

(Geliş Tarihi / Received Date: 09.05.2019, Kabul Tarihi/ Accepted Date: 16.05.2019)

İris Çiçeği Türünün YSA Yöntemleri ve ANFIS ile Tahmini

Serel ÖZMEN-AKYOL^{*1}, Eyyüp GÜLBANDILAR²

¹Eskişehir Osmangazi Üniversitesi, Sivrihisar Meslek Yüksekokulu, Bilgisayar Programcılığı, Eskişehir

²Eskişehir Osmangazi Üniversitesi, Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, Eskişehir

Anahtar Kelimeler:

Yapay Sinir Ağları,
Bulanık Sinir Ağları,
Uyarlanabilir Bulanık Sinir
Ağları Sistemi,
Örüntü Sınıflama

Özet: Örüntü kullanılarak sınıflandırma yapmak, sanayi ve tıp alanında yaygın olarak kullanılmaktadır. Fakat gözlemsel sınıflandırma yapılırken kişisel hatalar meydana gelmektedir. Bu sınıflandırma hatalarını azaltmak için yapay öğrenme yöntemleri kullanılmaktadır. Bu çalışmada, yapay sinir ağı (YSA) ve bulanık yapay sinir ağı (ANFIS) kullanılarak iris çiçeği türünün sınıflandırılması amaçlanmaktadır. Bu tür çalışmalarda yaygın olarak kullanılan iris çiçeğine ait örnek verilerden yararlanılmıştır. Üç katmanlı, ileri beslemeli, dört girişli ve bir çıkışlı YSA modeli seçilmiştir. YSA modelinin eğitiminde 90 adet veri ve testinde de 60 adet veri kullanılmıştır. Her girişinde iki adet bulanık küme bulunan, dört girişli ve bir çıkışlı, ANFIS modeli üretilmiştir. Bu modelde de aynı sayılarda örnekler kullanılarak eğitim ve test yapılmıştır. Çalışma neticesinde uygulanan her iki yöntem için, tahmin değerleri ile gerçek değerler arasında düşük hata oranları elde edilmiştir. YSA ve ANFIS yöntemlerinin sınıflandırma sonuçları karşılaştırılmış ve YSA yönteminin ANFIS yöntemine göre daha yakın tahminler ürettiği bulunmuştur.

Estimation of Iris Flower Type with ANN and ANFIS

Keywords:

Artificial Neural Networks,
Fuzzy Neural Networks,
Adaptive-Network Based Fuzzy
Inference Systems,
Pattern Classification

Abstract: Pattern classification is also widely used in industry and medicine. While the classical observational classification is made, the errors in classification due to personal mistakes occur. Artificial learning methods are usually used to reduce these classification errors. In this study, it is aimed to classify iris flower species by using the artificial neural network (ANN) and fuzzy artificial neural network (ANFIS). In this study, it was preferred to use the sample data of iris flower widely used. The selected ANN model has three layers, feedforward, four inputs and one output. In the ANN model training was used the 90 sample data and in the testing process were used 60 sample data. The selected ANFIS model has two fuzzy sets for each input neuron, four inputs, and one output. In this model, training and testing were carried out using similar samples. For both models, the actual values and predicted values were compared. It was obtained low error rates. The classification results of ANN and ANFIS methods were compared and it was found that ANN method produces closer estimations than ANFIS method.

1. GİRİŞ

Sanayide, medikal alanda ve pek çok akademik çalışmada yaygın olarak nesnelere örüntüleri kullanılarak sınıflandırma ve kümeleme yapılmaktadır. Örüntü üzerinde yapılan bu sınıflandırma ve kümeleme işlemleri, çıplak göz ile yapıldığında işlemlerde hatalar meydana gelebilmektedir. Son zamanlarda yapılan çalışmalarda, sınıflandırma ve kümeleme hatalarını azaltmak için çeşitli yapay öğrenme sistemleri kullanılmaktadır. Yapay öğrenme, bilgisayarların örnek veri ve geçmiş

deneyimleri kullanarak öğrenmesi ve tahminlemesi üzerine kurulmuş bir araştırma alanıdır.

Khehra ve Pharwaha çalışmalarında, mamografi film görüntülerinden yapay sinir ağları (YSA) ve destek vektör makinası (SVM) gibi yapay öğrenme yöntemlerini kullanarak sınıflama yapmışlardır. Mamografi görüntülerindeki iyi huylu ve kötü huylu tümör sınıflandırmasının başarılı bir şekilde yapılabilirliği ortaya koyulmuştur [1]. Barkana ve arkadaşları, retina damar görünümlerini bulanık mantık, YSA, SVM ve füzyon sınıflayıcı öğrenme metodlarını kullanarak diyabetik retinopati seviyesinin belirlenmesinde başarılı bir şekilde

kullanılabileceği ifade etmişlerdir [2]. Affonso ve arkadaşları çalışmalarında, derin öğrenme algoritmaları ile ağaç kalitesinin sınıflanmasının yapılabilirliğini sunmuşlardır [3]. Mohan ve Subashini tarafından yapılan çalışmada, manyetik rezonans görüntülerinden beyin tümör derecesinin tanımlanmasında bir çok yapay öğrenme yönteminin başarılı bir şekilde sınıflandırılabilirdiği tebliğ edilmiştir [4]. Bu çalışmada, Uyarlanabilir Bulanık Sinir Ağları Sistemi (Adaptive Neuro-Fuzzy Inference System –ANFIS) ve Yapay Sinir Ağları (YSA) yöntemleri kullanılarak, örnek örüntünün işlenmesi ve iris çiçeğinin, türünün belirlenmesi için uygun yöntemin belirlenmesi hedeflenmektedir. Çanak yaprak uzunluğu (sepal length), çanak yaprak genişliği (sepal width), taç yaprak uzunluğu (petal length), taç yaprak genişliği (petal width) kullanılan eğitim ağına giriş parametreleri olarak sunulmuş ve bu değerlere göre sistemin iris çiçeğinin türünü tahmin etmesi sağlanmıştır.

Bu çalışmada, ANFIS ve YSA sisteminin eğitiminde kullanılan veriler, Fisher tarafından oluşturulan ölçümlerden alınmıştır [5].

2. VERİNİN HAZIRLANMASI

2.1. İris Veri Seti

Fisher, iris çiçeğini çeşitli ölçümler neticesinde üç türe ayırarak sınıflandırmıştır [5]. Çiçek türünün sınıflandırılmasında çiçeğe ait dört ölçüm değerinden faydalanılmaktadır. Yapılan ölçümler; çanak yaprağın genişliği, çanak yaprağın uzunluğu, taç yaprağın uzunluğu ile taç yaprağın genişliğidir. Ölçümler sonucunda iris çiçeği için elde edilen bu dört değer kullanılarak iris çiçeği üç türe göre sınıflandırılmaktadır. Kullanılan veri setinde yer alan değerler şu şekildedir:

- A: Çanak Yaprığın Uzunluğu (sepal length)
- B: Çanak Yaprığın Genişliği (sepal width)
- C: Taç Yaprığın Uzunluğu (petal length)
- D: Taç Yaprığın Genişliği (petal width)
- E: İris çiçeğinin türü (setosa, versicolor, virginica)

Çalışmada kullanılan veri seti ve yapısı incelendiğinde, yukarıda ifade edilen A,B,C,D bağımsız değişkenleri giriş değerlerini, bağımlı E değişkeni ise çıkış değerini temsil etmektedir.

Veri seti içerisinde, daha önceden ölçümü yapılarak değerlendirilen 150 adet iris çiçeği örneği için ölçüm değerleri ve tür değeri bulunmaktadır. Eldeki veriler doğrultusunda eğitilen sistemin, yeni gelen verilere göre çiçek türünü tahmin etmesi üzerine sistem tasarlanmaktadır. Bu durumda sistemin eğitilebilmesi için verilerin, Eğitim Veri Seti ve test edilebilmesi için de Test Veri Seti olarak iki kısma ayrılması gerekmektedir. Öncelikle eğitim verileri ile ağ eğitilerek, ardından eldeki gerçek test verileri ile ağ üzerinde doğru sonuç verip vermeyeceği denenmektedir.

2.2. Normalizasyon İşlemi

Veri seti düzenlenirken öncelikle, tür kısmının sözel bir ifade olması sebebiyle, bu ifadeler sayısal değere

dönüştürülmektedir. Çünkü yapay sinir ağlarında değerlerin sisteme mutlaka sayısal olarak tanıtılması gerekmektedir. Bunun için 1-3 arası sayısal değerlerle işlem gerçekleştirilmiştir. Sayısal değerler ve karşılıkları şu şekildedir:

- 1: setosa
- 2: versicolor
- 3: virginica

Veri setleri ile çalışma yapılırken, değerlendirmenin daha iyi sonuçlar vermesi için; kullanılan tüm verilerin belirlenen bir değer aralığında normalize edilmesi daha iyi sonuçlar elde edilmesini sağlamaktadır. Verilerin normalize edilmesi ile, tüm sonuçların olumlu yönde etkileyeceği öngörülmektedir. Bu nedenle sistemin eğitiminde ve kontrolünde kullanılacak tüm veri setine normalize işlemi uygulanmaktadır [6].

Literatür incelendiğinde, verilerin normalize edilmesinde birçok yöntem kullanıldığı görülmektedir. Bu çalışmada normalize işlemi için Denklem (1) kullanılmıştır.

$$V_N = 0.8 \times \left[\frac{V_R - V_{min}}{V_{max} - V_{min}} \right] + 0.1 \quad (1)$$

- V_R = Normalize edilecek veriler
- V_{min} = En küçük değerdeki veri.
- V_{max} = En büyük değerdeki veri.

Normalizasyon işlemi uygulandığında, uygulanan tüm değerlerin pozitif çıktığı görülmektedir. Bu durumda log-sigmoid transfer fonksiyonu kullanılmalıdır.

2.3. Eğitim ve Test Veri Setlerinin Oluşturulması

Sistem tasarlanırken, önce sistemin eğitilmesi ardından eğitilen sistemin test edilmesi aşamaları yer almaktadır. Çalışma yapılırken toplamda 150 adet örnekten sistemin eğitilmesi için 90 tanesi ele alınmıştır. Geri kalan 60 adet örnek veri ise sistemin eğitim performansını değerlendirmek üzere Test veri seti olarak kullanılmıştır.

3. KULLANILAN YÖNTEMLER

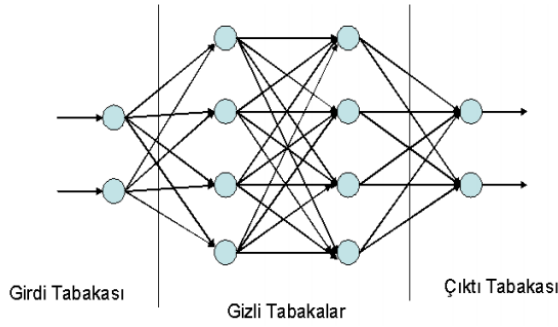
3.1. Yapay Sinir Ağları

İnsan beyni, çalışma prensibi nedeniyle bilim için çok dikkat çekici bir örnektir. Karmaşık yapısı ile bilimsel pek çok çalışmaya konu olan insan beyni, bulundurduğu yaklaşık 100 milyar nöron ile bir makineye benzetilmektedir [7].

Yapay sinir ağları, insan beyninin çalışma prensibinden faydalanılarak geliştirilmiştir. Nöronların birbiri ile iletişimi temel alınarak kurulan bu yapıda, düğümler arasında çeşitli ağırlıklardaki bağlantılar bulunmaktadır. Bu bağlantılar vasıtasıyla birbirine bağlanan, her birinin ayrı belleklere sahip olduğu işlem elemanlarından oluşmuş, dağıtılmış aynı zamanda da paralel bilgi işleme yapılarıdır. Yapay sinir ağlarının temel hedefi; insan beyninde bulunan biyolojik sinir ağları yapısının bilgisayar programları ile taklit edilmesidir [8]. Bir başka

deyişle yapay sinir ağı; sayısal dünyada insan beynine özgü katmanlı ve paralel sinir hücresi yapısının gerçekleştirilmeye çalışılan bir modellemesidir [9].

Yapay sinir ağları yapısı genellikle, girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan meydana gelmektedir. Şekil 1’de iki gizli katmanı bulunan bir ağ yapısı yer almaktadır. Buna göre; yapıda yer alan bir nöronun girdisi yapıdaki başka bir nöron hücresinin çıktısı olarak ifade edilmektedir. Bu çıktılar, şekilde de gösterildiği üzere bağlantılar aracılığı ile iletilir. Bağlantılar, nöronlar arasında yer alan ve ağırlık adı verilen nümerik değerlerle ifade edilmektedir. Yapıda bulunan herhangi bir i . nöronu, j . nöronuna sinyal gönderdiğinde; alınan bu sinyal i . sinapsın ağırlığı ile çarpılmaktadır. İletim sonrasında i . nöronun çıktısı ise x_i şeklinde gösterilmektedir. Aynı şekilde j . nörondaki ağırlıklandırılmış girdiler de $w_{ij} x_i$ şeklinde gösterilir ve nöronda bulunan işlemci eleman tarafından toplanmaktadır. Bu işlem sonucunda elde edilen değer; toplam nöron aktivasyonu olarak ifade edilmektedir. Aktivasyon değeri belirlendikten sonra çıktının belirlenmesi için nöron tarafından sinyal transfer fonksiyonları uygulanmaktadır [10].



Şekil 1. İki gizli katmanı bulunan geri-yayılma ağ yapısı

Aktivasyon fonksiyonları yapay sinir ağında bir bakıma normalizasyon işlemini gerçekleştirmektedir. Sistemde yer alan nöronun çıkış genliğinin belirli değerler aralığında sınırlanması için kullanılmaktadır. Bu değerler değişiklik göstermekle birlikte, genellikle $[0,1]$ veya $[-1,1]$ değerleri arasında yer almaktadır. Doğrusal olmayan ya da doğrusal aktivasyon fonksiyonlarının YSA’larda kullanılması sayesinde karmaşık ve çok çeşitli problemlere uygulanarak çözüm sağlanmaktadır. Yapay sinir ağlarında, sistemin eğitimi için kullanılan pek çok öğrenme algoritması bulunmaktadır. Mühendislik bilimleri ile birlikte pek çok alanda da sıklıkla kullanılan öğrenme algoritmalarından birisi, geriye yayılma algoritmasıdır. Bu çalışmada da sistemin eğitiminde kullanılmak üzere öğrenme algoritması olarak geriye yayılma algoritması kullanılmaktadır. Bu algoritmanın tercih edilmesinin en önemli sebebi, öğrenme performansının oldukça yüksek ve öğrenme algoritmasının da basit olmasıdır [10].

Geriye yayılma algoritmasının temel amacı; karesel hatayı en aza indirmek için dereceli azalma algoritması (gradient descent algorithm) ile çözüm sağlamaktır. Bu ifadede kullanılan karesel hata ise; sistemin gerçek çıktısı

olan “ y ” değeri ile sistemden istenen çıktı olan “ d ” değeri arasındaki fark olarak ifade edilmektedir [11].

3.2. Uyarlanabilir Bulanık Sinir Ağları Sistemi (Adaptive Neuro-Fuzzy Inference System –ANFIS)

Uyarlanabilir bulanık sinir ağları sistemi - ANFIS (Adaptive Network Based Fuzzy Inference System) yapısı, katmanlar şeklinde yerleştirilen düğümlerin birleşmesi ile oluşmaktadır. İnsan beyninden uyarlanılarak oluşturulan sinirsel öğrenme yeteneğine sahip bir Sugeno tipi bulanık sistem ağ yapısını içermektedir. Ağda yer alan katmanların hepsi, belirli bir fonksiyonu yerine getirmekle görevlendirilmiştir [12]. ANFIS’in yapısında, bulanık mantık ve yapay sinir ağları birlikte kullanılmaktadır [13].

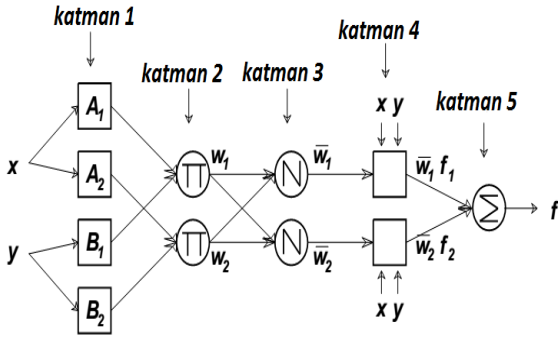
ANFIS yapısı, giriş ve çıkış bilgi çiftleri ve nöronlara uygulanan bulanık çıkarım sistemindeki eğer-ise kurallarından oluşmaktadır [14]. İç katman yapısında kullanılan kuralların yanı sıra sistemin eğitimi ve kontrolünde YSA öğrenme algoritmaları kullanılmaktadır. Birinci dereceden iki girişli bir ANFIS yapısı Şekil 2’de yer almaktadır.

ANFIS, yapı itibarıyla beş katmandan oluşan ileri beslemeli bir yapay sinir ağı yapısıdır. Yapıda yer alan katmanlar ve görevleri ise şu şekildedir [15].

1. Katman: Giriş değişkenlerinin sayısı yapıda bulunan düğüm sayısına eşittir. Düğüm fonksiyonları olarak değişkenlerin üyelik fonksiyonları kullanılmaktadır. “Öncül parametreler”, bu katmanda kullanılan üyelik fonksiyonlarının parametreleri olarak ifade edilmektedir.
2. Katman: Yapıda yer alan düğümlerin karakterleri sabittir. Düğüm sayısı kadar kural sayısı bulunmaktadır. Düğümün çıktıları, kuralların ağırlık derecelerini göstermektedir. Düğümün girdi değerleri ise, kuralların öncül kısmındaki değişkenlerinin üyelik fonksiyon değerlerini ifade etmektedir.
3. Katman: Bu katmana gelindiğinde yer alan düğümlerin girdileri, kuralların ağırlık derecelerini gösterirken, çıktıları ise, normalize edilmiş ağırlık derecelerini göstermektedir. Bu katmanın temel amacı, kural ağırlıklarının normalize edilmesidir.
4. Katman: Tüm düğümlerin adaptif olduğu bilinmektedir ve bu düğümlerin fonksiyonu, Sugeno Sistemi’nde bulunan bir fonksiyondur. Fonksiyon olarak herhangi bir mertebeden -ki bu çoğunlukla 1. mertebedir, fonksiyon kullanılmaktadır. Bu katmanda model parametreleri, “berraklaştırma” şeklinde adlandırılmaktadır.
5. Katman: Nihai nokta olan bu katmanın çıktısı tek düğümünden meydana gelmektedir. Katman çıktısı, bulanık olmayan değerler şeklindedir.

Öncül ve sonuç parametreleri beş katmanlı bu yapının temel parametreleridir. Öncelikle belirlenen eğitim veri seti, tasarlanmış yapay sinir ağına tanıtılmaktadır. Sistem, kullanılan herhangi bir eğitim algoritması sayesinde, eğitim veri setinde yer alan girdi-çıkış fonksiyonel ilişkisini en iyi biçimde öğrenmektedir. Yapılan bu işlem; optimizasyon işlemidir. Sistem modelinin çıktısı ve eğitim veri setinin çıktısı arasındaki farka bakılarak hata kareler toplamı elde edilmektedir. Hata fonksiyonu olarak

kabul edilen bu toplam değerin minimum olduğu durumlar bulunarak, kullanılan parametrelerin optimum değerlerinin belirlenmesi amaçlanmaktadır [16].



Şekil 2. Birinci dereceden iki girişli ve iki kuralı bulunan bir ANFIS yapısı

3. BULGULAR

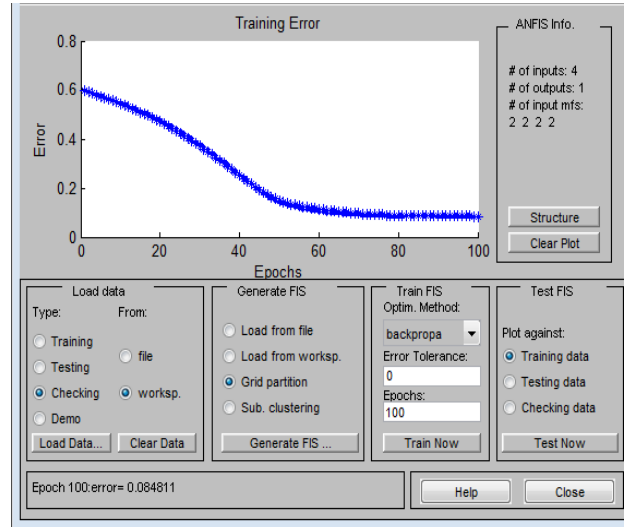
Bu çalışmada örnek olarak, yapay öğrenme alanında sıklıkla kullanılan veri setlerinden biri olan "İris" veri seti [5] ile uygulama yapılmıştır. İris veri seti; 3 iris bitki türüne (iris setosa, iris virginica ve iris versicolor) ait, her bir türden 50 örnek olmak üzere toplam 150 örnekleme sahip bir veri setidir. Veri setinde yer alan her bir bitki örneği ayrı bir gözlemi ifade etmektedir. Bitkilerin, ölçülen 4 temel özelliği bağımsız değişkenler iken "bitki tür ismi" bağımlı bir değişkeni göstermektedir. Bunun için, çanak yaprağın genişliği, çanak yaprağın uzunluğu, taç yaprağın genişliği ve taç yaprağın uzunluğu giriş değişkeni olarak kabul edilmiş, bu verilerden çiçek türü tahmini gerçekleştirilmiştir. Bu 4 özellik temel alınarak, sistemin üç türü birbirinden ayırabilmesi ve girilen yeni özellik değerlerine göre türün ANFIS ve YSA metodları kullanılarak tahmin etmesi amaçlanmaktadır. Bu amaç doğrultusunda öncelikle sistemin eğitilmesi gerekmektedir. Sistemin eğitilerek başka bir test veri seti ile denenmesinin ardından, hata oranı kabul edilebilir düzeyde ise sistemin yeni verilere göre tahmin üretmek için hazır hale geldiği kabul edilmektedir. Bu çalışmada iris çiçeği türünün tahmin işleminin gerçekleştirilmesi için ANFIS ve YSA modelleri önerilmektedir. İki farklı model ile elde edilen sonuçlar çeşitli hata yöntemleri kullanılarak değerlendirilmektedir. İki sistemin karşılaştırılması sırasında eğitim ve test verilerinin aynı olmasına dikkat edilmelidir. Verilerin farklı olması durumunda; her bir sistemin ürettiği hata değerinde değişim meydana gelmektedir, bu da iki sistemin doğru şekilde karşılaştırılmasına engel teşkil etmektedir.

Sistemin örnek veri seti kullanılarak, her iki yöntem ile eğitilmesinde MATLAB programından, sonuçlarının istatistiki olarak değerlendirilmesinde ise SPSS paket programından yararlanılmıştır.

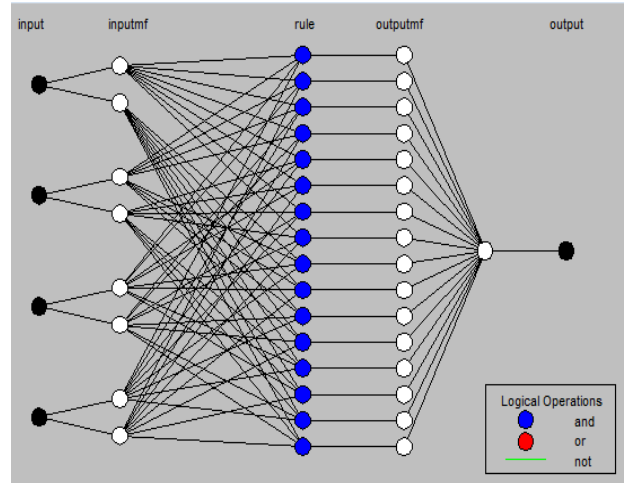
3.1. ANFIS'in Uygulanması

Ağın eğitimi için her iki yöntemde de kullanılan 90 adet örneklem işlenmiştir. ANFIS uygulamaları sırasında iterasyon sayısı önemli bir parametredir. Sistemi gereksiz

yere yormadan, yeterli ve gerekli iyileştirmelerin yapılmasına olanak sağlayan bir değer belirlenmelidir. Bu çalışmada örneklem büyüklüğü de göz önünde bulundurularak 100 iterasyon uygun görülmüştür. Eğitilen sistemin denenmesi ve verilere göre tahmin üretmesi için daha önce kullanılmayan 60 adet veri ağı sunulmuş ve çıkışlar geri yayılım (back propagation) algoritması ile tahmin edilmiştir. Sistemin ANFIS ile eğitilmesi sonucu oluşan hata grafiği Şekil 3'de verilmektedir. ANFIS ile hesaplanan hata değerinin RMSE olduğuna dikkat edilmelidir. Buna göre sistemin eğitim aşamasındaki hata değerinin 0,84811 olduğu görülmektedir. Dört özelliğin giriş kabul edildiği tek çıkışlı sistem için ağın yapısı ise Şekil 4'de yer almaktadır.



Şekil 3. Ağın eğitilmesi sonucu oluşan hata grafiği

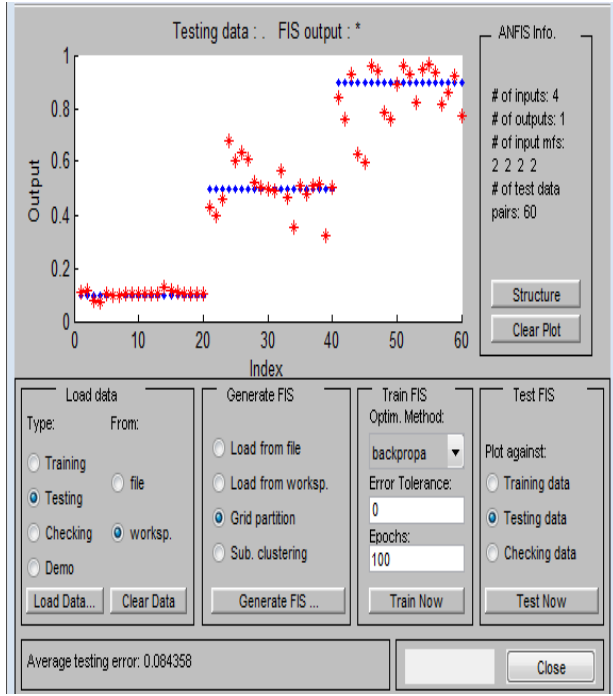


Şekil 4. ANFIS ile oluşturulan ağ yapısı

Verilerin 60 adet örneği içeren test seti ile test edilmesi sonucu ortaya çıkan değerler Şekil 5'te görüldüğü gibi elde edilmiştir. Ağın test edilmesi ile elde edilen RMSE hata değeri ise 0,084358 olarak tespit edilmiştir.

MATLAB programı ile eğitilen ağın, yeni bir veri seti ile test edilmesinin ardından elde edilen sonuçlar SPSS paket programı ile değerlendirilmektedir. Sistemin eğitilmesi sonucu elde edilen tahmin değerleri ile gerçek değerler

arasındaki farkı gösteren değerler, Tablo 1’de yer almaktadır.



Şekil 5. Gerçek değerler ile sistem tarafından tahmin edilen değerlerin karşılaştırılması

Tablo 1. ANFIS ile eğitilen sistemin tahmin ve gerçek çapraz tablosu

		Gerçek Değer			Toplam
		1.TİP	2.TİP	3.TİP	
Sistem Tarafından Tahmin Edilen	1.TİP Iris - Setosa	Sayı 19 %	0 0,0%	0 0,0%	19 31,7%
	2.TİP Iris - Virginica	Sayı 1 %	18 30,0%	2 3,3%	21 35,0%
	3.TİP Iris - versicolor	Sayı 0 %	2 3,3%	18 30,0%	20 33,3%
Toplam		Sayı 20 %	20 33,3%	20 33,3%	60 100,0%

Tablo 1 ve Tablo 2’deki veriler incelendiğinde, ANFIS ile eğitilen sistem için gerçek değerler ile oluşturulan sistemin tahminleri arasında istatistiksel olarak yüksek derecede ilişki bulunmuştur. ($\chi^2=103,173$; $p<0,048$; $K(\text{kappa})=0,901$)

Tablo 2. ANFIS ile eğitilen ağın ki-kare analizi

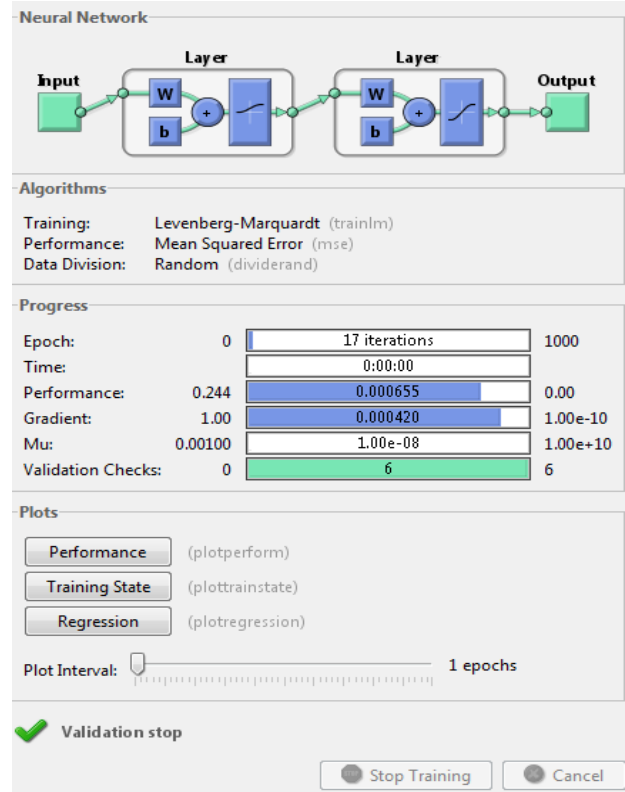
	Değer	Df
Pearson Ki- kare	103,173 ^a	6
Örneklem Sayısı	60	

3.2. YSA’nın Uygulanması

Yapay sinir ağı ile sistem eğitilirken, ANFIS’in eğitiminde kullanılan veriler aynı şekilde YSA eğitimi için de kullanılmıştır. YSA için ileri beslemeli geri

yayılım (feed-forward back propagation) algoritması seçilerek sistemin eğitilmesi sağlanmıştır.

Sistemde optimum sonucu elde etmek için belirlenmesi gereken, gizli katman sayısı, her katmanın aktivasyon fonksiyonu ve her gizli katman/katmanlarda yer alan nöron sayısı değerleri denenerek belirlenmekte ve buna göre uygulanmaktadır. Bu çalışmada, dört nörondan oluşan giriş katmanı ile sekiz nörondan oluşan gizli katman ve bir nörondan oluşan çıkış katmanı olmak üzere 3 katmanlı YSA tasarlanmıştır ve optimum sonuçların elde edildiği görülmüştür. Katmanlarda yer alan transfer fonksiyonu olarak, verilerin pozitif olması sebebiyle LOGSIG fonksiyonu kullanılmıştır. Şekil 6’da YSA ile verilerin eğitim aşaması yer almaktadır.



Şekil 6. YSA ile ağın eğitilmesi

Sistemin eğitimi için 1000 iterasyonluk bir denemenin yeterli olacağı öngörülerek, hata değeri 10^{-10} olarak belirlenmiştir. Eğitime başlandıktan sonra 15. iterasyonun sonunda istenilen hedefe ulaşıldığı görülmüştür. YSA’da sistemin eğitim aşamasının doğruluk testi yapılırken, eğitim için kullanılan verilerin ağı girdi parametresi olarak verilmesi durumunda çıkışların gerçek değerlere çok yakın olduğu görülmüştür. Eğitimin ardından sistemde daha önce kullanılmayan 60 adet test verisi için iris çiçeği türü tahmininin yapılmıştır. Sonuçlara göre elde edilen veriler ile istatistik analiz yapılmış ve R kare değeri % 0,9279 bulunmuştur. Bulunan bu değer 1’e yakın olması sebebiyle kabul edilebilir bir seviyededir.

Sistemin eğitilmesi sonucu elde edilen tahmin değerleri ile gerçek değerler arasındaki farkı gösteren değerler, Tablo 3’de yer almaktadır.

Tablo 3. YSA ile eğitilen sistemin tahmin ve gerçek çapraz tablosu

			Gerçek Değer			Toplam
			1.TİP	2.TİP	3.TİP	
Sistem Tarafından Tahmin Edilen	1.TİP Iris - Setosa	Sayı %	19 31,7%	0 0,0%	0 0,0%	19 31,7%
	2.TİP Iris - Virginica	Sayı %	1 1,7%	19 31,7%	2 3,3%	21 36,7%
	3.TİP Iris - versicolor	Sayı %	0 0,0%	1 1,7%	18 30,0%	20 31,7%
Toplam		Sayı %	20 33,3%	20 33,3%	20 33,3%	60 100,0%

Tablo 3 ve Tablo 4'deki veriler incelendiğinde, gerçek değerler ile oluşturulan sistemin tahminleri arasında istatistiksel olarak yüksek derecede ilişki bulunmuştur. ($\chi^2=98,225$; $p<0,05$; $K(\text{kappa})=0,900$)

Tablo 4. YSA aile eğitilen ağın ki-kare analizi

	Değer	Df
Pearson Ki- kare	98,225 ^a	4
Örneklem Sayısı	60	

3.3. Hata Değerlendirme Yöntemleri

Bu çalışmada uygulanan metotlar 3 farklı hata yöntemi ile değerlendirilmektedir. Bunlar;

$$MSE = \frac{\sum(y_1 - y_2)^2}{n} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum(y_1 - y_2)^2}{n}} \quad (3)$$

$$MAPE = \frac{\sum \left| \frac{(y_1 - y_2)}{y_1} \right|}{n} \times 100(\%) \quad (4)$$

Burada; y_1 = Gerçek Değerler, y_2 = Tahmini Değerler, n = Gözlem Sayısı'nı göstermektedir. Denklem 2'de ortalama karesel hata (Mean Square Error-MSE) hesaplanmaktadır. Tüm örnekler için, gerçek değer ile tahmini değerlerin farkının karesini alarak, örnek sayısına bölümü ile elde edilmektedir. Hatanın sıfır veya sıfıra çok yakın olması, ağın çok iyi eğitildiğini göstermektedir.

Ortalama hata kareleri toplamı kökü (Root Mean Squared Error - RMSE) yapay sinir ağlarında model performansını değerlendirmek için sıklıkla kullanılan bir indistir. Ölçüm değerleri ile model tahminleri arasındaki hata oranını belirlemek için kullanılmaktadır. RMSE değerinin sıfır olması oluşturulan modelin mükemmel olması anlamına gelmektedir.

Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) ise yüzdelik hataların mutlak değerleri toplamalarının ortalamasını almaktadır. MAPE'de hata değerleri birbirini yok etmemekte ve tahminde oluşan tüm

hata büyüklükleri kendilerini gösterebilmektedir [17]. Bu yüzden MAPE ölçüsü daha sık olarak hata ölçümleri için kullanılmaktadır. Yüzdelik hata değerleri, tahmin sonuçlarının daha anlamlı olmasını sağlamak ve sonuçların yorumlanmasını daha kolay hale getirmektedir. Witt ve Witt'e göre, MAPE değerleri % 10 ile % 20 arasında olan modelleri "doğru" tahminler olarak, % 10'un altında olan tahmin modellerini ise "yüksek doğruluk" derecesine sahip olarak sınıflandırmıştır [18]. Benzer şekilde Lewis, MAPE değeri %10'un altında olan modelleri "çok iyi", % 10 ile % 20 arasında olan modelleri "iyi", değeri % 20 ile % 50 arasında olan modelleri "kabul edilebilir" ve % 50'nin üzerinde olan modelleri ise "yanlış ve hatalı" olarak sınıflandırmaktadır [19]. Veri seti ve değerlendirme yöntemlerine göre belirtilen farklı hata türlerinden biri ya da birkaçı birlikte kullanılabilir. Hata değeri türleri, yapıları gereği farklı dahi olsa, temelde tahmin edilen veri ile gerçek veri arasındaki farklılık - benzerlikten faydalanmaktadır. Her bir model için belirtilen hata türlerinin hesaplanması durumunda Tablo 5'de yer alan veriler elde edilmektedir.

Tablo 5. ANFIS ve YSA yöntemlerinin hatalarının karşılaştırılması

Hata Türü	Kullanılan Yöntemler	
	ANFIS	YSA
MSE	0,71929	0,00769655
RMSE	0,84811	0,087729984
MAPE	% 0,76213	% 8,143459259

4. SONUÇ

Bu çalışmada, iris çiçeğinin çanak yaprak uzunluğu, çanak yaprak genişliği, taç yaprak uzunluğu ve taç yaprak genişliği değerlerine göre çiçek türünün tahmin edilmesi için ANFIS ve YSA yöntemleri kullanılmıştır. Yapılan tahmin işlemlerinin doğruluğu daha önce yapılan deney sonuçları ile test edilmiştir. ANFIS yöntemi kullanıldığında 0.719'luk test hatası, YSA yöntemi kullanıldığında ise tahmin işlemi sonucunda % 8,143459259 değerinde bağıl hata ortalaması elde edilmiştir. Her iki yöntem için elde edilen tahmin sonuçları karşılaştırıldığında, özellikle YSA ile daha iyi sonuçlar elde edildiği görülmektedir. Elde edilen düşük MSE, RMSE ve MAPE değerleri, gerçek "tür" bilgisi ile yapay sinir ağı modelinden elde edilen tahmin sonuçları arasındaki sapmaların çok küçük olduğunu göstermektedir. Eğer gerçek ve tahmini tür bilgisi verilerine ulaşılmak istenirse her iki sistem içinde gerçek çıktılar ile tahmini çıktılara denormalizasyon işlemi uygulanmalıdır.

Kullanılan kısıtlı veri sayısı da dikkate alındığında elde edilen doğruluk değerleri oldukça iyi değerlerdir. Sonuç olarak bu çalışmada iris çiçeği türünün ANFIS ve YSA yöntemleri ile çok az bir hata ile tahmin edilebileceği gösterilmiştir. Eğitimde kullanılan veri sayısının artırılmasının test verilerinin tahminlerindeki doğruluk derecesinin artırılmasına katkıda bulunacağı düşünülmektedir. O halde yapılan deneysel çalışmalardan yola çıkılarak söylenilebilir ki; iris çiçeği için yapılan tür tahmininde test hata türü YSA'da ANFIS'den daha düşük

çıkılmış ve sonuç olarak bu çalışmada YSA'nın ANFIS'den daha iyi sonuçlar verdiği görülmüştür.

KAYNAKÇA

- [1] B. S. Khehra and A. P. S. Pharwaha, "Classification of Clustered Microcalcifications using MLFFBP-ANN and SVM," *Egypt. Informatics J.*, vol. 17, no. 1, pp. 11–20, 2016.
- [2] B. D. Barkana, I. Sariçicek, and B. Yıldırım, "Knowledge-Based Systems Performance analysis of descriptive statistical features in retinal vessel segmentation via fuzzy logic , ANN , SVM , and classifier fusion," *Knowledge-Based Syst.*, vol. 118, pp. 165–176, 2017.
- [3] C. Affonso, A. L. D. Rossi, F. H. A. Vieira, and A. C. P. de L. F. de Carvalho, "Deep learning for biological image classification," *Expert Syst. Appl.*, vol. 85, pp. 114–122, 2017.
- [4] G. Mohan and M. M. Subashini, "Biomedical Signal Processing and Control MRI based medical image analysis : Survey on brain tumor grade classification," *Biomed. Signal Process. Control*, vol. 39, pp. 139–161, 2018.
- [5] "İris veri seti," <https://archive.ics.uci.edu/ml/datasets/iris>. [Accessed: 21-Dec-2016].
- [6] I. S. Jacobs and C. P. Bean, "Fine particles, thin films and exchange anisotropy, in Magnetism," *New York Acad.*, vol. 3, pp. 271–350, 1963.
- [7] E. Binici, "Java ile yapay zeka mekanizmasına sahip bir ağ yönetim sistemi geliştirilmesi," Ege Üniversitesi, 2006.
- [8] Ç. Elmas, *Yapay Sinir Ağları*, Kuram, Mima. Ankara: Seçkin Yayıncılık, 2003.
- [9] "Yapay Sinir Ağları," 1994. [Online]. Available: <http://ube.ege.edu.tr/~cinsdiki/UBI521/Chapter-1/cinsdikici-neural-net-giris.pdf>. [Accessed: 22-Dec-2016].
- [10] İ. Kaya, S. Oktay, and O. Engin, "Kalite Kontrol Problemlerinin Çözümünde Yapay Sinir Ağlarının Kullanımı," *Erciyes Üniversitesi Fen Bilim. Enstitüsü Derg.*, vol. 21, no. 1–2, pp. 92–107, 2005.
- [11] M. Caner and E. Akarslan, "Mermer Kesme İşleminde Spesifik Enerji Faktörünün ANFIS ve YSA Yöntemleri ile Tahmini Estimation of Specific Energy Factor in Marble Cutting Process Using," *Pamukkale Üniversitesi Mühendislik Bilim. Derg.*, vol. 15, no. 2, pp. 221–226, 2009.
- [12] L. H. Tsoukalas and R. E. Uhrig, *Fuzzy and neural approaches in engineering*. New York: Jhon Wiley & Sons, 1996.
- [13] B. Kosko, *Neural networks and fuzzy systems, A Dynamical Systems Approach*. Englewood Cliffs: NJ: Prentice Hall, 1991.
- [14] J.-S. Jang, "ANFIS: Adaptive network-based fuzzy inference systems," *IEEE Trans. Syst. Man. Cybern.*, vol. 23, no. 3, pp. 665–685, 1993.
- [15] J. S. R. Jang, C. T. Sun, and E. Mizutani, "Neuro-Fuzzy and Soft Computing-A Computational Approach to Learning and Machine Intelligence [Book Review]," *IEEE Trans. Automat. Contr.*, vol. 42, no. 10, pp. 1482–1484, 1997.
- [16] P. Perez, "Prediction of sulfur dioxide concentrations at a site near downtown Santiago, Chile," *Atmos. Environ.*, vol. 35, no. 29, pp. 4929–4935, 2001.
- [17] Çuhadar, M. and Kayacan, C., "Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye ' deki Konaklama İşletmeleri Üzerine Bir Deneme," *Anatolia Tur. Araştırmaları Derg.*, vol. 16, no. 1, pp. 24–30, 2005.
- [18] Witt, S. F. ve Witt, C. A., *Modeling and forecasting demand in tourism*. Swansea, UK: European Business Management School, University of Wales, 1992.
- [19] Lewis, C.D. 1982. *Industrial and Business Forecasting Methods*, Butterworths Publishing, Londra.