

**YUMURTA TAVUĐU KÜMESİNDE AMONYAK
EMİSYONLARININ YAPAY SİNİR AĐLARI
KULLANILARAK TAHMİN EDİLMESİ**

Umut KILIÇ



T.C.
BURSA ULUDAĞ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**YUMURTA TAVUĞU KÜMESİNDE AMONYAK EMİSYONLARININ YAPAY
SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ**

Umut KILIÇ
0000-0002-2389-3249

Prof. Dr. İlker KILIÇ
(Danışman)

YÜKSEK LİSANS
BİYOSİSTEM MÜHENDİSLİĞİ ANABİLİM DALI

BURSA – 2023
Her Hakkı Saklıdır

TEZ ONAYI

Umut KILIÇ tarafından hazırlanan “YUMURTA TAVUĞU KÜMESİNDE AMONYAK EMİSYONLARININ YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ” adlı tez çalışması aşağıdaki jüri tarafından oy birliği ile Bursa Uludağ Üniversitesi Fen Bilimleri Enstitüsü Biyosistem Mühendisliği Anabilim Dalı’nda **YÜKSEK LİSANS** olarak kabul edilmiştir.

Danışman: Prof. Dr. İlker KILIÇ

- Başkan** : Prof. Dr. İlker KILIÇ
0000-0003-0087-6718
Bursa Uludağ Üniversitesi,
Ziraat Fakültesi,
Biyosistem Mühendisliği Anabilim Dalı İmza
- Üye** : Prof. Dr. Ferhat KURTULMUŞ
0000-0002-7862-6906
Bursa Uludağ Üniversitesi,
Ziraat Fakültesi,
Biyosistem Mühendisliği Anabilim Dalı İmza
- Üye** : Prof. Dr. Hakan KİBAR
0000-0003-1739-4547
Bolu Abant İzzet Baysal Üniversitesi,
Ziraat Fakültesi,
Tohum Bilimi ve Teknolojisi Anabilim Dalı İmza

Yukarıdaki sonucu onaylarım

Prof. Dr. Ali KARA
Enstitü Müdürü
.././....

B.U.Ü. Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada;

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

15/06/2023

Umut KILIÇ

TEZ YAYINLANMA FİKRİ MÜLKİYET HAKLARI BEYANI

Enstitü tarafından onaylanan lisansüstü tezin/raporun tamamını veya herhangi bir kısmını, basılı (kâğıt) ve elektronik formatta arşivleme ve aşağıda verilen koşullarla kullanıma açma izni Bursa Uludağ Üniversitesi'ne aittir. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları ile tezin tamamının ya da bir bölümünün gelecekteki çalışmalarda (makale, kitap, lisans ve patent vb.) kullanım hakları tarafımıza ait olacaktır. Tezde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alınarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederiz.

Yükseköğretim Kurulu tarafından yayınlanan “**Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge**” kapsamında, yönerge tarafından belirtilen kısıtlamalar olmadığı takdirde tezin YÖK Ulusal Tez Merkezi / B.U.Ü. Kütüphanesi Açık Erişim Sistemi ve üye olunan diğer veri tabanlarının (Proquest veri tabanı gibi) erişimine açılması uygundur.

Danışman Adı-Soyadı
Tarih

Prof. Dr. İlker KILIÇ

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

Öğrencinin Adı-Soyadı
Tarih

Umut KILIÇ

İmza

Bu bölüme kişinin kendi el yazısı ile okudum
anladım yazmalı ve imzalanmalıdır.

ÖZET

Yüksek Lisans Tezi

YUMURTA TAVUĞU KÜMESİNDE AMONYAK EMİSYONLARININ YAPAY SİNİR AĞLARI KULLANILARAK TAHMİN EDİLMESİ

Umut KILIÇ

Bursa Uludağ Üniversitesi
Fen Bilimleri Enstitüsü
Biyosistem Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. İlker KILIÇ

Bu çalışmada Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezinde bulunan toplam 5000 hayvan kapasitesine sahip bir yumurta tavuğu kümesinden kaynaklanan amonyak emisyonunun yapay sinir ağları ile tahminlenmesi amaçlanmaktadır. Kümeste bir yıl süreyle gerçekleştirilen sıcaklık, bağıl nem, havalandırma, hava hızı, hayvan sayısı, amonyak konsantrasyonu ölçümleri İlkbahar, Yaz, Sonbahar, Kış ve tüm yıllık veriler olmak üzere beş veri setine ayrılmıştır. Beş veri seti için yapay sinir ağlarında amonyak emisyonu çıktı ölçümü gerçekleştirilen diğer parametreler ise girdi olarak kullanılarak 4 farklı eğitim algoritmasında tahminlemeler gerçekleştirilmiş ve karşılaştırılmaları yapılmıştır.

Çalışmada, Levenberg Marquardt eğitim algoritması ile İlkbahar, Yaz, Sonbahar, Kış ve tüm yılı kapsayan veriler için sırasıyla (0,99107), (0,99026), (0,98613), (0,99223) ve (0,98699) regresyon katsayısı ile en yüksek başarıya sahip tahminlemeler gerçekleştirilmiştir. Tahminleme gerçekleştirilen diğer üç eğitim algoritması da düşük hata oranına sahip olsa da performans olarak Levenberg Marquardt eğitim algoritmasının gerisinde kalmıştır

Çalışmada ayrıca tahminlemede kullanılan girdi parametrelerinden çıktı performansını en çok etkileyeni bulmak amacıyla girdi parametrelerinden her biri bir kez çıkartılmak koşuluyla 5 girdi ve 1 çıktı olacak şekilde 6 farklı tahminleme gerçekleştirilmiştir. Sinir ağının performansını en çok etkileyen girdi parametresinin hayvan sayısı olduğu ve ağın performansını olumsuz olarak büyük oranda etkilediği görülmüştür. Çalışma sonucunda yapay sinir ağlarında Levenberg Marquardt (trainlm) eğitim algoritması ile bir yumurta tavuğu kümesinden kaynaklanan amonyak emisyonunun yüksek bir başarı oranı ile tahminlenebileceği sonucuna varılmıştır

Anahtar Kelimeler: Amonyak emisyonu, Yapay sinir ağları, Tahminleme, Yumurta tavuğu kümesi

2023, xvi + 115 sayfa.

ABSTRACT

MSc Thesis

PREDICTION OF AMMONIA EMISSIONS IN LAYING HEN HOUSE USING ARTIFICIAL NEURAL NETWORKS

Umut KILIÇ

Bursa Uludağ University
Graduate School of Natural and Applied Sciences
Department of Biosystem Engineering

Supervisor: Prof. Dr. Ilker KILIÇ

This study aims to estimate the ammonia emission from a chicken coop with a total capacity of 5000 animals located at the Animal Health and Animal Production, Research and Application Center of the Faculty of Veterinary Medicine of Bursa Uludağ University with artificial neural networks. Temperature, relative humidity, ventilation, air velocity, number of animals, ammonia concentration, and ammonia emission measurements performed in the hen house for a year were divided into five data sets Spring, Summer, Autumn, Winter, and all annual data. For five data sets, ammonia emission in artificial neural networks was used as output, and other measurement parameters were used as input; estimations were made in 4 different training algorithms, and comparisons were made.

In the study, the Levenberg Marquardt education algorithm for Spring, Summer, Autumn, winter, and all-year data, respectively (0,99107), (0,99026), (0,98613), (0,99223) (0,98699) has the highest value with the regression rate. Although the other three training algorithms for which the estimation was performed had low error rates, they lagged behind the Levenberg Marquardt training algorithm in performance.

In addition, six different estimations were made as five inputs and one output, provided that each input parameter is removed once, to find the one that affects the output performance the most among the input parameters used in the estimation. It has been seen that the input parameter that most affects the neural network's performance is the number of animals, and it affects the network's performance negatively. As a result of the study, it was concluded that ammonia emission from a layer hen could be predicted with a high success rate with the Levenberg Marquardt (trainlm) training algorithm in artificial neural networks.

Key words: Ammonia emission, Artificial neural networks, Laying hens house, Prediction

2023, xvi + 115 pages.

TEŐEKKÖR

Yüksek lisans eğitimin ve tez çalışmalarımın her aşamasında yardımını esirgemeyen, ihtiyaç duyduğum her an yanımda olarak bana cesaret veren sevgili danışman hocam Prof. Dr. İLKER KILIÇ'a, tez çalışmalarımda desteęi esirgemeyen Araş. Gör. BÜŐRA YAYLI'ya, hayatımın her döneminde maddi ve manevi olarak yanımda olup her şeyin en güzeline layık olan canım annem ve babama teşekkür ederim.

Umut KILIÇ
16/06/2023

İÇİNDEKİLER

	Sayfa
ÖZET.....	vi
ABSTRACT.....	vii
TEŞEKKÜR.....	viii
SİMGELER ve KISALTMALAR DİZİNİ.....	xi
ŞEKİLLER DİZİNİ.....	xii
ÇİZELGELER DİZİNİ.....	xv
1. GİRİŞ.....	1
2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI.....	3
2.1 Yapay Sinir Ağları.....	3
2.1.1 Yapay Sinir Ağlarının Genel Özellikleri ve Avantajları.....	3
2.1.2 Yapay Sinir Ağlarının Dezavantajları.....	4
2.1.3 Yapay Sinir Ağlarının Kullanım Şekilleri.....	4
2.1.4 Yapay Sinir Ağlarının Kullanım Yerleri.....	4
2.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları.....	5
2.2.1 Biyolojik Sinir Hücresi.....	6
2.2.2 Yapay Sinir Hücresi.....	7
2.3 Yapay Sinir Ağlarının Yapısı.....	9
2.4 Yapay Sinir Ağlarının Sınıflandırılması.....	10
2.4.1 Yapay Sinir Ağlarının Yapısına Göre Sınıflandırılması.....	10
2.4.1.1 İleri Beslemeli Ağlar.....	10
2.4.1.2 Geri Beslemeli Ağlar.....	11
2.4.2 Yapay Sinir Ağlarının Öğrenme Algoritmasına Göre Sınıflandırılması.....	11
2.4.2.1 Danışmanlı Öğrenme.....	11
2.4.2.2 Danışmansız Öğrenme.....	12
2.4.2.3 Destekleyici Öğrenme.....	13
2.4.3 Yapay Sinir Ağlarının Uygulamaya Göre Sınıflandırılması.....	13
2.4.3.1 Çevrimiçi Öğrenme.....	13
2.4.3.2 Çevrimdışı Öğrenme.....	14
2.5 Yapay Sinir Ağlarında Öğrenim Kuralları.....	14
2.5.1 Hebb Kuralı.....	14
2.5.2 Delta Kuralı.....	14
2.5.3 Hopfield Kuralı.....	15
2.5.4 Kohonen Kuralı.....	15
2.6 Yapay Sinir Ağlarının Tasarımı.....	15
2.6.1 Sinir Ağı Türünün Seçimi.....	15
2.6.2 Öğrenim Algoritmasının Seçimi.....	16
2.6.3 Ara Katman Sayısının Belirlenmesi.....	16
2.6.4 Nöron Sayısının Belirlenmesi.....	17
2.6.5 Aktivasyon Fonksiyonunun Seçimi.....	17
2.7 Verilerin Normalizasyonu.....	17
2.8 İstatiksel Hata Ölçütleri.....	18
2.9 Kaynak Araştırması.....	19
3. MATERYAL ve YÖNTEM.....	27
3.1 Çalışma Alanı.....	27
3.2 Sinir Ağının Oluşturulması.....	28
4 BULGULAR ve TARTIŞMA.....	32

4.1 Verilen Tanıtılması.....	32
4.2 Levenberg Marquardt Eğitim Algoritması (Levenberg Marquardt Backpropagation) ile Yapılan Tahminlemeler.....	35
4.2.1 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması.....	40
4.2.1.1 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması.....	42
4.2.1.2 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik Olarak Karşılaştırılması.....	49
4.3 Fletcher-Reeves Güncelleme Eğitim Algoritması (Conjugate Gradient Backpropagation with Fletcher-Reeves Updates) ile Yapılan Tahminlemeler.....	51
4.3.1 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması.....	57
4.3.1.1 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması.....	59
4.3.1.2 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik olarak Karşılaştırılması.....	66
4.4 Kademeli Çekim Eğitim Algoritması (Scaled Conjugate Gradient Backpropagation) ile Yapılan Tahminlemeler.....	68
4.4.1 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması.....	73
4.4.1.1 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması.....	75
4.4.1.2 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik olarak Karşılaştırılması.....	82
4.5 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması (Gradient Descent with Momentum and Adaptive Learning Rate Backpropagation ile Yapılan Tahminlemeler.....	84
4.5.1 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması.....	89
4.5.1.1 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması.....	91
4.5.1.2 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik Olarak Karşılaştırılması.....	98
4.6 Tahminleme’de Kullanılan Eğitim Algoritmalarının Karşılaştırılması.....	100
4.7 Girdi Parametrelerinin Yapay Sinir Ağlarının Performansına Etkisinin Karşılaştırılması.....	104
5. SONUÇ.....	107
KAYNAKLAR.....	109
ÖZGEÇMİŞ.....	115

SİMGELER ve KISALTMALAR DİZİNİ

Simgeler	Açıklama
X1	Sıcaklık
X2	Nem
X3	Hava Hızı
X4	Havalandırma
X5	Hayvan Sayısı
X6	Amonyak Konstantrasyonu
Trainlm	Levenberg Marquardt eğitim algoritması
Traincgf	Fletcher-Reeves Güncelleme eğitim algoritması
Trainscg	Kademeli çekim eğitim algoritması
Traingdx	Kümelerin adaptifli momentumlu yokuş inmesi eğitim algoritması

ŞEKİLLER DİZİNİ

	Sayfa
Şekil 2.1.	Biyolojik Sinir Sisteminin Gösteri..... 6
Şekil 2.2.	Sinir Hücresi Yapısı..... 7
Şekil 2.3.	McCulloch-Pitts Nöron Modeli..... 7
Şekil 2.4.	Tipik bir yapay sinir ağı modeli..... 9
Şekil 2.5.	İleri beslemeli sinir ağları mimarileri..... 10
Şekil 2.6.	Geri beslemeli ağların çalışma prensibinin gösterimi..... 11
Şekil 2.7.	Danışmanlı Öğrenme..... 12
Şekil 2.8.	Danışmansız Öğrenme..... 12
Şekil 2.9.	Destekleyici Öğrenme..... 13
Şekil 3.1.	Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezi Tavuk İşletmesi..... 27
Şekil 3.2.	Testo 435 ve MultiRAE çoklu gaz ölçer..... 28
Şekil 3.3.	Çalışmada kullanılan yapay sinir ağı yapısı..... 29
Şekil 3.4.	Çalışmada karşılaştırmaları gerçekleştirilen nöron sayıları..... 30
Şekil 3.5.	Çalışmada kullanılan eğitim, doğrulama ve test veri setleri yüzdeleri..... 30
Şekil 3.6.	Çalışmada kullanılan eğitim algoritmaları seçim bölümü..... 31
Şekil 4.1	Tüm yılı kapsayan veri setinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri..... 35
Şekil 4.2	İlkbahar ve Yaz mevsimi verilerinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri..... 36
Şekil 4.3	Sonbahar ve Kış mevsimi verilerinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri..... 37
Şekil 4.4	Tüm yılı kapsayan ve mevsimsel verilerde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin hata histogramları.. 38
Şekil 4.5	Yıllık ve Mevsimsel verilerde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin performans grafikleri..... 39
Şekil 4.6	Levenberg Marquardt eğitim algoritması ile tüm yılı kapsayan veri setinin tahminleri ile gerçek değerlerin karşılaştırılması..... 40
Şekil 4.7	Levenberg Marquardt eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması..... 41
Şekil 4.8	Levenberg Marquardt eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları..... 48
Şekil 4.9	Levenberg Marquardt eğitim algoritması ile tahminlemeleri yapılan tüm yılı kapsayan verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması..... 49
Şekil 4.10	Levenberg Marquardt eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması..... 50

Şekil 4.11	Tüm yılı kapsayan verilerin Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	51
Şekil 4.12	İlkbahar ve Yaz mevsimi verilerinde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	52
Şekil 4.13	Sonbahar ve Kış mevsimi verilerinde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	53
Şekil 4.14	Tüm yılı kapsayan ve mevsimsel verilerde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin hata histogramları.....	55
Şekil 4.15	Tüm yılı kapsayan ve mevsimsel verilerde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin performans grafikleri.....	56
Şekil 4.16	Fletcher-Reeves Güncelleme eğitim algoritması ile tüm yılı kapsayan verilerin tahminleri ile gerçek değerlerin karşılaştırılması.....	57
Şekil 4.17	Fletcher-Reeves Güncelleme eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması.....	58
Şekil 4.18	Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları.....	65
Şekil 4.19	Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemeleri yapılan tüm yıllık verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması	66
Şekil 4.20	Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması.....	67
Şekil 4.21	Tüm yılı kapsayan verilerin Kademeli Çekim eğitim algoritması ile yapılan tahminlemelerinin regresyon grafikler....	68
Şekil 4.22	İlkbahar ve Yaz mevsimi verilerinin Kademeli Çekim eğitim algoritması ile yapılan tahminlemelerinin regresyon grafikleri...	69
Şekil 4.23	Sonbahar ve Kış verilerinin Kademeli Çekim eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	70
Şekil 4.24	Tüm yılı kapsayan ve mevsimsel verilerde Kademeli Çekim eğitim algoritması ile yapılan tahminlemenin hata histogramları...	71
Şekil 4.25	Tüm yılı kapsayan ve mevsimsel verilerde Kademeli Çekim eğimi algoritması ile yapılan tahminlemenin performans grafikleri	72
Şekil 4.26	Kademeli Çekim eğitim algoritması ile tüm yıllık kapsayan veri gruplarının tahminleri ile gerçek değerlerin karşılaştırılması....	73
Şekil 4.27	Kademeli Çekim eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması.....	74
Şekil 4.28	Kademeli Çekim eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının sayılarına göre hata miktarları.....	81

Şekil 4.29	Kademeli Çekim eğitim algoritması ile tahminlemeleri yapılan tüm yıllık verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması.....	82
Şekil 4.30	Kademeli Çekim eğitim algoritması ile tahminlemeleri yapılan Mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması.....	83
Şekil 4.31	Tüm yılı kapsayan veri setinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	84
Şekil 4.32	İlkbahar ve Yaz mevsimi verilerinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	85
Şekil 4.33	Sonbahar ve Kış mevsimi verilerinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri.....	86
Şekil 4.34	Tüm yılı kapsayan ve mevsimsel verilerde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin hata histogramları.....	87
Şekil 4.35	Tüm yılı kapsayan ve mevsimsel verilerde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin performans grafikleri.....	88
Şekil 4.36	Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile tüm yıllık verilerin tahminleri ile gerçek değerlerin karşılaştırılması.....	89
Şekil 4.37	Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması.....	90
Şekil 4.38	Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları.....	97
Şekil 4.39	Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile tahminlemeleri yapılan tüm yılı kapsayan verilerin gerçek değerleri ile saatlik ortalamalarının karşılaştırılması.....	98
Şekil 4.40	Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması.....	99
Şekil 4.41	Tüm yılı kapsayan ve mevsimsel veri setlerinde eğitim algoritmalarının gerçekleştirdiği tahminlemeler ile gerçek ortalama amonyak emisyon miktarlarının karşılaştırılması.....	103

ÇİZELGELER DİZİNİ

	Sayfa
Çizelge 2.1	Biyolojik sinir sistemi yapay sinir ağları arasındaki benzerlikler... 8
Çizelge 2.2	Sinir Ağlarının türleri ve kullanım amaçları..... 16
Çizelge 3.1	Yapay sinir ağlarında eğitilen girdi ve çıktı parametreleri..... 29
Çizelge 4.1	Tüm yılı kapsayan verilerin tanımlayıcı istatistik değerleri..... 32
Çizelge 4.2	İlkbahar mevsimi verilerinin tanımlayıcı istatistik değerleri..... 33
Çizelge 4.3	Yaz mevsimi verilerinin tanımlayıcı istatistik değerleri..... 33
Çizelge 4.4	Sonbahar mevsimi verilerinin tanımlayıcı istatistik değerleri..... 34
Çizelge 4.5	Kış mevsimi verilerinin tanımlayıcı istatistik değerleri..... 34
Çizelge 4.6	Levenberg Marquardt modeli ile tahminlemesi yapılan tüm yıllık kapsayan verilerin nöron sayılarına göre hata miktarı..... 43
Çizelge 4.7	Levenberg Marquardt modeli ile tahminlemesi yapılan ilkbahar mevsiminin nöron sayılarına göre hata miktarları..... 44
Çizelge 4.8	Levenberg Marquardt modeli ile tahminlemesi yapılan Yaz mevsiminin nöron sayılarına göre hata miktarları..... 45
Çizelge 4.9	Levenberg Marquardt modeli ile tahminlemesi yapılan sonbahar mevsiminin nöron sayılarına göre hata miktarları..... 46
Çizelge 4.10	Levenberg Marquardt modeli ile tahminlemesi yapılan kış mevsiminin nöron sayılarına göre hata miktarları..... 47
Çizelge 4.11	Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan tüm yıllık kapsayan verilerin nöron sayılarına göre hata miktarı..... 60
Çizelge 4.12	Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan İlkbahar mevsiminin verilerin nöron sayılarına göre hata miktarı..... 61
Çizelge 4.13	Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Yaz mevsiminin verilerin nöron sayılarına göre hata miktarı..... 62
Çizelge 4.14	Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Sonbahar mevsiminin verilerin nöron sayılarına göre hata miktarı..... 63
Çizelge 4.15	Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Kış mevsiminin verilerin nöron sayılarına göre hata miktarı..... 64
Çizelge 4.16	Kademeli Çekim modeli ile tahminlemesi yapılan tüm yıllık verilerin nöron sayılarına göre hata miktarı..... 76
Çizelge 4.17	Kademeli Çekim modeli ile tahminlemesi yapılan İlkbahar mevsimi verilerinin nöron sayılarına göre hata miktarı..... 77
Çizelge 4.18	Kademeli Çekim modeli ile tahminlemesi yapılan Yaz mevsimi verilerinin nöron sayılarına göre hata miktarı..... 78
Çizelge 4.19	Kademeli Çekim modeli ile tahminlemesi yapılan Sonbahar mevsimi verilerinin nöron sayılarına göre hata miktarı..... 79
Çizelge 4.20	Kademeli Çekim modeli ile tahminlemesi yapılan Kış mevsimi verilerinin nöron sayılarına göre hata miktarı..... 80

Çizelge 4.21	Kümelerin Adaptifli Momentumlu Yokuş İnmesi modeli ile tahminlemesi yapılan tüm yıllık verilerin nöron sayılarına göre hata miktarı.....	92
Çizelge 4.22	Kümelerin Adaptifli Momentumlu Yokuş İnmesi modeli ile tahminlemesi yapılan İlkbahar mevsimi verilerinin nöron sayılarına göre hata miktarı.....	93
Çizelge 4.23	Kümelerin Adaptifli Momentumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Yaz mevsimi verilerinin nöron sayılarına göre hata miktarı.....	94
Çizelge 4.24	Kümelerin Adaptifli Momentumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Sonbahar mevsimi verilerinin nöron sayılarına göre hata miktarı.....	95
Çizelge 4.25	Kümelerin Adaptifli Momentumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Kış mevsimi verilerinin nöron sayılarına göre hata miktarı.....	96
Çizelge 4.26	Tüm yılı kapsayan veri setinde eğitim algoritmalarının en iyi performanslarının karşılaştırılması.....	100
Çizelge 4.27	Mevsimsel veri setinde eğitim algoritmalarının en iyi performanslarının karşılaştırılması.....	101
Çizelge 4.28	Tüm yılı kapsayan ve mevsimsel veri setlerinde eğitim algoritmalarının gerçekleştirdiği tahminlemeler ile gerçek ortalama amonyak emisyon miktarlarının karşılaştırılması	102
Çizelge 4.29	Tüm yılı kapsayan veri setinde farklı girdi parametreleri ile gerçekleştirilen tahminlemelerin sonuçları.....	104
Çizelge 4.30	Mevsimsel veri setlerinde farklı girdi parametreleri ile gerçekleştirilen tahminlemelerin sonuçları.....	105

1.GİRİŞ

Çevre kirliliği insan kaynaklı ya da yapay olarak hava, toprak ve suda oluşan kirlenme olarak tanımlanabilir. Dünyada nüfusun devamlı olarak artıyor oluşu, teknoloji ve sanayi de yaşanan gelişmeler çevre kirliliğinin gün geçtikçe artmasına yol açmaktadır. Çevre kirliliğinin artıyor olması canlılarda oluşan hastalıkların artmasına ya da daha kolay bir şekilde bulaşmasına neden olabilir. (İbadullayeva ve ark., 2019). Dünya popülasyonunun sürekli olarak artmasıyla doğru orantılı olarak ortaya çıkan ihtiyacı karşılamak amacıyla hayvancılık ve hayvan sayısında da ciddi artışlar söz konusudur. Hayvan barınaklarından kaynaklanan amonyak emisyonu barınak çevresinde bulunan ormanlardaki ağaçların doku ölümü yaşamasına, kötü koku oluşumuna ve barınak yakınlarında yaşayan insanların sağlıklarının olumsuz etkilenmesine neden olan en önemli gaz emisyonlarından bir tanesidir. Aynı zamanda amonyak emisyonun çevreye salındıktan sonra azot döngüsüne katılması sonucunda toprak ve nehirlerde asitlilik yaşanmasına, görüş mesafesinin ve kıyı verimliliklerinde azalmalar yaşanmasına neden olmaktadır. Dünya da ortaya çıkan amonyak emisyonun yaklaşık olarak %50'si hayvan barınaklarından kaynaklanmaktadır (Fangmeier ve ark. 1994; Hartung, 1998; Galloway ve Cowling, 2002; Kılıç ve Arıcı, 2013). Bu durumdan dolayı hayvan barınaklarından kaynaklanan emisyon miktarının takibinin yapılması ve koruyucu önlemler alınması gerekmektedir.

Hayvan barınaklarından kaynaklanan amonyak emisyonunun miktarı gaz ölçüm cihazları ile gerçekleştirilebilmektedir ancak bu cihazların maliyetlerinin yüksek olmasından dolayı bütün barınaklarda kullanılması mümkün değildir. Bu durumdan dolayı hayvan barınaklarından kaynaklanan amonyak emisyon miktarını belirlemek için alternatif yollara başvurmak gerekmektedir.

Yapay sinir ağları insan beynine benzer özellikler gösteren örnekler yardımıyla bilgileri öğrenen ve benzer örnekler için ezberleme, bilgileri sınıflandırma ve tahminleme gibi fonksiyonları yerine getirebilen sistemlerdir (Akkaya ve ark, 2009). Yapay sinir ağları ile gerçekleştirilen tahminlemeler ile yüksek başarı oranında sonuçlar elde edilebilmektedir.

Hayvan barınaklarından kaynaklanan emisyon miktarının yapay sinir ađları ile tahminlenmesi işletmelere maliyet, zaman ve iş gücünden tasarruf etmek gibi faydaları olmaktadır. Yapay sinir ađlarında tahminleme gerçekleştirirken sinir ađının girdilerinin, nöron sayılarının, katman sayısının, aktivasyon fonksiyonun ve eğitim algoritmasının doğru seçilmesi performansın başarı oranını çok etkilemektedir. Sinir ađının yapısını oluşturan bu parametrelerin tahminleme yapılacak probleme göre performansları deđişkenlik gösterebilir. Bu durumdan dolayı sinir ađının yapısı için kesin bir yargıya varmak doğru deđildir. Deneme yanılma yöntemine başvurarak en iyi ađ yapısı oluşturulmaktadır.

Bu çalışma da Bursa Uludađ Üniversitesi Veterinerlik Fakültesi Hayvan Sađlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezinde bulunan toplam 5000 hayvan kapasitene sahip bir yumurta tavuđu kümesinde 1 yıllık süreçte ortaya çıkan amonyak emisyon miktarının İlkbahar, Sonbahar, Kış, Yaz ve tüm yılı kapsayan verileri olmak üzere 5 farklı veri setinde farklı sinir ađı yapıları (farklı sayıda nöron sayısı, girdi sayısı, eğitim algoritması) ile tahminlenmesi ve sonuçların karşılaştırılması amaçlanmaktadır.

2. KURAMSAL TEMELLER ve KAYNAK ARAŞTIRMASI

2.1 Yapay Sinir Ağları

Yapay sinir ağları, insan beyninin kullanılması sonucu gerçekleşmiş olayları öğrenebilen ve bu öğrendikleri bilgilerden yola çıkarak daha önce hiç karşılaşmadığı olaylar hakkında fikir üretebilen bir bilgisayar programıdır. Temel olarak bakıldığında yapay sinir ağı sisteme girilen girdi parametrelerini öğrenmiş olduğu benzer olaylar ile genelleme yaparak çıktı sonuçları elde etmesidir. Yapay sinir ağları ele alınan konu hakkında bilgi sahibi olunmadığı ancak belirli örneklerle sahip olduğu durumlarda sonuca ulaşmak ve karar verme aşamalarında oldukça yardımcı olmaktadır (Öztemel, 2006).

2.1.1 Yapay Sinir Ağlarının Genel Özellikleri ve Avantajları

Yapay sinir ağlarının özellikleri kullanılacak olan sinir ağı ve eğitim algoritmasına göre değişiyor olsa da bazı genel özelliklere sahiptir. Bu özellikler; (Öztemel, 2006)

- 1) Yapay sinir ağları bilgisayar öğrenmesi gerçekleştirirler ve daha önceki gerçekleşmiş olayları öğrenerek benzer sonuçlar ortaya koyabilirler.
- 2) Bilgi işleme yöntemlerinde geleneksel programlara oranla daha farklı metotlara sahiptirler aynı anda birçok farklı işlem gerçekleştirebilir.
- 3) Yapay sinir ağları daha önce meydana gelmiş olaylar ile öğrenme gerçekleştirebilir eğer daha önce o konu hakkında bir olay gerçekleşmemişse yapay sinir ağları o konuda öğrenme gerçekleştiremez.
- 4) Yapay sinir ağları kendilerine öğretilen örneklerden yola çıkarak çıktı üretebilirler ancak ağın başarılı çıktı sonuçları verebilmesi ağına öğretilen örnek ile bağlantılıdır. Sinir ağına doğru örnekler öğretilmesi ile beraber çok başarılı sonuçlar elde edilebilir.
- 5) Yapay sinir ağları ilgili konu ile alakalı öğretilen tüm örnekler arasında kendi mekanizması yardımıyla bağlantı kurar.
- 6) Yapay sinir ağları kendisine öğretilen örneklerden yola çıkarak daha önce öğretilmeyen örnekler içinde bilgi üretebilirler.
- 7) Yapay sinir ağları geleneksel sistemlerin aksine eksik bilgi ile çalışabilmektedir. Ağın performansı eksik olan bilginin durumuna göre değişmektedir. Eksik olan bilgi önemli değilse sinir ağının performansı hiç etkilenmezken eğer önemli bir bilgi ise ağın

performansı eksi yönde etkilenebilmektedir. Ağın performansının etkilendiği durumlarda eksik bilginin tamamlanması ağın performansı yükseltecektir.

8) Yapay sinir ağları daha önce gerçekleşmiş olayları öğrendikten sonra olaylar arasında ilişki kurarak olaylarda olan belirsizlikler ile ilgili bir karara varabilirler.

9) Sinir ağları hatalara karşı hoşgörülü davranır ve hızlı bir şekilde bozulmazlar. Ağ da eksik olan bilgilerden ya da bozuk olan hücrelerden dolayı adım adım dereceli olarak bozulurlar.

2.1.2 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının kullanımı birçok avantaja sahip olsa da bazı dezavantajları da mevcuttur. Bu dezavantajlar; (Vural, 2007; Karahan, 2011; Öztemel, 2006; Bilgin, 2023)

1) Sinir ağının yapısını belirlemek için herhangi bir kesin kural yoktur ve en iyi sonucu elde edebilmek için deneme yanılma yönteminden yararlanmak gerekmektedir. Bu nedenle ağın yapısının oluştururken kullanıcının deneyimi ve yeteneği ön plana çıkmaktadır.

2) Yapay sinir ağları sadece sayısal veriler ile çalışmaktadır. Sistemi kullanmak için kullanılacak olan verilerin sayısal verilere çevrilmesi gerekmektedir.

3) Yapay sinir ağlarını kullanabilmek için belirli özelliklere sahip donanıma ihtiyaç duyulmaktadır.

4) Yaşanan en büyük sorunlardan bir tanesi sinir ağının eldeki sorun ile ilgili çözüm ürettikten sonra bu çözüm hakkında nasıl ve neden oluştuğu hakkında bilgi vermemesidir. Bu durum kullanıcıda üretilen çözüm için güvensizlik oluşturabilir.

5) Sinir ağının eğitimi sürecinde hataların belli bir seviyenin altına inmesi sonucunda eğitim tamamlanır ancak bununla ilgili net bir süre olmaması eğitim süresi ile alakalı belirsizlik oluşturmaktadır.

2.1.3 Yapay Sinir Ağlarının Kullanım Şekilleri

Yapay sinir ağlarının günümüzde kullanımı her geçen gün artmasıyla birlikte kullanım alanları da gittikçe genişlemektedir. Günümüzde yapay sinir ağları en çok tahminleme yapma, sınıflandırma ve verileri ilişkilendirmek, yorumlamak ve filtrelemek amacıyla kullanılmaktadır. (Öztürk ve Şahin, 2018)

Tahminleme: Yapay sinir ađları ađa ğretilen girdi parametrelerinden yola ıkararak ıktı parametresinin deđerini tahminlemek amacıyla alıřır.

Sınıflandırma: Sinir ađına ğretilen girdi parametrelerini sınıflandırarak ađın daha hızlı ve dođru alıřması iin gerekleřtirilen iřlemdir.

Veri İliřkilendirme: Sinir ađı ğrenmiř olduđu bilgiler ile rnekler arasında bađ kurar ve eksik verileri tamamlar.

Veri Yorumlama: Sinir ađı eđitilen girdi parametrelerini inceleyerek farklı bir rnek hakkında bu parametrelerden yola ıkararak yorumlamada bulunabilir.

Veri Filtreleme: Yapay sinir ađı ğrendiđi rneklerde elde ettiđi veriler ierisinde en ok iřine yarayacak verileri filtreler.

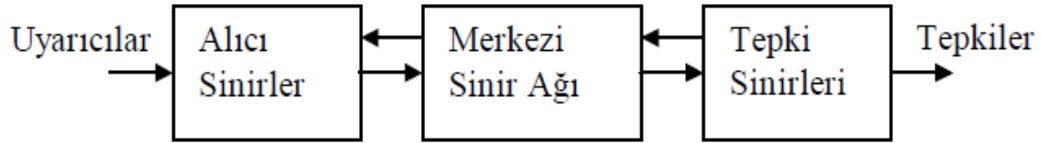
2.1.4 Yapay Sinir Ađlarının Kullanım Yerleri

Yapay sinir ađlarının gn getike kullanımının artması ile birlikte kullanım yerleri de geniřlemektedir. Birok sektrde farklı amalarla sinir ađı kullanımı grlmektedir. Dnyamızda akla gelebilecek hemen hemen btn sektrlerde ileriye dnk tahminleme yapabilmek, ya da mevcut durumu yorumlamak ve belirli kořullar altında sınıflandırmak amacıyla sinir ađlarından faydalanılmaktadır. Sađlık sektrnn en nemli ařamalarından bir tanesi olan hastalarda hastalıkların teřhis edilmesi, bazı tektiklerinin yapılması ve tedavi ařamalarında kullanılmakta ve sreci hızlandırmaktadır. Sanayide retimi yapılacak olan rnlerin kalitelerinin kontrol edilmesinde, mrlerinin tahmin edilmesinde ve planlamalarının yapılmasında kullanılmaktadır. Savunma sanayi ve askeri alanlarda radar kullanımı, sonar sinyalleri sınıflandırmasında kullanılmaktadır. Gnlk hayatta hayatı kolaylařtıracak hava kořullarının tahmin edilmesi, maillerin sınıflandırılması gibi birok alanda da kullanımı mevcuttur. (Wu ve Feng, 2018)

2.2 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

2.2.1 Biyolojik Sinir Hücresi

Biyolojik sinir sistemi merkezinde bilgileri alan, yorumlayan ve kararlar verebilen beyinin bulunduğu ve 3 katmandan meydana gelen bir sistemdir. Bu katmanlar elde ettikleri bilgileri elektriksel sinyaller aracılığıyla beyine gönderen alıcı sinirler, beyin tarafından üretilen elektriksel sinyalleri uygun tepkilere dönüştüren tepki sinirleri, alıcı ve tepki sinirleri arasında ileri ve geri olarak besleme gerçekleştirip uygun olan tepkileri ortaya çıkaran merkezi sinir ağıdır. Biyolojik sinir sisteminin işleyişinin gösterimi Şekil 2.1' de gösterilmiştir (Fırat ve Güngör, 2004).



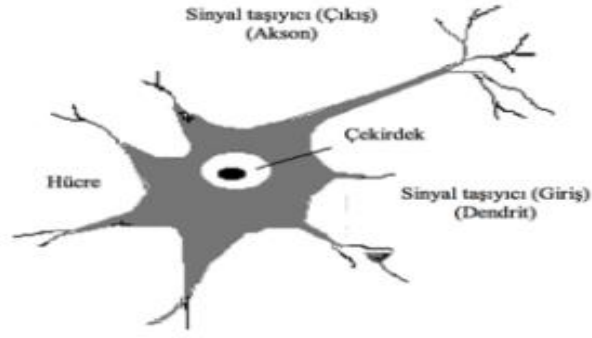
Şekil 2.1. Biyolojik Sinir Sisteminin Gösterimi (Fırat ve Güngör, 2004)

Bir sinir sisteminin en hayati işlevlerini gerçekleştiren yapı sinir hücreleridir ve insan beyinde yaklaşık 10 milyar ile 100 milyar arasında değişen sinir hücresi mevcuttur. Sinir hücresi giriş (dendirit), çıkış (akson), gövde ve bağlantılar (snaps) olmak üzere 4 temel bileşenden meydana gelmektedir (Anderson ve McNeill, 1992)

Snapslar: Komşu sinir hücreleri arasında bağlantıyı sağlayan yapılar olduklarından dolayı hücreler arası iletişimi gerçekleştirirler.

Dendiritler: Hücreler arası iletişimi sağlayan snapslardan bilgileri alarak gövdeye aktaran yapıya dendiritler denilmektedir.


Akson: Hücre gövdesinin uyarı eşiği sınırı geçildiği zaman hücre uyarılır bu nedenle aksonlar aracılığıyla diğer hücrelere uyarı yollar. Aksonlar ve dendiritler görevleri bakımından birbirlerine benzemektedirler ancak aksonlar dendiritlere oranla daha uzun ve daha düzenli bir yapıya sahiptirler. Biyolojik sinir hücresinin yapısı Şekil 2.2' de gösterilmiştir.



Şekil 2.2. Sinir Hücresi Yapısı (Şen, 2004)

2.2.2 Yapay Sinir Hücresi

Yapay sinir ağları da biyolojik sinir ağlarına benzer şekilde benzer yapıya sahiptir. İlk yapay sinir hücresi modellenmesi McCulloch ve Pitts tarafından 1943 yılında meydana getirilmiştir. Geliştirilen ilk yapay sinir hücresi Şekil 2.3’de verilmiştir.



Şekil 2.3. McCulloch-Pitts Nöron Modeli

McCulloch-Pitts nöron modeline göre modeldeki yuvarlak şekiller biyolojik nörondaki gövde kısmıdır. Modelde biyolojik sinir hücresindeki sinyalleri ileten dendritler ise oklar ile ifade edilmiştir. Model gerçek biyolojik sinir hücresi ile aynı mantıkla çalışmakta ve modele gelen her sinyal iletilmemektedir. Gövdeye ulaşan toplam sinyal miktarı belirli bir uyarı eşiğini aştığı zaman sinyal gönderilmektedir. McCulloch-Pitts Nöron modelinin geliştirilmesi ve bu nöronların bir ağ oluşturacak şekilde bağlanması ile birlikte yapay sinir ağları oluşturulmuştur (Eğrioğlu ve ark., 2020).

Yapay sinir ağlarında nöronlar 5 temel bileşenden meydana gelmektedir. Bu bileşenler; (Öztemel, 2006)

Girdiler: Yapay sinir hücresine dışarıdan ya da diğer sinir hücrelerinden örnekler aracılığıyla verilen bilgilere denilmektedir.

Ağırlıklar: Yapay sinir hücresine girilen bilgilerin o sinir hücresi üzerindeki etkisine ağırlık denilmektedir. Ağırlıkların aldıkları büyük veya küçük değerler hücre için önemini belirtmez sadece girdinin hücre üzerindeki etkisini gösterir.

Toplam Fonksiyonu: Hücreye verilen net girdiyi hesaplayan fonksiyon toplam fonksiyonu olarak ifade edilmektedir. Bu işlemi gerçekleştirmek için farklı fonksiyonlar mevcuttur ancak en yaygın ağırlıklı toplamı hesaplamaktır.

Aktivasyon Fonksiyonu: Hücrenin verilen net girdiyi kullanarak bu girdiye karşı çıktı değer üretmesine aktivasyon fonksiyonu olarak ifade edilmektedir. Aktivasyon fonksiyonunda da farklı tipte fonksiyonlar mevcuttur ancak en iyi sonucu elde etmek için farklı fonksiyonların denenip test edilmesi gerekmektedir.

Çıktı: Hücrenin aktivasyon fonksiyonu aracılığıyla elde edilen değer çıktı olarak ifade edilmektedir. Biyolojik sinir sistemi ve yapay sinir ağının yapısında bulunan ve aynı görevi yerine getiren elemanlar yan yana olacak şekilde Çizelge 2.1'de gösterilmiştir.

Çizelge 2.1. Biyolojik sinir sistemi yapay sinir ağları arasındaki benzerlikler (Baş, 2006; Küçükönder, 2011)

Sinir Sistemi	Sinirsel Hesaplama Sistemi
Nöron (Sinir)	İşlem elemanı
Dendirit	Toplama fonksiyonu
Hücre gövdesi	Aktivasyon fonksiyonu
Aksonlar	Eleman çıktısı
Sinapslar	Ağırlıklar


2.3 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları yapay sinir hücrelerinin bir düzen içerisinde bir araya gelmesi ile meydana gelmektedir. Bu hücreler 3 katman halinde ve kendi içinde paralel olacak şekilde bir araya gelerek yapay sinir ağlarını oluştururlar. Tipik bir yapay sinir ağı modeli Şekil 2.4' deki gibidir. Bu katmanlar; (Kukreja ve ark., 2016).

Girdi katmanı: Dışarıdan gelen bilgileri ara katmanlara aktarma işini girdi katmanı gerçekleştirmektedir.

Ara katman: Girdi katmanından gelen bilgilerin çıktı katmanına aktarıldığı bölümdür. Verilerin işleme aşaması ara katmanda gerçekleştirilir. Eğitilen bir ağda birden fazla ara katman olabilir.

Çıktı katmanı: Ara katmandan gelen bilgilerin işlenmesi ile birlikte sisteme ilk girilen bilgilere karşılık çıktı değerleri elde edilen bölümdür.



Şekil 2.4. Tipik bir yapay sinir ağı modeli (Dehkordi 2012; Öztürk,2015)

2.4 Yapay Sinir Ağlarının Sınıflandırılması


Yapay sinir ağları genel olarak öğrenme algoritmalarına ve yapılarına göre 2 farklı şekilde sınıflandırılabilirler.

2.4.1 Yapay Sinir Ağlarının Yapısına Göre Sınıflandırılması

Sinir ağları, ağı oluşturan sinirlerin kendi aralarındaki bağlantıların yönlerine ya da sinir ağının içerisindeki girdilerin akış durumuna göre ileri beslemeli ve geri beslemeli sinir ağları olmak üzere 2 gruba ayrılırlar (Ataseven, 2013).

2.4.1.1 İleri Beslemeli Ağlar


İleri beslemeli yapay sinir ağlarında girdiler girdi katmanından çıktı katmanına doğru tek yönlü olarak gönderilir. Sinir ağında sinir hücreleri sadece bir sonra ki katman ile bağlantılıdır aynı katmandaki verilerin birbirleri ile ilişkisi yoktur ve sistem ileri yönlü işler. İleri beslemeli sinir ağının çalışma prensibi Şekil 2.5’de verilmiştir (Barutçu, 2013; Akın, 2017).



Şekil 2.5. İleri beslemeli sinir ağları mimarileri (Barutçu 2013; Akın 2017)

2.4.1.2 Geri Beslemeli Ağlar

Geri beslemeli ağlarda katmanlardaki nöronların çıktı değerleri mevcut girdi değerleri ve ağırlık değerlerine bağlı olmakla birlikte aynı zaman da ileri beslemeli ağların tam tersi olarak diğer tabakalardaki ve nöronlardaki çıktı değerlerinden de etkilenmektedirler. Bu tip ağlar daha çok tahmin yapmak amacıyla kullanılmaktadır. Geri beslemeli ağların çalışma prensibi Şekil 2.6' daki gibidir (Altınkum, 2013).



Şekil 2.6. Geri beslemeli ağların çalışma prensibinin gösterimi (Altınkum, 2013)


2.4.2 Yapay Sinir Ağlarının Öğrenme Algoritmasına Göre Sınıflandırılması

Öğrenme yapay sinir ağlarının sahip olduğu en önemli işlevlerden bir tanesidir. Öğrenmenin gerçekleşmesi ile birlikte ağırlıklar minimum hata miktarına düşmek amacıyla değişmektedir. Yapay sinir ağlarında danışmanlı, danışmansız ve destekleyici olmak üzere 3 farklı öğrenme algoritmasından bahsedilebilir. (Altınkum, 2013)

2.4.2.1 Danışmanlı Öğrenme

Danışmanlı öğrenmede sinir ağı girdi ve her bir girdi değerine karşılık gelecek çıktı değerleri ile birlikte eğitilmektedir. Eğitim sırasında ağ elde ettiği çıkış değeri ve gerçek çıkış değeri arasındaki hata miktarını daha önce belirlenen hata miktarından daha düşük oluncaya kadar eğitimi sürdürür. Gerçek hata miktarının istenilen hata miktarının altına düşmesi ile birlikte eğitim sonlandırılır ve ağırlıklar elde edilir (Filiz, 2013).

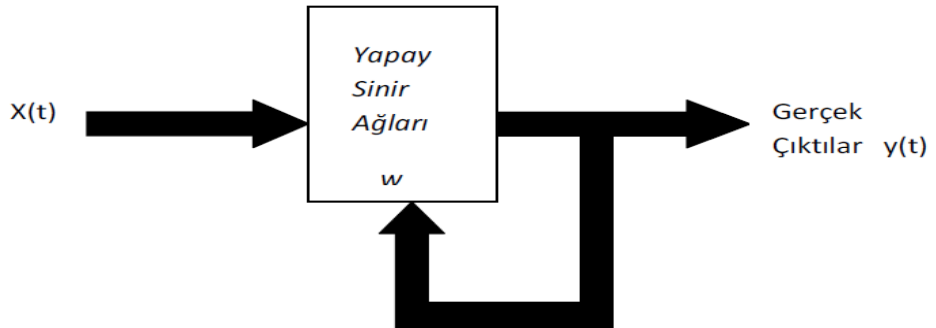
Böylelikle ağ eğitimi gerçekleştirilen örneklere benzer örneklerde başarılı çıktı performansı gösterebilir. Danışmanlı öğrenmenin gerçekleşme şematiği Şekil 2.7' de gösterilmiştir.



Şekil 2.7. Danışmanlı Öğrenme (Sağiroğlu ve ark., 2004; Ataseven, 2013)

2.4.2.2 Danışmansız Öğrenme

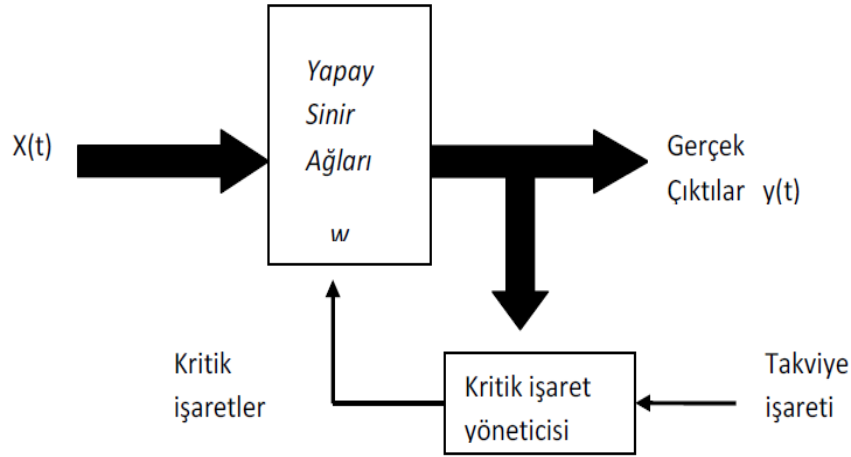
Danışmansız öğrenmede eğitim amacıyla sinir ağına yalnızca girdi değerleri verilir. Ağa çıktı değerleri verilmemektedir dolayısıyla sinir ağında bir danışman mevcut değildir. Sinir ağı, verilen girdiler arasında ilişkiyi kendisi oluşturarak benzer özellik gösteren girdileri sınıflandırarak bağlantı ağırlıklarını belirler. Danışmansız öğrenme daha çok sınıflandırma amacıyla kullanılmaktadır (Baş, 2006). Şekil 2.8' de danışmansız öğrenmenin gerçekleşme şematiği gösterilmiştir.



Şekil 2.8. Danışmansız Öğrenme (Altinkum, 2013)

2.4.2.3 Destekleyici Öğrenme

Destekli öğrenmede de danışmanlı öğrenme de olduğu gibi sinir ağına girdi ve çıktı değerlerinin verilmesi gerekmektedir ancak danışmanlı öğrenmenin aksine destekleyici öğrenmede ağa verilen çıktı değerleri sinir ağına doğrudan gösterilmez. Sinir ağının elde ettiği çıktı değerinin ne kadar doğru ya da yanlış olduğu ağa söylenir. Böylece ağa verilen çıktı değeri sadece elde edilen çıktı değerinin doğruluğunu test eden kriter olarak kullanılmakta ve buradan yola çıkarak ağın bağlantı ağırlıklarının en iyi şekilde belirlenmesi amaçlanmaktadır (Özgün, 2011). Destekleyici öğrenme çalışma prensibi Şekil 2.9' da verilmiştir.



Şekil 2.9. Destekleyici Öğrenme (Altinkum, 2013)

2.4.3 Yapay Sinir Ağlarının Uygulamaya Göre Sınıflandırılması

Yapay sinir ağları öğrenme çeşitlerine göre çevrimiçin ve çevrimdışı öğrenme olarak 2 gruba ayrılırlar. (Özgün, 2011)

2.4.3.1 Çevrimiçi Öğrenme

Çevrimiçi olarak öğrenme gerçekleştiren sinir ağları öğrenme gerçekleştirirken aynı zamanda diğer fonksiyonlarını da yerine getirebilmektedir.

3.4.3.2 Çevrimdışı Öğrenme

Çevrimdışı öğrenme çevrimiçi öğrenmenin aksine öğrenme ve diğer fonksiyonlarını birlikte meydana getiremez. Çevrimdışı öğrenmede örnekler aracılığıyla öğrenme gerçekleştirilir ve tamamladır. Sistemin gerçek hayatta kullanılması esnasında eğitim gerçekleşemez.

2.5 Yapay Sinir Ağlarında Öğrenim Kuralları

Yapay Sinir Ağlarında sinir hücrelerinin bağlantı ağırlıkları öğrenme gerçekleşmeden önce rastgele olarak yapılmaktadır ancak sisteme örnekler aracılığıyla girdi ve çıktılar verilerek sinir ağının çıktıları ve gerçek çıktı değerleri arasındaki farkın karşılaştırılmasıyla bağlantı ağırlıkları doğru bir şekilde ayarlanmaktadır. Bu olaya öğrenme denmektedir. Sinir ağlarında öğrenme ile birlikte hatanın minimum düzeye indirilmesi ve doğru sonuçlar elde edilebilmesi adına bazı öğrenme kuralları mevcuttur. En yaygın 4 öğrenme kuralı Hebb kuralı, Delta kuralı, Hopfield kuralı ve Kohonen kuralıdır. (Bekin, 2015; Oğuz 2019)

2.5.1 Hebb Kuralı

1949 yılında Donald Hebb tarafından biyolojik öğrenmeye dayanarak geliştirilen öğrenme kuralıdır. Bu kurala göre birbirleri ile girdi alışverişi yapan sinir hücreleri aynı anda etkileşirse bağlantı değerleri artarken farklı anlarda etkileşirse bağlantı değerleri azalır (Gupta, 2013).

2.5.2 Delta Kuralı

Delta kuralı Hebb kuralının geliştirilmiş halidir ve en çok kullanılan kurallardan bir tanesidir. Delta kuralı sinir ağının elde ettiği çıktı değerleri ile gerçek çıktı değerleri arasında farkı en aza indirebilmek için nöronların bağlantı ağırlıklarının en uygun noktaya getirene kadar sürekli olarak değiştirilmesi prensibiyle çalışmaktadır. Delta kuralının temel amacı gerçek çıktı ve sinir ağının çıktı değerleri arasındaki farkın karesini minimize etmektir bu nedenle hata kareleri ortalamasının minimuma indirilmesi olarak da adlandırılabilir (Küçükönder, 2011; Akbaba, 2019).

2.5.3 Hopfield Kuralı

Hopfield kuralı Hebb kuralına büyük oranda benzemektedir ancak aralarında birkaç fark mevcuttur. Hopfield kuralında bağlantılı sinir hücrelerinin girdi ve hedefledikleri çıktılarının her ikisinde aktif ya da pasif olma durumlarına bağlı olarak bağlantı ağırlıklarında öğrenme katsayısı kadar artış veya azalış meydana gelmektedir. Öğrenim katsayısı kullanıcı tarafından belirlenen 0 ile 1 arasında değerler alabilen bir katsayıdır. (Baş, 2006).

2.5.4 Kohonen Kuralı

Kohonen Kuralı biyolojik sinir sistemlerinden yola çıkılarak geliştirilmiştir. Kohonen kuralında işlemci elemanlar, bağlantı ağırlıklarının düzenlenebilmesi amacıyla birbirleri ile yarışır, en iyi çıktı verisine sahip işlemci elemanın kazandığı yarış sonucunda bu nöronun bağlantı ağırlıklarına göre diğer nöronların bağlantı ağırlıkları da güncellenebilir (Akbaba 2019).

2.6 Yapay Sinir Ağlarının Tasarımı

2.6.1 Sinir Ağı Türünün Seçimi

Yapay sinir ağlarında bir ağ tasarımı gerçekleştirirken dikkat edilmesi gereken birçok nokta söz konusudur. Öncelikle ağ tasarımı gerçekleştirirken çözülecek problemin türüne göre hareket etmek gerekmektedir. Sinir ağları farklı ağ türlerine sahiptir ve bu ağ türleri de farklı amaçlar için kullanılmaktadır. Kullanıcının sahip olduğu problemi başarılı bir şekilde çözmek için doğru sinir ağı türünü seçmesi gerekmektedir. Sinir ağları öncelikle amaçlarına göre tahmin etme, sınıflandırma ve verileri ilişkilendirme olarak 3 farklı grupta incelenebilmektedir. Bu gruplar da hangi sinir ağlarının kullanıldığı Çizelge 2.2’de verilmiştir (Saraç, 2004; Küçükönder, 2011).

Çizelge 2.2. Sinir Ağlarının Türleri ve Kullanım Amaçları (Saraç, 2004; Küçükönder, 2011).

Ağın Kullanım Amacı	Sinir Ağı Türü	Ağın İşlevi
Tahmin	Çok katmanlı ağ	Ağın girdilerden faydalanarak çıktı tahmininde bulunmasıdır.
Sınıflandırma	LVQ ART Olasılıklı sinir ağları Counterpropagation	Ağa girilen girdilerin sınıflandırılması
Verileri ilişkilendirme	Hopfield Boltzmann makinası	Ağa girilen girdilerin eksik ya da hatalı olanların belirlenmesi

2.6.2 Öğrenim Algoritmasının Seçimi

Başarılı bir sinir ağı yapısı oluşturabilmek için öğrenim algoritmasını seçerken kullanılacak olan sinir ağı türüne dikkat etmek gerekmektedir. Öğrenim algoritmalarının başarılı sonuçlar verdiği sinir ağları ile birlikte kullanılması önemlidir. Aksi takdirde sinir ağının performansı oldukça düşecektir (Altinkum, 2013).

2.6.3 Ara Katman Sayısının Belirlenmesi

Yapay sinir ağı oluştururken ağın türü ve öğrenim algoritmasına kadar verdikten sonra ara katman sayısını belirlemek gerekmektedir. Ara katman sayısını tam olarak söylemek pek mümkün değildir. Çözülecek olan probleme göre veya sinir ağının yapısına göre değişiklik gösterebilir. O yüzden ara katman sayısını belirlemek için deneme ve yanılma yönteminden yararlanmak en iyi tercihtir (Akbaba, 2019).

2.6.4 Nöron Sayısının Belirlenmesi

Sinir ağlarında nöron sayısının belirlenirken katman sayısında olduğu gibi kesin bir karara varılamaz. Sinir ağının performansını en çok arttırarak en iyi sonucu verecek nöron sayısını bulmak amacıyla deneme ve yanılma yöntemine başvurmak gerekmektedir. Ancak burada dikkat edilmesi gereken bir nokta söz konusudur. Seçilecek olan nöron sayısının çok fazla olması ağın girdi verilerini ezberlemesine bu yüzden ezber sonuçlar vermesine neden olabilir ve aynı zaman da nöron sayısının çok az olması eğitimin başarısız olarak gerçekleşerek sinir ağının performansında düşüş yaşanmasına neden olabilir.

2.6.5 Aktivasyon Fonksiyonun Seçimi

Sigmoid ve hiperbolik tanjant fonksiyonları yapay sinir ağlarında en fazla tercih edilen aktivasyon fonksiyonlarıdır. Kullanılacak sinir ağında çıktıkların aralıkları sigmoid fonksiyonunda 0 ile 1 arasındayken hiperbolik tanjant fonksiyonunda -1 ile 1 arasında değişmektedir. (Küçükönder, 2011).

2.7 Verilerin Normalizasyon

Kullanılacak olan veri grubunun ölçeklendirilmesinin farklı olduğu ya da veriler arası değer farklılığının çok olduğu durumlarda verileri tek bir düzende daha doğru olarak kullanılabilmek ve karşılaştırabilmek amacıyla verilere minimum-maksimum normalizasyon işlemi yapılmalıdır. Minimum-maksimum normalleştirilmesine göre veri grubundaki en küçük ve en büyük değerlere göre veri grubunun diğer verileri de normalleştirilir. Veri grubunda en küçük değer 0 en büyük değer de 1 olarak normalleştirilir ve bu duruma göre kalan diğer bütün veriler 0 ile 1 arasında değerler alırlar (Ali ve Faraj, 2014).

$$X' = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \quad (3.1)$$

Bu eşitlikte;

X' = Normalize edilmiş olan değer

X_i = Normalize edilecek olan değer

X_{\max} = Veri grubundaki en büyük değer

X_{\min} = Veri grubundaki en küçük değer

İle ifade edilmiştir. (Banda, 2016) (Lapedes ve Farber., 1988)

Örneğin veri grubu 2, 15, 25 ,66, 42, 18 ,29,92 sayılarından oluşması durumunda normalizasyon sonundan bu sayıların yeni değerleri 0, 0,144, 0,255, 0,711, 0,444, ,0,1777, 0,3 ,1 şeklinde olacaktır. Normalleşme sonucunda en küçük değer 0 en büyük değer ise 1 değerini alacak kalan değerlerde 0 ile 1 arasında değerler alacaktır.

2.8 İstatiksel Hata Ölçütleri

Yapay sinir ağlarında gerçekleştirilen tahminleme sonucunda sinir ağının performansını değerlendirmek ve hata miktarlarını elde etmek amacıyla istatiksel hata ölçütlerinden yararlanılır. Bu performans ölçütlerine ortalama karesel hata (MSE), ortalama karesel hata karakökü (RMSE), ortalama mutlak hata (MAE) ve Ortalama mutlak hata yüzdesi (MAPE) örnek olarak verilebilir. Bu hata ölçütlerinin değerlerinin sıfıra yaklaşması hata miktarının azaldığını ve sinir ağının performansının yükseldiğini göstermektedir (Karasu ve ark, 2018; Gültepe, 2019).

Ortalama Hataların Karesi (Mean Squared Error – MSE)

$$\frac{1}{n} \sum_{i=1}^n (g_i - t_i)^2 \quad (3.2)$$

Bu eşitlikte;

g_i : i numaralı gerçek çıktı değeri

t_i : i numaralı tahmin edilen çıktı değeri

n : Toplam veri sayısı

ile ifade edilmiştir.

Ortalama Hatalar Karesinin Karekökü (Root Mean Squared Error – RMSE)

$$\sqrt{\frac{1}{n} \sum_{i=1}^n e^2} \quad (3.3)$$

Bu eşitlikte;

g_i : i numaralı gerçek çıktı değeri

t_i : i numaralı tahmin edilen çıktı değeri

n : Toplam veri sayısı ile ifade edilmiştir.

Ortalama Hata Mutlak Değeri (Mean Absolute Error – MAE)

$$\frac{1}{n} \sum_{i=1}^n |g_i - t_i| \quad (3.4)$$

Bu eşitlikte;

g_i : i numaralı gerçek çıktı değeri

t_i : i numaralı tahmin edilen çıktı değeri

n : Toplam veri sayısı

ile ifade edilmiştir.

Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error – MAPE)

$$\frac{\sum \frac{|y_1 - y_1^t|}{y_1}}{n} \times 100 \% \quad (3.5)$$

Bu eşitlikte;

y_1 : Gerçek değer

y_1^t : Tahmin değeri

n : Toplam veri sayısı

Ortalama Mutlak Hata Yüzdesi (MAPE) ile elde edilen sonuçlar değerlendirilirken %10'un altında olan değerler "çok iyi", %10 ila %20 arasında olan değerler "iyi", %20 ile %50 arasında olan değerler "kabul edilebilir" ve %50'nin üstünde olan değerler ise "yanlış ve hatalı" olarak değerlendirilir (Aslay ve Özen, 2013; Lewis, 1982).

2.9 Kaynak Araştırması

Charytoniuk ve Chen (2000), Amerika Birleşik Devletleri'ndeki bir elektrik tesisinde yapay sinir ağlarında Levenberg-Marquardt eğitim algoritması ile çevrimiçi yük tahmini gerçekleştirmişlerdir. Çalışma da yapay sinir ağlarının elektrik tesisinde çevrimiçi yükü tahmin etmek için uygulanması, iyi performans ve yüksek güvenilirlikli sonuçlar ortaya koymuştur.

Campolo ve ark. (2003), İtalya'da bulunan Arno nehrinde insanlar için riski azaltmak, ekonomik kayıpların önüne geçmek ve nehirde su seviye değişimini altı saat önceden belirleyebilmek amacıyla yapay sinir ağları yardımıyla nehrin taşkın ihtimalini tahminlemişlerdir. Çalışmalarında girdi parametresi olarak yağış verileri, hidrometrik ve baraj işletimi hakkında bilgiler kullanmışlardır. Sonuçlar su seviyesinin tahmin edilmesinde tatmin edici sonuçlar ortaya konduğunu ancak kısa süreli şiddetli yağışlarda zamanlama hataları olabildiğini göstermiştir.

Daliakopoulos ve ark. (2005), Yunanistan Girit'te bulunan Messara Vadisi'ndeki yer altı su seviyesini tahminlemek amacıyla yapay sinir ağlarını kullanmışlardır. Tahminleme amacıyla yedi farklı ağ mimarisi ve eğitim algoritmasından yararlanmış ve en iyi sonucu Levenberg-Marquardt algoritması ile elde etmişlerdir. Genel olarak, çalışmanın sonuçları tatmin edicidir ve yapay sinir ağlarının yeraltı suyu seviyesinin belirlenmesinde yararlı bir tahmin aracı olarak kullanılabileceğini göstermektedir.

Tolon ve Güneri Tosunoğlu (2008), Ankara'da bulunan Ankamall alışveriş merkezinde yapay sinir ağları ve regresyon analizi yardımı ile müşterilerin tatminlik seviyeleri tahmin etmiş ve karşılaştırmışlardır. Çalışma da kullanılacak girdi ve çıktı parametrelerini müşteriler ile yaptıkları anket ile temin etmişlerdir. Tahminleme sonucunda yapay sinir ağlarının regresyon analizine oranla daha az hata ile daha iyi sonuçlar verdiği sonucuna ulaşmışlardır.

Boniecki ve ark. (2012), yaptıkları çalışmada yapay sinir ağlarında çok katmanlı algılayıcı sinir ağı, radyal tabanlı fonksiyon ağı ve genelleştirilmiş regresyon sinir ağından faydalanarak kanalizasyonlardaki atık kompostlanmasıyla salınan amonyak emisyon miktarını tahminleyerek en uygun yapan sinir ağını bulmayı amaçlamışlardır. Çalışma sonucunda en iyi tahminlemeyi çok katmanlı algılayıcı sinir ağı ile yapıldığı ve yapay sinir ağlarının bu tür emisyonları tahminlemek için uygun olabileceği sonucuna varılmıştır.

Antanasijević ve ark. (2013), 2004 ile 2010 yılları arasında 28 Avrupa ülkesi için on iki farklı girdi parametresi kullanarak yapay sinir ağları ile birlikte sera gazı emisyonu tahminlemesi gerçekleştirmişlerdir. Tahminleme de genel regresyon sinir ağı ve doğrusal regresyon modelinden faydalanmışlardır. Çalışma sonucunda doğrusal regresyon modeli %15'lik bağıl hata ile tahminlemede bulunurken regresyon sinir ağı ise %4 bağıl hata ile çok daha iyi tahmin performansı göstermiş ve başarılı sonuçlar ortaya koymuştur.

Gichovi ve ark. (2013), Kenya Ruiru'da bulunan trafo merkezinde yedi farklı geçmiş girdi değişkeni kullanılarak yapay sinir ağları ile kilovat cinsinden elektrik yükü tahmininde bulunmuşlardır. Çalışmada farklı örnek sayıları ve gizli katman sayıları ele alınarak karşılaştırma gerçekleştirmişlerdir ve en iyi sonuç 900 örnek ve 70 nöron gizli katman ile %2,6 hata ile tahminlendiğini göstermiştir.

Turhan ve ark. (2013), İzmir'de üç ilçede 148 farklı binada yaptıkları çalışma ile binaların enerji tüketimlerini yapay sinir ağlarında Levenberg-Marquardt modeli ile tahminlemişler ve yazılım ile hesaplanan enerji tüketimleri ile karşılaştırmışlardır. Sonuçlar yazılım ve tahminleme sonuçları karşılaştırıldığında değerlerin birbirlerine çok yakın olduğunu ve yapay sinir ağlarının ile enerji tüketimi tahminlenmesinin yapılabileceğini ortaya koymuştur.

Antanasijević ve ark. (2013), 1999'dan 2006'ya kadar olan dönem için bir bütün olarak Avrupa birliği ve Malta hariç Avrupa birliği ülkeleri için gayri safi yurtiçi hasıla, brüt ülke içi enerji tüketimi ve motorizasyon oranı parametrelerini dikkate alarak ve yapay sinir ağlarında genel regresyon sinir ağını kullanarak PM10 emisyon tahminlemesinde bulunmuşlardır. Yapay sinir ağları modeli iki yıla kadar PM10 emisyon tahminininin

başarılı ve doğru bir şekilde yapılabileceğini göstermiştir. Çalışmada aynı zamanda aynı veri kümeleri ve girdi değişkenleri kullanılarak çoklu doğrusal regresyon ve temel bileşen regresyonu modelleri ile de tahminlemeler yapılmıştır ancak yapay sinir ağları diğer modellere oranla çok daha iyi tahmin performansına sahiptir.

Radojević ve ark. (2013), yapay sinir ağlarından yararlanarak Sırbistan'daki amonyak emisyon miktarını tahminlemek üzerine çalışma gerçekleştirmişlerdir. Modellemede girdi parametreleri olarak yenilenebilir enerji kaynaklarının payı, gayri safi yurtiçi hasıla, brüt enerji tüketimi ve enerji yoğunluğundan faydalanmışlardır. Çalışma sonucunda çoğu durumda tahmin edilen ve gerçek amonyak emisyonu değerleri arasında %10'un altında bir bağıl hata ile sonuçları tatmin edici bulmuşlardır ve yapay sinir ağlarının amonyak emisyonlarını tahminlenmesi için uygulanabileceği sonucuna varmışlardır.

Khoshnevisan ve ark. (2014), İran'ın İsfahan şehrinde patates üretimi sırasında ortaya çıkan enerji ve sera gazı emisyonlarını tahminlemesini yapay sinir ağları yardımıyla gerçekleştirmişlerdir. Çalışma için rastgele seçilmiş olan 260 çiftlikten anket yöntemi ile veriler toplanmış ve on farklı girdi parametresi kullanılarak tahminleme gerçekleştirilmiştir. Çalışma da çalışılan bölgedeki patates çıkış enerjisinin ve sera gazı emisyonunun tahmin edilmesi için başarılı sonuçlar ortaya konmuştur.

Kaplan ve ark. (2014), Kütahya ilinde rüzgar, bağıl nem, PM10 ve kükürt dioksit girdi parametreleri kullanarak yapay sinir ağlarında Levenberg – Marquardt eğitim algoritması ile PM10 miktarı tahminlenmesi gerçekleştirmişlerdir. Yapay sinir ağları ile gerçekleştirilen tahminlemenin gerçek değerlere yakın sonuçlar verdiği sonucuna ulaşmışlardır.

Kumar ve ark. (2014), yaptıkları çalışmada Hindistan'da bulunan bir valf imalat şirketinde 10''X 150 sınıfı sürgülü vana için yapay sinir ağları ile talep tahminlemesi gerçekleştirmişlerdir. Çalışma da ürünün son iki aylık süreçteki satış fiyatındaki indirim miktarı, son iki aydan önceki satış miktarı (üçüncü ve dördüncü aylar), son iki ve üç aylık satışların ortalamaları girdi olarak kullanılmış ve dört farklı öğrenme algoritması için tahminleme gerçekleştirilmiştir. Çalışma sonucu en iyi tahminlemenin Levenberg-Marquardt algoritması ile gerçekleştirildiğini ve yapay sinir ağlarının müşteri taleplerinin tahmin edilmesinde başarılı destek aracı olabileceğini ortaya koymuştur.

Abuella ve ark. (2015), güneş enerjisi tahminlemesi amacıyla on iki farklı hava durumu girdi değişkeni kullanarak yapay sinir ağları, çoklu doğrusal regresyon analiz modeli ve kalıcılık modeli ile tahminlemede bulunmuşlardır. Çalışmada yapay sinir ağları modeli ile yapılan tahminlemenin çoklu doğrusal regresyon analizi modelinden ve kalıcılık modelinden daha iyi performans gösterdiği bulunmuştur.

Stamenković ve ark. (2015), çalışmalarında 2000-2008 yılları arasında elde edilmiş dört farklı girdi parametresi kullanarak ABD ve Avrupa ülkelerinde oluşan amonyak emisyon miktarını yapay sinir ağlarında çok katmanlı algılayıcı mimarisi ile tahminlemişlerdir. Aynı zaman da girdiler arasındaki korelasyonu azaltmak için aynı girdilere temel bileşenler analizi uygulayarak oluşturulan çok katmanlı algılayıcı modeli ve bir temel bileşen regresyon modeliyle de tahminlemede bulunmuşlar ve üç farklı tahminleme için sonuçları karşılaştırmışlardır. Çalışma sonucu temel bileşenler analizi uygulayarak oluşturulan çok katmanlı algılayıcı modelin orijinal girdilere dayalı çok katmanlı algılayıcı modele kıyasla daha doğru bir tahmin sağladığını göstermiştir ve yapay sinir ağlarının, amonyak emisyonlarının ulusal düzeyde tahminlenmesi için geleneksel modellere alternatif olarak kullanılabilmesi sonucuna varılmıştır.

Pabuçcu ve Bayramoğlu (2016), yaptıkları çalışmada 1990 ile 2030 yılları arasında beşer yıllık arayla yedi farklı girdi değişkeni kullanarak yapay sinir ağlarında Levenberg-Marquardt algoritması ile Türkiye için karbondioksit emisyonu miktarı tahminlemesinde bulunmuşlardır. Çalışmada yapay sinir ağları ile yapılan tahminleme sonucunda Türkiye'nin 2030 yılında taahhüt ettiği karbondioksit emisyon miktarından çok daha fazla salım gerçekleştireceği sonucuna ulaşılmıştır.

Fente ve Singh (2018), hava durumunun tahminini gerçekleřtirmek amacıyla yapay sinir ađlarından faydalanmıřlardır. Tahminleme alıřmalarında sıcaklık, yađıř, rüzgar hızı, basın, iy noktası görünürlüğü ve nemi girdi parametresi olarak kullanmıřlar, sinir ađı olarak da uzun kısa süreli bellek ađlarını kullanmıřlardır ve diđer hava tahmin tekniklerine oranla daha yüksek dođrulukta sonuçlar ortaya koymuřlardır.

Özden ve Öztürk (2018), Türkiye’de bulunan bir sanayi bölgesinin enerji tüketimini bulmak amacıyla yapay sinir ađları ve zaman serilerinden yararlanmıřlardır. 2014-2016 yılları arasındaki sıcaklık ve enerji tüketimi verileri ele alınarak tahminleme gerçekleştirilmiřtir ve tahminleme sonucunda yapay sinir ađlarının zaman serilerine oranla daha iyi performans gösterdiđi sonucuna ulařılmıřtır.

Taşar ve ark. (2018), yaptıkları alıřmada Amerika’nın Massachusett bölgesinde iklim verileri kullanarak üç farklı geleneksel yöntem ve yapay sinir ađları ile günlük buharlaşma miktarının tahminlenmesini ve karşılaştırılmasını yapmıřtır. Yapay sinir ađlarının diđer geleneksel yöntemlere oranla daha dođru sonuçlar verdiđini ve bu geleneksel yöntemlere ek olarak buharlaşma miktarı hesaplanırken bir seçenek olarak kullanılabileceđi sonucuna ulařmıřlardır.

Alias ve ark. (2018), Malezya’da çiftlik hayvanlarını etkileyen hastalıkları tahmin etmek amacıyla yapay sinir ađlarından yararlanmıřlardır. alıřmalarında SPSS ve MATLAB yazılımlarından faydalanmıřlar ve alıřma sonucunda MATLAB ile gerçekleştirilen tahminleme iyi sonuçlar vermesine rağmen SPSS ile gerçekleştirilen tahminlemeye oranla daha geride kalmıřtır.

Mohamed (2019), yapmış olduđu çalışmada üç farklı Mısır şehrinin yatay bir yüzeyinde küresel güneş radyasyonunu tahmin etmek için yapay sinir ağı modellerini kullanmıştır. Çalışmada 2002 ile 2016 yılları arası ölçümü gerçekleşmiş altı farklı iklim verisi girdi parametresi olarak kullanılmış ve yapay sinir ağıları sırasıyla temel geri yayılım ve momentum ve öğrenme oranı katsayılı temel geri yayılım olmak üzere iki farklı algoritma ile eğitilmiştir. Momentum ve öğrenme oranı katsayılı temel geri yayılım algoritması, temel geri yayılım algoritmasına oranla daha iyi sonuçlar vermiştir. Bu sonuçlar, yapay sinir ağılarının kabul edilebilir bir doğrulukla geleneksel tahmin modellerine iyi bir alternatif olabileceğini göstermiştir.

Pençe ve ark. (2019), 1970-2016 yılları arasında sanayide kullanılan 47 adet elektrik tüketimi verisi yapay sinir ağıları ile eğitilerek 2017-2023 yılları arası elektrik tüketimi miktarı tahminlemiştir. Tahminleme ile elde edilen değerler ile çalışmanın yapıldığı döneme kadar geçen süredeki gerçek değerler karşılaştırıldığında başarılı sonuçlar ortaya konmuştur.

Lorente-Leyva ve ark. (2019), yapay sinir ağılarında Levenberg Marquardt eğitim algoritması ile kentsel su talebi tahmininde bulunmuşlar ve bu tahminlemeleri ARIMA modeli ile gerçekleştirdikleri tahminleme ile karşılaştırmışlardır. Bu çalışma sonucunda Yapay sinir ağıları tarafından tahminlenen sonuçlar, gerçek tüketim değerleri ile daha büyük benzerlik sunarken, ARIMA modelinin sonuçları, hesaplandıkları ortalamaya göre sabit tahminler sunmuştur.

Kononenko ve ark. (2020), çalışmalarında Rusya'da tarımdan kaynaklı karbondioksit emisyonlarının miktarının tahminlemek amacıyla yapay sinir ağılarından yararlanmışlardır. Çalışmada 1992-1997 yılları arasında Rusya'da gerçekleştirilmiş gözlemler ele alınarak on farklı girdi parametresi kullanılmıştır, eğitim yöntemi olarak ise Adadelta algoritmasından yararlanılmıştır. Tahmin edilen ve gerçek değerleri karşılaştırıldığında oluşturulan ağ gerçek tahminlerle neredeyse örtüşen tahminler gerçekleştirmiştir ve model çalışabilirliğini kanıtlamıştır.

Özhan (2020), gerçekleştirdiği çalışmada Türkiye için son 55 yıllık sera gazı emisyonu değerlerini kullanarak yapay sinir ağları ve üstel düzleştirme yöntemine dayanan Holt'un lineer trend modeli ile karbondioksit emisyonu miktarının tahminlemesini gerçekleştirmiştir. Karşılaştırma sonucunda yapay sinir ağlarının Holt'un lineer trend modeline oranla daha doğru ve düşük hata ile tahminleme gerçekleştirdiği sonucuna varılmıştır.

Akbulut ve Özcan (2020), 2012-2019 yılları arasında hava kirliliğini etkileyen ve girdi parametresi olarak belirledikleri beş farklı değişkeni kullanarak Türkiye'de 31 il için yapay sinir ağları ve regresyon analizi ile PM10 miktarı tahminlemesinde bulunmuş ve sonuçları karşılaştırmışlardır. Yapay sinir ağlarının regresyon analizine oranla daha iyi tahminlemede bulunduğu ve hata oranının daha düşük olduğu sonucuna ulaşılmıştır.

Norouzian ve ark. (2021), İran'ın Varamir şehrinde bir süt ineği çiftliğinde yapay sinir ağları ve çoklu regresyon analizinden yararlanarak 123 süt ineği için hareket skoru tahminlemesinde bulunarak sonuçları karşılaştırmışlardır. Hareket skorunun tahmininde yapay sinir ağları çoklu regresyon analizine oranla daha düşük hata ile daha doğru sonuçlar ortaya koymuştur.

Yıldız ve Özgüven (2022), yaptıkları çalışmada Tokat ilinde bir süt sığırcılığı işletmesinde hayvanların hareketlilik ve iklim parametrelerinden yola çıkarak yapay sinir ağları ile hayvanlar için kızgınlık tahminlemesi yapmışlardır. Yapay sinir ağları için en uygun girdileri ve model topolojisini belirledikten sonra tahminleme sonucunda tahminleme %99'un üzerinde doğruluk ile gerçekleştirilmiştir.

3. MATERYAL ve YÖNTEM

3.1 Çalışma Alanı

Bu çalışma, Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezinde bulunan toplam 5000 hayvan kapasitesine sahip yumurta tavukçuluğu kümesinde gerçekleştirilmiştir. Çalışma da incelenen yumurta tavuğu kümesinden bir yıl boyunca kaynaklanan amonyak emisyon miktarının farklı girdi parametreleri kullanılarak yapay sinir ağları ile tahminlenmesi amaçlanmaktadır. Çalışmada yapay sinir ağları tahminlemeleri MATLAB 2020a programında gerçekleştirilmiştir.



Şekil 3.1. Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezi Tavuk İşletmesi (Google Maps, Erişim Haziran 2023)

Çalışmada 01.03.2021 ile 01.03.2022 tarihleri arasındaki bir yıllık süreçte incelenen kümeden kaynaklanan amonyak emisyonu (g/g.kümes) hesaplanması için, amonyak konsantrasyonu (ppm), sıcaklık (°C), hava hızı (m/s), bağıl nem (%) ve havalandırma (m³/h) ölçümleri gerçekleştirilmiş ve hayvan sayıları (adet) takip edilmiştir. Çizelge 3.1’de girdi ve çıktı parametresi olarak kullanılan parametreler verilmiştir. İşletmede gerçekleştirilen çalışma da amonyak konsantrasyonunun ölçümü için MultiRAE çoklu gaz ölçer cihazı ve diğer parametrelerin ölçümü için ise Testo 435 cihazı kullanılmıştır. Ölçümlerde kullanılan cihazlar Şekil 3.2’de verilmiştir.



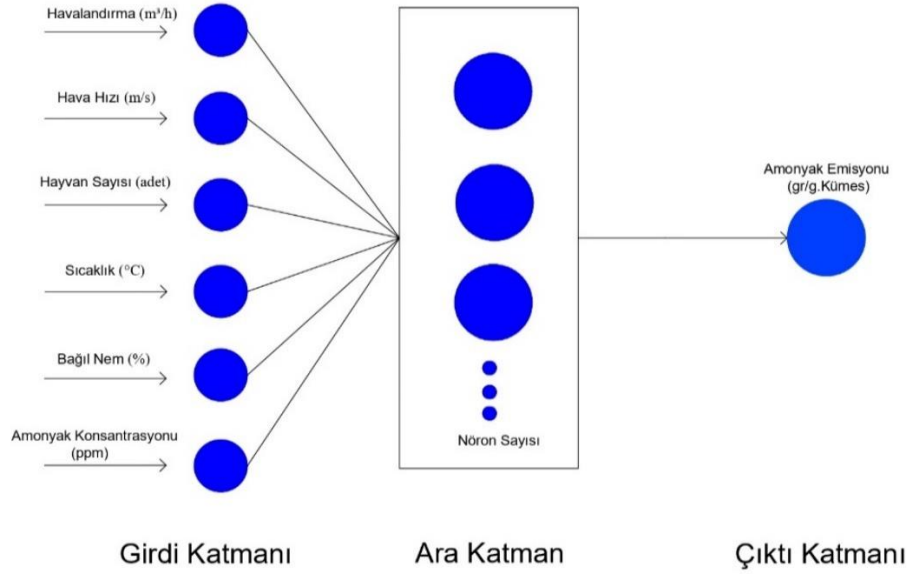
Şekil 3.2. Testo 435 ve MultiRAE çoklu gaz ölçer

3.3 Sinir Ağının Oluşturulması


Çalışmada mevsimlere göre veri setleri oluşturulmuştur. Buna göre İlkbahar veri setinde 12648 adet, Yaz veri setinde 12673, Sonbahar veri setinde 12511, Kış veri setinde 10155 ve toplam bir yıllık bütün verilerden oluşan veri setinde 47987 adet veri girdi parametresi bulunmaktadır. Sinir ağının yapısını oluştururken 6 adet girdi parametresi, 1 adet ara katman ve 1 adet çıktı parametresi sabit değerler olarak seçilerek kullanılmıştır. Ara katmanda bulunan nöron sayısı ise 5 ila 50 arasında 10 farklı nöron sayısında ayrı ayrı tahminleme işlemi gerçekleştirilmiş ve nöron sayısına göre sinir ağlarının performansları karşılaştırılmıştır. Şekil 3.3 ve 3.4’de tahminlemede kullanılan yapay sinir ağının yapısı ve nöron sayıları verilmiştir.

Çizelge 3.1. Yapay sinir ağlarında eğitilen girdi ve çıktı parametreleri

Kodlar	Giriş Parametreleri	Birim
X1	Havalandırma	(m ³ /h)
X2	Hava Hızı	(m/s)
X3	Hayvan sayısı	(adet)
X4	Sıcaklık	(°C)
X5	Bağıl Nem	(%)
X6	Amonyak Konsantrasyonu	ppm
Kodlar	Çıkış Parametresi	Birim
Y1	Amonyak Emisyonu	(g/g.Kümes)




Şekil 3.3. Çalışmada kullanılan yapay sinir ağı yapısı



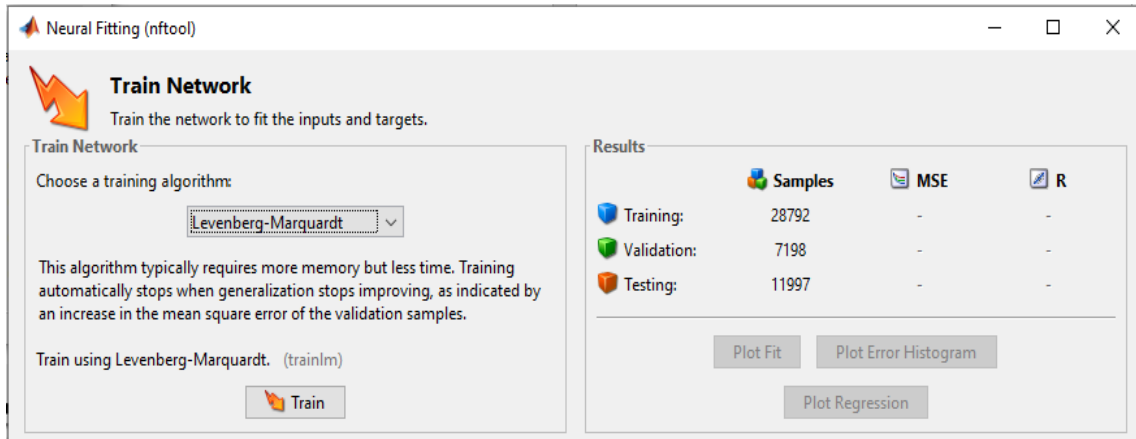
Şekil 3.4. Çalışmada karşılaştırmaları gerçekleştirilen nöron sayıları

Yapay sinir ağında tahminleme gerçekleştirirken toplam veri grubundan ağın öğrenmesini sağlamak amacıyla eğitim verileri, ağın ezberlemesinin önüne geçmek adına doğrulama verileri ve eğitimin ardından ağın performansını görmek amacıyla test verileri kullanılmaktadır. Tahminleme çalışmalarında genellikle eğitim veri seti için %60 ile %70, doğrulama veri seti için %15 ile %20 ve test veri seti için %20 ile %25 arasında veri dağılımı gerçekleştiği zaman daha başarılı sonuçlar elde edildiği görülmüştür (Altınkum, 2013). Çalışmada amonyak emisyonunu tahminleme amacıyla tüm verilerin %60'i eğitim seti, %15'i doğrulama seti ve %25'de test seti olarak kullanılmıştır. Şekil 3.4 ' de tahminlemede kullanılan veri setlerinin dağılım yüzdesi verilmiştir.



Şekil 3.5. Çalışmada kullanılan eğitim, doğrulama ve test veri setleri yüzdeleri

Sinir ağının yapısında aktivasyon fonksiyonu olarak sigmoid fonksiyonu kullanılmış ve 5 farklı şekilde kategorize edilen veri grupları için Levenberg Marquardt (trainlm), Kümelerin Adaptifli Momemtumlu Yokuş İnmesi (traingdx), Fletcher-Reeves Güncelleme Algoritması (traincgf), Kademeli Çekim Algoritması (trainscg) olmak üzere 4 farklı ileri beslemeli geri yayılım eğitim algoritması ile tahminlemeler gerçekleştirilmiştir (Küçükönder, 2011). Maksimum iterasyon sayısı 1000 olarak alınmıştır. Ancak sinir ağı minimum hata miktarına ulaştığı zaman durmuştur. Sinir ağı her eğitim için 10'ar tekrar şeklinde çalıştırılmış ve en iyi performansı gösteren ağ kayıt altına alınmıştır. Şekil 3.5' de çalışmadan kullanılan eğitim modellerinin seçim ekranı verilmiştir.



Şekil 3.6. Çalışmada kullanılan eğitim algoritmaları seçim bölümü

Sinir ağlarında tahminleme için kullanılan verilerinin aralarında yüksek farklar olması, birimlerin farklı olması gibi nedenlerden dolayı ağın performansında düşüşler yaşanabilmektedir. Bu durumun önüne geçebilmek için çalışmada kullanılacak veri grubuna maksimum-minimum normalizasyon işlemi uygulanarak girdi ve çıktı parametresi olarak kullanılan bütün veriler 0 ile 1 değerleri arasında normalleştirilerek kullanılmıştır.

4. BULGULAR ve TARTIŞMA

4.1 Verilerin Tanıtılması

Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezinde bulunan 5000 hayvan kapasitesine sahip yumurta tavuğu kümesinde 1 Mart 2021 tarihi ile 1 Mart 2022 tarihleri arasındaki bir yıllık süreçte gerçekleştirilen ölçümler neticesinde sıcaklık (°C), bağıl nem (%), hava hızı (m/s), havalandırma (m³/h), hayvan sayısı (adet), amonyak konsantrasyonu (ppm) ve amonyak emisyonu (g/g.kümes) parametrelerinde her bir parametre için toplam 47987 adet veri toplanmıştır. Çizelge 4.1’ de tüm yılı kapsayan veri setleri için tanımlayıcı istatistik değerleri verilmiştir.

Çizelge 4.1. Tüm yıllık kapsayan verilerinin tanımlayıcı istatistik değerleri

	Parametreler	Birim	Min	Maks	Std. Sapma	Ort.
Girdiler	Havalandırma	(m ³ /h)	7,2	2044,5	106,3357	113,253
	Hava Hızı	(m/s)	0	0,72	0,0377	0,0400
	Hayvan sayısı	(adet)	3290	4053	295,5504	3640
	Sıcaklık	(°C)	11,3	34,1	4,11236	21,2376
	Bağıl Nem	(%)	28,1	80,2	7,6912	58,4336
	Amonyak Konsantrasyonu	ppm	0,241	9,875	1,0731	2,0650
	Çıktılar	Amonyak Emisyonu	(g/g.kümes)	307,33	1645,68	433,625

Yapay sinir ağları kullanılarak bir yumurta kümesinden gerçekleşen amonyak emisyonunun tahminleme performansın mevsimsel olarak karşılaştırmak amacıyla veriler İlkbahar, Yaz, Sonbahar, Kış ve bütün yıl olmak üzere beş farklı şekilde kategorize edilmiş ve her bir kategori için ayrı ayrı olacak şekilde yapay sinir ağları ile amonyak emisyonunun tahminlemesi gerçekleştirilmiştir. Çizelge 4.2 ila 4.5 arasında mevsimsel veri setleri için tanımlayıcı istatistik değerleri verilmiştir.

Çizelge 4.2. İlkbahar mevsimi verilerinin tanımlayıcı istatistik değerleri

	Parametreler	Birim	Min.	Maks.	Std. Sapma	Ort.
Girdiler	Havalandırma	(m ³ /h)	31,42	1067,5	52,797	98,033
	Hava Hızı	(m/s)	0,01	0,38	0,019	0,035
	Hayvan sayısı	(adet)	3300	4053	329,312	3779,87
	Sıcaklık	(°C)	12,5	28,3	2,994	19,018
	Bağıl Nem	(%)	31,1	74,1	6,347	57,308
	Amonyak Konsantrasyonu	ppm	0,482	6,021	0,998	2,288
Çıktılar	Amonyak Emisyonu	(g/g.kümes)	307,3	525,96	73,875	400,660

Çizelge 4.3. Yaz mevsimi verilerinin tanımlayıcı istatistik değerleri

	Parametreler	Birim	Min.	Maks.	Std. Sapma	Ort.
Girdiler	Havalandırma	(m ³ /h)	7,2	2044,5	157,358	187,099
	Hava Hızı	(m/s)	0	0,72	0,056	0,066
	Hayvan sayısı	(adet)	3833	3980	60,590	3917,50
	Sıcaklık	(°C)	17,7	34,1	3,280	25,756
	Bağıl Nem	(%)	28,1	80,2	10,353	57,892
	Amonyak Konsantrasyonu	ppm	0,241	5,058	0,504	1,246
Çıktılar	Amonyak Emisyonu	(g/g.kümes)	368,7	380,20	3,948	375,727

Çizelge 4.4. Sonbahar mevsimi verilerinin tanımlayıcı istatistik değerleri


	Parametreler	Birim	Min.	Maks.	Std. Sapma	Ort.
Girdiler	Havalandırma	(m ³ /h)	11,5	1435	74,488	71,995
	Hava Hızı	(m/s)	0	0,51	0,026	0,025
	Hayvan sayısı	(adet)	3400	3600	82,098	3500
	Sıcaklık	(°C)	14	32,1	2,685	21,365
	Bağıl Nem	(%)	33,5	73	6,781	57,859
	Amonyak Konsantrasyonu	ppm	0,482	4,817	0,702	1,673
	Çıktılar	Amonyak Emisyonu	(g/g.kümes)	823,816	1220,951	111,673

Çizelge 4.5. Kış mevsimi verilerinin tanımlayıcı istatistik değerleri

	Parametreler	Birim	Min.	Maks.	Std. Sapma	Ort.
Girdiler	Havalandırma	(m ³ /h)	21,6	1113,4	50,332	90,885
	Hava Hızı	(m/s)	0,01	0,39	0,018	0,032
	Hayvan sayısı	(adet)	3290	3300	4,970	3294,45
	Sıcaklık	(°C)	11,3	23,6	2,373	18,208
	Bağıl Nem	(%)	36,7	78,7	5,371	61,220
	Amonyak Konsantrasyonu	ppm	0,723	9,875	0,828	3,292
	Çıktılar	Amonyak Emisyonu	(g/g.kümes)	1191,7	1645,68	134,427


4.2 Levenberg Marquardt Geri Yayılım Eğitim Algoritması ile Yapılan Tahminlemeler

Levenberg Marquardt eğitim algoritması kullanılarak 5 ile 50 arasında değişen 10 farklı nöron sayısında 5 veri seti için tahminlemeler gerçekleştirilmiştir. Tahminlemeler sonucunda en iyi performansa, eğitim regresyon katsayısı (0,99326), doğrulama regresyon katsayısı (0,99107) ve test regresyon katsayısı (0,99038) olmak üzere kış mevsimi sahiptir. Bir yıllık bütün verilerden oluşan veri seti ile yapılan tahminleme ise (0,98722) eğitim regresyon katsayısı, (0,98551) doğrulama regresyon katsayısı ve (0,98731) test regresyon katsayısı ile mevsimsel tahminlemelere oranla daha kötü bir performansı göstermiştir ancak 5 veri kümesi içinde başarılı performansı yüksek tahminler gerçekleştirildiği söylenebilir. Tahminleri gerçekleştirilen mevsimsel ve yıllık verilerin regresyon grafikleri Şekil 4.1 ila 4.3 arasında verilmiştir.




Şekil 4.1. Tüm yılı kapsayan veri setinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

a) İlkbahar Mevsimi

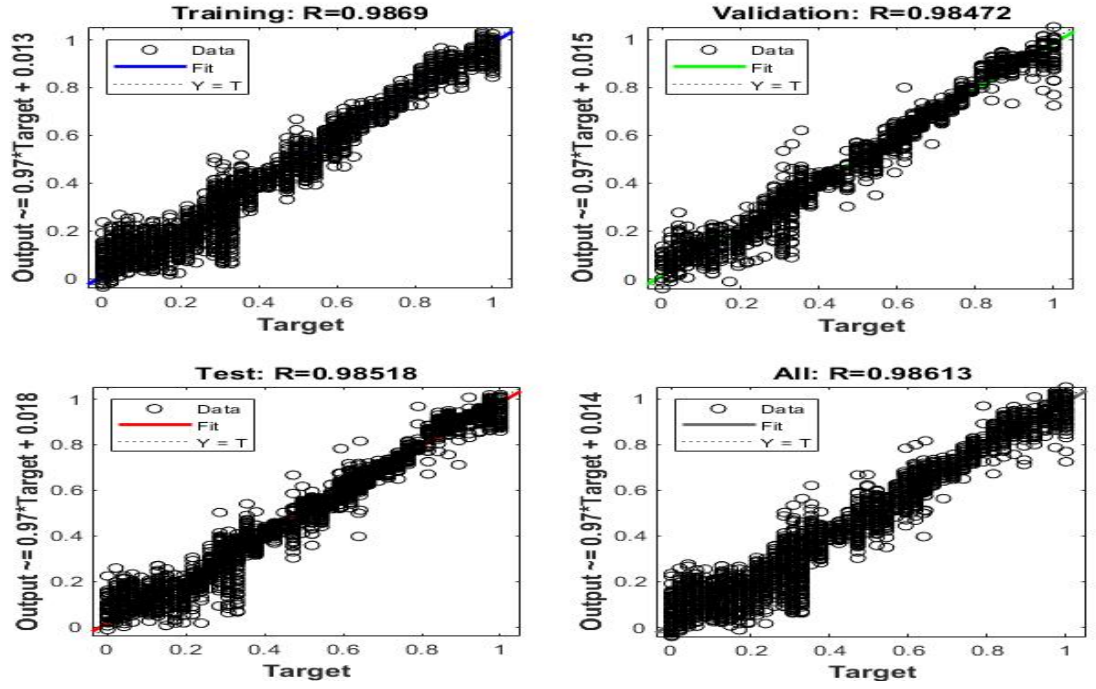


b) Yaz Mevsimi




Şekil 4.2. İlkbahar ve Yaz mevsimi verilerinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

a) Sonbahar Mevsimi




b) Kış Mevsimi



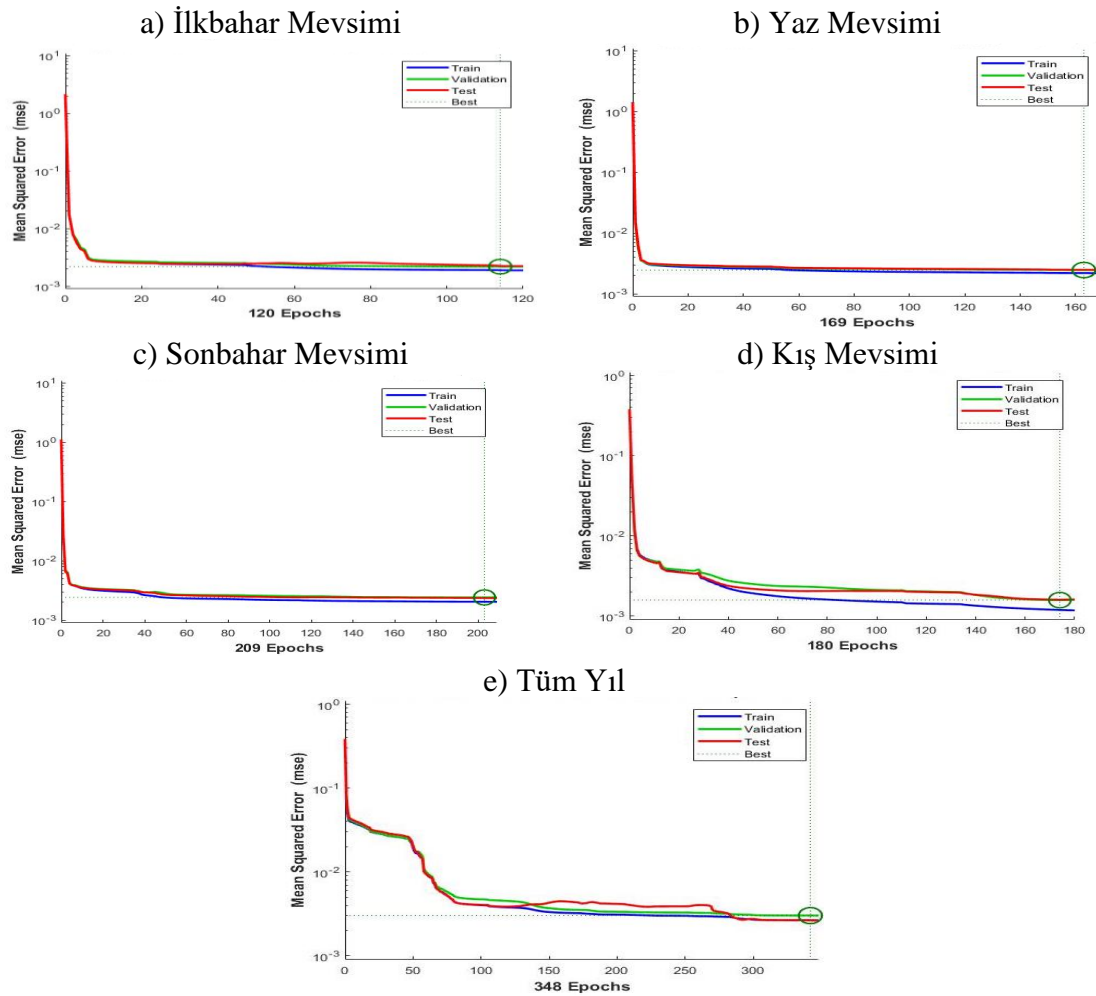
Şekil 4.3. Sonbahar ve Kış mevsimi verilerinde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

Şekil 4.4'te gerçekleştirilen tahminlemelerin hata histogramı verilmiştir. Grafikte yatay eksen gerçek değerler ile tahmin edilen değerler arasındaki farkı dikey eksen ise veri sayılarını ifade etmektedir. Grafikte sarı çizgi sıfır hata çizgisidir ve elde edilmiş olan değerler sıfır hata çizgisine ne kadar yakın olursa o kadar başarılı bir tahminleme gerçekleştirilmiş demektir. Tahminleme gerçekleştirilen yıllık ve mevsimsel verilerin hepsi sıfır hata çizgisine yakın yani düşük hata oranına sahiptir.



Şekil 4.4. Tüm yılı kapsayan ve mevsimsel verilerde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin hata histogramları


Performans grafiklerinde eğitim, doğrulama ve test veri setleri için hata eğrileri verilmektedir. Bu grafiklerde doğrulama ve test veri setlerini ifade eden hata eğrilerinin birbirlerine oranla ters hareket etmesi tahminleme performansının düşük olduğu anlamına gelmektedir (Kurtulmuş ve ark, 2020). Levenberg ve Marquardt eğitim algoritması ile gerçekleştirilen tahminlemelerde tüm veri setlerinde doğrulama ve test hata eğrilerinin benzer performans gösterdiği bu nedenle tahminlemelerin başarılı bir şekilde gerçekleştirildiği söylenebilir. Gerçekleştirilen tahminlemeler en düşük doğrulama hata miktarına ulaşıncaya tamamlanmıştır. Yaz ayında tahminleme işlemi 120. iterasyonda doğrulama için minimum hata değerine ulaşarak tamamlanmıştır. En yüksek iterasyon ise 348 ile yıllık verilerin tahminlemesinde görülmüştür. Şekil 4.5’ te gerçekleştirilen tahminlemeler için performans grafikleri verilmiştir.



Şekil 4.5. Yıllık ve Mevsimsel verilerde Levenberg Marquardt eğitim algoritması ile yapılan tahminlemenin performans grafikleri


4.2.1 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması

Mevsimsel ve yıllık verilerin Levenberg Marquardt eğitim algoritması ile gerçekleştirilen tahminler ile gerçek değerlerin karşılaştırılması Şekil 4.6 ve 4.7’de gösterilmiştir. Grafikte mavi değerler sinir ağının tahmin değerlerini turuncu değerler ise gerçek değerleri göstermektedir. Yıllık verilerin tahmin ve gerçek değerlerinin karşılaştırılmalarına bakınca sinir ağının genel tahmin performansının iyi olmasına rağmen ilk baştaki ve son kısımda ki verilerde sapmalar ortaya çıkmıştır. Mevsimsel tahminlemelerde gerçek değerler ve tahmin değerleri birbirlerine yakın ve benzer oranda seyretmektedir. Yıllık tahminlemeye oranla sapmaların daha az olduğu ortaya çıkmıştır.




Şekil 4.6. Levenberg Marquardt eğitim algoritması ile tüm yılı kapsayan veri setinin tahminleri ile gerçek değerlerin karşılaştırılması

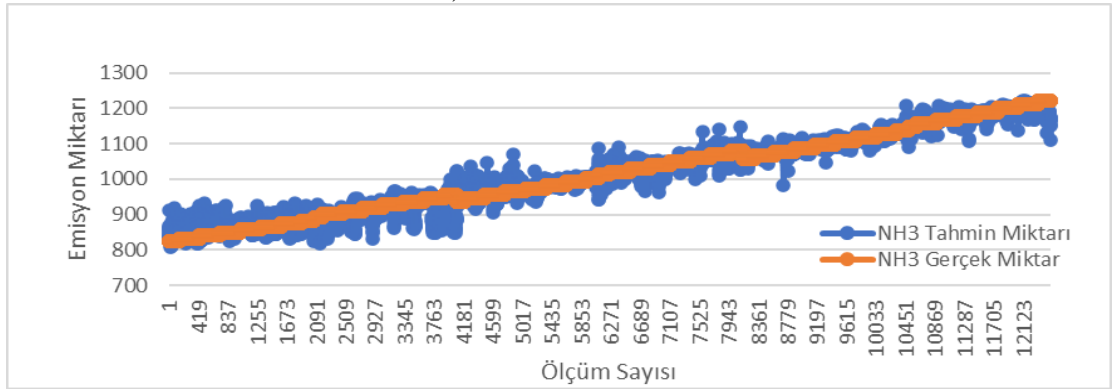
a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi



d) Kış Mevsimi



Şekil 4.7. Levenberg Marquardt eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması

4.2.1.1 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması

Yapay sinir ağları ile yıllık ve mevsimsel verilerin tahminlemesini gerçekleştirirken nöron sayısına göre tahminleme performanslarının karşılaştırılması yapılmıştır. Tahminleme aşamasında 5, 10, 15, 20, 25, 30, 35, 40, 45 ve 50 nöron sayıları için tahminlemeler gerçekleştirilmiş, ortalama hataların karesi (MSE), ortalama hatalar karesinin karekökü (RMSE), ortalama hata mutlak değeri (MAE), ortalama mutlak yüzde hata (MAPE) ve R^2 skoru (belirlilik katsayısı) hesaplanarak sonuçlar karşılaştırılmıştır. Çalışmada tahminleme gerçekleştirirken her bir nöron sayısı için tahminleme 10 ar kez tekrarlanmış en iyi performansı gösteren sonuçlar kayıt altına alınmıştır. Levenberg marquardt eğitim algoritması, tüm veri setleri için yapılan tahminlemelerde %10'dan düşük ortalama mutlak yüzde hata ile “çok iyi” performans göstermiştir Tüm yıllık verilerin tahminlenmesinde en iyi sonuç 20 ve 40 nöron sayısında görülmüştür (Aslay ve Özen, 2013; Lewis, 1982). İki nöron sayısında da ağıın genel ve eğitim performansları benzer sonuçlar gösterirken 20 nöron sayısında test eğitim seti, 40 nöron sayısında ise doğrulama eğitim seti daha iyi performansa sahiptir. İlkbahar, Yaz, Sonbahar mevsimlerine ait karşılaştırmalarda sırasıyla en iyi performansa sahip nöron sayısı 50, 40 ve 30 olmuştur ancak 3 mevsim içinde özellikle 20 ile 50 nöron sayısında ağların benzer performansa sahip olduğu söylenebilir. Çizelge 4.6 ila 4.10 arasında gerçekleştirilen tahminlerin nöron sayılarına göre hata oranları verilmiştir.

Çizelge 4.6. Levenberg Marquardt modeli ile tahminlemesi yapılan tüm yıllık kapsayan verilerin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,942	0,0063	0,079	0,048	0,105	0,0063	0,080	0,049	0,11	0,0055	0,074	0,048	0,104
10	0,954	0,0048	0,069	0,033	0,073	0,0054	0,074	0,034	0,08	0,0047	0,069	0,033	0,073
15	0,962	0,0039	0,062	0,031	0,072	0,0043	0,065	0,031	0,07	0,0040	0,063	0,030	0,070
20	0,974	0,0027	0,052	0,023	0,053	0,0030	0,055	0,024	0,06	0,0027	0,051	0,024	0,055
25	0,963	0,0038	0,061	0,030	0,072	0,0041	0,064	0,031	0,07	0,0041	0,064	0,031	0,076
30	0,958	0,0044	0,066	0,035	0,078	0,0044	0,066	0,034	0,08	0,0046	0,068	0,036	0,077
35	0,963	0,0036	0,060	0,030	0,071	0,0045	0,067	0,031	0,07	0,0041	0,064	0,030	0,071
40	0,973	0,0027	0,052	0,025	0,059	0,0026	0,051	0,025	0,06	0,0031	0,055	0,026	0,061
45	0,971	0,0028	0,053	0,027	0,060	0,0037	0,061	0,028	0,06	0,0032	0,056	0,028	0,063
50	0,967	0,0032	0,056	0,028	0,066	0,0036	0,060	0,030	0,07	0,0040	0,063	0,030	0,072

Çizelge 4.7. Levenberg Marquardt modeli ile tahminlemesi yapılan İlkbahar mevsiminin nöron sayılarına göre hata miktarları

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,969	0,0031	0,056	0,041	0,019	0,0031	0,056	0,040	0,025	0,0033	0,057	0,041	0,019
10	0,973	0,0029	0,054	0,039	0,016	0,0028	0,053	0,039	0,016	0,0031	0,056	0,040	0,016
15	0,974	0,0029	0,054	0,039	0,017	0,0030	0,055	0,040	0,018	0,0032	0,057	0,044	0,018
20	0,975	0,0023	0,048	0,035	0,016	0,0025	0,050	0,036	0,017	0,0025	0,050	0,036	0,016
25	0,976	0,0024	0,049	0,035	0,016	0,003	0,050	0,036	0,016	0,0024	0,049	0,035	0,016
30	0,977	0,0024	0,049	0,035	0,014	0,002	0,047	0,033	0,015	0,0028	0,053	0,039	0,017
35	0,978	0,0023	0,048	0,035	0,015	0,002	0,048	0,033	0,016	0,0024	0,049	0,034	0,015
40	0,977	0,0023	0,048	0,035	0,019	0,003	0,050	0,035	0,016	0,0022	0,047	0,032	0,016
45	0,975	0,0024	0,049	0,035	0,015	0,002	0,049	0,034	0,144	0,0026	0,051	0,039	0,015
50	0,979	0,0022	0,047	0,032	0,015	0,002	0,047	0,033	0,016	0,0024	0,049	0,035	0,017

Çizelge 4.8. Levenberg Marquardt modeli ile tahminlemesi yapılan Yaz mevsiminin nöron sayılarına göre hata miktarları

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9726	0,0032	0,057	0,03850	0,0012	0,0033	0,0575	0,03909	0,0012	0,0034	0,0583	0,04013	0,0012
10	0,9764	0,0028	0,053	0,03643	0,0011	0,0028	0,0525	0,03624	0,0011	0,0028	0,0531	0,03639	0,0011
15	0,9775	0,0027	0,052	0,03552	0,0011	0,0025	0,0503	0,03493	0,0011	0,0028	0,0531	0,03683	0,0011
20	0,9784	0,0025	0,050	0,03341	0,0010	0,0026	0,0509	0,03387	0,0010	0,0028	0,0526	0,03549	0,0011
25	0,9801	0,0023	0,048	0,03193	0,0009	0,0026	0,0513	0,03423	0,0011	0,0025	0,0500	0,03354	0,0010
30	0,9795	0,0024	0,049	0,03266	0,0010	0,0025	0,0504	0,03456	0,0011	0,0026	0,0506	0,03393	0,0010
35	0,9793	0,0024	0,049	0,03283	0,0010	0,0025	0,0505	0,03411	0,0010	0,0026	0,0513	0,03389	0,0010
40	0,9806	0,0022	0,047	0,03107	0,0009	0,0025	0,0496	0,03226	0,0009	0,0025	0,0499	0,03283	0,0010
45	0,9802	0,0023	0,048	0,03157	0,0009	0,0027	0,0517	0,03408	0,0010	0,0024	0,0486	0,03273	0,0010
50	0,9806	0,0022	0,047	0,03075	0,0009	0,0026	0,0506	0,03296	0,0010	0,0024	0,0493	0,03287	0,0010


Çizelge 4.9. Levenberg Marquardt modeli ile tahminlemesi yapılan Sonbahar mevsiminin nöron sayılarına göre hata miktarları

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9552	0,0035	0,0593	0,04484	0,0182	0,0036	0,0601	0,04514	0,0184	0,0036	0,0596	0,04470	0,0182
10	0,9666	0,0026	0,0508	0,03629	0,0149	0,0029	0,0542	0,03788	0,0155	0,0026	0,0511	0,03613	0,0148
15	0,9677	0,0024	0,0495	0,03565	0,0146	0,0027	0,0515	0,03603	0,0147	0,0027	0,0524	0,03709	0,0151
20	0,9696	0,0023	0,0475	0,03405	0,0139	0,0026	0,0510	0,03563	0,0146	0,0026	0,0512	0,03605	0,0148
25	0,9696	0,0011	0,0330	0,01473	0,0134	0,0024	0,0488	0,03372	0,0138	0,0026	0,0511	0,03534	0,0145
30	0,9725	0,0020	0,0451	0,03148	0,0129	0,0024	0,0491	0,03383	0,0138	0,0024	0,0485	0,03323	0,0136
35	0,9720	0,0021	0,0455	0,03169	0,0129	0,0021	0,0453	0,03140	0,0128	0,0027	0,0515	0,03439	0,0142
40	0,9699	0,0023	0,0480	0,03364	0,0138	0,0024	0,0493	0,03478	0,0142	0,0025	0,0504	0,03523	0,0143
45	0,9709	0,0022	0,0468	0,03250	0,0133	0,0025	0,0497	0,03472	0,0143	0,0025	0,0496	0,03341	0,0137
50	0,9711	0,0021	0,0463	0,03212	0,0132	0,0023	0,0477	0,03291	0,0134	0,0026	0,0511	0,03401	0,0139

Çizelge 4.10. Levenberg Marquardt modeli ile tahminlemesi yapılan Kış mevsiminin nöron sayılarına göre hata miktarları

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9773	0,0019	0,0434	0,02860	0,0090	0,0021	0,0460	0,02855	0,0090	0,0022	0,0468	0,02908	0,0092
10	0,982	0,0015	0,0386	0,02529	0,0080	0,0017	0,0409	0,02484	0,0079	0,0017	0,0416	0,02558	0,0081
15	0,9822	0,0016	0,0397	0,02549	0,0081	0,0015	0,0391	0,02609	0,0083	0,0016	0,0394	0,02575	0,0081
20	0,9777	0,0019	0,0431	0,02859	0,0091	0,0021	0,0453	0,02967	0,0093	0,0021	0,0462	0,02903	0,0093
25	0,9788	0,0017	0,0408	0,02729	0,0087	0,0022	0,0469	0,02975	0,0095	0,0021	0,0460	0,02883	0,0092
30	0,9828	0,0014	0,0376	0,02382	0,0075	0,0016	0,0403	0,02508	0,0079	0,0017	0,0407	0,02513	0,0080
35	0,9810	0,0014	0,0370	0,02358	0,0074	0,0020	0,0442	0,02457	0,0078	0,0022	0,0470	0,02621	0,0083
40	0,9803	0,0016	0,0394	0,02574	0,0082	0,0019	0,0438	0,02707	0,0086	0,0020	0,0450	0,02713	0,0086
45	0,9846	0,0012	0,0346	0,02186	0,0069	0,0016	0,0396	0,02446	0,0077	0,0016	0,0400	0,02313	0,0073
50	0,9781	0,0018	0,0425	0,02807	0,0089	0,0020	0,0450	0,02910	0,0093	0,0021	0,0461	0,02961	0,0094

Yıllık ve her bir mevsim için en iyi performansı gösteren nöron sayısı farklı çıkmıştır. Levenberg Marquardt eğitim algoritması ile gerçekleştirilen tahminlemeler için en iyi sonucu veren nöron sayısını söylemek mümkün değildir. Ancak 5 nöron sayısı ile yapılan tahminlemelerin sonuçları bütün veri gruplarında en kötü performansı göstermiştir. Şekil 4.8’ de farklı nöron sayılarında elde edilen ortalama karesel hata miktarları verilmiştir.



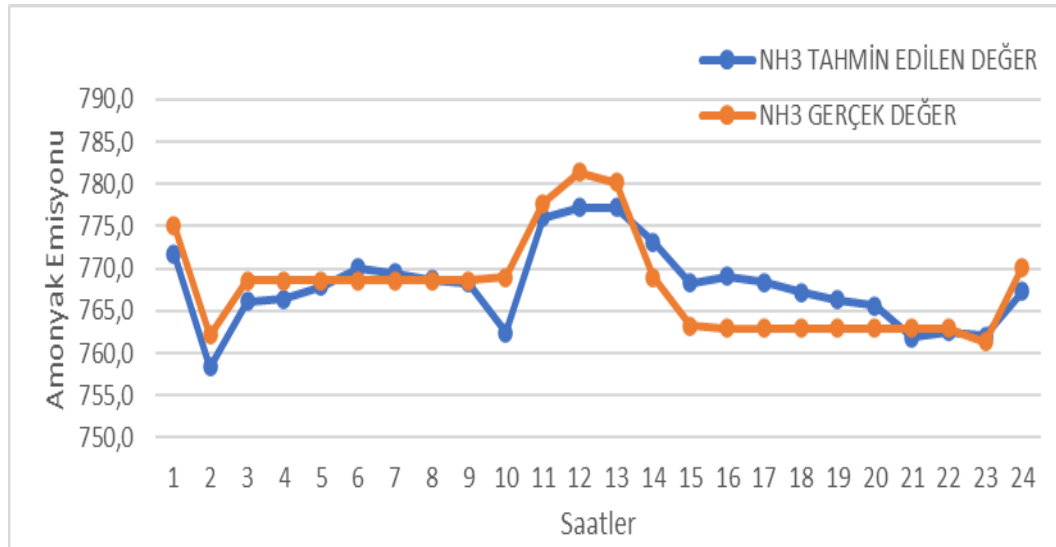
Şekil 4.8. Levenberg Marquardt eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarlar

4.2.1.2 Levenberg Marquardt Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik Olarak Karşılaştırılması

Çalışmanın gerçekleştirildiği kümeşte oluşan gerçek amonyak emisyon miktarı ile yapay sinir ağlarında Levenberg Marquardt eğitim algoritması ile tahmin edilen emisyon miktarlarının saatlik olarak ortalamaları karşılaştırılmıştır. Tüm yıl boyunca ölçülen verilerin saatlik ortalamaları karşılaştırılınca genel performans iyi olsa da ortalama olarak saatlik karşılaştırmalarda gerçek değerlere oranla artı ya da eksi olarak günlük 2-3 gramlık sapmalar söz konusudur.


Mevsimsel olarak yapılan karşılaştırmalarda da yıllık verilerde olduğu gibi saatlik ortalamalarda başarılı ve birbirlerine yakın sonuçlar elde edilmiştir. İlkbahar, Sonbahar ve Kış aylarında gerçek ortalamalara yakın günlük ortalama 1-2 gramlık sapmalar bazı saatlerde söz konusudur. Yaz ayında ise ölçüm yapılan üç aylık süreçte gerçek amonyak emisyonu çok fazla değişkenlik göstermediği için saatlik ortalamalarda tahmin edilen ve gerçek değerler de birbirlerine daha yakın sonuçlar elde edilmiştir.

Yıllık ve mevsimsel veriler için gerçekleştirilen saatlik ortalama tahminlerinin grafikleri Şekil 4.9 ve 4.10 da gösterilmiştir. Grafikte yatay sütun günlük saatleri, dikey sütun ise amonyak emisyonunun(g/g.kümes) ifade etmektedir.




Şekil 4.9. Levenberg Marquardt eğitim algoritması ile tahminlemeleri yapılan tüm yılı kapsayan verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi




d) Kış Mevsimi



Şekil 4.10. Levenberg Marquardt eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


4.3 Fletcher-Reeves Güncelleme Geri Yayılım Eğitim Algoritması ile Yapılan Tahminlemeler

Fletcher-Reeves Güncelleme Eğitim Algoritması (traincgf) ile tüm yılı kapsayan, İlkbahar, Sonbahar, Yaz ve Kış mevsimleri olmak üzere 5 veri seti için amonyak emisyonu tahminlemesi gerçekleştirilmiştir. Regresyon grafiklerinde x eksenini gerçek çıktı değerleri y eksenini ise gerçekleştirilen tahminlemenin çıktı değerlerini ifade etmektedir. Tahminlemenin daha iyi bir performans göstermesi amacıyla gerçekleştirilen normalizasyon işleminden dolayı grafikte çıktılar 0 ile 1 arasındaki değerler ile gösterilmiştir. Tahminlemeler içerisinde İlkbahar, Yaz, Sonbahar ve Kış eğitim setleri benzer ve yüksek tahminleme performansına sahip olmak ile birlikte en iyi performansı 0,9865 genel regresyon katsayısı ile Yaz mevsimi göstermiştir. Tüm yılı kapsayan veri seti ise mevsimsel tahminlemelere oranla 0,93253 regresyon katsayısı ile daha kötü bir tahminleme gerçekleştirmiştir. Veri gruplarına ait regresyon grafikleri Şekil 4.11 ila 4.13 arasında verilmiştir.




Şekil 4.11. Tüm yıllı kapsayan verilerin Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

a) İlkbahar Mevsimi




b) Yaz Mevsimi




Şekil 4.12. İlkbahar ve Yaz mevsimi verilerinde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikler

a) Sonbahar Mevsimi




b) Kış Mevsimi




Şekil 4.13. Sonbahar ve Kış mevsimi verilerinde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

İlkbahar, Sonbahar ve Kış mevsimlerinin tahminlemelerine ait hata histogramlarında sütunların dağılımı çoğu grafikte sıfır hata çizgisine yakın ve hata miktarları ise düşüktür. Tüm yılı kapsayan verilerin veri aralığı geniş ve tahmin performansı daha düşük olduğundan dolayı sütunların dağılımı az da olsa hata miktarları yüksek seviyededir. Yaz ayında ise bu durum tüm yılı kapsayan tahminlemelere kıyasla tam tersi olarak toplam veri aralığının çok dar olmasından dolayı hata yayılımları çok fazla sütundan oluşmasına rağmen hata miktarları düşük seviyededir. Tüm yılı kapsayan ve mevsimsel veri setlerine ait hata histogramları Şekil 4.14 de verilmiştir.



Şekil 4.14. Tüm yılı kapsayan ve Mevsimsel verilerde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin hata histogramları


Gerçekleştirilen bütün tahminlemelerde eğitim, doğrulama ve test işlemleri benzer seyir göstermiştir. Doğrulama ve test hata eğrilerinin benzer seyretmesi nedeniyle tahminlerde aşırı öğrenme durumunun gerçekleşmediği sonucuna ulaşılmıştır. Tüm verileri kapsayan tahminleme dışında bütün veri setlerinde doğrulama performansı daha düşük iterasyonlarda minimum hata değerine ulaşarak tahminleme tamamlanmıştır. Ancak tüm verileri kapsayan veri setinde iterasyon sayısı maksimum değer olarak kullandığımız 1000'e ulaşıncaya kadar tamamlanmıştır. Tahminlemelere ait performans grafikleri Şekil 4.15' de verilmiştir.



Şekil 4.15. Tüm yılı kapsayan ve mevsimsel verilerde Fletcher-Reeves Güncelleme eğitim algoritması ile yapılan tahminlemenin performans grafikleri


4.3.1 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması

Tüm yılı kapsayan verilerin tahmin değerleri ile gerçek değerler karşılaştırılınca genel performansın iyi olmasına rağmen veri setinin başındaki ve sonundaki değerlerin tahminlemesinde sapmalar yaşandığı görülmüştür. Mevsimsel verilerin tahminlenmesinde ise sinir ağının iyi performansı ile doğru orantılı olarak sapmalar çok daha nadir ve düşük düzeydedir. Tahminlemelere ait karşılaştırma grafikleri Şekil 4.16 ve 4.17’de verilmiştir.




Şekil 4.16. Fletcher-Reeves Güncelleme eğitim algoritması ile tüm yılı kapsayan verilerin tahminleri ile gerçek değerlerin karşılaştırılması


a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi



d) Kış Mevsimi



Şekil 4.17. Fletcher-Reeves Güncelleme eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması

4.3.1.1 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması

Bütün veri grupları için yapay sinir ağları ile 10 farklı nöron sayısında tahminlemeler gerçekleştirilip, elde edilen sonuçların eğitim, doğrulama ve test veri setleri için hata oranları ile değerlendirilerek karşılaştırılmaları yapılmıştır. Tahminlemeler sonucunda en (0,9732) R^2 skoru ile en yüksek doğruluğa sahip olan Yaz mevsimi 45 nöron sayısında (0,0030) ortalama karesel hata miktarı ile doğrulamada en düşük hata miktarına ulaşmıştır. Eğitim ve test için ise sırasıyla (0,0032) ve (0,0033) ile çok benzer sonuç vermiştir. Veri grupları arasında en kötü tahminlemeye sahip tüm yılı kapsayan verilerden oluşan veri grubu ise en iyi performans gösterdiği 20 nöron sayısında eğitim için (0,0117), doğrulama için (0,0122) ve test için (0,0121) ortalama karesel hata ile daha kötü bir performansa sahiptir. Gerçekleştirilen tahminlemelerde mevsimsel veri setleri ortalama mutlak yüzde hatada %10'un altında "çok iyi" performans göstermiştir. Tüm yılı kapsayan veri seti ise %13,13 ile "iyi" performans göstermiştir (Aslay ve Özen, 2013; Lewis, 1982). Bütün veri gruplarında farklı nöron sayısında en iyi performanslarını gösterdiğinden dolayı hangi nöron sayısı ile daha iyi sonuç alınabileceğine dair bir genelleme yapmak söz konusu değildir. Fletcher-Reeves Eğitim algoritması ile tahminlemeleri gerçekleştirilen veri setlerinin hata oranları Çizelge 4.11 ila 4.15 arasında verilmiştir.

Çizelge 4.11. Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan tüm yıllık verilerin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,695	0,032	0,179	0,0970	0,2502	0,0320	0,1790	0,0968	0,2498	0,0321	0,1792	0,0973	0,2503
10	0,787	0,022	0,148	0,0843	0,1924	0,0233	0,1526	0,0868	0,1957	0,0237	0,1539	0,0868	0,1994
15	0,858	0,015	0,122	0,0682	0,1513	0,0146	0,1208	0,0676	0,1488	0,0155	0,1244	0,0681	0,1503
20	0,887	0,012	0,108	0,0608	0,1303	0,0122	0,1105	0,0621	0,1341	0,0121	0,1102	0,0623	0,1322
25	0,725	0,029	0,169	0,0945	0,2408	0,0281	0,1678	0,0934	0,2375	0,0295	0,1719	0,0957	0,2444
30	0,739	0,027	0,165	0,0957	0,2303	0,0283	0,1682	0,0968	0,02305	0,0275	0,1657	0,0956	0,2308
35	0,870	0,014	0,117	0,0694	0,1502	0,0133	0,1151	0,0676	0,1459	0,0138	0,1174	0,0689	0,1474
40	0,729	0,028	0,168	0,0964	0,2330	0,0302	0,1737	0,0999	0,2482	0,0281	0,1676	0,0954	0,2319
45	0,763	0,025	0,158	0,0907	0,2210	0,0254	0,1593	0,0916	0,2194	0,0244	0,1563	0,0896	0,2149
50	0,708	0,031	0,175	0,0938	0,2261	0,0278	0,1668	0,0889	0,2106	0,0319	0,1786	0,0947	0,2312

Çizelge 4.12. Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan İlkbahar mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9646	0,0053	0,0728	0,05769	0,021	0,0055	0,0742	0,05887	0,0208	0,0052	0,0721	0,05583	0,0241
10	0,9632	0,0051	0,0714	0,05597	0,0232	0,0054	0,0735	0,05837	0,0206	0,0053	0,0728	0,05789	0,0217
15	0,9612	0,0044	0,0663	0,05154	0,0241	0,0045	0,0671	0,05214	0,0237	0,004	0,0663	0,05133	0,0269
20	0,9647	0,0045	0,0671	0,05202	0,0219	0,0043	0,0656	0,05036	0,0218	0,0046	0,0678	0,05256	0,0256
25	0,9610	0,0043	0,0656	0,05014	0,0257	0,004	0,0648	0,05001	0,0256	0,004	0,0656	0,05012	0,0252
30	0,9598	0,0042	0,0648	0,04965	0,0240	0,004	0,0663	0,05098	0,0295	0,005	0,0671	0,05197	0,0246
35	0,9640	0,004	0,0640	0,04872	0,0246	0,004	0,0648	0,04988	0,0223	0,004	0,0648	0,04992	0,0225
40	0,9662	0,004	0,0640	0,04732	0,0222	0,004	0,0600	0,04702	0,0219	0,004	0,0616	0,04750	0,0258
45	0,9620	0,004	0,0656	0,05016	0,0242	0,004	0,0663	0,05167	0,0237	0,004	0,0656	0,05042	0,0228
50	0,9632	0,004	0,0648	0,04912	0,0226	0,004	0,0663	0,05134	0,0232	0,004	0,0656	0,05087	0,0264

Çizelge 4.13. Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Yaz mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9667	0,0039	0,062	0,04992	0,0013	0,0040	0,0636	0,05130	0,0014	0,0042	0,0649	0,05225	0,0016
10	0,9689	0,0037	0,061	0,04663	0,0014	0,0037	0,0606	0,04628	0,0014	0,0038	0,0619	0,04791	0,0015
15	0,9705	0,0035	0,060	0,04570	0,0014	0,0034	0,0585	0,04486	0,0014	0,0035	0,0593	0,04564	0,0014
20	0,9704	0,0035	0,059	0,04534	0,0014	0,0035	0,0595	0,04615	0,0014	0,0037	0,0607	0,04676	0,0014
25	0,9723	0,0033	0,057	0,04300	0,0013	0,0032	0,0567	0,04257	0,0013	0,0034	0,0579	0,04284	0,0013
30	0,9731	0,0032	0,057	0,04143	0,0013	0,0031	0,0561	0,04057	0,0012	0,0032	0,0568	0,04182	0,0013
35	0,9728	0,0032	0,056	0,04158	0,0013	0,0033	0,0576	0,04209	0,0013	0,0033	0,0579	0,04259	0,0013
40	0,9720	0,0033	0,058	0,04366	0,0013	0,0033	0,0577	0,04352	0,0013	0,0033	0,0577	0,04347	0,0013
45	0,9732	0,0032	0,056	0,04126	0,0013	0,0030	0,0551	0,04042	0,0012	0,0033	0,0575	0,04248	0,0013
50	0,9715	0,0033	0,057	0,04348	0,0013	0,0035	0,0592	0,04412	0,0014	0,0036	0,0597	0,04429	0,0014


Çizelge 4.14. Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Sonbahar mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9382	0,0049	0,0697	0,05604	0,0227	0,0051	0,0717	0,05753	0,0234	0,0048	0,0693	0,05555	0,0226
10	0,9388	0,0048	0,0691	0,05523	0,0224	0,0049	0,0701	0,05667	0,023	0,0049	0,0703	0,05657	0,0229
15	0,9458	0,0043	0,0655	0,05141	0,0208	0,0042	0,0651	0,04986	0,0203	0,0043	0,0656	0,05153	0,0208
20	0,9447	0,0043	0,0652	0,05144	0,0208	0,0041	0,0640	0,05009	0,0203	0,0042	0,0650	0,05163	0,0210
25	0,9540	0,0036	0,0601	0,04541	0,0184	0,0034	0,0587	0,04461	0,0181	0,0038	0,0616	0,04641	0,0188
30	0,9475	0,0042	0,0645	0,05043	0,0204	0,0039	0,0621	0,04822	0,0195	0,0043	0,0656	0,05058	0,0205
35	0,9497	0,0040	0,0630	0,04787	0,0194	0,0040	0,0632	0,04800	0,0195	0,0040	0,0633	0,04830	0,0196
40	0,9474	0,0040	0,0632	0,04901	0,0197	0,0046	0,0678	0,05253	0,0214	0,0043	0,0653	0,04974	0,0201
45	0,9533	0,0036	0,0597	0,04609	0,0187	0,0039	0,0622	0,04804	0,0196	0,0039	0,0625	0,04755	0,0194
50	0,9505	0,0039	0,0623	0,04810	0,0195	0,0038	0,0620	0,04823	0,0196	0,0040	0,0636	0,04912	0,0200

Çizelge 4.15. Fletcher-Reeves Güncelleme modeli ile tahminlemesi yapılan Kış mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9355	0,0057	0,0752	0,05726	0,0180	0,0055	0,0744	0,05777	0,0181	0,0057	0,0757	0,05790	0,0182
10	0,9331	0,0059	0,0767	0,05948	0,0189	0,0058	0,0762	0,05927	0,0189	0,0059	0,0766	0,06011	0,0191
15	0,9381	0,0053	0,0729	0,05460	0,0173	0,0055	0,0741	0,05603	0,0178	0,0056	0,0751	0,05634	0,0178
20	0,9459	0,0046	0,0675	0,05064	0,0161	0,0051	0,0712	0,05289	0,0168	0,0050	0,0706	0,05194	0,0165
25	0,9355	0,0056	0,0749	0,05848	0,0187	0,0057	0,0754	0,05981	0,0192	0,0058	0,0763	0,05984	0,0191
30	0,9350	0,0058	0,0761	0,05771	0,0184	0,0054	0,0733	0,05642	0,0180	0,0057	0,0755	0,05745	0,0184
35	0,9361	0,0056	0,0748	0,05711	0,0181	0,0057	0,0758	0,05730	0,0182	0,0055	0,0744	0,05712	0,0181
40	0,9426	0,0049	0,0701	0,05167	0,0164	0,0052	0,0720	0,05367	0,0171	0,0052	0,0721	0,05276	0,0167
45	0,9381	0,0054	0,0733	0,05545	0,0176	0,0054	0,0732	0,05533	0,0176	0,0056	0,0751	0,05660	0,0180
50	0,9432	0,0049	0,0701	0,05195	0,0165	0,0050	0,0706	0,05268	0,0168	0,0052	0,0720	0,05361	0,0170


Fletcher-Reeves güncelleme eğitim algoritması ile gerçekleştirilmiş olan tahminlerin farklı nöron sayıları ile hata miktarının karşılaştırılması Şekil 4.18 de verilmiştir



Şekil 4.18. Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları


4.3.1.2 Fletcher-Reeves Güncelleme Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik olarak Karşılaştırılması

Verilerin saatlik olarak karşılaştırılması incelendiğinde İlkbahar ve Yaz ayları için gerçek değerler ile tahmin değerlerin çok yakın sonuçlar gösterdiği söylenebilir. Sonbahar ve Kış aylarında tahmin ve gerçek değerler arasındaki farklar biraz daha fazla olmasına rağmen genel performansları iyi düzeydedir. Tüm yılı kapsayan verilerin tahminlemesinde ise mevsimsel verilere oranla gerçek ve tahmin verileri arasında daha büyük farklılıklardan söz edilebilir. Yapay sinir ağlarında Fletcher-Reeves güncelleme eğitim algoritması ile yapılan tahminlemelerin, gerçek değerler ile saatlik olarak karşılaştırılması Şekil 4.19 ve 4.20’de verilmiştir.




Şekil 4.19. Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemeleri yapılan yıllık verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi




d) Kış Mevsimi



Şekil 4.20. Fletcher-Reeves Güncelleme eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


4.4 Kademeli Çekim Geri Yayılım Eğitim Algoritması ile Yapılan Tahminlemeler

Kademeli Çekim Eğitim algoritması (trainscg) ile gerçekleştirilen tahminlemeler sonucunda İlkbahar, Yaz ve Sonbahar mevsimleri için birbirlerine çok benzer performanslarda tahmin sonuçları elde edilmiştir. Gerçekleştirilen tahminleme de en iyi regresyon katsayısı (0,98616) ile Yaz mevsiminde bulunmuştur. En düşük regresyon katsayısı ise (0,93323) ile tüm yıllık verileri kapsayan veri setinde ulaşılmıştır. Tüm yılı kapsayan verilerin tahminlemesi mevsimsel verilere kıyasla performans olarak daha geride kalmıştır. Tahminlemeler sonucu elde edilen regresyon grafikleri Şekil 4.21 ile 4.23 arasında verilmiştir




Şekil 4.21. Tüm yılı kapsayan verilerin Kademeli Çekim eğimi algoritması ile yapılan tahminlemelerinin regresyon grafikler

a) İlkbahar Mevsimi




b) Yaz Mevsimi




Şekil 4.22. İlkbahar ve Yaz mevsimi verilerinin Kademeli Çekim eğitim algoritması ile yapılan tahminlemelerinin regresyon grafikleri

a) Sonbahar Mevsimi




b) Kış Mevsimi




Şekil 4.23. Sonbahar ve Kış verilerinin Kademeli Çekim eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

Mevsimsel tahminleme sonuçlarının hata histogramlarında hata sayıları bütün yıllı kapsayan verilerin tahminlerine oranla daha fazla yayılım gösterebilir de hata miktarları çok daha düşük seviyededir. Tahminlemelere ait hata histogramları Şekil 4.24 de verilmiştir.



Şekil 4.24. Tüm yılı kapsayan ve mevsimsel verilerde Kademeli Çekim eğitim algoritması ile yapılan tahminlemenin hata histogramları


Şekil 4.25’de tahminlemesi gerçekleştirilen veri setlerinin performans grafikleri verilmiştir. Eğitim, doğrulama ve test veri setleri için hata eğrileri benzer performans göstermiştir. Grafiklerde yeşil halka ile gösterilen noktalar doğrulama veri setlerinde minimum hata miktarına ulaşarak tahminlemenin durduğu kısımdır. İlkbahar ve Yaz ayları doğrulama veri setinde minimum hata miktarına 200’ün altında düşük iterasyon sayısında ulaşılmıştır. Sonbahar ve Kış veri setleri ise minimum hata miktarına 350. iterasyondan sonra ulaşabilmişlerdir Tüm verileri kapsayan tahminlemeler ise maksimum iterasyon sayısına ulaştıkları için tahminleme işlemi tamamlanmıştır.



Şekil 4.25. Tüm yılı kapsayan ve mevsimsel verilerde Kademeli Çekim eğitim algoritması ile yapılan tahminlemenin performans grafikleri


4.4.1 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması

Bütün veri setlerinde tahmin edilen değerlerin karşılaştırılması yapıldığında mevsimsel veri setlerinde çok yüksek doğrulukta tahminlemeler gerçekleştirilmiştir. Gerçek çıktı dağılımı ile tahminlenen doğru dağılımın yayılımın arada oluşan ufak sapmalar dışında çok başarılı sonuçlar verdiği görülmüştür. Tüm yıllık verileri kapsayan tahminlemelerde ise bir yıl boyunca toplanan amonyak emisyon miktarı ile tahmin edilen amonyak emisyon miktarı çok yakın sonuçlar vermek ile birlikte verilerin yayılım kısımlarına sıkıntılar olduğu ve bazı verilerin tahminlenmesinde hatalar meydana geldiği görülmüştür. Şekil 4.26 ve 4.27’de tahminlenen değerlerin gerçek değerler ile kıyaslanma grafikleri verilmiştir.




Şekil 4.26. Kademeli Çekim eğitim algoritması ile tüm yıllık kapsayan veri gruplarının tahminleri ile gerçek değerlerin karşılaştırılması


a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi



d) Kış Mevsimi



Şekil 4.27. Kademeli Çekim eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması

4.4.1.1 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması

Nöron sayılarına göre gerçekleştirilen karşılaştırmalar sonucunda İlkbahar mevsimi dışında bütün mevsimlerde yüksek nöron sayılarında daha iyi sonuçlar elde edilirken ilkbahar mevsiminde en düşük hata oranı 10 nöron sayısı ile elde edilmiştir. Yaz mevsiminde 45 nöron sayısında ağın eğitim, doğrulama ve test için sırasıyla performansı (0,0033), (0,0033), (0,0032) ortalama karesel hata (MSE), (0,058), (0,056), (0,57) ortalama karesel hata kara kökü (RMSE) ve (0,044), (0,042), (0,043) ortalama mutlak hata (MAE), (0,0013) ortalama hata mutlak değeri (MAPE) ve (0,9725) R^2 skoru ile bütün tahminlemeler içerisinde en iyi performansa sahip ağ olmuştur. Eğitim, doğrulama ve test veri setleri stabil ve başarılı bir tahminleme işlemi gerçekleştirmiştir. İlkbahar, Sonbahar ve Yaz ayları için hata oranları benzer olarak seyrederken tüm yıllık kapsayan veri seti için ise hata oranları daha yüksektir. Çizelge 4.16 ile 4.20 arasında elde edilen tahmin değerlerinin farklı nöron sayılarında hata miktarları verilmiştir.

Çizelge 4.16. Kademeli çekim modeli ile tahminlemesi yapılan tüm yıllık verilerin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,7666	0,0246	0,1569	0,0907	0,2184	0,0234	0,1530	0,0889	0,2113	0,0245	0,1566	0,0901	0,2199
10	0,7229	0,0288	0,1698	0,0931	0,2337	0,0289	0,1700	0,0929	0,2383	0,0298	0,1727	0,0951	0,2437
15	0,7336	0,0278	0,1667	0,0941	0,2312	0,0285	0,1689	0,0958	0,2356	0,0281	0,1675	0,0954	0,2358
20	0,8244	0,0186	0,1365	0,0743	0,1739	0,0184	0,1358	0,0741	0,1749	0,0180	0,1341	0,0734	0,1712
25	0,7958	0,0216	0,1470	0,0826	0,2009	0,0220	0,1482	0,0834	0,2082	0,0210	0,1451	0,0815	0,1984
30	0,8421	0,0167	0,1294	0,0702	0,1639	0,0175	0,1321	0,0717	0,1663	0,0158	0,1257	0,0682	0,1562
35	0,7771	0,0235	0,1533	0,0833	0,2030	0,0241	0,1552	0,0847	0,2092	0,0227	0,1507	0,0820	0,1983
40	0,8372	0,0173	0,1314	0,0740	0,1697	0,0164	0,1279	0,0724	0,1673	0,0173	0,1314	0,0746	0,1714
45	0,8489	0,0160	0,1263	0,0688	0,1568	0,0153	0,1239	0,0685	0,1567	0,0160	0,1264	0,0694	0,1575
50	0,8709	0,0135	0,1160	0,0641	0,1443	0,0137	0,1172	0,0651	0,1498	0,0137	0,1170	0,0647	0,1481

Çizelge 4.17. Kademeli Çekim modeli ile tahminlemesi yapılan İlkbahar verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9553	0,0047	0,0686	0,05568	0,0265	0,0050	0,0707	0,05753	0,0251	0,0049	0,0700	0,05683	0,0250
10	0,9635	0,0039	0,0624	0,04872	0,0247	0,0039	0,0624	0,04869	0,0229	0,0038	0,0616	0,04791	0,0235
15	0,9518	0,0044	0,0663	0,05272	0,0273	0,0045	0,0671	0,05330	0,0262	0,0043	0,0656	0,05150	0,0263
20	0,9603	0,0042	0,0648	0,05070	0,0249	0,0042	0,0648	0,05063	0,0233	0,0039	0,0624	0,04849	0,0242
25	0,9544	0,0045	0,0671	0,05346	0,0260	0,0047	0,0686	0,05560	0,0258	0,0047	0,0686	0,05352	0,0294
30	0,9630	0,0044	0,0663	0,05280	0,0227	0,0046	0,0678	0,05499	0,0229	0,0043	0,0656	0,05142	0,0260
35	0,9527	0,0041	0,0640	0,05001	0,0265	0,0042	0,0648	0,05052	0,0321	0,0044	0,0663	0,05263	0,0271
40	0,9538	0,0041	0,0640	0,04991	0,0281	0,0042	0,0648	0,05061	0,0271	0,0042	0,0648	0,05044	0,0269
45	0,9521	0,0044	0,0663	0,05280	0,0272	0,0045	0,0671	0,05349	0,0270	0,0045	0,0671	0,05378	0,0307
50	0,9513	0,0043	0,0656	0,05163	0,0260	0,0040	0,0632	0,04950	0,0261	0,0045	0,0671	0,05363	0,0303

Çizelge 4.18. Kademeli Çekim modeli ile tahminlemesi yapılan Yaz verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9686	0,0037	0,061	0,04615	0,0014	0,0038	0,0615	0,04695	0,0014	0,0038	0,0614	0,04619	0,0014
10	0,9693	0,0036	0,060	0,04673	0,0014	0,0035	0,0596	0,04608	0,0014	0,0038	0,0616	0,04755	0,0015
15	0,9712	0,0034	0,058	0,04477	0,0014	0,0035	0,0590	0,04527	0,0014	0,0034	0,0586	0,04496	0,0014
20	0,9700	0,0035	0,059	0,04505	0,0014	0,0035	0,0593	0,04495	0,0014	0,0038	0,0618	0,04674	0,0014
25	0,9709	0,0034	0,058	0,04427	0,0014	0,0036	0,0597	0,04572	0,0014	0,0036	0,0599	0,04543	0,0014
30	0,9706	0,0035	0,059	0,04478	0,0014	0,0035	0,0590	0,04456	0,0014	0,0035	0,0590	0,04476	0,0014
35	0,9722	0,0033	0,057	0,04301	0,0013	0,0035	0,0589	0,04421	0,0014	0,0032	0,0570	0,04283	0,0013
40	0,9723	0,0033	0,057	0,04263	0,0013	0,0032	0,0568	0,04169	0,0013	0,0033	0,0575	0,04171	0,0013
45	0,9725	0,0033	0,058	0,04357	0,0013	0,0031	0,0559	0,04197	0,0013	0,0032	0,0570	0,04250	0,0013
50	0,9723	0,0033	0,057	0,04235	0,0013	0,0033	0,0571	0,04213	0,0013	0,0034	0,0585	0,04335	0,0013


Çizelge 4.19. Kademeli Çekim modeli ile tahminlemesi yapılan Sonbahar verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9410	0,0047	0,0685	0,05540	0,0224	0,0046	0,0675	0,05443	0,0220	0,0046	0,0682	0,05543	0,0223
10	0,9417	0,0045	0,0674	0,05253	0,0213	0,0047	0,0687	0,05347	0,0217	0,0047	0,0684	0,05314	0,0216
15	0,9433	0,0045	0,0670	0,05192	0,0211	0,0044	0,0666	0,05178	0,0209	0,0045	0,0671	0,05156	0,0210
20	0,9474	0,0041	0,0642	0,05002	0,0203	0,0043	0,0653	0,05020	0,0203	0,0042	0,0645	0,04965	0,0202
25	0,9480	0,0041	0,0643	0,04974	0,0202	0,0039	0,0627	0,04832	0,0196	0,0042	0,0647	0,05034	0,0205
30	0,9498	0,0040	0,0636	0,04876	0,0198	0,0036	0,0602	0,04567	0,0185	0,0039	0,0627	0,04827	0,0196
35	0,9525	0,0037	0,0610	0,04651	0,0188	0,0038	0,0617	0,04699	0,0190	0,0038	0,0616	0,04733	0,0192
40	0,9553	0,0036	0,0597	0,04534	0,0184	0,0035	0,0590	0,04501	0,0183	0,0035	0,0591	0,04488	0,0182
45	0,9533	0,0037	0,0605	0,04592	0,0186	0,0037	0,0605	0,04627	0,0187	0,0038	0,0616	0,04685	0,0190
50	0,9547	0,0035	0,0595	0,04499	0,0182	0,0039	0,0621	0,04649	0,0189	0,0035	0,0592	0,04529	0,0183

Çizelge 4.20. Kademeli Çekim modeli ile tahminlemesi yapılan Kış verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9420	0,0050	0,0708	0,05457	0,0173	0,0055	0,0742	0,05693	0,0180	0,0050	0,0706	0,05438	0,0172
10	0,9389	0,0052	0,0724	0,05507	0,0174	0,0057	0,0753	0,05703	0,0180	0,0054	0,0738	0,05585	0,0176
15	0,9440	0,0049	0,0701	0,05242	0,0166	0,0047	0,0686	0,05090	0,0161	0,0050	0,0707	0,05301	0,0168
20	0,9418	0,0050	0,0707	0,05245	0,0166	0,0054	0,0736	0,05423	0,0172	0,0052	0,0718	0,05233	0,0166
25	0,9402	0,0052	0,0722	0,05434	0,0172	0,0053	0,0725	0,05439	0,0172	0,0053	0,0728	0,05525	0,0174
30	0,9380	0,0053	0,0729	0,05569	0,0176	0,0054	0,0736	0,05614	0,0178	0,0058	0,0760	0,05747	0,0182
35	0,9480	0,0044	0,0664	0,05001	0,0158	0,0044	0,0663	0,05038	0,0160	0,0050	0,0708	0,05188	0,0165
40	0,9481	0,0044	0,0662	0,04882	0,0155	0,0047	0,0685	0,05036	0,0160	0,0048	0,0696	0,04946	0,0157
45	0,9449	0,0046	0,0681	0,05010	0,0158	0,0051	0,0713	0,05208	0,0164	0,0052	0,0718	0,05019	0,0159
50	0,9451	0,0020	0,0449	0,02167	0,0169	0,0049	0,0697	0,05160	0,0164	0,0048	0,0695	0,05198	0,0165


Şekil 4.28'e bakıldığında İlkbahar mevsiminde 45 nöron sayısı haricinde nöron sayısı arttıkça hata miktarının azaldığı ancak diğer tahminlemeler için nöron sayısı değiştiğinde bir artış ya da azalış eğiliminde olduğu ve dalgalanma yaşandığı söylenebilir.




Şekil 4.28. Kademeli Çekim eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları

4.4.1.2 Kademeli Çekim Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik olarak Karşılaştırılması

Kademeli Çekim eğitim algoritması ile en yüksek tahminleme performansı Yaz mevsiminde gerçekleştiğinden dolayı amonyak emisyonun saatlik ortalamalarında özellikle gece saatlerindeki karşılaştırmalarda neredeyse birebir aynı sonuçlar elde edilmiştir. İlkbahar, sonbahar ve kış mevsimleri de saatlik ortalama amonyak emisyonu karşılaştırmasında toplam ortalama da 1-2 gram fark olacak şekilde tahminleme gerçekleştirmiştir. Bütün yılı kapsayan verilerin tahminlemesinde ise regresyon katsayısı ve hata miktarına paralel olarak daha düşük performanslar elde edilmiştir. Amonyak emisyonun bütün veri gruplarında saatlik olarak ortalamalarının karşılaştırma grafikleri Şekil 4.29 ve 4.30’da verilmiştir. Grafikte mavi değerler tahmin edilen değerleri turuncu değer ise gerçek amonyak emisyon miktarını göstermektedir.




Şekil 4.29. Kademeli Çekim eğitim algoritması ile tahminlemeleri yapılan tüm yılı kapsayan verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması



Şekil 4.30. Kademeli Çekim eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


4.5 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Geri Yayılım Eğitim Algoritması ile Yapılan Tahminlemeler

Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması (traingdx) ile gerçekleştirilen tahminlemeler sonucunda Yaz mevsimi verileri ile gerçekleştirilen tahminlemelerde 0,98189 regresyon katsayısı ile en iyi performans gösterilmiştir. İlkbahar, Kış ve Sonbahar veri setleri sırasıyla (0,94893), (0,94233), ve (0,96497) regresyon ortalamaları ile benzer performanslar sergilemişlerdir. Tüm yıllık verileri kapsayan veri seti ise (0,78413) regresyon katsayısı ile mevsimsel veri setlerine kıyasla daha düşük başarı oranına sahiptir. Şekil 4.31 ile 4.33 arasında tahmini gerçekleştirilen veri setlerinin eğitim, doğrulama ve test veri setleri için regresyon grafikleri verilmiştir.




Şekil 4.31. Tüm yılı kapsayan veri setinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

a) İlkbahar Mevsimi




b) Yaz Mevsimi




Şekil 4.32. İlkbahar ve Yaz mevsimi verilerinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

a) Sonbahar Mevsimi




b) Kış Mevsimi



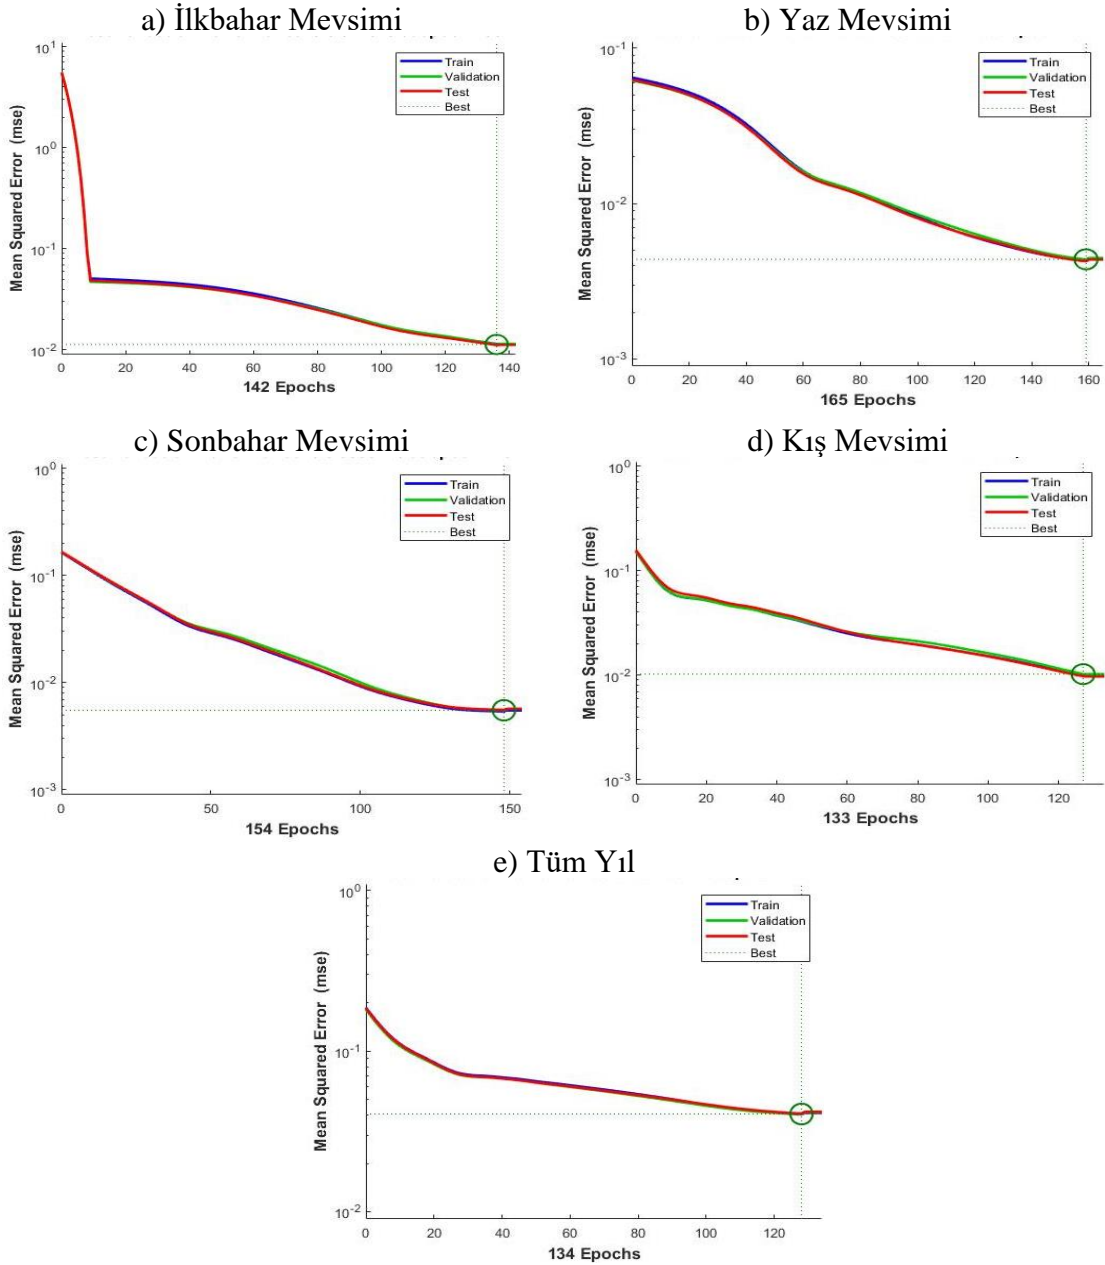
Şekil 4.33. Sonbahar ve Kış mevsimi verilerinde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin regresyon grafikleri

Tahminlemelerin hata histogramları karşılaştırıldığında mevsimsel verilerin tahminlerinde hata yayılımları fazla, sıfır hata çizgisine yakın ancak düşük hata miktarlarında çok sayıda veri olduğu sonucuna varılmıştır. Yıllık verilerin kapsayan verilerin tahmininde ise hata sütunlarının yayılımın daha az ancak hata miktarının büyük olduğu çok sayıda örnek söz konusudur. Şekil 4.34’de gerçekleştirilen tahminlere ait hata histogramları verilmiştir.



Şekil 4.34. Tüm yılı kapsayan ve Mevsimsel verilerde Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin hata histogramları


Kümelerin Adaptifli Momentumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemelerde bütün veri setleri hızlı bir şekilde düşük iterasyon sayılarında minimum hata miktarına ulaşarak sonuçlanmıştır. İlkbahar mevsiminde hata miktarı hızlı bir düşüş gerçekleştirmiş ardından doğrusal olarak azalarak minimum hata miktarına ulaşmıştır. Performans grafikleri Şekil 4.35’de verilmiştir.



Şekil 4.35. Tüm yılı kapsayan ve mevsimsel verilerde Kümelerin Adaptifli Momentumlu Yokuş İnmesi eğitim algoritması ile yapılan tahminlemenin performans grafikleri


4.5.1 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Karşılaştırılması

Bir yıl boyunca ölçümü gerçekleştirilen amonyak emisyon miktarının ortalaması 767,917 (g/g.kümes) iken Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile gerçekleştirilen tahminleme sonucu elde edilen değer 781,798 (g/g.kümes) olarak bulunmuştur. Ortalama amonyak emisyon miktarları karşılaştırıldığında iyi bir sonuç elde edilse de toplam elde edilen gerçek ve tahmin çıktı değerlerinin karşılaştırılması yapıldığında özellikle veri grubunun ilk ve son kısımlarındaki tahminlemelerde hatalar söz konusudur. Hataların karşılaştırma grafiği Şekil 4.36'da verilmiştir.



Şekil 4.36. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile yıllık verilerin tahminleri ile gerçek değerlerin karşılaştırılması

Mevsimsel verilerin karşılaştırılmasında ise hem ortalama amonyak emisyon miktarı hem de genel tahminleme performansı yıllık verilere oranla çok daha yüksek doğrulukta gerçekleşmiştir. Şekil 4.37 de mevsimsel veri grupları için gerçek ve tahmin değerlerinin karşılaştırması gösterilmiştir.



Şekil 4.37. Kümelerin Adaptifli Momentumlu Yokuş İnmesi eğitim algoritması ile mevsimsel verilerin tahminleri ile gerçek değerlerin karşılaştırılması

4.5.1.1 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Nöron Sayılarına göre Karşılaştırılması

Yapay sinir ağlarında 5 farklı veri setinde gerçekleştirilen tahminlemeler sonucunda İlkbahar ve Kış mevsimleri en iyi performanslarını 40 nöron sayısında gösterirken Yaz ve sonbahar mevsimleri ise en iyi performanslarını sırasıyla 10 ve 15 nöron sayısında gerçekleştirmiştir. Tahminlemeler içerisinde en kötü performansa sahip olan tüm yılı kapsayan veri grubu ise en iyi performansını 30 nöron sayısında göstermiştir. Traingdx eğitim algoritması ile gerçekleştirilen tahminlemeler sonucunda mevsimsel veri setlerinde %10'un altında ortalama mutlak hata yüzdesi (MAPE) sonucu ile "çok iyi" tahminleme gerçekleştirilmiştir. Tüm yılı kapsayan veri setinin tahminlenmesinde ise %34,15 ortalama mutlak hata yüzdesi (MAPE) ile mevsimsel veri setlerine oranla daha kötü bir sonuç ortaya çıksa da kriterlere göre "kabul edilebilir" bir sonuç ortaya konmuştur (Aslay ve Özen, 2013; Lewis, 1982). Tahminlemelerin nöron sayılarına göre hata miktarı karşılaştırmaları Çizelge 4.21 ila 4.25 arasında verilmiştir.

Çizelge 4.21. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi modeli ile tahminlemesi yapılan tüm yıllık verilerin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,5969	0,0427	0,2067	0,1219	0,3143	0,0431	0,2076	0,1224	0,3170	0,0410	0,2024	0,1191	0,3035
10	0,6067	0,0412	0,2029	0,1191	0,3036	0,0404	0,2011	0,1170	0,3067	0,0423	0,2057	0,1209	0,3139
15	0,5971	0,0422	0,2054	0,1229	0,3213	0,0432	0,2079	0,1248	0,3237	0,0420	0,2049	0,1215	0,3193
20	0,6032	0,0413	0,2032	0,1182	0,3045	0,0435	0,2086	0,1231	0,3219	0,0414	0,2034	0,1185	0,306
25	0,6057	0,0420	0,2048	0,1239	0,3234	0,0407	0,2016	0,1207	0,3134	0,0405	0,2013	0,1215	0,3130
30	0,6157	0,0404	0,2010	0,1273	0,3417	0,0404	0,2010	0,1276	0,3386	0,0406	0,2016	0,1275	0,3428
35	0,6054	0,0417	0,2042	0,1253	0,3406	0,0410	0,2024	0,1247	0,3335	0,0412	0,2030	0,1251	0,3366
40	0,5952	0,0422	0,2054	0,1268	0,3254	0,0436	0,2089	0,1299	0,3392	0,0428	0,2070	0,1270	0,3343
45	0,5817	0,0430	0,2075	0,1234	0,3285	0,0445	0,2110	0,1250	0,3365	0,0462	0,2150	0,1282	0,347
50	0,5921	0,0431	0,2077	0,1325	0,3399	0,0436	0,2088	0,1332	0,3430	0,0423	0,2057	0,1314	0,3385

Çizelge 4.22. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi modeli ile tahminlemesi yapılan İlkbahar mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,8822	0,0107	0,1034	0,08205	0,0497	0,0105	0,1025	0,08115	0,0466	0,0105	0,1025	0,08123	0,0453
10	0,8612	0,0110	0,1049	0,08411	0,512	0,0107	0,1034	0,08205	0,0529	0,0116	0,1077	0,08932	0,0518
15	0,8677	0,0112	0,1058	0,08597	0,0500	0,0111	0,1054	0,08529	0,0473	0,0108	0,1039	0,08295	0,0481
20	0,8701	0,0113	0,1063	0,08691	0,0478	0,0120	0,1095	0,09200	0,0487	0,0107	0,1034	0,08219	0,0496
25	0,8810	0,0117	0,1082	0,09002	0,0508	0,0115	0,1072	0,08792	0,0507	0,0116	0,1077	0,09002	0,0474
30	0,8640	0,0115	0,1072	0,08762	0,0494	0,0111	0,1054	0,08521	0,0478	0,0123	0,1109	0,09519	0,046
35	0,8673	0,0109	0,1044	0,08349	0,0521	0,0108	0,1039	0,08301	0,0525	0,0110	0,1049	0,08435	0,0503
40	0,8898	0,0100	0,1000	0,07751	0,0491	0,0101	0,1005	0,07802	0,0428	0,0101	0,1005	0,07815	0,0438
45	0,8235	0,0123	0,1109	0,09470	0,0595	0,0122	0,1105	0,09607	0,0598	0,0126	0,1122	0,09591	0,0599
50	0,8305	0,0124	0,1114	0,09729	0,0587	0,0122	0,1105	0,09657	0,0573	0,0123	0,1109	0,09481	0,059

Çizelge 4.23. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Yaz mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9611	0,0046	0,068	0,05393	0,0017	0,0047	0,0685	0,05396	0,0017	0,0047	0,0689	0,05495	0,0017
10	0,9641	0,0043	0,065	0,05030	0,0015	0,0044	0,0661	0,05119	0,0016	0,0043	0,0653	0,05014	0,0015
15	0,9630	0,0044	0,067	0,05412	0,0017	0,0046	0,0676	0,05401	0,0017	0,0044	0,0663	0,05352	0,0016
20	0,9617	0,0046	0,068	0,05216	0,0016	0,0045	0,0671	0,05205	0,0016	0,0047	0,0688	0,05296	0,0016
25	0,9604	0,0048	0,069	0,05410	0,0017	0,0046	0,0680	0,05344	0,0016	0,0048	0,0691	0,05457	0,0017
30	0,9533	0,0057	0,075	0,05745	0,0018	0,0057	0,0758	0,05714	0,0018	0,0054	0,0733	0,05675	0,0017
35	0,9486	0,0062	0,079	0,06133	0,0019	0,0064	0,0800	0,06263	0,0019	0,0059	0,0766	0,05943	0,0018
40	0,9450	0,0065	0,080	0,06388	0,0020	0,0068	0,0823	0,06525	0,0020	0,0068	0,0824	0,06560	0,0020
45	0,9438	0,0068	0,083	0,06423	0,0020	0,0066	0,0811	0,06375	0,0020	0,0068	0,0822	0,06408	0,0020
50	0,9403	0,0071	0,084	0,06292	0,0019	0,0072	0,0849	0,06272	0,0019	0,0074	0,0861	0,06256	0,0019


Çizelge 4.24. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Sonbahar mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,9297	0,0056	0,0747	0,06064	0,0246	0,0054	0,0738	0,05982	0,0242	0,0056	0,0746	0,06066	0,0246
10	0,9278	0,0057	0,0753	0,05966	0,0243	0,0056	0,0746	0,05955	0,0241	0,0060	0,0775	0,06076	0,0247
15	0,9312	0,0054	0,0734	0,05887	0,0238	0,0055	0,0743	0,05920	0,0239	0,0056	0,0746	0,05905	0,0239
20	0,9289	0,0056	0,0747	0,05750	0,0232	0,0056	0,0750	0,05812	0,0235	0,0058	0,0763	0,05801	0,0235
25	0,9267	0,0057	0,0755	0,05896	0,0239	0,0061	0,0780	0,06116	0,025	0,0059	0,0765	0,05942	0,0241
30	0,928	0,0058	0,0760	0,06174	0,0249	0,0056	0,0746	0,06080	0,0245	0,0056	0,0746	0,06060	0,0244
35	0,9258	0,0058	0,0765	0,06100	0,0248	0,0060	0,0777	0,06109	0,0249	0,0059	0,0768	0,06092	0,0247
40	0,9168	0,0066	0,0812	0,06284	0,0256	0,0068	0,0828	0,06294	0,0257	0,0067	0,0820	0,06324	0,0259
45	0,9044	0,0075	0,0868	0,06896	0,0280	0,0081	0,0899	0,06914	0,0283	0,0076	0,0870	0,06831	0,0277
50	0,9063	0,0074	0,0862	0,06810	0,0273	0,0073	0,0852	0,06678	0,0267	0,0078	0,0883	0,06906	0,0278

Çizelge 4.25. Kümelerin Adaptifli Momemtumlu Yokuş İnmesi modeli ile tahminlemesi yapılan Kış mevsimi verilerinin nöron sayılarına göre hata miktarı

Nöron Sayısı	R ²	Eğitim				Doğrulama				Test			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
5	0,8867	0,0102	0,1009	0,08138	0,0256	0,0095	0,0972	0,07927	0,0248	0,0097	0,0985	0,08075	0,0254
10	0,8611	0,0125	0,1119	0,09380	0,0295	0,0121	0,1099	0,09164	0,0288	0,0118	0,1088	0,09134	0,0288
15	0,8770	0,0107	0,1035	0,08596	0,0273	0,0109	0,1044	0,08669	0,0275	0,0112	0,1058	0,08830	0,028
20	0,8890	0,0100	0,0999	0,07710	0,0242	0,0085	0,0919	0,07269	0,0231	0,0100	0,1001	0,07566	0,024
25	0,8823	0,0101	0,1005	0,08242	0,0259	0,0114	0,1069	0,08399	0,0265	0,0103	0,1013	0,08262	0,0259
30	0,8837	0,0100	0,0999	0,08160	0,0257	0,0101	0,01011	0,08180	0,0198	0,0104	0,1021	0,08254	0,0261
35	0,8866	0,0100	0,0999	0,07840	0,0247	0,0103	0,1016	0,07701	0,0243	0,0097	0,0986	0,07794	0,0245
40	0,8892	0,0096	0,0981	0,08301	0,0263	0,0102	0,1009	0,08355	0,0264	0,0097	0,0987	0,08258	0,0261
45	0,8859	0,0101	0,1003	0,08131	0,0258	0,0102	0,1012	0,08355	0,0266	0,0100	0,1001	0,08169	0,0259
50	0,8882	0,0101	0,1005	0,07704	0,0242	0,0095	0,0973	0,07639	0,0240	0,0099	0,0993	0,07714	0,0242


Sonbahar, Yaz ve tüm yılı kapsayan veri setlerinde nöron sayısı arttıkça ağın performansının azaldığından bahsedilebilir. Kış mevsimi nöron sayısı arttıkça stabil bir performans ortaya koymuştur. Tahminlemelerin nöron sayılarına oranla performans karşılaştırmaları Şekil 4.38’de verilmiştir



Şekil 4.38. Kümelerin Adaptifli Momentumlu Yokuş İnmesi eğitim algoritması ile tahminlemesi yapılan tüm veri gruplarının nöron sayılarına göre hata miktarları


4.5.1.2 Kümelerin Adaptifli Momemtumlu Yokuş İnmesi Eğitim Algoritması ile Yapılan Tahminlemelerin Saatlik Olarak Karşılaştırılması

Kümelede oluşan saatlik ortalama amonyak emisyonlarının tahmin değerler ile karşılaştırılması sonucu mevsimsel verilerin hepsinde hata miktarlarının düşük olduğu görülmüştür. Bütün yılı kapsayan veri grubu ise yüksek benzerlikte tahmin gerçekleştirmiş olsa da performans olarak hata miktarında mevsimsel verilerin tahminleme performansının gerisinde kalmıştır. Tahminlemeler sonucunda elde edilen amonyak emisyon miktarının saatlik ortalamasının gerçek veriler ile karşılaştırılması Şekil 4.39 ve 4.40'da verilmiştir




Şekil 4.39. Adaptifli Momemtumlu Yokuş İnmesi eğitim algoritması ile tahminlemeleri yapılan tüm yılı kapsayan verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması


a) İlkbahar Mevsimi




b) Yaz Mevsimi



c) Sonbahar Mevsimi



d) Kış Mevsimi



Şekil 4.40. Adaptifli Momentumlu Yokuş İnmesi eğitim algoritması ile tahminlemeleri yapılan mevsimsel verilerin gerçek değerler ile saatlik ortalamalarının karşılaştırılması

4.6 Tahminleme 'de Kullanılan Eğitim Algoritmalarının Karşılaştırılması

Bu tez çalışmasında yapay sinir ağları kullanılarak İlkbahar, Yaz, Kış, Sonbahar ve tüm yıllık veriler olmak üzere 5 farklı veri grubunda trainlm, traincgf, trainscg ve traingdx eğitim algoritmalarında tahminlemeler gerçekleştirilmiş ve sinir ağlarının performans karşılaştırmaları yapılmıştır. Gerçekleştirilen tahminlemeler içerisinde en iyi performansı trainlm eğitim algoritması göstermiş ve bütün veri setlerinde en düşük hata miktarına sahip olarak tahminleme yapmıştır. Trainscg ve traincgf eğitim algoritmaları ise tahminleme çalışmaları boyunca birbirlerine çok benzer hata oranına sahip tahminlemeler gerçekleştirmiştir. Traingdx eğitim algoritması ise tahminleme performansı olarak iyi sonuçlar elde etse de diğer eğitim algoritmalarına oranla daha düşük R^2 değerlerine sahiptir. Tüm yılı kapsayan veri setinde gerçekleştirilen tahminlemelerde ise diğer veri setlerinin tahminlemesine oranla daha düşük performans sonuçları elde edilmiştir. Eğitim algoritmalarından trainlm tüm yılı kapsayan veri setinde 0,9741 R^2 skoruna sahip iken diğer eğitim algoritmaları performans olarak geride kalmıştır. Özellikle traingdx eğitim algoritması 0,6157 R^2 skoru ile diğer performanslarına oranla yüksek hata miktarına sahiptir. Çizelge 4.26 ve 4.27'de mevsimsel ve tüm yılı kapsayan veri setleri için eğitim algoritmalarının en iyi performans gösterdiği nöron sayısı ve hata miktarları verilmiştir.

Çizelge 4.26. Tüm yılı kapsayan veri setinde eğitim algoritmalarının en iyi performanslarının karşılaştırılması

Eğitim Algoritmaları	Nöron Sayısı	R^2	MSE	RMSE	MAE	MAPE
Trainlm	20	0,9741	0,0027	0,0521	0,0236	0,0536
Traincgf	20	0,8868	0,0136	0,1168	0,0690	0,1313
Trainscg	50	0,8709	0,0136	0,1165	0,0644	0,1428
Traingdx	30	0,6157	0,0405	0,2011	0,1274	0,3415

Çizelge 4.27. Mevsimsel veri setinde eğitim algoritmalarının en iyi performanslarının karşılaştırılması


Mevsimler	Eğitim Algoritmaları	Nöron Sayısı	R ²	MSE	RMSE	MAE	MAPE
İlkbahar	Trainlm	50	0,9786	0,0022	0,0469	0,03221	0,0153
	Traincgf	40	0,9662	0,0039	0,0624	0,04755	0,0219
	Trainscg	10	0,9635	0,0039	0,0624	0,04890	0,0233
	Traingdx	40	0,8988	0,0100	0,1000	0,07722	0,0442
Yaz	Trainlm	40	0,9806	0,0023	0,0481	0,03170	0,0010
	Traincgf	45	0,9732	0,0032	0,0565	0,04145	0,0013
	Trainscg	45	0,9725	0,0033	0,0572	0,04307	0,0013
	Traingdx	10	0,9641	0,0043	0,0655	0,05040	0,0015
Sonbahar	Trainlm	30	0,9725	0,0022	0,0466	0,03229	0,0132
	Traincgf	25	0,9540	0,0036	0,0603	0,04556	0,0184
	Trainscg	40	0,9553	0,0035	0,0594	0,04519	0,0183
	Traingdx	15	0,9312	0,0055	0,0739	0,05900	0,0239
Kış	Trainlm	45	0,9846	0,0014	0,0368	0,02259	0,0070
	Traincgf	20	0,9459	0,0048	0,0689	0,05134	0,0161
	Trainscg	40	0,9481	0,0046	0,0675	0,04925	0,0155
	Traingdx	40	0,8892	0,0097	0,0987	0,08301	0,0260

Çalışma da kullanılan eğitim algoritmalarının tüm veri setleri için gerçekleştirdiği ortalama amonyak emisyon(g/g.kümes) tahminlemeleri ile gerçek değerlerin karşılaştırılması yapılmıştır. Trainlm, traincgf ve trainscg algoritmalarında bütün tahminlemeler için gerçek değerlere çok yakın sonuçlar elde edilmiştir. Traingdx eğitim algoritmasında ise özellikle tüm verileri kapsayan veri setinde gerçek ve tahmin değeri arasında bir fark söz konusudur. Çizelge 4.28 de eğitim algoritmalarının gerçekleştirdiği tahminlemeler ile gerçek ortalama amonyak emisyon miktarlarının karşılaştırılması verilmiştir.

Çizelge 4.28. Tüm yılı kapsayan ve mevsimsel veri setlerinde eğitim algoritmalarının gerçekleştirdiği tahminlemeler ile gerçek ortalama amonyak emisyon miktarlarının karşılaştırılması

Analiz	Trainlm		Traincgf		Traingdx		Trainscg	
	Tahmin	Gerçek	Tahmin	Gerçek	Tahmin	Gerçek	Tahmin	Gerçek
İlkbahar	400,434	400,660	400,742	400,660	400,832	400,660	400,833	400,660
Yaz	375,735	375,727	375,727	375,727	375,697	375,727	375,731	375,727
Sonbahar	1014,68	1014,61	1014,59	1014,61	1016,04	1014,61	1014,40	1014,61
Kış	1410,90	1410,83	1410,56	1410,83	1411,91	1410,83	1410,83	1410,83
Bütün Yıl	768,002	767,917	764,080	767,917	781,798	767,917	765,698	767,917

Tahminlemeler sonucunda elde edilen ortalama amonyak emisyon miktarının gerçek değerler ile karşılaştırılması Şekil 4.41’de verilmiştir.



Şekil 4.41. Tüm yılı kapsayan ve mevsimsel veri setlerinde eğitim algoritmalarının gerçekleştirdiği tahminlemeler ile gerçek ortalama amonyak emisyon miktarlarının karşılaştırılması

4.7 Girdi Parametrelerinin Yapay Sinir Ağının Performansına Etkisinin Karşılaştırılması

Yapay sinir ağları kullanılarak 6 farklı girdi parametresinden yararlanarak amonyak emisyonu tahminlemesi gerçekleştirilmiştir. Girdi olarak kullanılan Sıcaklık, Bağıl nem, Hava hızı, Havalandırma, Hayvan sayısı ve amonyak konsantrasyonu sırasıyla X1, X2, X3, X4, X5, X6 olarak kodlanmış ve her bir tahminleme işlemi için bir girdi parametresi çıkarılarak 5 girdi ile toplam 5 farklı tahminleme gerçekleştirilmiş ve çıktı parametresinin tahminlenmesinin performansında en çok etkili olan girdi parametresi bulunmaya çalışılmıştır. Bütün tahminlemelerin eşit şartlar altında gerçekleştirilebilmesi için bir sinir ağı oluşturulmuş ve bütün tahminlemeler bu sinir ağı yapısında gerçekleştirilmiştir. Sinir ağının yapısında çalışmada gerçekleştirilen tahminlemeler sonucunda en iyi performansa sahip sonuçlar veren Levenberg Marquardt eğitim algoritması kullanılmıştır. Her bir tahminleme 10'ar kere tekrarlanmış, nöron sayısı 20 olarak seçilmiş ve en iyi performansa sahip tahminleme sonuç olarak alınmıştır.

Tahminleme gerçekleştirilen İlkbahar, Yaz, Sonbahar ve tüm yıllık kapsayan veri setlerinde girdi parametrelerinde hayvan sayısı (X5) çıkarılması tahmin performansını ciddi oranda negatif olarak etkilemiş ancak diğer parametrelerin çıkarılması ile gerçekleştirilen tahminlemeler çok benzer ve yüksek doğrulukta gerçekleşmiştir. Kış mevsiminde gerçekleştirilen tahminlemeler ise yüksek doğrulukta gerçekleşmiştir. Çizelge 4.29 ve 4.30'da farklı girdi parametreleri ile elde edilen tahminleme sonuçları verilmiştir.

Çizelge 4.29. Tüm yılı kapsayan veri setinde farklı girdi parametreleri ile gerçekleştirilen tahminlemelerin sonuçları

Girdi Parametreleri	R ²	MSE	RMSE	MAE	MAPE
X1+X2+X3+X4+X5	0,9666	0,0035	0,0592	0,02730	0,0614
X1+X2+X3+X4+X6	0,8188	0,0190	0,1379	0,08784	0,2024
X1+X2+X3+X5+X6	0,9459	0,0057	0,0753	0,03204	0,0735
X1+X2+X4+X5+X6	0,9640	0,0038	0,0615	0,02910	0,0636
X1+X3+X4+X5+X6	0,9645	0,0037	0,0610	0,02848	0,0645
X2+X3+X4+X5+X6	0,9749	0,0026	0,0513	0,02339	0,0508

Çizelge 4.30. Mevsimsel veri setlerinde farklı girdi parametreleri ile gerçekleştirilen tahminlemelerin sonuçları

Mevsimler	Girdi Parametreleri	R ²	MSE	RMSE	MAE	MAPE
İlkbahar	X1+X2+X3+X4+X5	0,9554	0,0050	0,0707	0,05663	0,218
	X1+X2+X3+X4+X6	0,8853	0,0132	0,1149	0,08152	0,0444
	X1+X2+X3+X5+X6	0,9764	0,0028	0,0529	0,03787	0,0166
	X1+X2+X4+X5+X6	0,9778	0,0026	0,0510	0,03657	0,0159
	X1+X3+X4+X5+X6	0,9767	0,0027	0,0520	0,03711	0,0157
	X2+X3+X4+X5+X6	0,9753	0,0027	0,0520	0,03720	0,0178
Yaz	X1+X2+X3+X4+X5	0,9767	0,0028	0,0527	0,03552	0,0010
	X1+X2+X3+X4+X6	0,5329	0,0557	0,2360	0,17609	0,0054
	X1+X2+X3+X5+X6	0,9777	0,0027	0,0516	0,03552	0,0010
	X1+X2+X4+X5+X6	0,9785	0,0026	0,0506	0,03476	0,0010
	X1+X3+X4+X5+X6	0,9693	0,0037	0,0604	0,04599	0,0014
	X2+X3+X4+X5+X6	0,9724	0,0033	0,0574	0,04135	0,0012
Sonbahar	X1+X2+X3+X4+X5	0,9597	0,0032	0,0564	0,04164	0,0170
	X1+X2+X3+X4+X6	0,8308	0,0134	0,1157	0,08376	0,0338
	X1+X2+X3+X5+X6	0,9666	0,0026	0,0514	0,03690	0,0150
	X1+X2+X4+X5+X6	0,9613	0,0031	0,0553	0,03995	0,0162
	X1+X3+X4+X5+X6	0,9537	0,0037	0,0605	0,04477	0,0183
	X2+X3+X4+X5+X6	0,9389	0,0048	0,0695	0,05119	0,0206
Kış	X1+X2+X3+X4+X5	0,9759	0,0021	0,0460	0,02923	0,0092
	X1+X2+X3+X4+X6	0,9436	0,0050	0,0704	0,04452	0,0143
	X1+X2+X3+X5+X6	0,9700	0,0026	0,0513	0,03379	0,0107
	X1+X2+X4+X5+X6	0,9748	0,0022	0,0470	0,03205	0,0101
	X1+X3+X4+X5+X6	0,9801	0,0017	0,0418	0,02733	0,0086
	X2+X3+X4+X5+X6	0,9673	0,0029	0,0536	0,03770	0,0119

Radojević ve ark. (2013), yapay sinir ağlarından yararlanarak Sırbistan'daki amonyak emisyon miktarını tahminlemek üzerine çalışma gerçekleştirmişlerdir. Çalışma sonucunda tahmin edilen amonyak emisyonu değerlerini tatmin edici bulmuşlar ve bu çalışmamıza paralel olarak yapay sinir ağlarının amonyak emisyonlarını tahminlenmesi için uygulanabileceği sonucuna ulaşmışlardır.

Pabuçcu ve Bayramoğlu (2016), yapay sinir ağları kullanarak 1990 ile 2030 yılları arasında beşer yıllık arayla yedi farklı girdi değişkeni kullanarak Türkiye için karbondioksit emisyonu miktarının tahminlemesini gerçekleştirmişlerdir. Bu çalışmadaki ile benzer olarak yüksek başarı oranı ile en iyi tahminleme performansına Levenberg-Marquardt eğitim algoritması ile ulaşmışlardır.

Ahmadi ve ark. (2019), yaptıkları çalışmada beş orta doğu ülkesinde 1990 ile 2015 yılları arasında petrol, doğal gaz, kömür, yenilenebilir enerji kullanımı ve gayri safi yurt içi hasıla girdi parametrelerini kullanarak yapay sinir ağları ile karbondioksit emisyonu miktarı tahminlemesinde bulunmuşlardır. Yapay sinir ağları karbondioksit emisyonlarının tahmini için başarılı sonuçlar ortaya koymuştur ve tahminleme için doğru ve güvenilir bir yaklaşımdır.

5. SONUÇ

Bu çalışma Bursa Uludağ Üniversitesi Veterinerlik Fakültesi Hayvan Sağlığı ve Hayvansal Üretim, Araştırma ve Uygulama Merkezinde bulunan toplam 5000 hayvan kapasitene sahip bir yumurta tavuğu kümesinde gerçekleştirilmiştir. Kümeste bir yıl boyunca gerçekleştirilen sıcaklık, bağıl nem, hava hızı, havalandırma, hayvan sayısı ve amonyak konsantrasyonu verileri İlkbahar, Sonbahar, Yaz, Kış ve tüm yıllık veriler olarak 5 veri setine ayrılmış ve bu veri setleri kullanılarak yapay sinir ağları ile kümeden kaynaklanan amonyak emisyon miktarının tahminlenmesi gerçekleştirilmiştir. Sinir ağları oluşturulurken 6 adet girdi parametresi, bir ara katman ve bir çıktı parametresi sabit olarak seçilmiştir.

Gerçekleştirilecek tahminlemeler için trainlm, traincgf, traibscg ve traingdx olmak üzere dört farklı eğitim algoritmasından yararlanılarak tahminleme gerçekleştirilmiş ve karşılaştırmaları yapılmıştır. Tahminlemeler sonucunda trainlm eğitim algoritması ile tüm veri seti gruplarında %98'in üzerinde regresyon katsayısı elde edilmiş ve tahminleme gerçekleştirilen tüm algoritmalar için de en başarılı sonuçları ortaya koymuştur. Traincgf ve traibscg eğitim algoritmaları trainlm eğitim algoritmasının arkasında kalsa da yüksek performansa sahiptirler. Traingdx eğitim algoritması ise performans olarak Yaz mevsiminde 0,98189 regresyon ile iyi bir tahminleme gerçekleştirmiş olsa da diğer tüm veri setlerinde genel performansı en düşük eğitim algoritması olmuştur.

Nöron sayılarının sinir ağının performansını hangi düzeyde etkilediğini bulmak amacıyla nöron sayısı 5 ile 50 arasında 10 farklı değerde değiştirilerek en iyi performans sahip nöron sayısı bulunmaya çalışılmıştır. Çalışmada yıllık ve mevsimlik olmak üzere 5 farklı veri grubu 4 farklı eğitim algoritmasında değerlendirildiği için yaklaşık 20 adet en iyi tahminleme performansına sahip nöron sayısı ortaya çıkmıştır. Veri grubu ve eğitim algoritması iterasyonuna göre 5 nöron sayısı 0 kez, 10 nöron sayısı 2 kez, 15 nöron sayısı bir kez, 20 nöron sayısı 2 kez, 25 nöron sayısı bir kez, 30 nöron sayısı 2 kez, 35 nöron sayısı bir kez, 40 nöron sayısı 6 kez, 45 nöron sayısı 3 kez ve 50 nöron sayısı 2 kez en iyi performansa sahiptir.

Elde edilen bu sonuçlara göre 6 kez en iyi tahminleme performansı gösteren 40 nöron sayısı bu çalışma için en iyi nöron sayısı olduğu söylenebilir.

Yapay sinir ağları ile amonyak emisyonunun tahminlenmesi sonucunda elde edilen veriler karşılaştırıldığında gerçeğe en yakın sonuçların Yaz ve İlkbahar mevsiminde ortaya çıktığı gözlenmiştir. Bu durumun ortaya çıkmasında Yaz mevsiminin çıktı değerlerinin verilerindeki değişimin daha dar olması ve kış mevsimi veri grubunda ise veri sayısının diğer gruplara göre daha az olmasının etkili olduğu söylenebilir. Aynı şekilde tüm yılı kapsayan veri setinde veri aralığının çok geniş olması ve veri sayısının çok fazla olmasından dolayı yıllık ortalama emisyon miktarının tahminlenmesinde sapmalar söz konusudur. Mevsimsel veri setlerinin tahminlenmesine oranla tüm yıllık kapsayan veri setinin tahminlenmesinde daha başarısız tahminleme sonuçları elde edilmiştir.

Sinir ağına girdi olarak verilen 6 adet parametrenin hangisinin çıktının tahminlenmesini üzerinde daha fazla etkili olduğunu bulmak amacıyla girdiler arasından bir girdi çıkarılarak tahminleme gerçekleştirilmiş ardından çıkarılan girdi sisteme tekrar eklenip başka bir girdi çıkarılmış ve tahminlemeyi en çok etkileyen girdi parametresi belirlenmeye çalışılmıştır. Yapılan değerlendirmeler sonucunda girdi parametreleri arasında amonyak emisyonunun tahminini en çok etkileyen parametrenin hayvan sayısı olduğu ve diğer parametrelerin tahminleme üzerinde fazla bir etkiye sahip olmadığı belirlenmiştir.

Yapılan bu tez çalışması sonucunda bir yumurta tavuğu kümesinden kaynaklanan amonyak emisyonunun yapay sinir ağları kullanılarak tahminlenmesinde en iyi sonucu veren eğitim algoritmasının Levenberg Marquardt (trainlm) olduğu, nöron sayıları içerisinde 40 nöron sayısının en iyi tahminleme performansını gösterdiği ve tahminlemede kullanılan girdi parametreleri içerisinde amonyak emisyonunu etkileyen en önemli girdi parametresinin hayvan sayısı olduğu belirlenmiştir.

Sonuç olarak çalışmada elde edilen tahminleme eşitliklerinin regresyon katsayısı değerlerinin yüksek olması yapay sinir ağlarının hayvancılık işletmelerinden kaynaklanan amonyak emisyonlarının tahminlenmesinde kullanılabileceğini göstermektedir.

KAYNAKLAR

- Abuella, M. & Chowdhury, B. (2015). Solar power forecasting using artificial neural networks. *Proceedings of the 47th Annual North American Power Symposium. 13-16 June 2016*. Orlando, Florida, USA.
- Ahmadi, M. H., Jashnani, H., Chau, K., Kumar, R. & Rosen, M. A. (2019). Carbon dioxide emissions prediction of five middle eastern countries using artificial neural networks. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*.
- Akbulut, İ. & Özcan, B. (2020). Hava kirliliği tahmini: Yapay sinir ağları ve regresyon yöntemleriyle bir karşılaştırma. *Kocaeli Üniversitesi Fen Bilimleri Dergisi*. 3(1), 12-22.
- Akın, B. (2017). *Yapay sinir ağlarıyla Konya bölgesinde kullanıcı doğal gaz tüketim öngörüsü*. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Enerji Enstitüsü. Enerji Bilim ve Teknoloji Anabilim Dalı, İstanbul.
- Akkaya, G. C., Demireli, E. & Yakut, Ü. H. (2009). İşletmelerde finansal başarısızlık tahminlenmesi: Yapay sinir ağları modeli ile İmkb üzerine bir uygulama. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*. 10(2), 187-216.
- Ali, P.J.M. & Faraj, R. H. 2014. Data Normalization and Standardization: A Technical Report. *Machine Learning Technical Reports*. 1(1), 1-6.
- Alias, N., Farid, F.N.M., Al-Rahmi, W. M., Yahaya, N. & Al-Maatouk, Q. (2018). A modeling of animal diseases through using artificial neural network. *International Journal of Engineering & Technology*. 7(4), 3255-3262.
- Altinkum, N. (2013). *Meteorolojik Parametrelerin Atmosferik Uçucu Organik Bileşikleri Üzerine Etkisinin Yapay Sinir Ağları ile Modellenmesi*. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, Çevre Mühendisliği Anabilim Dalı, İstanbul
- Antanasijević, D., Ristić, M., Perić-Grujić, A. A. & Pocajt, V. (2013). Greenhouse gas emissions modeling using artificial neural networks approach. *6th Symposium Chemistry and Environmental Protection with international participation*. 21-24. May 2013. Vršac, Srbija.
- Antanasijević, D. Z., Pocajt, V. V., Povrenović, D. S., Ristić, M. D. & Perić-Grujić, A. A. (2013). PM10 emission forecasting using artificial neural networks and genetic algorithm input variable optimization. *Science of the Total Environment*. (443), 511–519.
- Aslay, F. & Özen, Ü. 2013. Meteorolojik parametreler kullanılarak yapay sinir ağları ile toprak sıcaklığının tahmini. *Politeknik Dergisi*. 16(4), 139,145.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellenmesi. *Öneri*, 10(39), 101-115.

Banda, P. (2016). *Yapay sinir ağırları kullanılarak evapotranspirasyonun tahmin edilmesi ve ampirik metotlarla karşılaştırılması*. Yüksek Lisans Tezi, On dokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü, Tarımsal Yapılar ve Sulama Anabilim Dalı, Samsun.

Barutçu, B., (2013). *Signal Processing and Analysis in Renewable Energy Systems, Prediction Problem*. Ders Notları, İstanbul Teknik Üniversitesi Enerji Enstitüsü.
Baş, N. (2006). *Yapay sinir ağırları yaklaşımı ve bir uygulama Yüksek Lisans Tezi*. Mimar Sinan Güzel Sanatlar Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.

Bekin, A. (2015). *Türkiye'de bazı temel gıda fiyatları için yapay sinir ağırları ve zaman serisi tahmin modellerinin karşılaştırmalı analizi*. Yüksek Lisans Tezi, Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü İşletme Ana Bilim Dalı, Denizli.

Boniecki, P., Dach, j., Pilarski, K. & Piekarska-Boniecka, H. (2012). Artificial neural networks for modeling ammonia emissions released from sewage sludge composting. *Atmospheric Environment*. (57), 49-54.

Campolo, M., Soldati, A. & Andreussi, P. (2003). Artificial neural network approach to flood forecasting in the river Arno. *Hydrological Sciences*. 48(3).

Charytoniuk, W. & Chen, M. (2000). Very short-term load forecasting using artificial neural networks. *IEEE Transactions on Power Systems*. 15(1).

Daliakopoulos, I. N., Coulibaly, P. & Tsanis, I. K., (2005). Groundwater level forecasting using artificial neural networks. *Journal of Hydrology* (309), 229–240.

Dehkordi M.B. (2012). Compressive sensing based compressed neural network for sound source localization. *American journal of intelligent systems*, 2(4), 35-39.

Dündar Oğuz, Z. (2019). *Türkiye'de tasarruf açığının yapay sinir ağırları modeli ile analizi*. Yüksek Lisans Tezi. Van Yüzüncü Yıl Üniversitesi Sosyal Bilimler Enstitüsü İktisat Abd İktisat Bilim Dalı. Van.

Eğrioğlu, E., Yolcu, U. & Baş, E. (2020). *Yapay sinir ağırları öngörü ve tahmin uygulamaları*. Nobel Akademik Yayıncılık.

Fangmeier A., Hadwiger-Fangmeier A., Van der Eerden L. & Jager HJ. (1994). Effects of atmospheric ammonia on vegetation. *A review. Environmental Pollution*. 86(1), 43-82.

Fente, D. N. & Singh, D. K., (2018). Weather forecasting using artificial neural network. *Proceedings of the 2nd International Conference on Inventive Communication and Computational Technologies*. 20-21 April 2018, Coimbatore, India.

Feng, J. & Wu. Y. 2018. Development and Application of Artificial neural network. *Wireless Pers Commun*. 102, 1645–1656.

- Fırat, M. & Güngör, M. (2004). Askı madde konsantrasyonu ve miktarının yapay sinir ağları ile belirlenmesi. *İMO Teknik Dergi*, 15(73), 3267-3282.
- Galloway, J. N. & Cowling, E. B. (2002) Reactive nitrogen and the world: Two Hundred Years of Change. *Ambio*. 31(2), 64-71.
- Gichovi, I, T., Murage, D, K. & Abungu, N. (2013). Short term load forecasting using artificial neural networks. *Proceedings of 2013 Mechanical Engineering Conference on Sustainable Research and Innovation*. 24th - 26th April 2013.
- Gupta, N. 2013. Artificial neural network. *Network and Complex Systems*. 3(1), 24-28.
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*. (16), 8-15.
- Hartung, J. (1998). Tentative calculations of gaseous emissions from pig houses by way of the exhaust air. *In Volatile Emissions From Livestock Farming and Sewage Operation*.
- İbadullayeva, J., Jumaniyazova, K., Azimzadeh, S., Canıgür, S. & Esen, F. (2019). Çevre kirliliğinin insan sağlığı üzerindeki etkileri. *Türk Tıp Öğrencileri Araştırma Dergisi*. 1(3), 52-58.
- Kaplan, Y., Saray, U. & Azkeskin, E. (2014). Hava kirliliğine neden olan PM10 ve SO2 maddesinin yapay sinir ağı kullanılarak tahmininin yapılması ve hata oranının hesaplanması. *Afyon Kocatepe Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*. (4), 1-6.
- Karahan, M. (2011). *İstatistiksel tahmin yöntemleri: Yapay nöron ağları metodu ile ürün talep tahmini uygulaması*. Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.
- Karasu, S., Hacıoğlu, R. & Altan, A. (2018, Mayıs 2-5). Prediction of Bitcoin Prices with Machine Learning Methods using Time Series Data. 26th signal Processing and Communications Applications Conference, İzmir, Türkiye
- Kayman Akbaba, H. (2019). *Beyaz akaryakıt satış miktarının yapay sinir ağları ile modellenmesi*. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstatistik Anabilim Dalı. İstanbul
- Khoshnevisan, B., Rafiee, S., Omid, M., Mousazadeh, H. & Rajaeifar, M. A. (2014). Application of artificial neural networks for prediction of output energy and ghg emissions in potato production in Iran. *Agricultural Systems*. (123), 120-127.
- Kılıç, İ. & Arıcı, İ. (2013). Hayvan barınaklarında açığa çıkan hava kirlleticilerin çevre, hayvan ve çalışan sağlığı üzerine etkileri. *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*. 23(3), 279-288.

- Kononenko, K. & Demidov, D. (2020). Use of artificial neural networks to predict greenhouse gases emissions. *Engineering for Rural Development. International Scientific Conference.* 20-22 May 2020.
- Kukraja, H., Bharath, N., Siddesh, C. S. & Kuldeep, S. 2016. An introduction to artificial neural network. *International journal of advance research and innovative ideas in education.* 1(5).
- Kumar, P., Herbert, M. & Rao, S. (2014). Demand forecasting using artificial neural network based on different learning methods: Comparative analysis. *International Journal for Resarch in Applied Science and Engineering Technology.* 2(4).
- Kurtulmuş, F., Polat, A. & İzli, N. 2020. Yapay sinir ağları kullanarak kayısının farklı kurutma yöntemleriyle kurutulmasında kuruma hızı ve nem oranı parametrelerinin modellenmesi. *Çanakkale On sekiz Mart Üniversitesi Ziraat Fakültesi Dergisi.* (8)2, 261-269.
- Küçükönder, H. (2011). *Yapay sinir ağları ve tarımda bir uygulama.* Doktora Tezi, Kahramanmaraş Sütçü İmam Üniversitesi Fen Bilimleri Enstitüsü. Zootečni Anabilim Dalı, Kahramanmaraş.
- Lapedes, A. S., & Farber, R. M. (1988). How neural networks works. *In Neural information processing systems.* 442-456.
- Lewis, C. D., (1982). *Industrial and Business Forecasting Methods.* Butterworths Publishing. Londra.
- Lorente-Leyva, L. L., Pavón-Valencia, J. F., Montero-Santos, Y., Herrera-Granda, I. D., Herrera-Granda, E. P. & Peluffo-Ordóñez, D. H. (2019). Artificial neural networks for urban water demand forecasting: A case study. *Journal of Physics: Conference Series.*
- McNeill, G. & Anderson, G. 1992. Artificial Neural Networks Technology. A dacs State-of-the-Art Report. USA.
- Mohamed, Z. E. (2019). Using the artificial neural networks for prediction and validating solar radiation. *Journal of the Egyptian Mathematical Society.* 27(47).
- Norouzian, M. A., Bayatani, H. & Alavijeh, M. V., (2021). Comparison of artificial neural networks and multiple linear regression for prediction of dairy cow locomotion score. *Veterinary Research Forum.* 12 (1), 33 – 37.
- Öztürk, K. & Şahin, M.E. (2018). Yapay sinir ağları ve yapay zeka'ya genel bir bakış. *Takvim-i Vekayi.* 6(2), 25-36.
- Pabuçcu, H. & Bayramoğlu, T. (2016). Yapay sinir ağları İle Co2 emisyonu tahmini: Türkiye örneği. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi.* 18(3), 762-778.

- Pençe, İ., Kalkan, A. & Şişeci Çeşmeli, M. (2019). Türkiye sanayi elektrik enerjisi tüketiminin 2017-2023 dönemi için yapay sinir ağları ile tahmini. *Mehmet Akif Ersoy Üniversitesi Uygulamalı Bilimler Dergisi*. 3(2), 206-228.
- Radojević, D., Pocajt, V., Popović, I., Perić-Grujić, A. & Ristić, M. (2013). Forecasting of greenhouse gas emissions in Serbia using artificial neural networks. *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*.
- Stamenković, L. J., Antanasijević, D. Z., Ristić, M, D., Perić-Grujić, A. A. & Pocajt, V. V. (2015). Modeling of ammonia emission in The USA and Eu countries using an artificial neural network approach. *environmental Science and Pollution Research*. (22) ,18849–18858
- Özden, S. & Öztürk, A. (2018). Yapay sinir ağları ve zaman serileri yöntemi ile bir endüstri alanının (İvedik OSB) elektrik enerjisi ihtiyaç tahmini. *Bilişim Teknolojileri Dergisi*. 11(3).
- Özgün, A. (2011). Yapay sinir ağları ile risk öngörüsü. Doktora Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, Gazetecilik Anabilim Dalı, İstanbul.
- Özhan, E. (2020). Yapay sinir ağları ve üstel düzleştirme yöntemi ile Türkiye'deki CO2 emisyonunun zaman serisi ile tahmini. *Avrupa Bilim ve Teknoloji Dergisi*. (19), 282-289.
- Öztemel, E. 2006. *Yapay sinir Ağları*. Papatya Yayıncılık.
- Öztürk, Z.C. (2015). *Modelling of atmospheric SO2 Pollution in Seydişehir town by artificial neural networks*. Yüksek Lisans, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, Çevre Mühendisliği Ana Bilim Dalı, Konya.
- Öztürk, K. & Şahin, M.E. (2018). Yapay sinir ağları ve yapay zeka'ya genel bir bakış. *Takvim-i Vekayi*. 6(2), 25-36.
- Sağiroğlu, Ş., Beşdok E. & Erler, M. (2003). *Mühendislikte yapay zeka uygulamaları I: Yapay sinir ağları*. Ufuk Kitap Kıratsiye-Yayıncılık.
- Şen, Z. (2004). Yapay sinir ağları ilkeleri. Su Vakfı Yayınları
- Taşar, B., Üneş, F., Demirci, M. & Kaya, Y. Z., (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *DÜMF Mühendislik Dergisi*. 9(1), 543 – 551.
- Tolon, M. & Güneri Tosunoğlu, N., (2008). Tüketici tatmini verilerinin analizi: Yapay sinir ağları ve regresyon analizi karşılaştırılması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 10(2), 247-259.
- Turhan, C., Gökçen, G. & Kazanasmaz, T. (2013). Yapay sinir ağları ile İzmir'deki çok katlı binaların toplam enerji tüketimlerinin tahmin edilmesi. *Tesisat Mühendisliği*. (134).

Vural, B. B. (2007). *Yapay sinir ađları ile finansal tahmin. Yüksek Lisans Tezi*, Ankara Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı, Ankara.

Yıldız, A. K. &Özgüven, M. M. (2022). Determination of estrus in cattle with artificial neural networks using mobility and environmental data.*Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Dergisi*. 39(1), 40-45

ÖZGEÇMİŞ

Adı Soyadı : Umut Kılıç
Doğum Yeri ve Tarihi : Bursa 14.05.1997
Yabancı Dil : İngilizce

Eğitim Durumu
Lise : Hürriyet Anadolu Lisesi
Lisans : Bursa Uludağ Üniversitesi
Yüksek Lisans : Bursa Uludağ Üniversitesi

Çalıştığı Kurum/Kurumlar :

İletişim (e-posta) : umutkl1903@hotmail.com

Yayımları :