



**BULANIK MANTIK VE YAPAY SINIR AđI YÖNTEMLERİ İLE KURUTMA
SÜRECİNİN MODELLENMESİ**

MERT LEVENT

Bilgisayar Mühendisliđi Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Halil Nusret BULUŞ

2022

T.C.
TEKİRDAĞ NAMIK KEMAL ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



BULANIK MANTIK VE YAPAY SİNİR AĞI YÖNTEMLERİ İLE KURUTMA
SÜRECİNİN MODELLENMESİ

MERT LEVENT

ORCID: 0000-0002-5496-6439

BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
YÜKSEK LİSANS TEZİ
Danışman: Dr. Öğr. Üyesi Halil Nusret BULUŞ

Temmuz-2022
Her hakkı saklıdır.

BİLİMSEL ARAŞTIRMA VE YAYIN ETİĞİ KURALLARINA UYUM BEYANI

Tekirdağ Namık Kemal Üniversitesi Bilgisayar Mühendisliği Anabilim Dalında Yüksek Lisans olarak sunulan ve Fen Bilimleri Enstitüsü Lisansüstü Tez Yazım Kurallarına uygun olarak hazırlanan “Bulanık Mantık Ve Yapay Sinir Ağı Yöntemleri İle Kurutma Sürecinin Modellenmesi” isimli bu tez çalışmasıyla ilgili olarak;

- Bu tez çalışmasının tarafımda hazırlanan özgün bir çalışma olduğunu,
- Hazırlık, veri toplama, analiz ve bulguların sunumu olmak üzere tüm aşamalarında “bilimsel araştırma ve yayın etiği kurallarına” uygun davrandığımı,
- Bu çalışma kapsamında elde edilmemiş olan tüm veri ve bilgiler için bilimsel normlara uygun kaynak gösterdiğimi ve bu kaynaklara tezin “Kaynaklar” bölümünde yer verdiğimi,
- Tez çalışmamın Tekirdağ Namık Kemal Üniversitesinde kullanılan “bilimsel intihal programı” ile tarandığını ve öngörülen standartları karşıladığımı,
- Çizelgede verilen bilgilerin doğruluğunu,

Şekil Sayısı	25	Çizelge Sayısı	7	Kaynak Sayısı	27
--------------	----	----------------	---	---------------	----

Ek Sayısı	0	Sayfa Sayısı	49	Tez Savunma Tarihi	06/07/2022
-----------	---	--------------	----	---------------------------	------------

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

(İmza)

Mert LEVENT

06/07/2022

ÖZET

BULANIK MANTIK VE YAPAY SINIR AĞI YÖNTEMLERİ İLE KURUTMA SÜREÇLERİNİN MODELLENMESİ

Mert LEVENT

Bilgisayar Mühendisliği Anabilim Dalı

Yüksek Lisans Tezi

Danışman: Dr. Öğr. Üyesi Halil Nusret BULUŞ

Fındık üretiminde ön sıralarda yer alan Türkiye’de, genelde Karadeniz Bölgesinde yetiştirilen bu ürünün, diğer gıda ürünleri gibi kurutularak saklanması ürünün kullanım ömrünü uzatmaktadır. Genelde açık havada kurutulan bu tip ürünler için zemin ve iklim şartlarının elverişli olmaması nedeniyle birçok kurutma yöntemi geliştirilmiştir. Bu yöntemler kurulması ve işletmesi maliyetli olan yöntemlerdir. Ürünün kurutulması ve nem miktarının hesaplanması ile bu maliyetin azaltılması planlanmaktadır. Bunun için kullanılacak yöntemlerden biri de yapay zeka teknikleridir. Bu tez çalışmasında yapay zeka tekniklerinden olan yapay sinir ağları ve bulanık mantık tabanlı çıkarım sistemi bu kurutma parametrelerinin tahmini için kullanılmıştır. Bu yüksek lisans tez çalışmasında birçok farklı model oluşturulan yapay sinir ağının, en iyi sonuç veren modeli ile bulanık mantık çıkarım modeli karşılaştırılmış, deneysel verilere olan yakınlıkları incelenerek bir tahmin sistemi kurulması hedeflenmiştir.

Anahtar Kelimeler: Yapay Sinir Ağları, Bulanık Mantık, ANFIS, Tahmin, Levenberg Marquardt, Kurutma

ABSTRACT

MODELING OF DRYING PROCESSES WITH FUZZY LOGIC AND ARTIFICIAL NEURAL NETWORK METHODS

Mert LEVENT

Department of Computer Engineering

MSc. Thesis

Supervisor: Assist. Prof. Dr. Halil Nusret BULUŞ

In Turkey, which is at the forefront of hazelnut production, this product, which is generally grown in the Black Sea Region, is stored by drying like other food products, extending the life of the product. Many drying methods have been developed for this type of products, which are generally dried in the open air, due to the unsuitable ground and climatic conditions. These methods are costly to set up and operate. It is planned to reduce this cost by drying the product and calculating the moisture content. One of the methods to be used for this is artificial intelligence techniques. In this thesis, artificial neural networks and fuzzy logic based inference system, which are artificial intelligence techniques, are used for the estimation of these drying parameters. In this master's thesis study, many different models of the artificial neural network were created, the model with the best results was compared with the fuzzy logic inference model, and it was aimed to establish a prediction system by examining their proximity to the experimental data.

Keywords: Artificial Neural Network, Fuzzy Logic, ANFIS, Forecast, Levenberg Marquardt, Drying

İÇİNDEKİLER

ÖZET	i
ABSTRACT	ii
İÇİNDEKİLER.....	iii
ÇİZELGELER DİZİNİ.....	v
ŞEKİLLER DİZİNİ.....	vi
KISALTMALAR DİZİNİ.....	vii
TEŞEKKÜR.....	viii
1. GİRİŞ	1
1.1 Literatür Özeti	1
1.2 Çalışmanın Amacı ve Kapsamı.....	3
2. YAPAY SİNİR AĞLARI.....	5
2.1 Yapay Sinir Ağları Topolojileri	6
2.1.1 İleri Beslemeli YSA	6
2.1.2 Geri Beslemeli YSA	7
2.1.3 Modüler Sinir Ağları.....	8
2.1.4 Tekrarlayan Sinir Ağları (TSA)	9
2.1.5 RADYAL TABANLI FONKSİYON SİNİR AĞI.....	10
2.1.6 Evrişimsel Sinir Ağları (ESA)	11
2.2 Eğitim Algoritmaları	11
2.2.1 Gradyan İniş Algoritması (GİA)	11
2.2.2 Eşlenik Gradyan Algoritması (EGA).....	12
2.2.3 Quasi-Newton Algoritması (QNA).....	12
2.2.4 Levenberg-Marquardt Algoritması (LMA).....	12
2.3 Transfer Fonksiyonları	12
2.3.1 Eşik	13
2.3.2 Sigmoid	13

2.3.3 Parçalı Doğrusal.....	13
2.3.4 Gauss.....	14
2.4 Normalizasyon	14
3. ANFIS.....	16
3.1 Bulanık Mantık Yöntemleri	16
3.1.1 Mamdani Çıkarımı	16
3.1.2 Sugeno Çıkarımı	16
3.2 Üyelik Fonksiyonları.....	17
4. PERFORMANS ÖLÇÜMLERİ	18
4.1 Kök Ortalama Kare Hatası (RMSE)	18
4.2 Ortalama Mutlak Yüzde Hatası (MAPE).....	18
4.3 R Kare	18
5. MATERYAL – METOT.....	19
6. SONUÇ.....	33
KAYNAKLAR.....	34
ÖZGEÇMİŞ	Hata! Yer işareti tanımlanmamış.

ÇİZELGELER DİZİNİ

Çizelge 5.1. Deneysel Veri (120W güç için).....	19
Çizelge 5.2. Deneysel Veri (350W güç için).....	20
Çizelge 5.3.Deneysel Veri (460W güç için).....	20
Çizelge 5.4. ANN Model Sonuçları.....	26
Çizelge 5.5.ANN En iyi Model Performans Ölçümü	27
Çizelge 5.6.ANFIS performans ölçümü	30
Çizelge 5.7. ANFIS ve ANN tahmin sonuçları	31



ŞEKİLLER DİZİNİ

Şekil 2.1. Yapay Sinir Ağları Genel Mimarisi [14].....	6
Şekil 2.2. İleri Beslemeli YSA [16].....	7
Şekil 2.3. Geri Beslemeli YSA [17]	8
Şekil 2.4. Modüler Sinir Ağları	9
Şekil 2.5. Tekrarlayan Sinir Ağı.....	10
Şekil 2.6. Radyal Tabanlı Fonksiyon Sinir Ağı.....	10
Şekil 2.7. Evrişimsel Sinir Ağı	11
Şekil 2.8. Eşik Transfer Fonksiyonu	13
Şekil 2.9.Sigmoid Transfer Fonksiyonu	13
Şekil 2.10.Parçalı Doğrusal Transfer Fonksiyonu.....	14
Şekil 2.11.Parçalı Doğrusal Transfer Fonksiyonu.....	14
Şekil 5.1.YSA’da nöron sayısı ayarlama ekranı.....	22
Şekil 5.2. Çıktı katmanı ayar ekranı	22
Şekil 5.3.YSA yapısı	23
Şekil 5.4.Ağ eğitme ekranı	23
Şekil 5.5. YSA eğitim parametreleri	24
Şekil 5.6. YSA simülasyon ekranı.....	24
Şekil 5.7.Oluşturulan YSA modelleri.....	25
Şekil 5.8.Seçilen modele ait regresyon grafiği	25
Şekil 5.9. YSA eğitim performansı	26
Şekil 5.10.ANFIS Sugeno Mimarisi.....	27
Şekil 5.11.ANFIS eğitim ve genel ayar ekranı	28
Şekil 5.12.ANFIS kurallar editörü.....	29
Şekil 5.13. ANFIS modeli kuralları.....	29
Şekil 5.14.ANFIS modeli üyelik fonksiyonları	30

KISALTMALAR DİZİNİ

ANN	Artificial Neural Network
ANFIS	Adaptive Neuro Fuzzy Inference System
BM	Bulanık Mantık
LM	Levenberg-Marquardt
MLR	Multiple Linear Regression
MSE	Mean Squared Error
NPAA	Nano Porous Anodic Aluminum
RMSE	Root Mean Square Error
SVM	Support Vector Machine
YSA	Yapay Sinir Ağları

TEŐEKKÜR

Lisans ve Yüksek Lisans eğitimim boyunca bilgi, birikim ve tecrübeleri ile bana yol gösteren ve destek olan değerli danışma hocam Dr. Öğr. Üyesi Halil Nusret BULUŐ'a sonsuz teşekkür ve saygılarımı sunarım. Tezin ana planını oluŐturan tahminlerin yapılabilmesi için gerekli olan deneysel verileri bizimle paylaşan Doç. Dr. Soner ÇELEN ve Dr. Öğr. Üyesi Aytaç MORALAR'a teşekkür ederim. Eğitim hayatım boyunca yardımını ve desteğini hiç esirgemeyen sevgili annem AyŐe LEVENT'e, kendime güvenmemi sađlayan babam Bahtiyar LEVENT'e, maddi ve manevi desteğini esirmeyen teyzem Kadriye KARAGÜNEY'e sonsuz teşekkür ederim.

Mert LEVENT

Bilgisayar Mühendisi

1. GİRİŞ

Günümüzde birçok besin ve gıda maddeleri içerdikleri fazla sudan dolayı uzun süre saklanamamaktadır. Bu yüzden kurutma yöntemleri gıdalarda önemli bir yere sahiptir. Kurutma işlemini gerçekleştirmek için birçok yöntem kullanılmaktadır.

Fındık ürünü Türkiye’de Karadeniz bölgesinde yetişmekte olan bir üründür. Karadeniz bölgesinde fındık kurutması önemli bir yere sahiptir. Bölgenin iklim koşulları ve zemin yapısı göz önüne alındığında açık alan kurutmalarında zorluklar mevcuttur. Bu yüzden güneş ışığı yardımı ile kurutmak yerine daha çok kullanılan yöntem kurutma makineleridir. Bu kurutma makinelerini de içeren kurutma düzenekleri, güneş ışığı ile açık alanda kurutma işlemine göre daha maliyetli bir yaklaşımdır. Bu maliyete düzeneğin kurulması ve işletilmesi dahildir. Bu sebepten dolayı geçmişte elde edilen veriler kullanılarak, kurutma hızı ve verimi açısından yapay zeka teknikleri kullanılarak tahmin yapma işlemi gittikçe popüler bir yaklaşım haline almıştır.

1.1 Literatür Özeti

Hamed Akbarpour ve arkadaşları (2016), doğrusal olmayan modellerin nano gözenekli anodik alümina (NPAA) gözenek çapının öngörüsü üzerindeki etkisini göstermek için sayısal ve deneysel sonuçlar elde etmiştir. Bunu yapmak için ANFIS ve MLR uygulamalarını kullanmıştır. Modellerden elde edilen sonuçlar, test verileri ve modellerin doğruluğunu göstermek için iki ampirik formül arasında bir karşılaştırma yapmıştır. Yapılan deneyde modellerin NPAA membranlarının gözenek çapını tahmin etmek için yeterince iyi olduğunu göstermektedir. ANFIS en iyisi ve MLR ise diğer ampirik formüllerden daha iyi olduğu ortaya çıkmıştır [1].

Saban Pusat ve arkadaşları (2016), kurutma işlemi sırasında kömür nemi içeriğini tahmin etmek için yeni bir metodoloji uygulamışlardır. Kurutma işlemi sırasında herhangi bir zamanda kömür nemi içeriğini tahmin etmek için adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) uygulanmıştır. MSE ve R2 değerleri test aşaması için sırasıyla 1.899 ve 0.998 olarak hesaplandı. MSE ve R2 değerleri deney 1 için “2.834 ve 0.992”, deney 2 için “2.928 ve 0.964”, deney 3 için “1.895 ve 0.998” ve deney 4 için “0.409 ve 0.995” olarak hesaplandı. ANFIS ağı kabul edilebilir sapmalarla oldukça tatmin edici bilimsel sonuçlar elde eder. ANFIS kullanarak, gerçekleştirilmeyen diğer vakaların kurutma kanalları kolayca tahmin edilebilir. Bununla birlikte, gerekli deney sayısı azalır [2].

Maryam Dolatabad ve arkadaşları (2018), eş zamanlı Bazik Red46 (BR46) ve Cu (boya ve ağır metal) giderim verimliliğinin araştırmışlardır. Katyonik bir boya ve ağır metal iyonunun sulu çözeltiden eş zamanlı olarak çıkarılmasında talaşın adsorpsiyon potansiyelinin öngörülmesinde ileri beslemeli bir yapay sinir ağı (ANN) ve uyarlanabilir bir nöro-bulanık çıkarım sistemini (ANFIS) kullanmışlardır. Raporlanan sonuçlara göre, ANN ve ANFIS'in eş zamanlı boya ve Cu (II) 'nin sulu çözeltiden uzaklaştırılmasının öngörülmesi için tatmin edici bir doğrulukla etkili bir şekilde kullanılabilir umut verici bir tahmin tekniği olduğu kanıtlanmışlardır. İstatistiksel parametrenin düşük değeri, her iki modelde de daha iyi performans göstermiştir. Burada, hem model hem de Cu için boya için 0.98 - 0.99 aralığında R2 ile iyi bir regresyon analizi elde edilmiştir [3].

Victor H. Quej ve arkadaşları (2017), Meksika, Yucatán'daki günlük küresel güneş ışınımını tahmin etmek için SVM, ANFIS ve ANN tekniklerinin performansını karşılaştırmışlardır. Model performansını değerlendirmek için üç istatistiksel gösterge (R2, RMSE ve MAE) kullanmışlardır. RBF çekirdeği ile SVM tekniğinin, Meksika'daki Yucatán'da küresel güneş radyasyonu tahmininde kullanılan diğer yaklaşımlardan daha üstün olduğunu göstermiştir. Bu sonuçla birlikte Meksika altı nemli tropik ortamlarda günlük güneş ışınımını tahmin etmek için başarıyla kullanılabilir olduğu ortaya çıkmıştır. ANFIS ve ANN teknikleri benzer sonuçlara sahipti, ancak SVM tekniği kadar iyi performans göstermemiştir [4].

Mohammad Kaveh ve arkadaşları (2018), konvektif sıcak hava kurutucuda patates, sarımsak ve kavunların kuruma özelliklerini tahmin etmek için adapte bir nöro-bulanık çıkarım sistemi (ANFIS) ve Yapay Sinir Ağları (YSA) modeli geliştirmek ve uygulamak için bir araştırma yaptılar. Kurutma deneyleri, 40, 50, 60 ve 70 ° C hava sıcaklıklarında ve 0.5, 1 ve 1.5 m / s hava hızlarında gerçekleştirmişlerdir. D efekti ve SEC performansını belirlemek için çeşitli ANN ve ANFIS modellerini kullanılmışlardır. Bu araştırma sonucunda ANFIS modeli, sırasıyla D ef, SEC, MR ve DR'nin tahmin edilme kabiliyetinin yüksek olduğunu, sırasıyla 0,9900, 0,9917, 0,9774, 0,9901, R2'yi göstermiştir. Bu nedenle, ANFIS modeli en iyi model olarak önerilebilir olduğu sonuca varılmıştır [5].

Bahman Najafi ve arkadaşları (2018), harcanan mantar kompostu (SMC) kullanılarak küçük ölçekli bir biyogaz üretimi yapmışlardır. Biyogaz üretiminden elde edilen biyokütleden, ANN ve ANFIS yöntemlerini kullanarak biyogaz üretimi ve üretim modellemesinde bağımsız değişkenler olarak C/N oran sıcaklığı ve kalma süresi dahil olmak üzere biyogaz üretimini

etkileyen faktörleri araştırmışlardır. Bu çalışma ile ANFIS ağıının termofilik ve mezofilik durumlarda çıktı değerlerini doğru bir şekilde tahmin ettiği sonucuna varmışlardır [6].

Artur S. C. ve arkadaşları (2018), Alkalin Hidrojen Peroksit (AHP) kullanarak şeker kamışı delignifikasyon işleminde Yapay Sinir Ağları (ANN) ve Adaptif Şebeke Bazlı Bulanık Çıkarım Sistemi (ANFIS) kullanarak optimizasyonu karşılaştırmışlardır. İki değişken deneysel olarak değerlendirilmiştir: sıcaklık (25-45 ° C) ve hidrojen peroksit konsantrasyonu (% 1.5 - 7.5 (a/h)). Karşılaştırma sonucunda AHP ön-muamelesi, şeker kamışı küspesinin delignifikasyonunda başarılı olmuştur. ANN ve ANFIS, düşük RMSE değerleri ve 1'e yakın R2 değerleri ile iyi tahmin verimliliği sunmuştur. Ksiloz konsantrasyonu tahmini için ANFIS modeli, ANN modeline kıyasla daha iyi bir performans gösterdiği ortaya çıkmıştır [7].

Fatih Güzel ve arkadaşları (2016), Borsa İstanbul'da ana gösterge niteliği taşıyan BİST-100 endeks getirisi tahmini üzerine çalışma yapmışlardır. Çalışmada ANFIS yöntemini kullanmışlardır. İkili Gauss fonksiyonu için % 98,54 tahmin başarıları yakalamışlardır. ANFIS tekniği, kolay uygulanması ve yüksek tahmin yeteneğiyle diğer yöntemlere göreli olarak tercih edilmiştir. Yapılan çalışmada tek bir method uygulandığı için veriler kısıtlı kalmıştır [8].

Tolgay Balcı (2021), bankacılık sektörünün performans ve karlılığını ölçmek için Yapay Sinir Ağlarını (ANN) kullanmıştır. Öz kaynak getirilerini tahmin etmek için 11 yıla ait çeyrek dönem verilerinden faydalanmıştır. Verileri Bankacılık Düzenleme ve Denetleme Kurumu, Türkiye Bankalar Birliği, Türkiye İstatistik Kurumu ve Türkiye Cumhuriyet Merkez Bankası bilgilerine dayanarak oluşturmuştur. Yaptığı çalışmalar sonucunda yöntemlerin %80 üzerinde doğruluk payı ile öz kaynak karlılığını tahmin etme başarısını göstermiştir ve en iyi YSA yönteminin her banka için farklı olduğunu saptamıştır [9].

Ömer Fatih Aydın (2019), Anfis ve K-means algoritma modellerini kullanarak geleceğe yönelik enflasyon tahminleri yapmıştır. Veri setini enflasyonu etkileyen faktörlerden seçmiştir ve 148 aylık TÜFE, para arzı, dolar, işsizlik, kamu harcamaları, ihracat ve ÜFE verileri kullanılmış olup 2006/10 ve 2019/01 dönemlerini içermektedir. Kullanılan iki yöntem sonucunda K-Means algoritması hata payı en düşük çıktıyı verdiği sonucuna ulaşmıştır [10].

1.2 Çalışmanın Amacı ve Kapsamı

Bu yüksek lisans tez çalışmasında fındık ürünü için laboratuvarında mikrodalga düzeneği ile elde edilmiş kurutma işlemi sonuçları temin edilerek, sonuçların %80'i ile yapay zeka

yöntemlerine eğitim verisi olarak girdi oluşturulmuş, kalan %20 deneysel verinin tahmin edilmesi amaçlanmıştır. Tahmin sonuçlarına göre kullanılan iki yöntemin karşılaştırılması gerçekleştirilmiştir.

Kullanılan yapay zeka yöntemlerinden ilki ileri beslemeli yapay sinir ağıdır. Yapay Sinir Ağları (YSA) oluştururken farklı transfer fonksiyonları kullanılarak çeşitli modeller oluşturulmuştur. Bu modeller arasından deneysel verilere en yakın sonuç veren YSA modeli ile diğer bir yöntem olan bulanık mantık tabanlı Uyarlamalı Ağ Tabanlı Bulanık Çıkarım Sistemi (Adaptive-Network Based Fuzzy Inference Systems – ANFIS) karşılaştırılmıştır.

Bu tezde YSA ve ANFIS modelleri oluşturularak eğitim ve tahmin işlemlerinin gerçekleştirilmesi için MATLAB yazılımı kullanılmıştır.



2. YAPAY SİNİR AĞLARI


İnsan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme ve keşfedebilme gibi yetenekleri, matematiksel olarak ortaya koyan bir sistemdir. YSA insanlar gibi tecrübeler yaşayarak öğrenir ve bu öğrendiklerini karar vermede kullanır. Bu sebeple YSA, iyi bir genelleme yapabilme yeteneğine sahiptir [11].

YSA nöronlardan oluşur ve bu nöronlar çeşitli şekillerde birbirlerine bağlanarak sinir ağı oluştururlar. Bunlar öğrenme, hatırlama ve veriler arasında ilişkiyi ortaya çıkarma kapasitesine sahiptirler.

YSA, beyin gibi biyolojik sinir ağına dayanan bir sistemdir. Beyin, elektro-kimyasal sinyaller aracılığıyla iletişim kuran yaklaşık 100 milyar nörona sahiptir. Nöronlar, sinaps adı verilen bağlantılarla birbirine bağlanır. Her nöron, hücre gövdesine ulaşmak için sürekli olarak gelen sinyalleri alarak diğer nöronlarla binlerce bağlantı alır. Elde edilen sinyallerin toplamı belirli bir eşiği aşarsa, akson aracılığıyla bir yanıt gönderilir.

Son zamanlarda yapay sinir ağları, birçok disiplinde sınıflandırma, kümeleme, örüntü tanıma ve tahmin için popüler ve yararlı bir model haline geldi. YSA'lar, makine öğrenimi için bir tür modeldir ve kullanılabilirlik açısından geleneksel regresyon ve istatistiksel modellerle nispeten rekabetçi hale gelmiştir [12].

YSA katmanlardan oluşur (Şekil 2.1.). Her katmandaki nöronlar bir sonraki katmanın nöronlarıyla bağlantılıdır. Yapay sinir ağları üç ana katmanda incelenir. Girdi katmanı, gizli katman ve çıktı katmanı [13].



Şekil 2.1. Yapay Sinir Ağları Genel Mimarisi [14]

2.1 Yapay Sinir Ağları Topolojileri

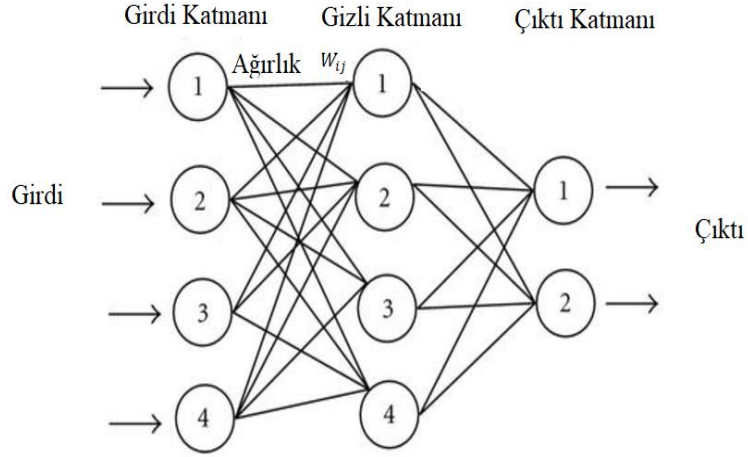
Yapay sinir ağları, insan sinir sisteminin işleyişine benzer şekilde çalışan hesaplama modelleridir. Birkaç çeşit yapay sinir ağı vardır. Bu tür ağlar, matematiksel işlemlere ve çıktıyı belirlemek için gereken bir dizi parametreye dayalı olarak uygulanır [14].

2.1.1 İleri Beslemeli YSA

Bu YSA'da bilgi akışı tek yönlüdür. Bu sinir ağı, verinin veya girdinin bir yönde hareket ettiği en basit YSA biçimlerinden biridir. Bir birim, herhangi bir bilgi almadığı diğer birime bilgi gönderir. Geri besleme döngüleri yoktur. Örüntü oluşturma/tanıma/sınıflandırmada kullanılırlar. Sabit giriş ve çıkışları vardır. Daha çok örüntü oluşturma, örüntü tanıma ve sınıflandırmada kullanılırlar [15].

Aşağıda Şekil .2.2.'de Tek gizli katmanlı ileri beslemeli bir ağ bulunmaktadır. Burada girdilerin ve ağırlıkların çarpımlarının toplamı hesaplanır ve çıktı beslenir.

Ağırlık, ağız gizli katmanları içindeki girdi verilerini dönüştüren bir sinir ağı içindeki parametredir. Bir sinir ağı, bir dizi düğüm veya nörondur. Her düğümün içinde bir dizi girdi, ağırlık ve bir sapma değeri bulunur. Bir girdi düğümüne girdiğinde, bir ağırlık değeri ile çarpılır ve ortaya çıkan çıktı ya gözlemlenir ya da sinir ağındaki bir sonraki katmana iletilir. Genellikle bir sinir ağının ağırlıkları, ağız gizli katmanlarında bulunur [15].




Şekil 2.2. İleri Beslemeli YSA [16]

2.1.2 Geri Beslemeli YSA

Geri Beslemeli sinir ağlarında sinyaller her iki yönde de hareket edebilir. Geri beslemeli sinir ağları çok güçlüdür ve çok karmaşık hale gelebilir. Geri beslemeli sinir ağları dinamiktir. Böyle bir ağdaki 'durum', bir denge noktasına ulaşana kadar değişmeye devam eder. Girdi değişene ve yeni bir denge bulunması gerekene kadar denge noktasında kalırlar.

Geri beslemeli sinir ağı mimarisi, etkileşimli veya tekrarlayan olarak da adlandırılır, ancak ikinci terim genellikle tek katmanlı organizasyonlarda geri besleme bağlantılarını belirtmek için kullanılır. Bu tür ağlarda geri besleme döngülerine izin verilir. İçerik adreslenebilir hafızalarda kullanılırlar.



Şekil 2.3. Geri Beslemeli YSA [17]

2.1.3 Modüler Sinir Ağları


Modüler Sinir Ağları, bağımsız olarak çalışan ve çıktıya katkıda bulunan farklı ağlardan oluşan bir koleksiyona sahiptir. Her sinir ağı, alt görevleri oluşturan ve gerçekleştiren diğer ağlara kıyasla benzersiz olan bir dizi girdiye sahiptir. Bu ağlar, görevlerin yerine getirilmesinde birbirleriyle etkileşime girmez veya sinyal vermez.

Bu tür sinir ağlarında, birçok bağımsız ağ sonuçlara toplu olarak katkıda bulunur. Bu sinir ağlarının her biri tarafından gerçekleştirilen ve oluşturulan birçok alt görev vardır. Bu, diğer sinir ağlarıyla karşılaştırıldığında benzersiz olan bir dizi girdi sağlar. Herhangi bir görevi yerine getirmek için bu sinir ağları arasında sinyal alışverişi veya etkileşimi yoktur.

Bu modüler ağlar tarafından problemler çözülürken bir problemin karmaşıklığı kolayca azaltılır, çünkü bunlar büyük boyutlu hesaplama sürecini tamamen küçük bileşenlere ayırır. Hesaplama hızı, bağlantı sayısı bozulduğunda da iyileşir ve sinir ağlarının birbirleriyle etkileşim ihtiyacını azaltır.

Toplam işleme süresi ayrıca sonuçların hesaplanmasında nöronların katılımına ve sürece kaç nöronun dâhil olduğuna bağlı olacaktır. Modüler Sinir Ağları (MNN'ler), yapay zekânın en hızlı büyüyen alanlarından biridir [18].

Şekil 2.4.'te modüler sinir ağının mimarisi gösterilmektedir.



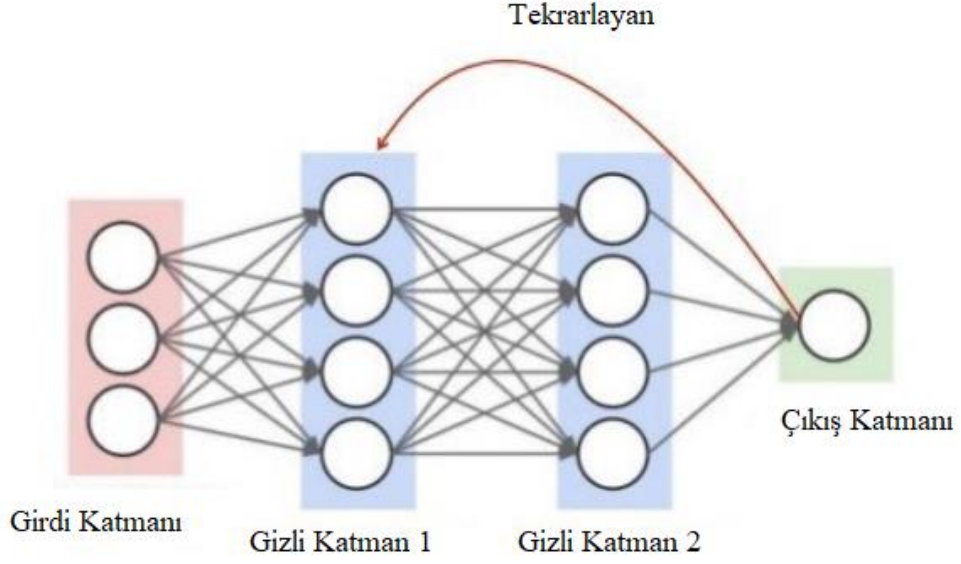
Şekil 2.4. Modüler Sinir Ağları

2.1.4 Tekrarlayan Sinir Ağları (TSA)

Tekrarlayan Sinir Ağı, bir katmanın çıktısını kaydetme ve katmanın sonucunu tahmin etmeye yardımcı olmak için bunu girdiye geri besleme olarak verme ilkesiyle çalışır. Burada, ağırlıkların ve özelliklerin toplamının çarpımı ile ileri beslemeli sinir ağına benzer şekilde birinci katman oluşturulur. Tekrarlayan sinir ağı süreci, bu hesaplandıktan sonra başlar. Bu, bir zaman adımından diğerine her nöronun bir önceki zaman adımında sahip olduğu bazı bilgileri hatırlayacağı anlamına gelir.

Her nöronun hesaplamaları gerçekleştirirken bir hafıza hücresi gibi davranmasını sağlar. Bu süreçte, sinir ağının ön yayılım üzerinde çalışmasına izin verilmeli ve daha sonra kullanmak için hangi bilgilere ihtiyaç duyduğunun hatırlanması sağlanmalıdır. Burada, tahmin yanlışsa, küçük değişiklikler yapmak için öğrenme oranı veya hata düzeltmesi kullanılır. Böylece geri yayılım sırasında doğru tahminde bulunmaya doğru kademeli olarak çalışacaktır [14].

Şekil 2.5'te tekrarlayan sinir ağının mimarisi gösterilmektedir.

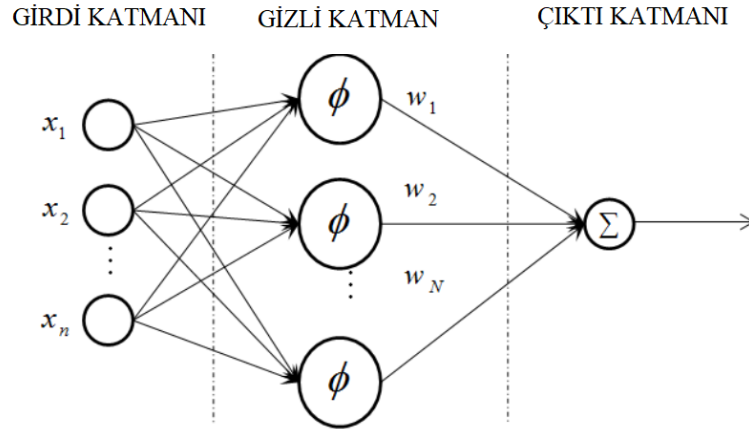


Şekil 2.5. Tekrarlayan Sinir Ağı

2.1.5 RADYAL TABANLI FONKSİYON SİNİR AĞI

Radyal tabanlı fonksiyon (RTF) ağları, fonksiyon yaklaşımı problemleri için yaygın olarak kullanılan bir yapay sinir ağı türüdür. Radyal tabanlı fonksiyon sinir ağı, evrensel yaklaşımları ve daha hızlı öğrenme hızları nedeniyle diğer sinir ağlarından ayrılır. Bir RBF ağı, giriş katmanı, gizli katman ve çıkış katmanı olmak üzere üç katmandan oluşan bir tür ileri beslemeli sinir ağıdır. Bu katmanların her birinin farklı görevleri vardır [19].

Şekil 2.6.'da radyal tabanlı fonksiyon sinir ağının mimarisi gösterilmektedir.




Şekil 2.6. Radyal Tabanlı Fonksiyon Sinir Ağı

2.1.6 Evrişimsel Sinir Ağları (ESA)

Evrişimsel sinir ağları, nöronların öğrenilebilir ağırlıklara ve önyargılara sahip olduğu ileri beslemeli sinir ağlarına benzer. Bu ağ bir girdi görüntüsünü alır ve görüntüdeki çeşitli görünüşleri ve nesnelere birbirinden ayırt eden bir derin öğrenme algoritmasıdır.

Girdi özellikleri bir filtre gibi toplu olarak alınır. Ağ, görüntüleri parçalar halinde anlar ve tam görüntü işlemeyi tamamlamak için bu işlemleri birden çok kez hesaplayabilir. İşleme, görüntünün RGB veya HSI ölçeğinden gri ölçeğe dönüştürülmesini içerir. Piksel değerindeki değişiklikleri iletirmek, kenarları algılamaya yardımcı olacaktır ve görüntüler farklı kategorilerde sınıflandırılabilir [18].

Şekil 2.7.'de evrişimsel sinir ağının mimarisi gösterilmektedir.



Şekil 2.7. Evrişimsel Sinir Ağı

2.2 Eğitim Algoritmaları

Eğitim algoritması, eğitim verilerinde, giriş verisi özniteliklerini hedefe eşleyen kalıpları bulur ve bu kalıpları yakalayan bir makine öğrenmesi modeli çıkarır. Hedefini bilmediğimiz yeni veriler hakkında tahminler almak için makine öğrenme modeli kullanılır.

Bu modeller, örneklerden oluşan bir eğitim veri seti verildiğinde girdileri çıktılarla eşleştirmeyi öğrenir. Eğitim süreci, belirli bir problemi çözmede iyi veya yeterince iyi olduğunu kanıtlayan ağda bir dizi ağırlık bulmayı içerir.

2.2.1 Gradyan İniş Algoritması (GİA)

Gradyan iniş (Gİ), belirli bir fonksiyonun yerel minimum/maksimumunu bulmak için kullanılan yinelemeli birinci dereceden bir optimizasyon algoritmasıdır. Bu yöntem, bir

maliyet/kayıp işlevini en aza indirmek için makine öğreniminde (MÖ) ve derin öğrenmede (DÖ) yaygın olarak kullanılır. Önemi ve uygulama kolaylığı nedeniyle, bu algoritma genellikle hemen hemen tüm makine öğrenmesi derslerinin başında öğretilir [20].

Ancak kullanımını yalnızca MÖ/DÖ ile sınırlı değildir, ayrıca aşağıdaki alanlarda da yaygın olarak kullanılmaktadır:

- Kontrol mühendisliği (robot, kimya, vb.)
- Bilgisayar oyunları
- Makine Mühendisliği

2.2.2 Eşlenik Gradyan Algoritması (EGA)

Matematikte, Eşlenik Gradyan Yöntemi, matrisi pozitif tanımlı olan belirli lineer denklem sistemlerinin sayısal çözümü için kullanılan bir algoritmadır. Bu yöntem genellikle, yinelemeli bir algoritma olarak kullanılır.

2.2.3 Quasi-Newton Algoritması (QNA)

Newton'un yöntemine alternatif olarak sıfırları veya kısmi maksimumları ve minimumları bulmak için kullanılan yöntemdir. Bu yöntem Jacobian veya Hessian kullanılamıyorsa veya her yineleme maliyetliyse kullanılır. Newton'un yöntemi, sıfırları aramak için Jacobian'ı, maksimum veya minimumu bulmak için Hessian'ı kullanmak gerektirir.

2.2.4 Levenberg-Marquardt Algoritması (LMA)

Matematik ve hesaplamada, doğrusal olmayan en küçük kareler problemlerini çözmek için kullanılır. Bu algoritma son yıllarda ağ topluluğunun popülaritesini artırmıştır. Ancak ağ uygulamaları arasında farklılıklar vardır ve optimizasyon ağ parametrelerinin tahmin edilmesi gerektiği gerçeğinden kaynaklanmaktadır.


Bu algoritma tarafından elde edilen optimizasyon performansı önemli ölçüde daha iyidir. LM, hem bellek hem de zaman kısıtlamalarının davranışını artırmak için sinirsel komşuluk kavramını kullanır [21].

2.3 Transfer Fonksiyonları

Transfer işlevi, giriş sinyallerini çıkış sinyallerine çevirir. Dört tür transfer işlevi yaygın olarak kullanılır. Eşik, sigmoid, parçalı doğrusal ve Gauss [22].

2.3.1 Eşik

Çıktı, toplam girdinin bazı eşik değerlerinden büyük veya küçük olmasına bağlı olarak iki seviyeden birine ayarlanır.




Şekil 2.8. Eşik Transfer Fonksiyonu

$$f(x) = \begin{cases} 0, & x < 0 \\ 1, & x \geq 0 \end{cases} \quad (2.1)$$

2.3.2 Sigmoid

Sigmoid işlevi, lojistik ve teğetsel olmak üzere 2 işlevden oluşur. Lojistik fonksiyonun değerleri, teğetsel fonksiyon için 0 ile 1 ve -1 ile +1 arasında değişir.




Şekil 2.9.Sigmoid Transfer Fonksiyonu

$$f(x) = \frac{1}{1 + e^{-\beta x}} \quad (2.2)$$

2.3.3 Parçalı Doğrusal

Parçalı doğrusal transfer fonksiyonunun çıktısı, toplam ağırlıklı çıktı ile doğrusal orantılıdır.




Şekil 2.10.Parçalı Doğrusal Transfer Fonksiyonu

$$f(x) = \begin{cases} 0, & x \leq x_{\min} \\ mx + b, & x_{\max} > x > x_{\min} \\ 1, & x \geq x_{\max} \end{cases} \quad (2.3)$$

2.3.4 Gauss

Gauss fonksiyonları, sürekli olan çan şeklindeki eğrilerdir. Düğüm çıktısı (yüksek/düşük), net girdinin seçilen ortalama değerine ne kadar yakın olduğuna bağlı olarak sınıf üyeliği (1/0) açısından yorumlanır.



Şekil 2.11.Parçalı Doğrusal Transfer Fonksiyonu

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.4)$$

2.4 Normalizasyon

Normalizasyon, sayısal verileri şeklini bozmadan ortak bir ölçeğe getirmek için kullanılan bir veri ön işleme aracıdır. Genel olarak, verileri bir makineye veya derin öğrenme algoritmasına girildiğinde, değerleri dengeli bir ölçeğe getirme eğilimindedir.

Derin bir sinir ađına ekstra katmanlar ekleyerek sinir ađlarını daha hızlı ve daha kararlı hale getirme sürecidir. İki aşamalı bir süreçtir. İlk olarak girdi normalleştirilir ve daha sonra yeniden ölçeklendirme ve kalıplama işlemi gerçekleştirilir [23].



3. ANFIS

ANFIS, bulanık mantık ve yüksek düzeyde birbirine bağılı sinir ağıları aracılığıyla girdileri çıktıya dönüştüren bir öğrenme tekniğidir. Hem yapay sinir ağlarının (YSA), hem de Bulanık Mantık (BM) avantajlarını tek bir çatı altında birleştirir. ANFIS, hibrit bir öğrenme algoritmasıdır.

Karmaşık kalıpları modellemek ve doğrusal olmayan ilişkileri anlamak için hızlandırılmış öğrenme kapasitesi ve uyarlanabilir yorumlama yetenekleri sağlar. ANFIS, çeşitli alanlarda uygulanmış ve geliştirilmiş, zaman ve mekân karmaşıklığı ile yaygın olarak tekrarlanan sorunlara çözümler sağlamıştır [24].

3.1 Bulanık Mantık Yöntemleri

Bulanık mantıkta birçok çıkarım yöntemleri bulunmaktadır. Bu çıkarımların bazıları doğrudan bulanık mantık üzerinde çalışmak için geliştirilmiştir. En çok kullanılan iki yöntem şunlardır.

3.1.1 Mamdani Çıkarımı

Bu çıkarım 1975 yılında İbrahim Mamdani tarafından geliştirilmiştir. Mamdani sisteminde her girdi ve çıktı bir bulanık değerdir.

Mamdani çıkarımı daha sezgisel ve anlaşılması daha kolay kural temellerine sahip olduğundan, tıbbi teşhis gibi kuralların insan uzman bilgisinden oluşturulduğu uzman sistem uygulamaları için çok uygundur [25].

3.1.2 Sugeno Çıkarımı

Takagi-Sugeno-Kang bulanık çıkarımı olarak da adlandırılan Sugeno bulanık çıkarımı, giriş değerlerinin sabit veya doğrusal bir fonksiyonu olan tekil çıktı üyelik fonksiyonlarını kullanır [25].

Bu çıkarım kontrol problemlerinde sıklıkla tercih edilen bir yöntemdir. Mamdani yönteminden farkı: Mamdani çıkarımı bulanık değerlerle çıktı verirken, Sugeno ise çıktıyı bir bir fonksiyon şeklinde vermektedir. Bu sebeple Sugeno çıkarım sistemi matematiksel olarak analiz için çok uygundur

3.2 Üyelik Fonksiyonları

Üyelik fonksiyonları ilk olarak 1965 yılında Lofti A. Zadeh tarafından “bulanık kümeler” adlı ilk araştırma makalesinde tanıtıldı. Üyelik fonksiyonları, giriş uzayındaki her noktanın 0 ile 1 arasında bir üyelik değerine (veya üyelik derecesine) nasıl eşlendiğini tanımlayan bir eğridir. Her bir girdinin katılımının büyüklüğünün grafiksel bir temsilidir. Kurallar, çıktı değerlerinin bulanık çıktı kümeleri üzerindeki etkilerini belirlemek için ağırlıklandırma faktörleri olarak girdi üyelik değerlerini kullanır. Fonksiyonlar çıkarıldıktan, ölçeklendirildikten ve birleştirildikten sonra, sistemi yönlendiren net bir çıktıya bulanıklaştırılırlar.

En basit üyelik fonksiyonları düz çizgiler kullanılarak oluşturulur. Basit formülleri ve hesaplama verimliliği nedeniyle, hem üçgen hem de yamuk yaygın olarak kullanılmıştır [26].

4. PERFORMANS ÖLÇÜMLERİ

Performans ölçümleri, her makine öğrenimi hattının bir parçasıdır. İlerleme kaydedip kaydetmediğinizi size söylerler ve üzerine bir numara koyarlar. Bu tez çalışmasında performans ölçümleri yapılan tahminlerin, deneysel verilere ne kadar yaklaştığının belirlenmesinde kullanılmıştır. Performans ölçümleri için kullanılan yöntemler kök ortalama kare hatası, ortalama mutlak yüzde hatası ve r kare olmuştur.

4.1 Kök Ortalama Kare Hatası (RMSE)

Ortalama kare hatası (RMSE), tahmin edilen sonuçlar ile gerçek değerler arasındaki uzaklığı mutlak bir sayı olarak verir. Tahminlerin kalitesini değerlendirmek için en sık kullanılan ölçülerden biridir. RMSE tahmin hatalarının (kalıntıların) standart sapmasıdır. Bu değer 0 ile sonsuz değer arasında değişebilir. Çıkan değerın sifira yakın olması modelin iyi performans gösterdiğine işarettir.

$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}} \quad (4.1)$$

4.2 Ortalama Mutlak Yüzde Hatası (MAPE)

Ortalama mutlak yüzde hatası (MAPE), ölçekten bağımsız olma ve yorumlanabilirlik avantajlarından dolayı, tahmin doğruluğunun en yaygın kullanılan ölçülerinden biridir. MAPE, yorumlanması ve açıklanması kolay olduğu için yaygın olarak kullanılır. Örneğin %10'lık bir MAPE değeri, tahmin edilen değer ile gerçek değer arasındaki ortalama farkın %10 olduğu anlamına gelir.

$$MAPE = \frac{100}{n} \sum_j^n \frac{|e_j|}{|A_j|} \quad (4.2)$$

4.3 R Kare

Doğrusal regresyon modelindeki bağımsız değişkenlerin bağımlı değişkendeki değişkenliği ne kadar iyi açıkladığını açıklamak için kullanılır. R Kare değeri, modelimizde gereksiz değişkenlerin eklenmesine yol açabilecek bağımsız değişkenlerin eklenmesiyle her zaman artar.

$$r^2 = 1 - \left(\frac{\sum_{i=1}^N (o_i - t_i)^2}{\sum_{i=1}^N (t_i)^2} \right) \quad (4.3)$$

5. MATERYAL – METOT

Bu yüksek lisans tez çalışmasında farklı transfer fonksiyonlarından oluşan 9 ileri beslemeli yapay sinir ağı modeli eğitilmiş ve fındık ürününün kurutulması sonuçlarının tahmin edilmesi sağlanmıştır. Buna ilave olarak ANFIS modeli de oluşturularak aynı veriler üzerinde benzer tahmin işlemi gerçekleştirilmiştir. Eğitim verisi olarak deneysel verinin %80'i alınmıştır.

Deneysel veriler Tekirdağ Namık Kemal Üniversitesi Makine Mühendisliği Bölümü Laboratuvarında kurulan konveyör bantlı bir mikrodalga düzeneğinden elde edilmiştir [27]. Çizelge 5.1, Çizelge 5.2 ve Çizelge 5.3 bu deneysel verileri göstermektedir.

Çizelge 5.1. Deneysel Veri (120W güç için)

100 g		
120W		MR Yaş
Zaman	My	My/Mo
0	100	1,00
5	98	0,86
10	95,5	0,68
15	93,5	0,53
20	92	0,42
25	91	0,34
30	90	0,26
35	89,5	0,21
40	89	0,17
45	88,5	0,13
50	88,25	0,11
55	88	0,09
60	88	0,09
65	88	0,09
70	88	0,09

Çizelge 5.2. Deneysel Veri (350W güç için)

100 g

350W		MR Yaş
Zaman	My	My/Mo
0	100,00	1,00
3	94,50	0,67
6	90,00	0,37
9	88,00	0,23
12	87,00	0,15
15	86,50	0,12
18	86,00	0,08
21	86,00	0,08
24	86,00	0,08

Çizelge 5.3.Deneysel Veri (460W güç için)

100 g

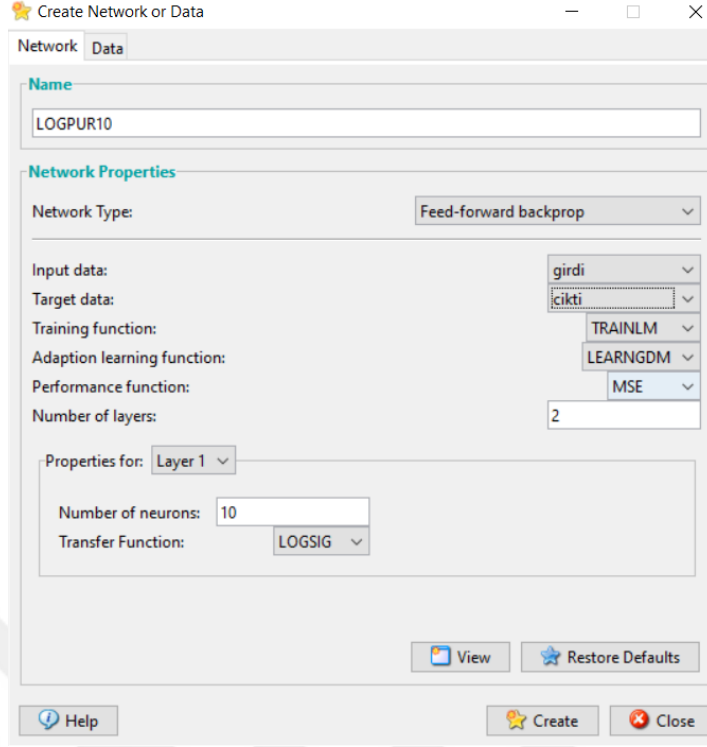
460W		MR Yaş
Zaman	My	My/Mo
0	100,00	1,00
1	99,00	0,95
2	97,00	0,84
3	95,00	0,72
4	93,00	0,60
5	91,00	0,48
6	90,00	0,42
7	89,00	0,35
8	88,50	0,32
9	88,00	0,28
10	87,50	0,25
11	86,00	0,15
12	85,50	0,11
13	85,25	0,09
14	85,10	0,08

Çizelge 5.3. Deneysel Veri (460W güç için) (devamı)

460W		MR Yaş
Zaman	My	My/Mo
15	85,00	0,07
16	85,00	0,07

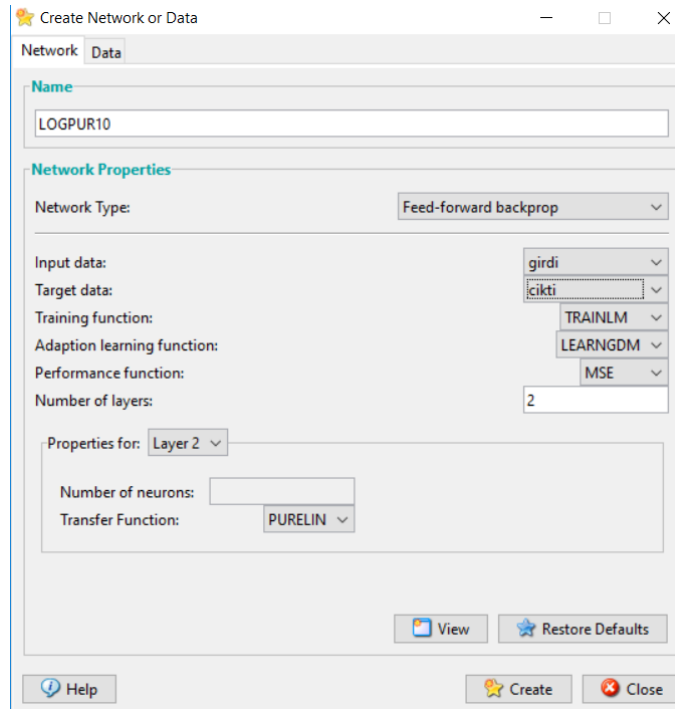
Yapay sinir ağlarında tahmin yapma işleminin ilk adımı girdi, çıktı ve test verilerinin seçilmesi ile başlar. Burada girdi verisi Çizelge 1, Çizelge 2 ve Çizelge 3'te verilmiş olan deneysel verilerin rastgele bir şekilde seçilmiş %80'inden oluşmaktadır. Girdi verileri 4 sütundan oluşmaktadır. Bu sütunlar zaman, güç, yaş kütle ve kuru kütlelerdir. Çıktı verileri deneysel verilerden girdi verisi olarak seçilenlerin ürettiği nem oranıdır. Test verileri ise deneysel verilerin girdi verisi olarak seçilmeyen %20'si olarak belirlenir.

Veriler seçildikten sonra MATLAB'da nntool aracı ile yapay sinir ağı oluşturma işlemi gerçekleştirilmiştir. Araçta YSA oluşturma işleminin ilk adımı Şekil 5.1'de gösterilmiştir. Burada ilk gizli katman için nöron sayısının belirlenmesi işlemi gerçekleştirilmiştir. Bu çalışmada yapılan denemelerde 10, 20, 30 nöronlu modeller denenmiştir. Şekil 5.1'de ise nöron sayısının 10 seçilmiş olan model gösterilmiştir. Buna ilave olarak ilk katman için transfer fonksiyonu da bu ekrandan seçilmektedir. Bu çalışmada yapılan denemelerde 3 tane transfer fonksiyonu kullanılmıştır. Bu fonksiyonlar tanjant sigmoid, logaritmik sigmoid ve lineer fonksiyonlardır. Bu transfer fonksiyonlarının ayrı ayrı denemelerde kullanılmasıyla 9 model oluşturulmuştur. Şekil 5.1'de ilk katman için logaritmik sigmoid fonksiyonun seçildiği gözükmektedir. Ayrıca eğitim fonksiyonu olarak da Levenberg-Marquardt belirlenmiştir.



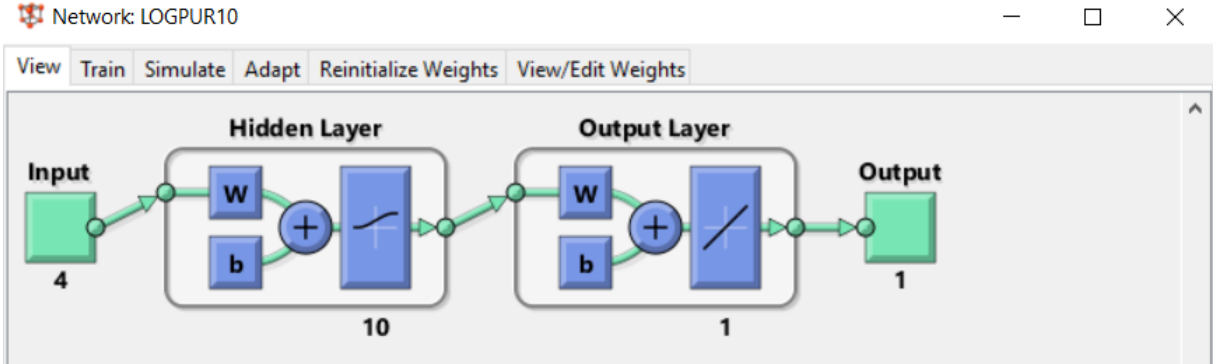
Şekil 5.1.YSA'da nöron sayısı ayarlama ekranı

Şekil 5.2 çıktı katmanı için ayarların yapıldığı ekran görüntüsüdür. Burada da transfer fonksiyonu olarak lineer fonksiyonun seçildiği model ayarları gözükmemektedir.



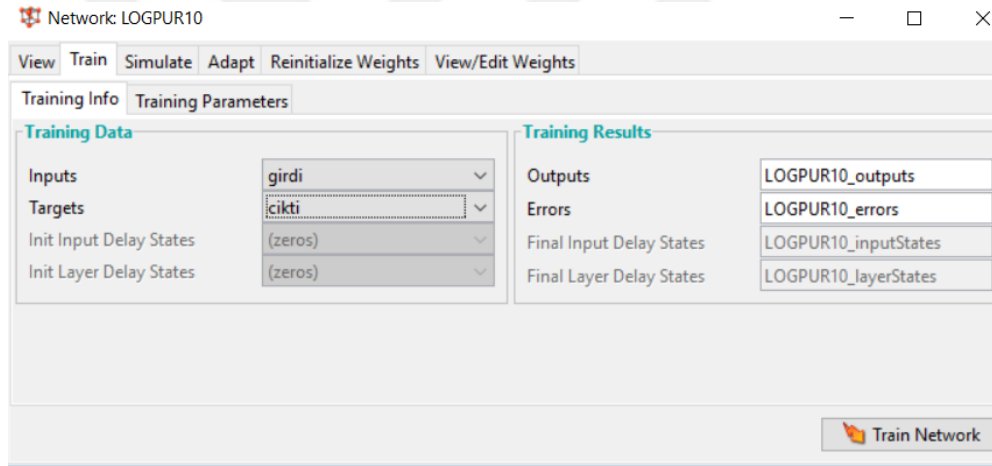
Şekil 5.2. Çıktı katmanı ayar ekranı

Belirtilen ayarlarla üretilmiş yapay sinir ağı modeli Şekil 5.3'te gösterilmiştir.



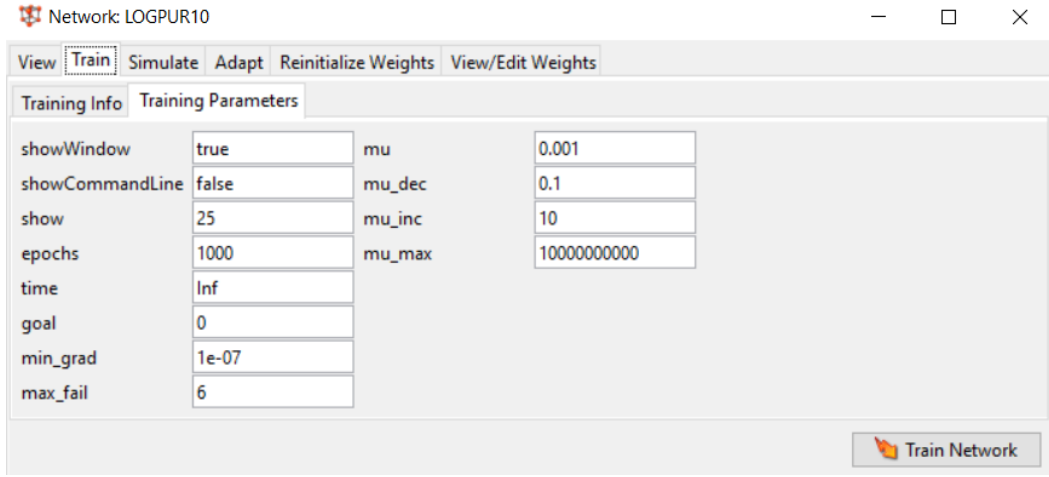
Şekil 5.3.YSA yapısı

Model oluşturulduktan sonra eğitim verileri ile modelin eğitilmesi gerekmektedir. Eğitim verilerinin oluşturduğu girdi ve çıktı verilerinin seçilerek ağın eğitildiği ekran Şekil 5.4'te gösterilmektedir.



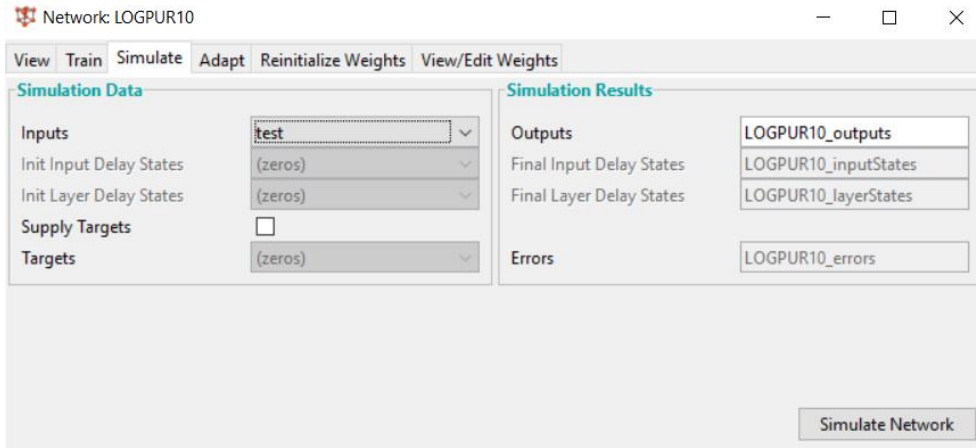
Şekil 5.4.Ağ eğitme ekranı

Ağın eğitilmesi bir takım parametre ayarını da gerektirmektedir. Bu ayarların yapıldığı ekran görüntüsü Şekil 5.5'te verilmiştir.



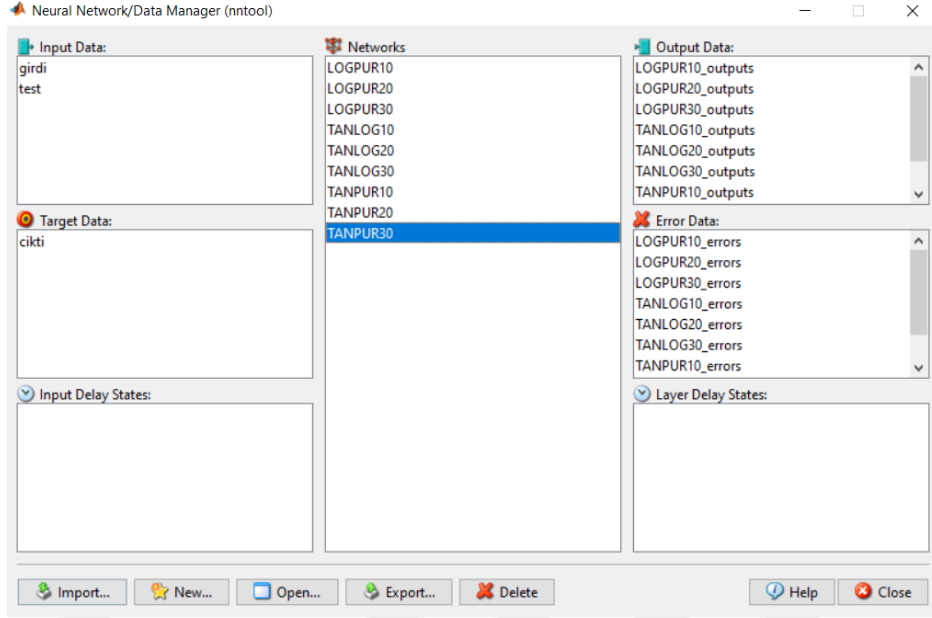
Şekil 5.5. YSA eğitim parametreleri

Eğitim işlemi tamamlandıktan sonra tahmin yapmak için test verilerinin oluşturulan YSA'ya verilmesi ve tahmin çıktılarının üretilmesi gerekmektedir. Şekil 5.6'da gösterilen ekranda test verileri eğitilen YSA'ya verilmektedir. Böylece sistemin simülasyonu gerçekleştirilmiş olur.



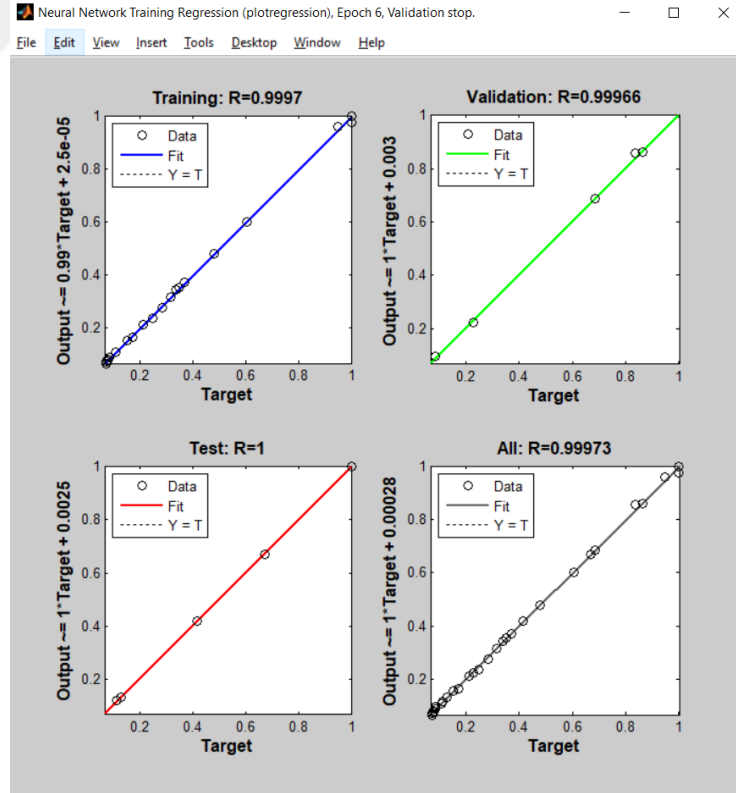
Şekil 5.6. YSA simülasyon ekranı

9 ayrı model için oluşturulmuş YSA listesi Şekil 5.7'de verilmiştir.




Şekil 5.7.Oluşturulan YSA modelleri

Bu 9 modelden deneysel sonuçlara en yakın sonuç veren modele ait regresyon grafiği Şekil 5.8’de verilmiştir.



Şekil 5.8.Seçilen modele ait regresyon grafiği

Seçilen modelin eğitim performansı grafiği ise Şekil 5.9’da verilmiştir.



Şekil 5.9. YSA eğitim performansı

Yapay sinir ağlarında tahmin işlemleri İleri Beslemeli Geriye Yayılım Sinir Ağı modeli kullanılmıştır. 3 farklı transfer fonksiyon modeli ve farklı nöron sayıları kullanılarak elde edilen sonuçlar Çizelge 5.4’ de belirtilmiştir.

Çizelge 5.4. ANN Model Sonuçları

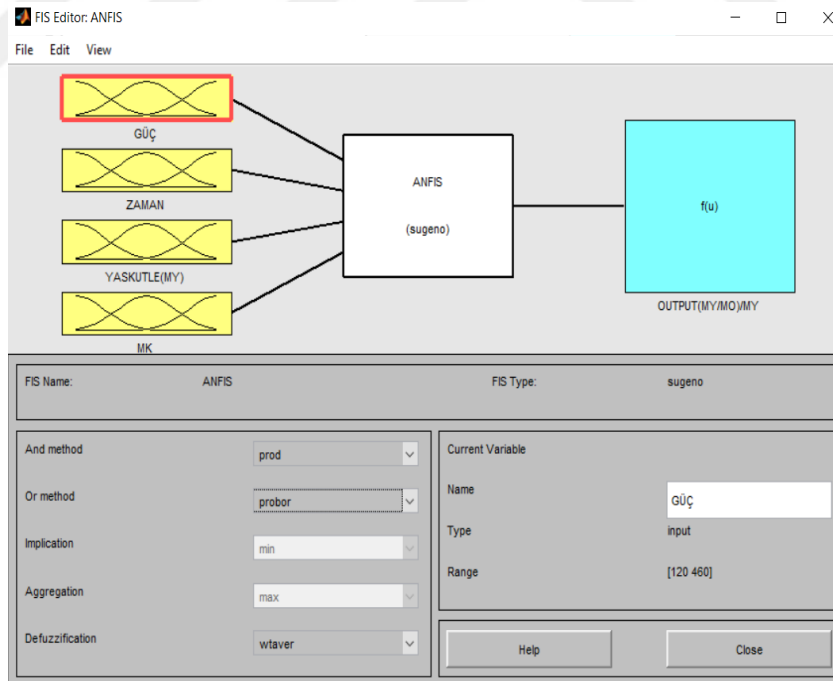
	10			20			30			
Deneysel Veri	Logsig	Tansig	Tansig	Logsig	Tansig	Tansig	Logsig	Tansig	Tansig	
	Purelin	Purelin	Logsig	Purelin	Purelin	Logsig	Purelin	Purelin	Logsig	
	0,41806	0,43816	0,39411	0,53676	0,38372	0,40042	0,5368	0,43253	0,46774	0,54458
	0,10896	0,10961	0,11399	0,53676	0,10059	0,10752	0,53677	0,11492	0,09048	0,53676
	0,53476	0,55196	0,51423	0,53678	0,49265	0,50845	0,53717	0,56101	0,71741	0,58266
	0,09164	0,09309	0,10358	0,53676	0,09589	0,08936	0,53677	0,09621	0,09096	0,53677
	0,07752	0,08376	0,06746	0,53676	0,05151	0,08769	0,53676	0,02169	0,07273	0,53676
	0,08741	0,09135	0,07763	0,53676	0,09315	0,09026	0,53677	0,09712	0,06534	0,53676
	0,25641	0,27203	0,24618	0,53676	0,26646	0,2692	0,53677	0,25767	0,26019	0,53685
	0,14535	0,14181	0,15429	0,53676	0,13545	0,14412	0,53677	0,15108	0,14557	0,53677
	0,72368	0,73066	0,73228	0,77759	0,72868	0,71914	0,73404	0,71098	0,71496	0,69299
	0,07752	0,0944	0,06901	0,53676	0,06033	0,09355	0,53677	0,07431	0,07038	0,53676

Elde edilen bu sonuçlara göre her bir modelin performans ölçümü yapılmıştır. Yapılan ölçümler göz önüne alındığında en başarılı YSA modelinin gizli katmanda 10 nörona, transfer LOGSIS ve çıktı katmanının transfer fonksiyonu da PURELIN olan model olduğu belirlenmiştir. Bu modele ait performans ölçümleri Çizelge 5.5'te verilmiştir.

Çizelge 5.5.ANN En iyi Model Performans Ölçümü

	Eğitim verisi	Test verisi	Tümü
RMSE	0,007405453	0,006591519	0,009914074
r^2	0,999784562	0,998787963	0,999661542
MAPE	1,92757443	5,402078092	2,775014347

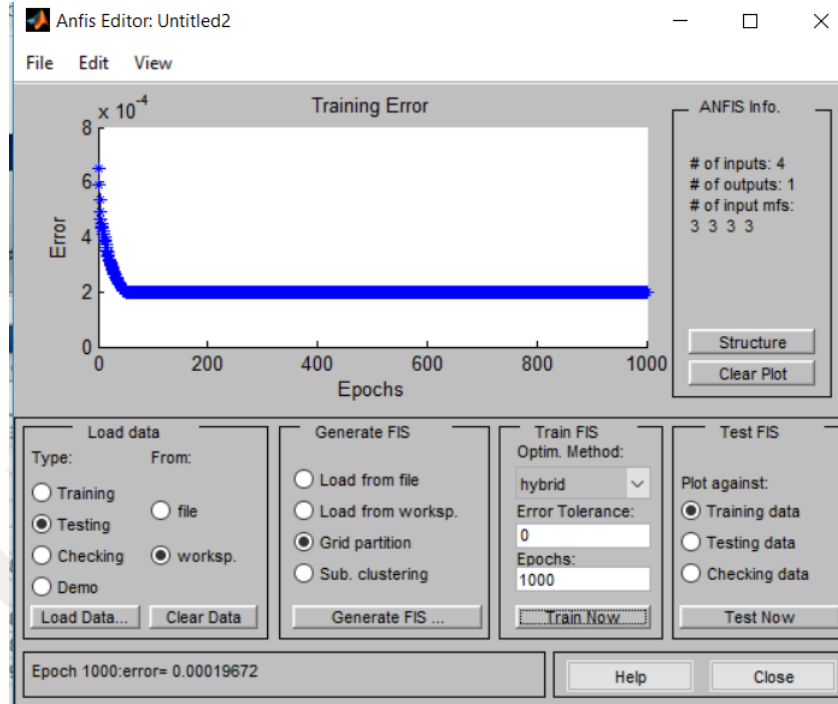
Bu YSA modeli ile karşılaştırması yapılacak olan ANFIS modelinin oluşturulması için MATLAB platformu kullanılmıştır. ANFIS modeli oluşturulurken Sugeno çıkarım yöntemi seçilir ve girdi sayısı YSA modeli ile aynı olarak 4 seçilir. Şekil 5.10, 4 girdili ve tek çıktılı olan ANFIS modelini göstermektedir.



Şekil 5.10.ANFIS Sugeno Mimarisi

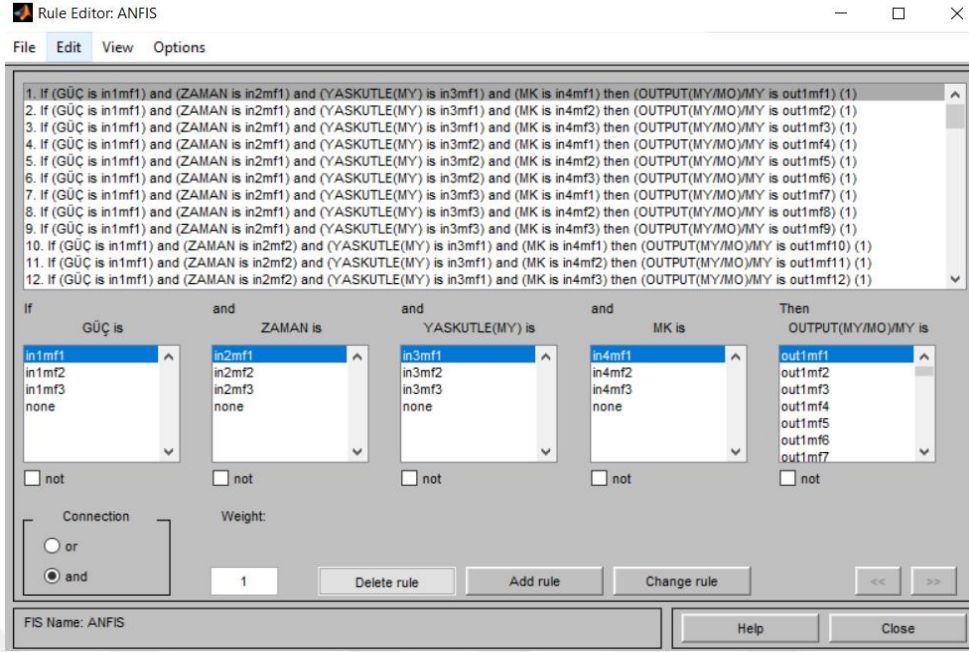
Çıkarım yöntemi seçildikten sonra yapılan işlem modelin eğitilmesi ile devam eder. Bu eğitimin gerçekleşmesi için öncelikle eğitim ve test verilerinin modele eklenmesi

gerekmektedir. Veri ekleme ve eğitimin yapılması için gerekli ayarlamaların yapıldığı ekranın görüntüsü Şekil 5.11’de verilmiştir.

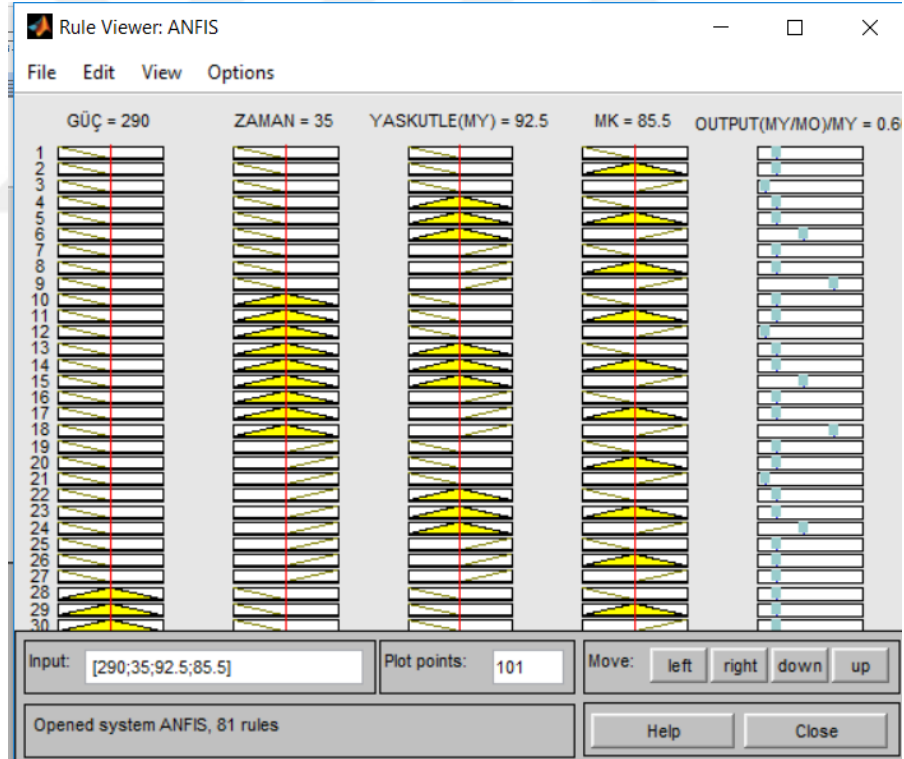


Şekil 5.11.ANFIS eğitim ve genel ayar ekranı

Eğitim yapıldıktan sonra ANFIS modelinin oluşturduğu kurallar elde edilir. Bu kurallar otomatik olarak elde edilebileceği gibi tek tek yazmak suretiyle de oluşturulabilir. Otomatik olarak elde edilmiş kuralların değiştirilebildiği, yeni kurallar eklenebildiği editör Şekil 5.12’de görülmektedir. Şekil 5.13’te ise model için oluşturulmuş olan kurallar yer almaktadır.

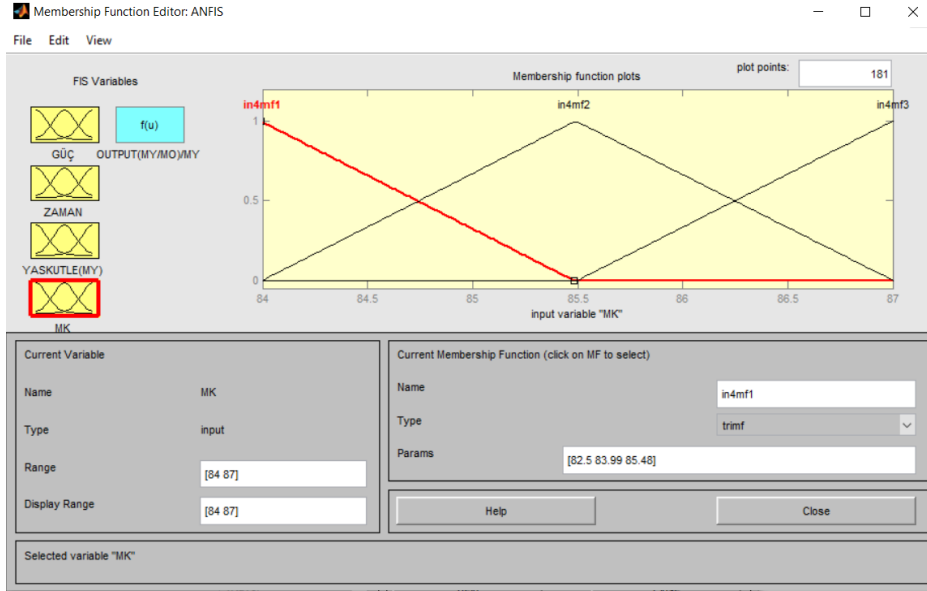


Şekil 5.12. ANFIS kurallar editörü



Şekil 5.13. ANFIS modeli kuralları

Kuralların yanında ANFIS modeli için önemli noktalardan biri de üyelik fonksiyonlarıdır. Oluşturulan modele ait üyelik fonksiyonları Şekil 5.14'te gösterilmiştir.



Şekil 5.14.ANFIS modeli üyelik fonksiyonları

Oluşturulan model ile sistem tahmin yapmaya hazırdır. Tahmin yapabilmesi MATLAB platformunun komut satırından gerçekleştirilmektedir. Bunun için kullanılan fonksiyon ise evalfis() fonksiyonudur. Bu komut ile hedeflenen çıktı değerleri elde edilir. Elde edilen çıktı değerlerinin YSA modeli ile aynı performans ölçüm parametreleri ile değerlendirilmesi yapılır. Çizelge 5.6 ANFIS modelinin performans ölçümünü göstermektedir.

Çizelge 5.6.ANFIS performans ölçümü

	Eğitim verisi	Test verisi	Tümü
RMSE	0,006183334	0,006842447	0,009222402
r²	0,999999848	0,99999325	0,999999034
MAPE	0,074624643	0,466279915	0,170150319

ANFIS ve YSA modeli ile gerçekleştirilen tahminlerin deneysel verilerle karşılaştırılması yapılır. Çizelge 7 her iki modelin de deneysel verilerle karşılaştırmasını göstermektedir.

Çizelge 5.7. ANFIS ve ANN tahmin sonuçları

OUTPUT(MY/MO)/MY	ANN	ANFIS
0,153256705	0,155727034	0,153264907
0,07751938	0,079583486	0,077372669
0,284090909	0,276335018	0,284109995
1	1,000011065	0,999912078
0,25	0,236796519	0,250022906
0,109649123	0,11022718	0,109816732
0,416666667	0,418159505	0,416630275
0,172860847	0,165986102	0,172846372
0,073529412	0,06841986	0,073427959
0,37037037	0,372671575	0,370758615
0,351123596	0,354087222	0,350981216
0,338123415	0,344878296	0,338126659
0,684655658	0,685593382	0,684660861
0,130378096	0,132260738	0,13037394
0,087412587	0,08990397	0,087413111
0,227272727	0,22408139	0,226623012
1	1,000334351	1,000007289
0,670194004	0,669545875	0,670087216
0,837628866	0,855874433	0,837450084
1	0,973448289	1,000023129
0,60483871	0,600312502	0,604830917
0,31779661	0,3156084	0,317761102

Çizelge 5.7. ANFIS ve ANN tahmin sonuçları (devamı)

OUTPUT(MY/MO)/MY	ANN	ANFIS
0,087412587	0,096496716	0,087436728
0,073529412	0,07289072	0,073818384
0,080787309	0,081535499	0,08047341
0,946969697	0,957774179	0,947194322
0,115606936	0,118230304	0,116082002
0,087412587	0,08958427	0,087401303
0,480769231	0,480291801	0,480947767
0,863422292	0,859570643	0,863406881
0,21486893	0,212010417	0,214870968
0,418060201	0,438159752	0,419428524
0,1089562	0,109613086	0,108977928
0,534759358	0,551961315	0,535292923
0,091642229	0,093088934	0,091619157
0,07751938	0,083756655	0,078458353
0,087412587	0,091350739	0,08742492
0,256410256	0,272034402	0,255902157
0,145348837	0,14180786	0,145519513
0,723684211	0,73065498	0,723412293
0,07751938	0,094395732	0,079544233

Karşılaştırma sonucunda her iki modelin de deneysel verilere oldukça yakın sonuçlar ürettiği görülmektedir.

6. SONUÇ

Daha önceden laboratuvar ortamında mikrodalga düzeneği ile kurutulmuş olan fındık ürününün deneysel sonuçları elde edilerek YSA ve ANFIS ile fındık ürününün kurutulması modellenmiştir. Deneysel verilerin bir kısmının modellere eğitim verisi olarak verilmesi ile modellerin eğitilmesi ve sonucunda da deneysel verilerin kalan kısmının tahmin edilmesi amaçlanmıştır.

Bu amaca ulaşmak için transfer fonksiyonları ve nöron sayısı farklı olan 9 YSA modeli değerlendirilmiş en başarılı olan model tespit edilmiştir. Elde edilen bulgular sonucunda Yapay sinir ağları modellerinde en iyi sonucu 10 nöronlu Log-sigmoid ve Purelin transfer fonksiyon modeli vermiştir.

Aynı verilerle oluşturulan ANFIS modelinin de test verileri için tahminleri elde edilmiştir. Yapılan incelemede ANFIS modelinin deneysel verilere daha yakın değerler ürettiği tespit edilmiştir.

Bu modeller ve veriler ışığında fındık ürünü için deney düzeneği kurmadan kurutma tahminleri yapılabilir hale gelmiştir.

Benzer verilerle, farklı tahmin yöntemleri ve modeller kullanılarak zaman ve maliyetten kurtararak farklı alanlarda çalışmak mümkün olacaktır.

KAYNAKLAR

- [1] H. Akbarpour, M. Mohajeri ve M. Akbarpour, «Pore Diameter of Nanoporous Anodic Alumina: Experimental Study and Application of ANFIS and MLR,» *Chemometrics and Intelligent Laboratory Systems*, pp. 82-91, 2016.
- [2] S. Pusat, M. T. Akkoyunlu, E. Pekel, M. C. Akkoyunlu, Ç. Özkan ve S. S. Kara, «Estimation of Coal Moisture Content in Convective Drying Process Using ANFIS,» *Fuel Processing Technology*, pp. 12-17, 2016.
- [3] M. Dolatabadi, M. Mehrabpour, M. Esfandyari, M. Davoudi ve H. Alidadi, «Modeling of simultaneous adsorption of dye and metal ion by sawdust from aqueous solution using of ANN and ANFIS,» *Chemometrics and Intelligent Laboratory Systems*, pp. 72-78, 2018.
- [4] V. Quej, J. Almorox, J. Arnaldo ve L. Saito, «ANFIS, SVM and ANN Soft-Computing Techniques to Estimate Daily Global Solar Radiation in a Warm Sub-Humid Environment,» *Journal of Atmospheric and Solar–Terrestrial Physics*, pp. 62-70, 2017.
- [5] M. Kaveh, V. R. Sharabiani, R. A. Chayjan, E. Taghinezhad, Y. Abbaspour-Gilandeh ve I. Golpour, «ANFIS and ANNs Model for Prediction of Moisture Diffusivity and Specific Energy Consumption Potato Garlic and Cantaloupe Drying Under Convective Hot Air Dryer,» *Information Processing in Agriculture*, p. 372–387, 2018.
- [6] B. Najafi ve S. F. Ardabili, «Application of ANFIS, ANN, and Logistic Methods in Estimating Biogas Production from Spent Mushroom Compost (SMC),» *Resources, Conservation & Recycling*, p. 169–178, 2018.
- [7] A. S. Rego, I. C. Valim, A. A. Vieira, C. Vilani ve B. F. Santos, «Optimization of sugarcane bagasse pretreatment using alkaline hydrogen peroxide through ANN and ANFIS modelling,» *Bioresource Technology*, p. 634–641, 2018.
- [8] F. Güzel, M. Acar ve D. Avcı, «Bulanık sinir ağı yapısı ile borsa endeks getirisi tahmini,» *Borsa İstanbul (BİST) 100 Örneği, Akademik Sosyal Araştırmalar Dergisi*, pp. 452-465, 2016.
- [9] T. Balcı, «Yapay sinir ağları optimizasyon algoritmalarının banka özkaynak karlılığı tahmini üzerinde karşılaştırmalı performans analizi,» 2021.
- [10] Ö. F. Aydın, «Yapay sinir ağları ile enflasyon tahmini,» 2019.
- [11] O. ErKaymaz, «İleri yönlü yapay sinir ağlarında küçük dünya ağ yaklaşımı ve uygulamaları,» 2012.
- [12] O. I. Abioduna, A. Jantana, A. E. Omolara, K. V. Dada, H. Arshad ve N. A. Mohamed, «State-of-the-art in artificial neural network applications: A survey,» *Heliyon*, 2018.
- [13] A. Tektaş ve A. Tektaş, «Yapay sinir ağları ve finans alanına uygulaması: Hisse senedi fiyat tahminlemesi,» *İktisadi ve İdari Bilimler Dergisi*, cilt 18, 2004.
- [14] K. Maladkar, «Analyticsindiamag,» 15 1 2018. [Çevrimiçi]. Available: <https://analyticsindiamag.com/6-types-of-artificial-neural-networks-currently-being-used-in-todays-technology/>.

- [15] A. Sight, «TechBlog,» 21 5 2018. [Çevrimiçi]. Available: <https://msatechnosoft.in/blog/artificial-neural-network-types-feed-forward-feedback-structure-perceptron-machine-learning-applications/>.
- [16] M. M. Raju, R. K. Srivastava, D. C. S. Bisht, H. C. Sharma ve A. Kumar, «Development of Artificial Neural-Network-Based Models for the Simulation of Spring Discharge,» *Advances in Artificial Intelligence*, 2011.
- [17] N. ŞENGÖZ ve G. ÖZDEMİR, «Sınıflandırma Problemlerinin Karşılaştırılmasında ANFIS ve Basamak Korelasyon Sınır Ağı'nın Kullanımı,» *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, cilt 21, no. 1, pp. 125-130, 2017.
- [18] K. Goyal, «Upgrad,» 17 12 2019. [Çevrimiçi]. Available: <https://www.upgrad.com/blog/types-artificial-neural-networks-in-machine-language/>.
- [19] A. S. Ahmadian, *Numerical Models for Submerged Breakwaters*, 2016.
- [20] Z. CÖMERT ve A. F. KOCAMAZ, «A study of artificial neural network training algorithms for classification of cardiocography signals,» *Journal of Science and Technology*, pp. 93-103, 2017.
- [21] D. Binu ve B. R. Rajakumar, *Artificial Intelligence in Data Mining*, 2021.
- [22] V. Sharma, S. Rai ve A. Dev, «A Comprehensive Study of Artificial Neural Networks,» *International Journal of Advanced Research in Computer Science and Software Engineering*, 2012.
- [23] Q. Zhang ve S. Sun, «Weighted Data Normalization Based on Eigenvalues for Artificial Neural Network Classification,» *International Conference on Neural Information Processing*, 2009.
- [24] S. Chopra, G. Dhiman, A. Sharma, M. Shabaz, P. Shukla ve M. Arora, «Taxonomy of Adaptive Neuro-Fuzzy Inference System in Modern Engineering Sciences,» *Computational Intelligence and Neuroscience*, 2021.
- [25] «MathWorks,» [Çevrimiçi]. Available: <https://www.mathworks.com/help/fuzzy/types-of-fuzzy-inference-systems.html>.
- [26] O. A. M. Ali, A. Y. Ali ve B. S. Sumait, «Comparison between the effects of different types of membership functions on fuzzy logic controller performance,» *International Journal*, 2015.
- [27] A. MORALAR ve S. ÇELEN, «Evaluation of Thermal and Drying Characteristics of Dried Hazelnut (*Corylus avellana* L.) Shell Waste,» *PHILIPP AGRIC SCIENTIST*, 2022.