellikleri nedeniyle yapay sinir ağları, tahmin etmede etkili bir yöntem olarak kullanılmaktadır.

KAYNAKÇA

- ALLAHVERDİ, Novruz; (2003), **Yapay Sinir Ağları**, Yayınlanmamış Ders Notları, Konya: Selçuk Üniversitesi.
- ASILKAN, Özcan ve Sezgin IRMAK; (2009), “İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları İle Tahmin Edilmesi”, **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 14(2), ss. 375-391.
- BAYIR, Fırat; (2006), “Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama”, Yayınlanmamış Yüksek Lisans Tezi, İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- ÇUHADAR, Murat; İbrahim GÜNGÖR ve Ali GÖKSU; (2009), “Turizm Talebinin Yapay Sinir Ağları İle Tahmini ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama”, **Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi**, 14(1), ss. 99-114.
- DEDE, Gülin; (2008), “Yapay Sinir Ağları İle Konuşma Tanıma”, Yayınlanmamış Yüksek Lisans Tezi, Ankara: Ankara Üniversitesi Fen Bilimleri Enstitüsü.
- DEVECİ, Muhammet; (2012), “Yapay Sinir Ağları ve Bekleme Süresinin Tahmininde Kullanılması”, Yayınlanmamış Yüksek Lisans Tezi, Ankara: Gazi Üniversitesi Sosyal Bilimleri Enstitüsü.
- DOĞAN, Emrah; Sebahattin IŞIK ve Mehmet SANDALCI; (2007), “Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi”, **İMO Teknik Dergi**, ss. 4119 -4131.
- ELMAS, Çetin; (2003), **Yapay Sinir Ağları**, Birinci Baskı, Ankara: Seçkin Yayıncılık.
- HAMZAÇEBİ, Coşkun ve Fevzi KUTAY; (2004), “Yapay Sinir Ağları İle Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini”, **Gazi Üniversitesi Mühendislik ve Mimarlık Fakültesi Dergisi**, 19(3), ss. 227-233.
- HAYKİN, Simon; (1994), **Neural Networks: A Comprehensive Foundation**, First Edition, New York: MacMillan College Publishing Company.
- HWANG, Gene and Adam DİNG; (1997), “Prediction Intervals for Artificial Neural Networks Journal of the American Statistical Association”, **Journal of the American Statistical Association**, 92, pp. 748-757, Internet Address: <http://www.math.neu.edu/~ding/paper/jasa97/jasa97.pdf>, Date of Access: 01.03.2012.

- JAYALAKSHMÍ, T. and A. SANTHAKUMARAN; (2011), “Statistical Normalization and Back Propagation for Classification”, **International Journal of Computer Theory and Engineering**, 3(1), pp. 1793-8201.
- KARAALÍ, F. Çağla ve Füsün ÜLENGİN; (2008), “Yapay Sinir Ağları ve Bi-lişsel Haritalar Kullanılarak İşsizlik Oranı Öngörü Çalışması”, **İstanbul Teknik Üniversitesi Mühendislik Fakültesi Dergisi**, 7(3), ss. 15-26.
- KARLIK, Bekir; (1994), “Çok Fonksiyonlu Protezler İçin Yapay Sinir Ağları Kullanılarak Miyoelektrik Kontrol”, Yayınlanmamış Doktora Tezi, İstanbul: Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- KAYA, İhsan; Selda OKTAY ve Orhan ENGİN; (2005), “Kalite Kontrol Problemlerinin Çözümünde Yapay Sinir Ağlarının Kullanımı”, **Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi**, 21(1-2), ss. 92-107.
- KAYNAR, Oğuz; Serkan TAŞTAN ve Ferhan DEMİRKOPORAN; (2010), “Ham Petrol Fiyatlarının Yapay Sinir Ağları İle Tahmini”, **Ege Akademik Bakış Dergisi**, 10 (2), ss.559-573.
- MASTERS, Timothy; (1993), **Practical Neural Network Recipes in C++**, London: Academic Press, Inc.
- ÖZTEMEL, Ercan; (2003), **Yapay Sinir Ağları**, Birinci Baskı, İstanbul: Papatya Yayıncılık.
- ÖZVEREN, Uğur; (2006), “Pem Yakıt Hücrelerinin Yapay Sinir Ağları İle Modellenmesi”, Yayınlanmamış Yüksek Lisans Tezi, İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- SAĞIROĞLU, Şeref; Erkan BEŞDOK ve Mehmet ERLER; (2003), **Mühendislikte Yapay Zeka Uygulamaları-1: Yapay Sinir Ağları**, Birinci Baskı, Kayseri: Ufuk Yayıncılık.
- SLAUGHTER Gymama E.; (2003), “Artificial Neural Network for Temporal Impedance Recognition of Neurotoxins”, Unpublished M.S. Thesis, Virginia: Virginia Common Wealth University, School of Engineering.
- YILDIZ, Birol; (2001), “Finansal Başarısızlığın Öngörülmesinde Yapay Sinir Ağı Kullanımı ve Halka Açık Şirketlerde Ampirik Bir Uygulama”, **İMKB Dergisi**, 17, s. 51-67.
- YÜKSEK, Ahmet G.; Hüdaverdi BİRCAN; Metin ZONTUL ve Oğuz KAYNAR; (2007), “Sivas İlinde Yapay Sinir Ağları İle Hava Kalitesi Modelinin Oluşturulması Üzerine Bir Uygulama”, **Cumhuriyet Üniversitesi İktisadi ve İdari Bilimler Dergisi**, 8(1), ss. 97-112.
- WARNER, Brad and Manavendra MISRA; (1996), “Understanding Neural Networks as Statistical Tools”, **The American Statistician**, 50 (4), pp.284-293.

