

**COĞRAFİ VE METEOROLOJİK PARAMETRELERE BAĞLI OLARAK
ORMAN YANGINININ VERDİĞİ ZARARIN YAPAY ZEKA
YÖNTEMLERİYLE TESPİTİ**

RECEP BOZER

**YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ**

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

ARALIK 2011

ANKARA

Fen Bilimleri Enstitü onayı

Prof. Dr. Ünver KAYNAK

Müdür

Bu tezin Yüksek Lisans derecesinin tüm gereksinimlerini sağladığımı onaylarım.

Doç. Dr. Erdoğan DOĞDU

Anabilim Dalı Başkanı

Recep BOZER tarafından hazırlanan COĞRAFİ VE METEOROLOJİK PARAMETRELERE BAĞLI OLARAK ORMAN YANGINININ VERDİĞİ ZARARIN YAPAY ZEKA YÖNTEMLERİYLE TESPİTİ adlı bu tezin Yüksek Lisans tezi olarak uygun olduğunu onaylarım.

Yrd. Doç. Dr. A.Murat ÖZBAYOĞLU

Tez Danışmanı

Tez Jüri Üyeleri

Başkan : Yrd. Doç. Dr. Osman ABUL

Üye : Yrd. Doç. Dr. A.Murat ÖZBAYOĞLU _____

Üye : Doç. Dr. Coşku KASNAKOĞLU _____

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada orijinal olmayan her türlü kaynağa eksiksiz atıf yapıldığını bildiririm.

Recep BOZER

Üniversitesi : TOBB Ekonomi ve Teknoloji Üniversitesi
Enstitüsü : Fen Bilimleri
Anabilim Dalı : Bilgisayar Mühendisliği
Tez Danışmanı : Yrd.Doç. Dr. A. Murat ÖZBAYOĞLU
Tez Türü ve Tarihi : Yüksek Lisans – Aralık 2011

Recep BOZER

**COĞRAFİ VE METEOROLOJİK PARAMETRELERE BAĞLI OLARAK
ORMAN YANGINININ VERDİĞİ ZARARIN YAPAY ZEKA
YÖNTEMLERİYLE TESPİTİ**

ÖZET

Orman yangınları, ekolojik olduğu kadar ekonomik zararlar da veren, çoğu zaman insan hayatını tehdit eden çevresel sorunlardır. Bu çalışmada, daha önce gerçekleşmiş orman yangını kayıtlarındaki ortamın mevcut coğrafi koşulları, yangının çıktığı gün ve saat ile sıcaklık, nem, rüzgar hızı gibi meteorolojik verileri ve yangın bölgesindeki ağaç türleri ile birim alandaki ağaç sayıları gibi parametreler kullanılarak çıkması muhtemel orman yangınlarında beklenen kayıplar tahmin edilmiştir. Çalışmada elde edilen çıktı ise yangın sonucunda kaybedilen yani yanan alan olmuştur. Buna göre, bir orman yangınının çevreyi nasıl etkileyeceği önceden tahmin edilmeye çalışılmış, ilgili yangınla mücadelede kaynak yönetiminin yapılması konusunda yol gösterici olmaya çalışılmıştır. Kullanılan veri kümesi, Türkiye Cumhuriyeti Orman ve Su İşleri Bakanlığı Orman Genel Müdürlüğü'nden elde edilmiştir. Veri kümesi, 2000-2009 yılları arasında Türkiye genelinde meydana gelen toplam 10.597 adet orman yangını kaydını içermektedir. Çalışma kapsamında verilerin düzenlenmesi aşamasında, girdi parametreleri için farklı bulanık modeller oluşturulmuş, yapılan testlerde çok katmanlı algılayıcı ağları ve merkezci tabanlı fonksiyon ağları ile birlikte bulanık mantık kullanılmış, temel bileşenler analizi ile girdi parametreleri yeniden düzenlenerek test sonuçlarındaki iyileşmeler gözlemlenmeye çalışılmıştır. Güvenilir bir tahmin modeli oluşturmak için farklı çıktılar analiz edilmiştir. Ortalama hata karesi 53,68 hektar², ortalama mutlak hata 3,36 hektar, ortalama mutlak oransal hata %51, ortalama hata karesinin kökü RMSE 7,33 hektar, bulanık mantık kullanımında ise en iyi toplam doğru tahmin oranı %99,94 ve grup bazında en iyi ortalama doğruluk değeri %65,63 olarak elde edilmiştir.

Anahtar Kelimeler: Orman yangını, Yanan alan tahmini, Yapay sinir ağları, Bulanık mantık, Temel bileşenler analizi, Destek vektör makineleri

University : TOBB Economics and Technology University
Institute : Institute of Natural and Applied Sciences
Science Programme : Computer Engineering
Supervisor : Assistant Professor Dr. A. Murat ÖZBAYOĞLU
Degree Awarded and Date : M.Sc. – December 2011

Recep BOZER

**ESTIMATION THE EXPECTED LOSS FROM A FOREST FIRE RELATED TO
GEOGRAPHICAL AND METEOROLOGICAL PARAMETERS BY USING
ARTIFICIAL INTELLIGENCE METHODS**

ABSTRACT

Forest fires are environmental issues that create economic problems as well as ecological damage. In this study, the loss due to the possible forest fire was estimated by using the records of previously occurred forest fire parameters like geographical conditions of the existing environment, day and hour when the fire broke out, meteorological data like temperature, humidity and wind speed, and type of trees and number of trees in unit area. The estimated output of this study is the lost area due to the fire. With reference to this output, an analysis about how a forest fire affects the environment was studied and a guideline for providing the proper resource management of fire fighting was aimed. The data used in this analysis was obtained from the Department of Forestry, a section of the Ministry of Forestry and Water Affairs in Turkey. This data set consists of 10.597 forest fire records which belong to the years between 2000 and 2009. During the organization of data, different fuzzy models were created for input parameters. The tests were implemented by using Multilayer Perceptron, Radial Basis Function Networks (RBFN), Support Vector Machines (SVM) and fuzzy logic. In order to observe improvements in the test results, input parameters were reorganized by using Principal Component Analysis (PCA). To create a reliable prediction model different outputs were analyzed. As a result, for performance measurement values were obtained as MSE 53,68 hectare², MAE 3,36 hectare, MAPE 51%, RMSE 7,33 hectare. From fuzzy logic experiments, the best total estimate rate was calculated as 99,94% and the best average accuracy value for fuzzy groups was obtained as 65,63%.

Keywords: Forest fire, Estimation of burned area, Neural networks, Fuzzy logic, Principal component analysis, Support vector machines

TEŐEKKÜR

Çalıřmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Yrd. Doç. Dr. A. Murat ÖZBAYOęLU'na, yine kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Bilgisayar Mühendislięi Bölümü öğretim üyelerine teşekkürü bir borç bilirim.

Bu çalıřma süresince şahsıma gösterdikleri anlayıř, sabır ve verdikleri destekten ötürü Türkiye Cumhuriyeti Gümrük ve Ticaret Bakanlığı İç Ticaret Genel Müdürlüęü Şirketler Dairesi Başkanı Sayın Adnan YANKIN'a ve çalıřma arkadaşım Sayın Erhan AĞIRMAN'a teşekkür ederim.

Ayrıca çalıřmamda kullandığım verileri elde etmemde sağladıkları kolaylıklar nedeniyle Türkiye Cumhuriyeti Orman ve Su İşleri Bakanlığı Orman Genel Müdürlüęü Orman Koruma ve Yangınla Mücadele Dairesi Başkanlığı Elektronik ve Haberleşme Şube Müdürü Sayın İlhami AYDIN ve personeline teşekkür ederim.

İÇİNDEKİLER

	Sayfa
ÖZET	v
ABSTRACT	vi
TEŞEKKÜR	vii
İÇİNDEKİLER	viii
ÇİZELGELERİN LİSTESİ	x
ŞEKİLLERİN LİSTESİ	xvi
KISALTMALAR	xix
1. GİRİŞ	1
2. GEÇMİŞ ÇALIŞMALAR	5
2.1. Orman Yangını Tahmininin Önemi	5
2.2. Orman Yangını Tahmini İle İlgili Geçmiş Çalışmalar	6
3. ÇALIŞMADA KULLANILAN TEKNİKLER	11
3.1. Yapay Sinir Ağları	11
3.2. Merkezci Tabanlı Fonksiyon Ağları	13
3.3. Bulanık Mantık	15
3.4. Temel Bileşenler Analizi	16
3.5. Destek Vektör Makineleri	16
4. VERİ KÜMESİNİN DÜZENLENMESİ	18
5. DENEY VE SONUÇLAR	38
6. SONUÇ VE TARTIŞMA	104
KAYNAKLAR	113

ÇİZELGELERİN LİSTESİ

Çizelge		Sayfa
Çizelge 4.1.	Bağıntı katsayıları	20
Çizelge 4.2.	Bakı parametresi dönüşümü	27
Çizelge 4.3.	$\ln(x+1)$ dönüşüm bağıntı katsayıları	32
Çizelge 5.1.	Yanan alan MP ve RBFN hata analiz tablosu	40
Çizelge 5.2.	Yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	40
Çizelge 5.3.	Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu	41
Çizelge 5.4.	Yanan alan bulanık çoğaltılmış veriler MP ve RBFN grup analiz tablosu	43
Çizelge 5.5.	Veri eleme MP ve RBFN hata analiz tablosu	45
Çizelge 5.6.	Öbekleme ile yeni yeri elde edilmesi MP ve RBFN hata analiz tablosu	45
Çizelge 5.7.	5 adet öbek sonucu oluşan merkez değerleri	46
Çizelge 5.8.	Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu	48
Çizelge 5.9.	Azaltılmış girdiler ile veri eleme MP ve RBFN hata analiz tablosu	50
Çizelge 5.10.	Azaltılmış parametreler veri eleme $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	52
Çizelge 5.11.	Azaltılmış parametreler öbekleme ile yeni veri elde edilmesi MP ve RBFN hata analiz tablosu	53
Çizelge 5.12.	Yeni veriler $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	54
Çizelge 5.13.	Azaltılmış parametreler 5 adet öbek sonucu oluşan merkez değerleri	55

Çizelge		Sayfa
Çizelge 5.14.	Yanan alan bulanık model kullanılan MP ve RBFN grup analiz tablosu	56
Çizelge 5.15.	Azaltılmış parametreler yanan alan $\ln(x+1)$ dönüşüm 5 adet öbek sonucu oluşan merkez değerleri	57
Çizelge 5.16.	Yanan alan $\ln(x+1)$ dönüşüm bulanık model kullanılarak MP ve RBFN grup analiz tablosu	59
Çizelge 5.17.	Test yerine eğitim veri kümesi kullanımı hata analiz tablosu	60
Çizelge 5.18.	Test yerine eğitim veri kümesi kullanılması yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	60
Çizelge 5.19.	Yeni verilerin elde edilmesi ile test yerine eğitim veri kümesi kullanımı hata analiz tablosu	61
Çizelge 5.20.	Yeni verilerin elde edilmesi ile test yerine eğitim veri kümesi kullanımı yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	61
Çizelge 5.21.	Bulanık model ile test yerine eğitim veri kümesi kullanımı MP ve RBFN grup analiz tablosu	62
Çizelge 5.22.	Bulanık model ile test yerine eğitim veri kümesi kullanımı yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN grup analiz tablosu	62
Çizelge 5.23.	3 adet öbek sonucu oluşan merkez değerleri	64
Çizelge 5.24.	Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu	65
Çizelge 5.25.	Yanan alan $\ln(x+1)$ dönüşüm 3 adet öbek merkez değerleri	66
Çizelge 5.26.	Yanan alan $\ln(x+1)$ dönüşüm bulanık model kullanılarak MP ve RBFN grup analiz tablosu	67
Çizelge 5.27.	PCA ile yanan alan MP ve RBFN hata analiz tablosu	69
Çizelge 5.28.	PCA ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	69
Çizelge 5.29.	PCA yeni veri elde edilmesi MP ve RBFN hata analiz tablosu	69

Çizelge	Sayfa
Çizelge 5.30. PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu	70
Çizelge 5.31. PCA yanan alan bulanık model MP ve RBFN grup analiz tablosu	70
Çizelge 5.32. PCA yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu	71
Çizelge 5.33. PCA yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu	72
Çizelge 5.34. PCA yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu	73
Çizelge 5.35. PCA ile yanan alan MP ve RBFN hata analiz tablosu	74
Çizelge 5.36. PCA ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	75
Çizelge 5.37. PCA yeni veri elde edilmesi MP ve RBFN hata analiz tablosu	75
Çizelge 5.38. PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu	76
Çizelge 5.39. PCA yanan alan bulanık model MP ve RBFN grup analiz tablosu	76
Çizelge 5.40. PCA yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu	77
Çizelge 5.41. PCA yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu	78
Çizelge 5.42. PCA yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu	79
Çizelge 5.43. 2 parametre ile yanan alan MP ve RBFN hata analiz tablosu	80
Çizelge 5.44. 2 parametre ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	81
Çizelge 5.45. 2 parametre yeni veri elde edilmesi MP ve RBFN hata analiz tablosu	81

Çizelge		Sayfa
Çizelge 5.46.	2 parametre yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu	81
Çizelge 5.47.	2 parametre yanan alan bulanık model MP ve RBFN grup analiz tablosu	82
Çizelge 5.48.	2 parametre yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu	83
Çizelge 5.49.	2 parametre yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu	84
Çizelge 5.50.	2 parametre yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu	85
Çizelge 5.51.	SVM ile yanan alan hata analiz tablosu	86
Çizelge 5.52.	SVM ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	86
Çizelge 5.53.	SVM yeni veri elde edilmesi hata analiz tablosu	87
Çizelge 5.54.	SVM yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu	87
Çizelge 5.55.	SVM ve PCA ile yanan alan hata analiz tablosu	87
Çizelge 5.56.	SVM ve PCA ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	88
Çizelge 5.57.	SVM ve PCA yeni veri elde edilmesi hata analiz tablosu	88
Çizelge 5.58.	SVM ve PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu	88
Çizelge 5.59.	SVM ve PCA ile yanan alan hata analiz tablosu	89
Çizelge 5.60.	SVM ve PCA ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	89
Çizelge 5.61.	SVM ve PCA yeni veri elde edilmesi hata analiz tablosu	90
Çizelge 5.62.	SVM ve PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu	90

Çizelge	Sayfa
Çizelge 5.63. SVM 2 parametre ile yanan alan hata analiz tablosu	91
Çizelge 5.64. SVM 2 parametre ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu	91
Çizelge 5.65. SVM 2 parametre yeni veri elde edilmesi hata analiz tablosu	92
Çizelge 5.66. SVM 2 parametre yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu	92
Çizelge 5.67. 2 adet öbek sonucu oluşan merkez değerleri	93
Çizelge 5.68. Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu	94
Çizelge 5.69. Yanan alan bulanık dönüşüm SVM grup analiz tablosu	94
Çizelge 5.70. Yanan alan $\ln(x+1)$ dönüşüm 2 adet öbek merkez değerleri	95
Çizelge 5.71. Yanan alan $\ln(x+1)$ dönüşüm bulanık model MP ve RBFN grup analiz tablosu	97
Çizelge 5.72. Yanan alan $\ln(x+1)$ dönüşüm bulanık model SVM grup analiz tablosu	97
Çizelge 5.73. Yeni veriler $\log(100x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	100
Çizelge 5.74. Yanan alan $\log(100x+1)$ dönüşüm 3 adet öbek merkez değerleri	100
Çizelge 5.75. 2 parametre yanan alan $\log(100x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu	102
Çizelge 5.76. 2 parametre ile yanan alan $\log(100x+1)$ dönüşüm MP ve RBFN hata analiz tablosu	102
Çizelge 5.77. 2 parametre yeni veri elde edilmesi yanan alan $\log(100x+1)$ dönüşümü MP ve RBFN hata analiz tablosu	103
Çizelge 6.1. Yangın kayıt örnekleri	105
Çizelge 6.2. Örnek kayıtlar için ölçülen hava durumu değerleri	106

Çizelge		Sayfa
Çizelge 6.3.	En iyi başarıml ölçüm sonuçları	108
Çizelge 6.4.	Test verisi yerine eğitim verisi kullanılması sonucu	109
Çizelge 6.5.	Test verisi yerine eğitim verisi kullanılması grup sonuçları	109
Çizelge 6.6.	5 bulanık grup sonuçları	110
Çizelge 6.7.	3 bulanık grup sonuçları	110
Çizelge 6.8.	2 bulanık grup sonuçları	111
Çizelge 6.9.	Bulanık gruplar genel sonuçları	111

ŞEKİLLERİN LİSTESİ

Şekil		Sayfa
Şekil 1.1.	Yangın üçgeni [1]	1
Şekil 1.2.	Orman yangını çıkış nedenleri	2
Şekil 3.1.	Yapay sinir ağı	11
Şekil 3.2.	Merkezcil tabanlı fonksiyon ağı [22]	14
Şekil 3.3.	Bulanık mantık örneği [24]	15
Şekil 3.4.	Doğrusal SVM örneği [28]	17
Şekil 4.1.	Nem yanan alan trend analiz sonucu	21
Şekil 4.2.	Rüzgar hızı yanan alan trend analiz sonucu	21
Şekil 4.3.	Sıcaklık yanan alan trend analiz sonucu	22
Şekil 4.4.	Bakı yanan alan trend analiz sonucu	22
Şekil 4.5.	Meyil yanan alan trend analiz sonucu	23
Şekil 4.6.	Mevsim yanan alan trend analiz sonucu	23
Şekil 4.7.	Saat yanan alan trend analiz sonucu	24
Şekil 4.8.	Ağaç tipi yanan alan trend analiz sonucu	24
Şekil 4.9.	Birim alandaki ağaç sayısı yanan alan trend analiz sonucu	25
Şekil 4.10.	Mevsim parametresi için bulanık model	26
Şekil 4.11.	Saat parametresi için bulanık model	26
Şekil 4.12.	Toplam hektar parametresi için bulanık model	28
Şekil 4.13.	Yanan toplam alan değerleri dağılımı	30

Şekil		Sayfa
Şekil 4.14.	Yanan toplam alan değerleri $\ln(x+1)$ dönüşüm dağılımı	31
Şekil 4.15.	Nem yanan alan $\ln(x+1)$ trend analiz sonucu	33
Şekil 4.16.	Rüzgar hızı yanan alan $\ln(x+1)$ trend analiz sonucu	33
Şekil 4.17.	Rüzgar hızı yanan alan $\ln(x+1)$ trend analiz sonucu	34
Şekil 4.18.	Bakı yanan alan $\ln(x+1)$ trend analiz sonucu	34
Şekil 4.19.	Meyil yanan alan $\ln(x+1)$ trend analiz sonucu	35
Şekil 4.20.	Mevsim yanan alan $\ln(x+1)$ trend analiz sonucu	35
Şekil 4.21.	Saat yanan alan $\ln(x+1)$ trend analiz sonucu	36
Şekil 4.22.	Ağaç tipi yanan alan $\ln(x+1)$ trend analiz sonucu	36
Şekil 4.23.	Birim alandaki ağaç sayısı yanan alan $\ln(x+1)$ trend analiz sonucu	37
Şekil 5.1.	Toplam hektar parametresi için bulanık model	46
Şekil 5.2.	Mevsim parametresi için yeni bulanık model	49
Şekil 5.3.	Saat parametresi için oluşturulan yeni bulanık model	49
Şekil 5.4.	Azaltılmış parametreler yanan toplam alan değerleri dağılımı	51
Şekil 5.5.	Azaltılmış parametreler yanan toplam alan $\ln(x+1)$ dönüşüm dağılımı	51
Şekil 5.6.	Yeni veriler yanan toplam alan değerleri dağılımı	53
Şekil 5.7.	Yeni veriler yanan toplam alan $\ln(x+1)$ dönüşüm dağılımı	54
Şekil 5.8.	Toplam hektar parametresi için bulanık model	55
Şekil 5.9.	Toplam hektar $\ln(x+1)$ dönüşüm parametresi için bulanık model	57
Şekil 5.10.	Yanan alan parametresi için bulanık model	64
Şekil 5.11.	Yanan alan $\ln(x+1)$ dönüşüm parametresi için bulanık model	66

Şekil		Sayfa
Şekil 5.12.	Yanan alan parametresi için bulanık model	93
Şekil 5.13.	Yanan alan $\ln(x+1)$ dönüşüm parametresi için bulanık model	96
Şekil 5.14.	Yanan toplam alan değerleri $\log(100x+1)$ dönüşüm dağılımı	99
Şekil 5.15.	Yanan alan $\log(100x+1)$ dönüşüm parametresi için bulanık model	101

KISALTMALAR

Kısaltmalar Açıklama

ART	Adaptive Resonance Theory (Adaptif Rezonans Teori)
CFFSDRS	Canadian Forest Fires Danger Rating System (Kanada Orman Yangını Tehlike Değerlendirme Sistemi)
DT	Decision Tree (Karar Ağacı)
EFFIS	European Forest Fire Information System (Avrupa Orman Yangını Bilgi Sistemi)
FBP	Fire Behavior Prediction (Yangın Davranış Tahmini)
FWI	Fire Weather Index (Yangın Hava İndeksi)
GIS	Geographic Information System (Coğrafi Bilgi Sistemi)
LFDB	Canada Large Fire Database (Kanada Geniş Yangın Veritabanı)
LVQ	Learning Vector Quantization (Öğrenmeli Vektör Kuantalama)
MAE	Mean Absolute Error (Ortalama Mutlak Hata)
MAPE	Mean Absolute Percentage Error (Ortalama Mutlak Oransal Hata)
MP	Multilayer Perceptron (Çok Katmanlı Algılayıcılar)
MR	Multiple Regression (Çoklu Regresyon)
MSE	Mean Square Error (Ortalama Hata Karesi)
NFDRS	National Fire Danger Rating System (Ulusal Yangın Tehlike Derecelendirme Sistemi)
NN	Neural Networks (Yapay Sinir Ağları)
PCA	Principal Component Analysis (Temel Bileşenler Analizi)
RBFN	Radial Basis Function Networks (Merkezcil Tabanlı Fonksiyon Ağları)
RF	Random Forest (Karar Ormanları)
RISICO	RISchio Incendi e COordinamento
RMSE	Root Mean Square Error (Ortalama Hata Karesinin Kökü)
SOM	Self Organizing Maps (Özdüzenleyici Haritalar)
STDM	Spatio-Temporal Data Mining (Mekan-Zaman Veri Madenciliği)
SVM	Support Vector Machines (Destek Vektör Makineleri)

1. GİRİŞ

Orman yangınları, ormanları ve doğal yaşamı tehdit eden önemli çevresel olaylardan biridir. Genel olarak, serbestçe yayılabilen, ormandaki bütün yaşayan birimlerle birlikte tüm doğal birimleri yakabilen ateşe orman yangını denilmektedir [1].

Yanma olayı yüksek sıcaklıklarda meydana gelen bir kimyasal reaksiyon olup, orman yangınlarında bitkiler tarafından fotosentez yoluyla depo edilen ısı enerjisini açığa çıkartmaktadır. Yanma olayının gerçekleşebilmesi için ortamda oksijen, tutuşmayı sağlayacak başlangıç sıcaklığı ve yanıcı maddenin bir arada bulunması gerekmektedir. Bu üçlünün bir arada bulunması Şekil 1.1.'de görüldüğü gibi yanma üçgeni olarak ifade edilmektedir [1].




Şekil 1.1. Yangın üçgeni [1]

Bir ortamda yanma üçgeninde bulunan unsurlardan birinin eksik olması, yanma olayının gerçekleşmemesine neden olmaktadır. Buna göre, orman yangınının yayılma özelliğiyle birlikte yangının türü ve şiddeti Şekil 1.1.'de bulunan unsurların miktarına ve niteliğine bağlıdır. Bu unsurlar incelendiğinde, yangının çıkmasına yol açan ilk faktörün ilk kıvılcımın yol açtığı tutuşma ısısı ya da sıcaklığı olduğu görülmektedir. 240-400 °C arasında tutuşma meydana gelmektedir. İkinci faktör olan oksijen havada %20-21

oranında bulunmaktadır ve bu miktar %15'in altına düştüğünde yanma olayı gerçekleşmemektedir. Üçüncü faktör ise tutuşmayı sağlayan yanıcı maddedir.

Orman yangınları çıkış nedenlerine göre incelendiğinde en önemli payı %59'luk bir oranla ihmal ve dikkatsizlik almaktadır. Bunlar insanların her türlü sosyal ve ekonomik faaliyetlerinde yangınların çıkmasını engelleyecek önlemleri almamaları sonucu ortaya çıkan orman yangınlarıdır. Nedeni bilinmeyen ve çıkışı hakkında hiçbir bilgi edinilememiş yangınlar %20'lik bir orana sahipken, %12'lik bir oranla içerisinde terör, kundaklama ve yer açma gibi nedenleri içeren kasıt, %9'luk bir oranla ise orman yangınlarının çıkışına neden olan doğal bir etmen olarak yıldırım yer almaktadır [1].



Şekil 1.2. Orman yangını çıkış nedenleri

Orman yangınları pek çok faktör tarafından etkilenmektedir. Topografya yangınların seyri açısından önemlidir. Orman yangını gündüzleri yamaç aşağı yavaş ilerlerken yamaç yukarı yangın alevinin yanıcı maddelere yakın olması nedeniyle hızla ilerler. Gece ise sıcaklık aşağılarda yüksek olduğundan yayılma yamaç aşağı doğru hızlıdır. Ülkemizde güney bakılarda nem miktarı güneş ışınları etkisiyle kısa zamanda azalır.

Aynı zamanda güney bakılarda ince ve çabuk tutuşabilen yanıcı madde miktarı fazla olduğundan yangın duyarlılığı kuzey bakılara oranla fazladır. Kuzey bakılarda ise nem miktarıyla birlikte kalın ve zor tutuşan yanıcı madde miktarı fazladır. Bu da, kuzey bakılarda yangının zor tutuşmasına fakat meydana gelen yangınlarda büyük enerji açığa çıkmasına neden olmaktadır.

Orman yangınları nem, sıcaklık, rüzgar hızı, havanın açık ya da kapalı olması, yangın mevsimi boyunca yağın yağmur miktarı dağılımı, en son yağış zamanı, havanın kararlılığı ya da kararsızlığı gibi hava durumlarından etkilenmektedir. Nem miktarı, yağışa, yağışlı gün sayısına, rüzgar yön ve hızına, hava sıcaklığına, güneşlenme şiddetine, bulunulan yerin deniz ve göl gibi geniş su yüzeylerine olan uzaklığına bağlı olarak değişiklik gösterir. Nem, yanıcı madde ıslaklığını belirlediğinden tutuşmayı kolaylaştırıcı ya da zorlaştırıcı bir etki gösterir. Rüzgar, yanıcı maddenin nemini azaltır veya artırır, bu nedenle yanmayı çabuklaştırdığı gibi yanma hızını da düşürebilir. Rüzgar, deniz, göl ya da baraj gibi su kütleleri üzerinden geliyorsa nem artırıcı, geniş kara kütleleri üzerinden geliyorsa nem azaltıcı etki göstermektedir. Havanın alt ve üst katmanları arasında sıcaklık farkı olmadığında hava karardır. Bu seviyeler arasında sıcaklık farklarının olması havanın kararsız olmasına ve dikey faaliyetlerle birlikte bulut oluşumuna neden olmaktadır. Bulutlanmalar gök gürültülü sağanak yağışlarla birlikte yıldırım oluşumunu etkiler. Yıldırımlar, ülkemizde özellikle ağustos sonu eylül başı dönemlerinde günde ortalama 45 adet orman yangınına neden olmaktadır [1].

Bu çalışmada, ekolojik olduğu kadar ekonomik zararlar da veren orman yangınlarında beklenen kayıplar geçmiş orman yangını kayıtlarındaki parametrelere bağlı olarak değişik yapay zeka yöntemleri ile tahmin edilmeye çalışılmış, böylece orman yangınlarının verdiği zararların azaltılması hedeflenmiştir. Çalışma dahilinde, 2. bölüm orman yangını tahmininin önemi ve bu konuda yapılmış geçmiş çalışmaları, 3. bölüm çalışmada kullanılan teknikler ile ilgili bilgileri, 4. bölüm çalışmada kullanılan veri

kümesinin düzenlenmesi ile ilgili yöntemleri, 5. bölüm yapılan deney ve bu deneylerin sonuçlarını, 6. ve son bölüm de çalışma genel sonucu ve tartışmaları içermektedir.

2. GEÇMİŞ ÇALIŞMALAR

2.1. Orman Yangını Tahmininin Önemi

Dünyada her yıl ortalama 4 milyon hektar orman yanarak yok olmaktadır. Bu miktar, özellikle orman yangınına kolaylaştıran sıcaklık ve yanıcı madde miktarının fazla olduğu Akdeniz iklim kuşağında 550 bin hektar civarındadır [1].

Orman yangınları sadece doğal yaşama ve çevreye zarar verip ekolojik dengeyi bozmakla kalmaz, ayrıca insan hayatı ve onun sahip oldukları için bir tehdit unsuru oluşturur. Bu bağlamda incelendiğinde, orman yangınları öncelikle yaşam kayıplarına neden olmaktadır. Yeşil, ağaçlık alanları yok etmesiyle birlikte büyük çevresel felaketlere yol açmaktadır. Ormandaki yanıcı maddelerin yanmasıyla birlikte atmosfere salınan karbondioksit miktarı 30-40 kg/ton kadardır [2]. Açığa çıkan zararlı gazların yanında toprak kayıpları, erozyon, hayvan yaşamı ve bitki örtüsünün yok olması, su kaynaklarının ve su döngüsünün zarar görmesi başlıca kayıplar arasında görülmektedir. Bütün bunlar hesaba katıldığında orman yangınlarının yol açtığı finansal kayıplar büyük miktarlara ulaşmaktadır. Yangın ile mücadelede yer alan insan kaynakları, malzeme giderleri, yangın öncesi yürütülen yangın önleme kampanyaları, bilinçlendirme çalışmaları, yangın öncesi ve sonrası ağaçlandırma bedelleri ile birlikte ağaç endüstrisinin kayıpları dikkate alındığında ekonomik kaybın büyüklüğü ortaya çıkmaktadır [3].

Birçok orman yangını hızlı müdahale ile kısa zamanda söndürülebilirken, bazıları hızlı ve etkili müdahalelere rağmen kontrol altına alınamamakta ve böylece büyük çevresel yıkıma neden olmaktadır. Örneğin; 1983 yılında Victoria, Avustralya'da meydana gelen orman yangını 392.000 hektar ormanlık alanın yanmasıyla sonuçlanırken, 75 insanın ölümüne neden olmuştur [4]. Hindistan'da 1985 ile 1990 yılları arasında 17.852 adet orman yangını kaydı alınmış, bu yangınlarda toplam 5.700.000 hektar ormanlık alan yok

olmuştur [5]. Akdeniz iklim kuşağında yer alan Portekiz’de 2003 yılında 420.000 hektar ormanlık alan yanarken, çıkan yangınlar 20 insanın hayatına mal olmuş [6], İspanya’da ise 2006 yılında çıkan yangınlarda toplam 150.000 hektar ormanlık alan kaybedilmiştir [7]. Kanada’da 1951 yılından itibaren yılda ortalama 8.000 orman yangını meydana gelirken, bu yangınlarda yıllık ortalama yanan alan 2.500.000 hektar olmuştur. Bu yangınların Kanada’ya maliyeti ise ortalama yıllık 300 ile 500 milyon dolar arasında değişmiştir [8].

Ülkemiz de, Portekiz ve İspanya gibi Akdeniz iklim kuşağında yangına karşı çok hassas bir bölgede yer almaktadır. Özellikle ormanlarımızın %60’ı yangına birinci derecede hassas bölgede bulunmaktadır. Orman yangınlarının ülkemiz açısından önemini 2008 yılında gerçekleşen 2.135 adet orman yangını ve bu yangınlarda yok olan toplam 29.749 hektar ormanlık alan ile gösterebiliriz. 2008 yılında meydana gelen bu yangınlarda yanan ağaçlardan oluşan zararlar ile birlikte ağaçlandırma ve diğer söndürme masraflarının toplamı yaklaşık olarak 126.000.000 TL olmuştur [1]. Bu, orman yangınlarının özellikle ülkemiz gibi yangına hassas bölgelerde yer alan ülkeler açısından önlenmesi gerekliliğini göstermektedir.

2.2. Orman Yangını Tahmini ile İlgili Geçmiş Çalışmalar

Orman yangınlarının hızlı bir şekilde belirlenmesi, kontrol edilmesi ve yangın yönetiminin verimli bir şekilde yapılabilmesi için pek çok ülke orman yangını veri tabanı ya da bilgi sistemi oluşturmaktadır. Örneğin; Kanada her il, bölge ve ormanlık alan için 200 hektardan daha büyük yangın kayıtlarının yer aldığı bir veri tabanına sahiptir (Canada Large Fire Database-LFDB) [8]. Avrupa Birliği Komisyonu ise 14 üye ülkenin her yıl orman yangını verilerini paylaştığı Avrupa Orman Yangını Bilgi Sistemi’ni (European Forest Fire Information System-EFFIS) [9] oluşturmuştur. Bu tür veri tabanları ve bilgi sistemlerinin oluşturulmasındaki amaç, orman yangınları ve ilgili hava durumu bilgilerinin sistematik olarak kayıt altına alınması ve böylece orman

yangını özelliklerinin anlaşılır ve tahmin edilebilir olmasıdır [10]. Orman yangınlarının tahmin edilebilir olması, yangınların neden olacağı ekolojik ve ekonomik zararların ortadan kaldırılması açısından büyük önem taşımaktadır.

Orman yangınlarının meydana gelmesi hakkında tahmin çalışmaları, orman yangını tahmin sistem ya da indeksleri ve orman yangını tahmini için yapay zeka çalışmaları olmak üzere iki aşamada yürütülmüştür.

Orman yangını tahmini ile ilgili en önemli sistem Kanada Orman Servisi tarafından Kanada Orman Yangını Tehlike Değerlendirme Sistemi (Canadian Forest Fires Danger Rating System-CFFSDRS) adı altında 1968 yılında oluşturulmuştur [11]. Karmaşıklığı azaltmak amacıyla sistem iki alt sisteme ayrılmıştır. Bunlardan ilki Yangın Hava İndeksi (Fire Weather Index-FWI) olarak adlandırılan, sadece gün içinde kaydedilen meteorolojik verileri kullanan ve yangının yayılma oranına bağlı olarak tehlike indeksi oluşturan alt sistemdir. FWI, topografik bilgilerden tamamen bağımsızdır ve yangının meydana geldiği yerde bulunan yakıt tiplerini dikkate alır. Bu nedenle benzer hava koşullarında farklı yakıt tipleri için FWI değişiklik göstermektedir. Diğer bir alt sistem ise Yangın Davranış Tahmini (Fire Behavior Prediction-FBP) olarak adlandırılmıştır. FBP, bitki örtüsü de dahil olmak üzere topografik verileri kullanarak yangının davranışını tahmin etmeye çalışır. Diğer bir sistem, Amerikan Modeli olarak adlandırılan Ulusal Yangın Tehlike Derecelendirme Sistemidir (National Fire Danger Rating System-NFDRS) [12]. Bu sistem, yakıt nemi, hava verileri ve yayılma oranı eğimini dikkate alarak gelecek 24 saat içinde yangın olma riskini tahmin etmektedir. Avustralya yangın tehlike indeksi ise istatistiksel bir sistemdir [13]. Yangın oluşumu ile sıcaklık, rüzgar hızı, toprak nemi ve yanıcı madde miktarı arasında ilişki kurmuş, her bitki örtüsü için bir eşitlik bulunmuş ve belli bitki örtülerindeki yangın yayılma tehlikesine göre yayılma indeksi oluşturulmuştur. Bunların dışında özellikle Akdeniz ülkeleri tarafından deneysel sistemler oluşturulmuştur. RISICO (RISchio Incendi e COordinamento) İtalya tarafından oluşturulan hava durumu verilerini kullanıp 72 saatlik

tahmin yapan modelin adıdır [14]. Bu modelde bitki örtüsü ve topografya gibi statik verilerin yanında hava durumu gibi dinamik veriler de kullanılmıştır.

Orman yangını tahmin sistemleri dışında, orman yangınları ile ilgili oluşturulan veri tabanları kullanılarak orman yangını tahminleri için yapay zeka modelleri geliştirilmiştir. Brillinger ve arkadaşlarının yaptığı çalışmada [15] her bir bölge için yangın tarihi, deniz seviyesinden yüksekliği, daha önceki yangınlı ve yangınsız gün sayısı ele alınarak bir model oluşturulmuş, belli bir bölge ve zamandaki yangın olasılığı tahmin edilmiştir. Bu modelde hava durumu verisi kullanılmamıştır. Model çıktısı ise belli bir eşik değerden büyük yangın sayılarının olasılığıdır. Model çalışılan alana bağımlı olduğundan diğer bölgeler için genelleştirilme yapılamamaktadır. Jaiswal ve arkadaşlarının yaptığı çalışmada [16] Coğrafi Bilgi Sistemi (Geographic Information System-GIS) tabanlı orman yangını tehlike modeli oluşturulmuş, bitki örtüsü, iklim, topografya ve bunlarla ilişkili faktörlerin orman yangını oluşturma ilişkisi incelenmiştir. Çalışma kapsamında 4 kategoriden oluşan risk ölçütü kullanılarak orman yangını tehlike bölgesi oluşturulmuştur. Bu model de, Brillinger ve arkadaşlarının yaptığı çalışmada [15] oluşturulan model gibi çalışılan alana bağımlıdır ve diğer bölgeler için genelleştirilememektedir. Genel anlamda orman yangını tehlike tahmini, bulanık mantık ve bulanık cebir uygulanarak oluşturulan karar destek sisteminin kullanılması Iliadis tarafından yapılan çalışmada [17] gösterilmiştir. Bu çalışmada, bulanık kümeleri (fuzzy set) ve bulanık otomatik öğrenme (fuzzy machine learning) tekniklerinin değişik yönlerini temel alan bir çıkarım mekanizması uygulayan karar destek sistemi oluşturulmuştur. Uygulanan yöntem ile Yunanistan'da riskli bölgelerin tahmini yapılmış ve tahmin sonuçlarına göre 20 en riskli bölgeden 12 tanesi için doğru sonuç alınmıştır. Bu da, uygulanan yöntemin %60 başarı sağladığını göstermiştir. Bunların dışında öbeleme teknikleri de orman yangını tahmin uygulamaları için kullanılmıştır. Yapılan çalışmalarda Mekan-Zaman Veri Madenciliği (Spatio-Temporal Data Mining-STDM) tekniklerinin orman yangını tahmini için uygun olduğu görülmüştür. Yanan alanla ilgili geçmiş veriler kullanılarak yanan alan ve yangın alanı büyüklüğünün tahmin edilmesi,

devam eden orman yangınının ilerlemesinin tahmin edilmesi için ilişkili kural madenciliği (association rule mining) kullanılması, mantıksal kurallar koyarak sıklıkla tekrar eden desenlerin tanımlanması, öbeleme ile yangın alanlarının tanımlanması ve yangının başlayabileceği yüksek olasılıklı yerlerin belirlenmesi STDM'in orman yangını uygulamaları olarak görülebilir [18]. Bunlara ek olarak hücresele otomata (Cellular Automata) ya da ajan tabanlı modelleme (Agent-Based Modelling) gibi yeni teknikler oluşturulmuştur. Hücresele otomatada, yangın alanı hücrelere ayrılmış, yanan bir hücrenin yanmayan komşusunda yangın başlatması ile hücreler arasında yangının yayılma süreci modellenmiştir [19]. STDM teknikleri ile yangın sonucu yanan alan tahmini Cheng ve Wang'ın yaptığı çalışmada [10] yapılmıştır. Bu çalışmada yangın alanının geçmiş yangın verileri ve hava durumu verileri özyineli yapay sinir ağı (Recurrent Neural Network) ile birlikte kullanılmıştır. Çalışma sonucunda 200 hektar ormanlık alanda 0,5 hektardan daha az hata görülmüştür. Cortez ve Morais'in yaptığı çalışmada [20] değişik veri madenciliği teknikleri ve meteorolojik veriler kullanılarak orman yangını ve bu yangınla ilgili olarak yanabilecek alan tahmini yapılmıştır. Tahmin için kullanılacak en iyi girdi parametrelerinin bulunması için denemeler yapılmış, sonuç olarak rüzgar, sıcaklık, nem ve yağışın en iyi parametreler olduğuna karar verilmiştir. Çoklu regresyon (Multiple Regression-MR), karar ağacı (Decision Tree-DT), karar ormanları (Random Forest-RF), yapay sinir ağları (Neural Networks-NN) ve destek vektör makineleri (Support Vector Machines-SVM) olmak üzere 5 farklı veri madenciliği tekniği uygulanmış ve en iyi sonuç SVM kullanımı ile gerçekleşmiştir. Bu çalışma, küçük orman yangınlarının tahmininde iyi sonuç vermiş, eğer 1 hektarlık hata kabul edilirse %46, eğer 2 hektarlık hata kabul edilirse %61 başarı sağlamıştır. Buna ek olarak, orman yangını tahmininde kullanılan girdi parametrelerinin sayısını azaltmak, hava tahmini mekanizmasının ve buna bağlı olarak yanlış hava tahminlerinin neden olduğu hataları devre dışı bırakmak ve en önemlisi gelişmekte olan ülkeler için teknik ve ekonomik imkansızlıklar nedeniyle tahmin sistemlerinin kurulamaması engelini aşmak amacıyla, sadece nem ve yağış parametrelerini girdi olarak kullanan çalışma Sakr ve arkadaşlarının yaptığı çalışmada [21] yapılmıştır. Çalışmada, NN ve SVM kullanılarak


dönemsel oluşacak yangın sayısı tahmini ile yangın var/yangın yok senaryosu test edilmiştir.

3. ÇALIŞMADA KULLANILAN TEKNİKLER

3.1. Yapay Sinir Ağları

Yapay sinir ağı; insan beyninin sinir hücrelerinden oluşmuş katmanlı ve paralel olan yapısını tüm fonksiyonlarıyla beraber yazılım ve donanımsal olarak gerçekleştirmeye çalışan modellerdir. Buna göre yapay sinir ağları, insanlar tarafından gerçekleştirilmiş örnekleri kullanarak olayları öğrenebilen, çevreden gelen olaylara karşı nasıl tepkiler üreteceğini belirleyebilen bilgisayar sistemleridir [22].

Yapay sinir ağları birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen yapay hücrelerden oluşmuştur. Proses elemanları da denilen bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Basit bir yapay sinir ağı Şekil 3.1.'de görülmektedir.



Şekil 3.1. Yapay sinir ağı

Bir yapay sinir ağında, girdiler yapay sinir hücresine dış dünyadan gelen bilgilerdir. Ağırlıklar gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Ağırlıkların

büyük ya da küçük olması önemli ya da önemsiz olduğu anlamına gelmez. Artı ya da eksi değerli olması etkisinin pozitif veya negatif olduğunu gösterir. Toplama fonksiyonu hücreye gelen net girdiyi hesaplar. En yaygın olan ağırlıklı girdiyi bulmaktır. Burada her gelen girdi kendi ağırlığı ile çarpılarak toplanır ve net girdi bulunur. Bir problem için en uygun toplama fonksiyonunu bulmanın bir formülü yoktur. Genellikle deneme yanılma yolu ile toplama fonksiyonu belirlenmektedir. Aktivasyon fonksiyonu hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Genel olarak sigmoid fonksiyonu kullanılır. Çıktı aktivasyon fonksiyonunun değeridir. Ağın ürettiği bu çıktı değeri dış dünyaya, kendisine ya da başka bir sinir hücresine gönderilir.

Yapay sinir ağlarının, öğrenmek ve öğrendiğinin sorgulaması yapıldığında buna yanıt vermek olmak üzere temel iki işlevi vardır. Yapay sinir ağındaki proses elemanlarının bağlantılarının ağırlık değerlerinin örnekler gösterildikçe değiştirilmesi ve bu değerlerin belirlenmesi işlemi ağın eğitilmesi olarak adlandırılmaktadır. Yapay sinir ağının kendisine verilen girdilere karşı doğru çıktıyı vermesi ise ağın öğrenmesidir.

Yapay sinir ağları kendisine gösterilen örneklere bakarak öğrenen sistemlerdir. Yapay sinir ağı öğrenmesinde genel olarak öğretmenli öğrenme, destekleyici öğrenme, öğretmensiz öğrenme ve karma öğrenme stratejileri uygulanır. Öğretmenli öğrenmede, öğretmen sisteme öğrenilmesi istenilen olay ile ilgili örnekleri girdi-çıktı seti olarak verir. Yani her örnek için hem girdiler hem de o girdiler karşılığında oluşturulması gereken çıktılar sisteme gösterilirler. Sistemin görevi girdileri öğretmenin belirlediği çıktılara haritalamaktır. Bu tip öğrenmede, girilen değerlerin ne tür bir çıktı vermesi gerektiği önceden bilinmekte ve yapay sinir ağı ağırlıkları bu değerlere göre güncellenmektedir. Örnek olarak çok katmanlı algılayıcılar gösterilebilir. Destekleyici öğrenmede, sisteme bir öğretmen yardımcı olur. Fakat öğretmen her girdi seti için olması gereken çıktı setini sisteme göstermek yerine, sistemin kendisine gösterilen girdilere karşılık ilgili çıktıyı üretmesini bekler ve üretilen çıktının doğru veya yanlış olduğunu gösteren bir sinyal üretir. Sistem, öğretmenden gelen sinyali dikkate alarak


öğrenme sürecine devam eder. Örnek olarak öğrenmeli vektör kuantalama (Learning Vector Quantization-LVQ) ağı gösterilebilir. Öğretmensiz öğrenmede, sisteme sadece girdi değerleri gösterilir. Örneklerdeki parametreler arasındaki ilişkileri sistemin kendi kendisine öğrenmesi beklenir. Sistem, aldığı bilgileri kendi içerisinde kıyaslama yapıp sınıflandırması ile öğrenme sürecini tamamlar. Bunun için ağ, aldığı ilk örneği bir sınıf olarak ilan eder ve geriden gelen tüm girdi örneklerini o sınıfa benzetmeye çalışır. Böylece tüm girdi örüntülerini kendi aralarında benzeyip benzememelerine göre ayırt eder. Bu yöntem daha çok sınıflandırma problemleri için kullanılmaktadır. Sistem öğrenmesi bittikten sonra çıktıların ne anlama geldiğini gösteren etiketlendirmeyi yapamaz, bunun kullanıcı tarafından yapılması gerekmektedir. Örnek olarak adaptif rezonans teori (Adaptive Resonance Theory-ART), özdüzenleyici haritalar (Self Organizing Maps-SOM) ağları gösterilebilir.

Yapay sinir ağlarında tek katmanlı algılayıcılar (Perceptron) girdi ve çıktı elemanlarından oluşur. Her bağlantının bir ağırlığı vardır. Bir yapay sinir ağının öğrenmesi istenen olaylarında, girdi ve çıktıları arasındaki ilişkiler doğrusal olmayan ilişkiler olursa o zaman tek katmanlı algılayıcılar ile öğrenme gerçekleşemez, çok katmanlı algılayıcılar (Multilayer Perceptron-MP) gibi yapay sinir ağları kullanılmalıdır. Çok katmanlı algılayıcılar özellikle daha karmaşık durumlarda sınıflandırma, tanıma ve genelleme yapmayı gerektiren problemler için önemli bir çözüm aracıdır.

3.2. Merkezil Tabanlı Fonksiyon Ağları

Merkezil tabanlı fonksiyonlar özel fonksiyon sınıflarıdır. Temel özellikleri ise fonksiyon cevaplarının merkezden olan uzaklık ile monoton olarak artması ya da azalmasıdır [23]. Bu fonksiyonlar herhangi bir doğrusal ya da doğrusal olmayan modelde ya da herhangi bir ağda uygulanabilirler.

Merkezcil tabanlı fonksiyon ağları (Radial Basis Function Networks-RBFN), aktivasyon fonksiyonları olarak merkezcil tabanlı fonksiyonları (Radial Basis Functions) kullanan ağlardır [22]. Şekil 3.2. genel bir merkezcil tabanlı fonksiyon ağının yapısını göstermektedir [23].




Şekil 3.2. Merkezcil tabanlı fonksiyon ağı [23]

Merkezcil tabanlı fonksiyonlar ara katmana yayıldıklarında girdi örüntüleri için merkez oluşturmaktadırlar. Merkezcil fonksiyonların karakteristik özellikleri tepkilerinin merkezi noktadan uzaklık ile monoton olarak artması ya da azalmasıdır. RBFN ile MP arasında önemli bir fark bulunmaktadır. MP’de aktivasyon fonksiyon girdileri, girdi özellik parametrelerinin doğrusal bir kombinasyonudur, ve bu nedenle nöronun çıktısı tüm girdi parametreleri için aynıdır. Bu nedenle çıktı S uzayındaki tüm noktalar için aynıdır. RBFN’te ise her düğümün çıktısı ilgili merkezden aynı Öklid uzaklığına sahip bütün noktalar için aynıdır. Başka bir deyişle, düğümlerin aktivasyon tepkileri RBFN için yerel, MP için evrenseldir [24]. Bu durum hem yakınsama hızı hem de genelleştirme performansları açısından bir etki yaratır. Genel olarak MP’lar RBFN’lere oranla daha yavaş öğrenirler. Fakat özellikle eğitim setinde yeteri kadar temsil edilemeyen alanlar

için gelişmiş genelleştirme özelliği sunarlar. Bir RBFN'ün MP ile aynı performansa sahip olması için daha yüksek dereceli olması gerekmektedir.

3.3. Bulanık Mantık

Bulanık mantık (Fuzzy Logic), klasik mantık kurallarının esnekleştirilmiş ve biraz daha hafifletilmiş şeklini kullanmaktadır. Mantıksal önermeler klasik mantıkta sadece 0 ve 1 şeklinde katı değerler alır ve bunların dışına çıkamazken, bulanık mantıkta 0 ve 1 değerlerinin arasında kalan tüm değerler de sistemin birer parçası haline getirilmiştir [25]. Örneğin; “Bugün hava sıcaklığı 10 derece” şeklinde bir önerme klasik mantık içerisine girerken, “Bugün hava soğuk” şeklinde bir önerme bulanık mantık içerisindedir. Görüldüğü gibi klasik mantıktaki önerme katı bir değer ifade ederken, bulanık mantıktaki önerme genel bir hava durumundan bahseder ve ifade sistemde soğuk tanımının nasıl yapıldığına bağlı olarak değişir. Buna göre klasik mantıkta bir önerme ya doğrudur ya da yanlıştır. Dolayısıyla hem doğru hem yanlış olma durumu yoktur. Fakat bulanık mantıkta bir önermenin içinde belirli bir ölçüde doğruluk ve yanlışlık payı bulunmaktadır.



Şekil 3.3. Bulanık mantık örneği [25]

Şekil 3.3. incelendiğinde, şeklin sol kısmı klasik mantıktaki siyah ve beyaz ayırımını, sağ kısmı ise bulanık mantıktaki ayırımı göstermektedir. Sol kısımda siyah ve beyaz olma durumu için kesin ve katı bir ayırım söz konusudur. Ancak sağ kısımda gördüğümüz gibi bir renk hem siyah hem beyaz olabilir, ikisine de belli ölçüde dahil olduğu durumlar olabilir, kesin ve katı bir ayırım söz konusu değildir. Bu durumda bir renk hem siyah hem de beyaz kümelerinde belli bir üyelik derecesiyle temsil edilebilir.

Üyelik derecesi ise bir elemanın bir kümeye ne derecede ait olduğunu gösteren bir ifadedir.

3.4. Temel Bileşenler Analizi

Temel bileşenler analizi (Principal Component Analysis-PCA), çok sayıda birbiri ile ilişkili değişkenler içeren veri kümesinin boyutlarının, veri içerisinde bulunan değişimlerin mümkün olduğunca korunarak aza indirgenmesini sağlayan dönüşüm yöntemidir [26]. Dönüşüm sonrasında elde edilen değişkenler ilk değişkenlerin temel bileşenleri olarak adlandırılır. İlk temel bileşen varyans değeri en büyük olandır ve diğer temel bileşenler varyans değerleri azalacak şekilde sıralanır [27]. PCA ile büyük boyutlu veri kümesinden anlamlı veriler elde edilebilmekte, büyük boyutlu veri kümelerinde benzerlikler ve farklılıklar ortaya koyulabilmektedir. PCA ile verilerin boyutu azaltılmakta, tahminleme yapılmakta ve veri seti bazı analizler için görüntülenmektedir.

PCA örüntü tanıma sistemlerinde sıkça kullanılan istatistiksel bir yöntemdir. PCA'nın amacı görüntü uzayında nesnelere dağılımını en iyi şekilde veren vektörü bulmaktır. Bu vektör orijinal nesnelere karşılık gelen kovaryans matrisinin öz vektörüdür.


PCA'de veriler alındıktan sonra ortalama hesaplanır. Daha sonra kovaryans matrisi ile birlikte özdeğer ve özvektör hesaplanır. Özdeğerlere göre özvektörler sıralanıp özellik vektörü oluşturulur. Son olarak, baştaki veriler özellik vektörü ile çarpılıp özellik uzayına transfer edilir.

3.5. Destek Vektör Makineleri

Destek vektör makineleri (Support Vector Machines-SVM), sınıflandırma problemlerinin çözümünde kullanılan en etkili yöntemlerden birisidir. Destek vektör makineleri sınıflandırma tekniği, istatistiksel öğrenme teorisine dayalı bir eğitimli

sınıflandırma tekniği olup temelleri Vapnik tarafından geliştirilmiştir [28]. SVM sınıflandırmasında başlıca üç aşama bulunmaktadır; eğitim hücrelerinin özellik vektörü olarak ifade edilmesi, özellik vektörlerinin özellik uzayına eşlenmesi ve sınıfları en uygun şekilde ayıran n-boyutlu hiper düzlemin oluşturulması [28].

Buna göre SVM temel olarak iki sınıflı bir veriye ait bir nokta kümesini ayıran en iyi alt düzlemi bulmaya çalışır. Eğer veri doğrusal olarak ayrılabilir değilse, destek vektör makineleri doğrusal olmayan haritalama ile veriyi çok boyutlu öznelik uzayına eşler. Bu işlem polinomsal ya da RBF gibi çeşitli doğrusal olmayan eşlemeler kullanılarak yapılır. Doğrusal olmayan bu dönüşümden sonra destek vektör makinesi öznelik uzayı içerisindeki en iyi ayırıcı düzlemi bulur. Şekil 3.4.'te doğrusal SVM örneği görülmektedir.



Şekil 3.4. Doğrusal SVM örneği [29]

SVM için genel yaklaşımlardan farklı bir yaklaşım kullanılmaktadır. Boyut azaltılmak yerine, veri çok boyutlu başka bir uzaya eşlenmekte, verimliliklerine bakılmadan yeni özellikler eklenmekte ve bu çok boyutlu uzayda sınıflandırma kuralı bulunmaya çalışılmaktadır [30].

4. VERİ KÜMESİNİN DÜZENLENMESİ

Orman yangınları pek çok faktör tarafından etkilenir. Sıcaklık, bağıl nem, rüzgar gibi hava durumları, orman yangınlarının yayılma özelliğini etkileyen en önemli unsurlardır [1].

Orman içindeki yanıcı içeriğin ıslaklığıyla ilişkili olan bağıl nem, sabahın erken saatlerinde en üst seviyeye ulaşırken, gün ortasına gelindiğinde en düşük değeri almaktadır. Orman yangınları açısından tehlike, havadaki nem oranının %40 'tan az olması ile başlar, fakat en tehlikeli oran ise nemin %10 'un altına inmesi durumudur. Artan sıcaklık ile birlikte buharlaşma da artmaktadır. Artan buharlaşma ise orman içindeki yanıcı içeriğin neminde hızlı bir düşüş meydana getirmektedir. Ülkemiz için yangın riski 25 °C 'de başlamakta ve sıcaklık arttıkça yangın riski de artmaktadır [1].

Yangını etkileyen başka bir hava etmeni ise rüzgardır. Rüzgar, yanan maddelerin üzerinde yıkıcı bir etkiye sahip olmanın yanında, yangının hızlı bir şekilde yayılmasına neden olmakta ve orman yangını mücadelesini olumsuz bir şekilde etkilemektedir. Orman yangınları açısından 15 km/saat ve üzeri hızla esen rüzgarlar risk oluşturmaktadır [1].

Hava etmenlerine ek olarak arazi koşulları da orman yangınları açısından önem teşkil etmektedir. Tepelerin gün ışığını alma derecesini gösteren bakı, orman yangınına etkileyen önemli etmenlerden biridir. Güney bakılarda yanıcı maddelerin nem içeriği çok hızlı bir şekilde azaldığından, özellikle ülkemiz için güneyde yanıcı madde miktarı kuzeye oranla daha fazladır. Bu durum ise direkt olarak yangının başlamasını ve yayılmasını etkilemektedir [1].

Orman yangınlarının yayılmasını etkileyen bir diğer arazi koşulu ise meyildir. Yüksek meyil, orman yangınlarının yayılmasını önleyici bir etki göstermektedir. Bununla

birlikte yangın riski artan rakım değeri ile birlikte azalmaktadır. Türkiye’de orman yangınlarının yaklaşık olarak %80’i, 0-400 metre rakım arasında gerçekleşmektedir [1].

Orman yangınının meydana geldiği mevsim ve yangının gün içerisindeki saati, yangın davranışı üzerinde dikkate değer bir etkiye sahiptir. Orman yangınlarının büyük bir bölümü ilkbahar ve sonbahar arasında gerçekleşmektedir. Bunun nedeni ise yaz mevsimlerini de içeren bu periyodun, Türkiye gibi ülkelerde yangının başlaması için uygun hava koşullarına sahip olmasıdır. Havadaki nem miktarını gün ışığı ve buharlaşma doğrudan etkilediğinden, havanın nem içeriği gün içerisindeki saat ile de ilişkilidir.

Bunlara ek olarak, orman yangınının olduğu bölgedeki ağaç tipleri ve bunun doğal bir sonucu olan değişik ağaç türlerinin yanma olayına karşı duyarlılıkları ile orman içeriğini oluşturan birim alandaki ağaç sayısı, muhtemel yangın durumunda ormanın yangına karşı duyarlılığına karar vermektedir. Bazı ağaç türleri hızlı bir şekilde yanma eğilimindeyken, bazıları yanma olayına ve yangına karşı direnç göstermektedir. Genel olarak geniş yapraklara sahip olan ağaçlar yangının hızla ilerlemesine neden olurken, iğne yapraklı ağaçlar orman yangınının yavaş bir şekilde yayılmasını sağlamaktadır. Çok fazla ağaç içeren bir alan, yangının büyümesini kolaylaştırmanın yanında, yangının hızlı bir şekilde yayılmasına neden olur ve bu durum yangınların önlenmesini ve yangınlarla mücadeleyi zorlaştırır [1].

Orman yangınlarını etkileyen faktörler üzerindeki bütün bu bilgiler ışığında, çalışmamızın nem, rüzgar hızı, sıcaklık, bakı, meyil, mevsim, saat, ağaç tipi ve birim alandaki ağaç sayısını içeren toplam 9 adet girdi parametresine sahip olması kararlaştırılmıştır. Çıktı parametremiz ise orman yangını sonucu kaybedilen yani yanan alan olarak belirlenmiştir. Elde edilen veriler çok miktarda eksik rakım değerine sahip olduğundan, çalışmanın doğruluğu açısından rakım parametresi ihmal edilmiş, çalışmaya dahil edilmemiştir.

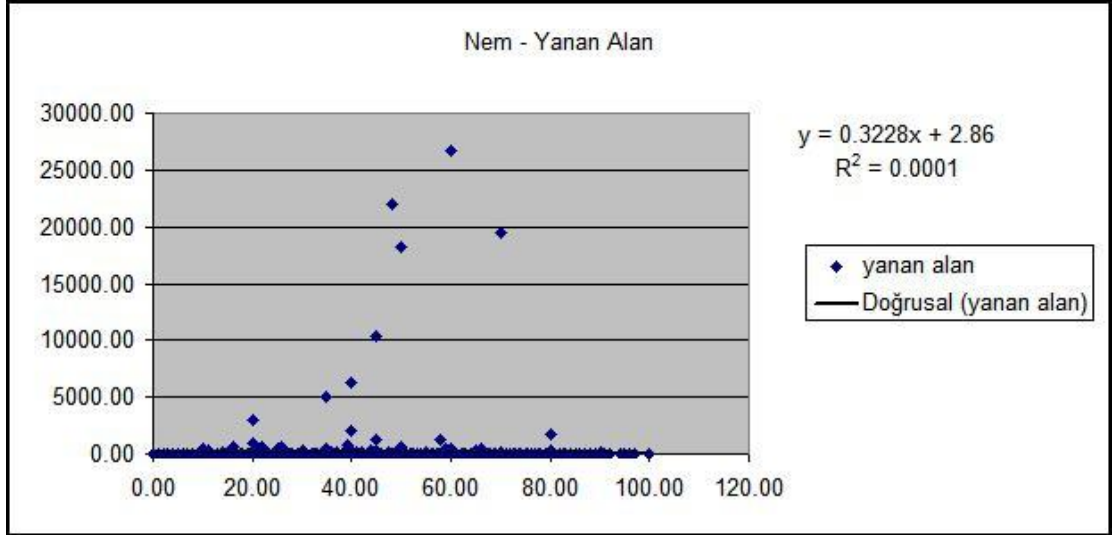
Çalışmada kullanılan veri kümesi, Türkiye Cumhuriyeti Orman ve Su İşleri Bakanlığı Orman Genel Müdürlüğü'nden elde edilmiştir [31]. Veri kümesi, 2000-2009 yılları arasında Türkiye genelinde meydana gelen toplam 10.597 adet orman yangını kaydını içermektedir.

Girdi ve çıktı parametrelerinin belirlenmesinden sonra, mevcut girdi parametrelerinin çıktı parametresi olan toplam yanan alan değerlerinin oluşumu üzerinde ne şekilde bir etkiye sahip olduklarını incelemek ve iki özellik arasındaki ilişkiyi belirlemek için her bir girdi parametresi ile çıktı parametresi olan yanan alan değerleri arasındaki bağıntı katsayısı bulunmuştur. Aşağıda Çizelge 4.1. bağıntı katsayısı sonuçlarını göstermektedir.


Çizelge 4.1. Bağıntı katsayıları

nem - yanan alan	0.01198
rüzgar hızı - yanan alan	0.03867
sıcaklık - yanan alan	0.00500
baki - yanan alan	0.02416
mevil - yanan alan	0.00707
mevsim - yanan alan	-0.01037
saat - yanan alan	0.00443
agaç tipi - yanan alan	-0.00128
birim alandaki ağaç sayısı - yanan alan	-0.01174

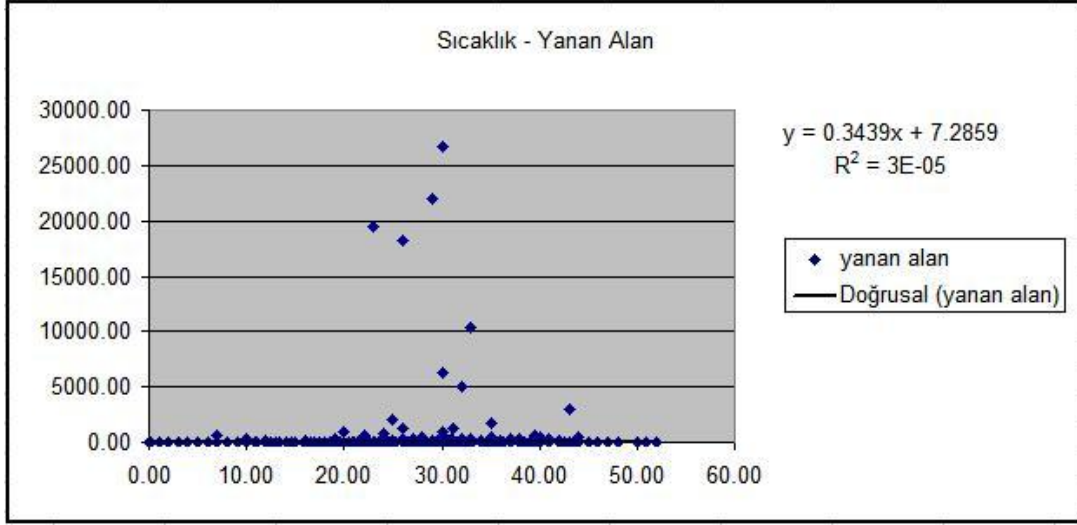
Çizelge 4.1.'e göre girdi parametreleri ile çıktı parametresi bağıntıları düşük değerlerde çıkmıştır. Buna bağlı olarak tek bir parametrenin yangın büyüklüğünün belirlenmesi için yeterli olmadığı görülmüştür. Daha sonra her bir girdi parametresi ile çıktı parametresi arasındaki ilişki trend analizi yapılarak incelenmiş ve böylece girdi parametrelerindeki bir değişikliğin çıktı parametresi üzerindeki bir değişiklik olarak görülüp görülemeyeceği çıkan sonuçlara göre yorumlanmıştır. Trend analizi sonuçları Şekil 4.1., Şekil 4.2., Şekil 4.3., Şekil 4.4., Şekil 4.5., Şekil 4.6., Şekil 4.7., Şekil 4.8. ve Şekil 4.9.'da yer almaktadır.



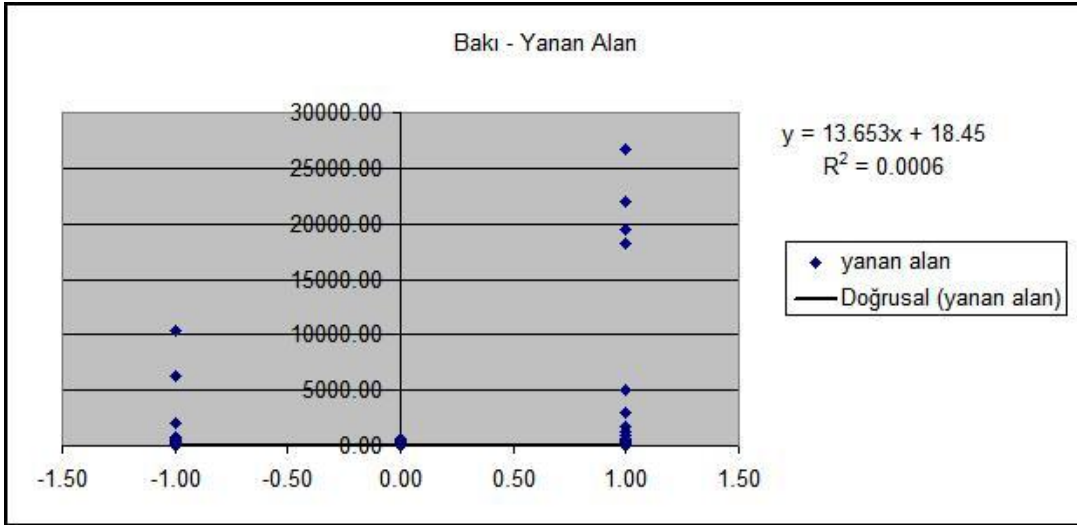
Şekil 4.1. Nem yanan alan trend analiz sonucu



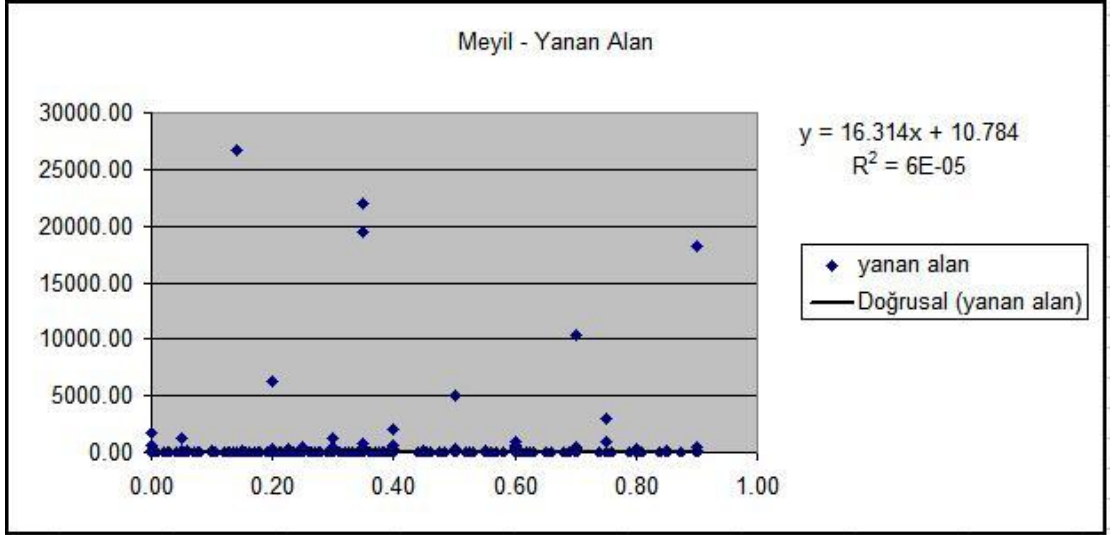
Şekil 4.2. Rüzgar hızı yanan alan trend analiz sonucu



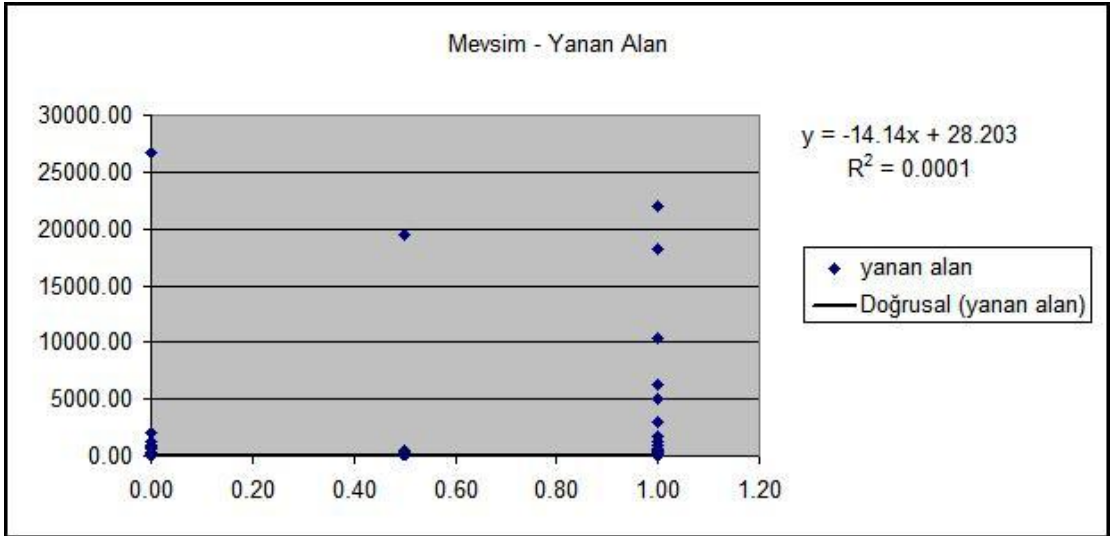
Şekil 4.3. Sıcaklık yanan alan trend analiz sonucu



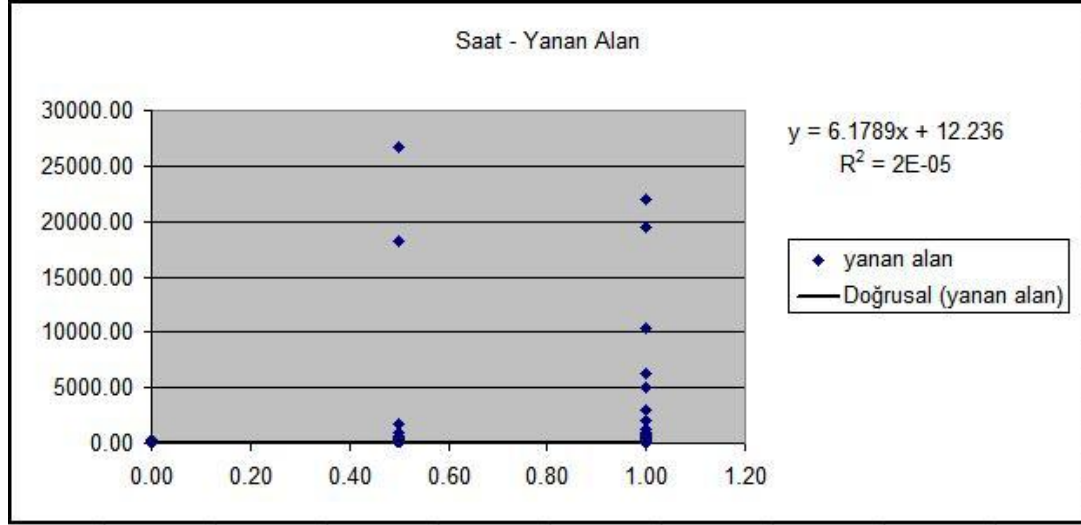
Şekil 4.4. Bakı yanan alan trend analiz sonucu



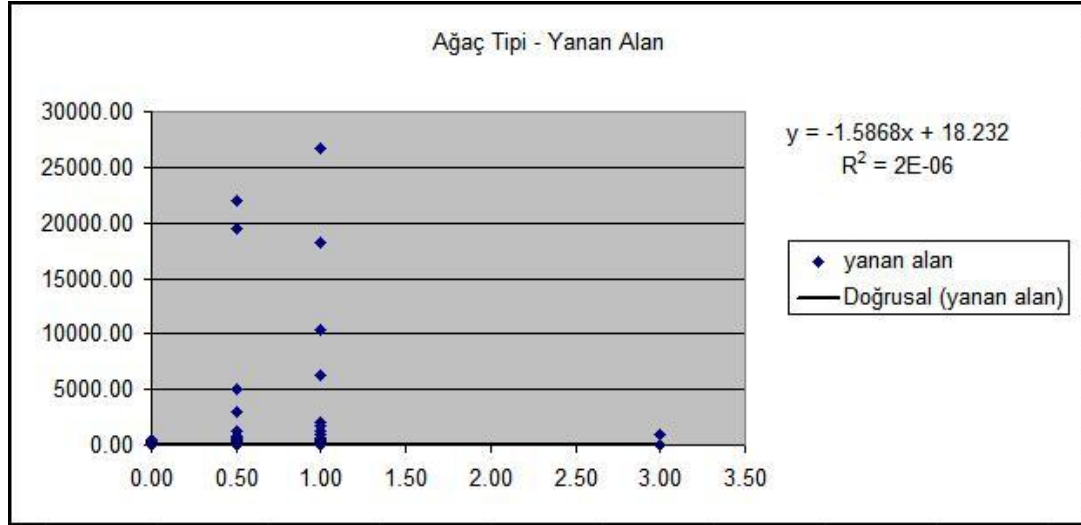
Şekil 4.5. Meyil yanan alan trend analiz sonucu



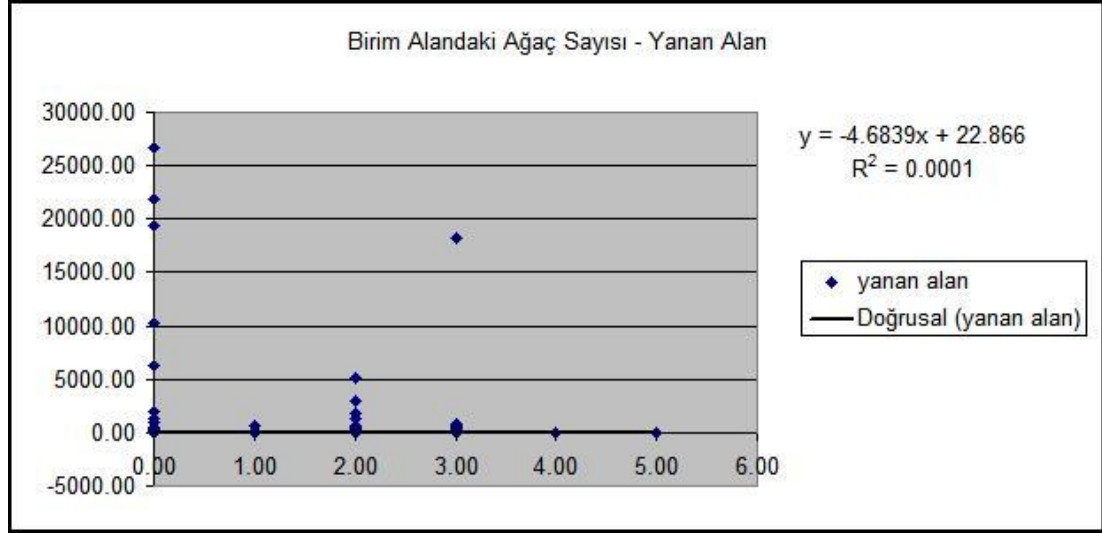
Şekil 4.6. Mevsim yanan alan trend analiz sonucu



Şekil 4.7. Saat yanan alan trend analiz sonucu



Şekil 4.8. Ağaç tipi yanan alan trend analiz sonucu




Şekil 4.9. Birim alandaki ağaç sayısı yanan alan trend analiz sonucu

Trend analizi sonuçları düşük değerlerde çıktığından, girdi parametrelerindeki bir değişiklik çıktı parametresinde yapılan bir değişiklik olarak yorumlanamamaktadır.


Yangın verileri Türkiye'nin her bölgesinden farklı kişiler tarafından kaydedildiğinden, mevcut veri kümesinin farklı biçimlerde oluşturulduğu görülmüştür. Bu nedenle, ilk olarak, verilerin çalışmamızda kullanabileceğimiz uygun biçimlere dönüştürülmesi için yoğun bir çaba harcanmıştır. Bu aşamada öncelikle kullanılacak parametrelerin düzenlenmesi çalışması yapılmıştır.

Mevsim ve saat parametreleri, her biri için birer bulanık model oluşturularak ifade edilmiştir. Mevsim parametresi, yaz ve kış olmak üzere iki alana ayrılmış ve iki bulanık grup ile temsil edilmiştir. İlgili mevsim bulanık modeli Şekil 4.10.'da görülmektedir. Buna göre, gerçekte 1 parametre olan mevsim değeri, iki bulanık grup kullanıldığından ve bu gruplara ait üyelik dereceleri ile ifade edildiğinden, çalışmamızda 2 parametre olarak yer almıştır.



Şekil 4.10. Mevsim parametresi için bulanık model

Saat parametresi için bir gün, yangın oluşumuna etkisi bakımından dört parçaya ayrılmış ve oluşturulan bulanık model kullanılarak 4 grup ile temsil edilmiştir. Şekil 4.11.'de görülmekte olan saat bulanık modeli ile gerçekte 1 parametre olan saat değeri oluşturulan 4 bulanık gruba ait üyelik dereceleri ile ifade edildiğinden çalışmamızda 4 parametre olarak yer almıştır.



Şekil 4.11. Saat parametresi için bulanık model

Bakı parametresi, kuzey, güney, doğu ve batı yönleri ile bu ana yönler arasında kalan ara yönleri de ifade edip, 1, 0 ve -1 değerleri kullanılarak 2 parametre olacak şekilde temsil edilmiştir. Buna göre oluşturulan bakı parametresi dönüşümü Çizelge 4.2.'de görülmektedir.

Çizelge 4.2. Bakı parametresi dönüşümü

Yönler	Karşılığı	
Kuzey	1	0
Güney	-1	0
Doğu	0	1
Batı	0	-1
Kuzeydoğu	1	1
Kuzeybatı	1	-1
Güneydoğu	-1	1
Güneybatı	-1	-1

Meyil parametresi için her veri 0 ile 1 arasında değişen değerlere dönüştürülmüştür. Örneğin 80 derecelik bir meyile sahip veri, 0,8 değeri ile ifade edilmiştir. Ağaç türü parametresine yangının çıktığı alanda kolay yanabilen geniş yapraklı ağaç buluyorsa 0, yanmaya karşı direnç gösteren iğne yapraklı ağaç bulunuyorsa 1, her iki ağaç türünden de ağaç bulunuyorsa 0,5 değerleri verilerek, bu parametre istenilen biçime dönüştürülmüştür. Birim alandaki ağaç sayısı parametresi ise, seyrek sıklık 1, yüksek sıklık 5 olmak üzere derecelendirilmiş, bu alanın dönüşümü 1, 2, 3, 4 ve 5 değerlerinden uygun olanı kullanılarak gerçekleştirilmiştir. Mevsim parametresinin 2 grup, saat parametresinin 4 grup ve bakı parametresinin 2 alan ile temsil edilmesiyle girdi parametresi sayısı toplamda 14 olmuştur.

Parametreler için gerekli dönüşümler yapıldıktan sonra, hatalı kayıt girilmesi nedeniyle bir ya da daha fazla eksik alan içeren verilerin Öklid uzaklığı [(3.1)] kullanılarak bilimsel olarak tamamlanması çalışması yapılmıştır.

$$\sqrt{(p_1 - q_1)^2 + (p_2 - q_2)^2 + \dots + (p_n - q_n)^2} = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (3.1)$$


Öklid uzaklığının hesaplanması için öncelikle veri kümesi üzerinde normalizasyon işlemi gerçekleştirilmiştir. Her sütundaki veri aralığı birbirinden farklı değer

gösterdiğinden, her sütundaki değer, [(3.2)] kullanılarak 0 ile 1 arasına normalize edilmiştir. Böylece bütün değerlerin Öklid uzaklığı hesaplamasında aynı etkiye sahip olması sağlanmış, büyük değerlere sahip olan alanların uzaklık sonucunu etkilemeleri ve sonucu kendilerine doğru çekmeleri engellenmiştir. Uzaklık hesaplaması sonucu ile, eksik alan içeren bir verinin eksik olan alan değerleri, Öklid uzaklığı sonucu bulunan kendisine en yakın veri noktasının ilgili alan değerleri ile tamamlanmıştır.

$$x_{normalize} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.2)$$

Bütün bu çalışmalardan ve bazı bozuk verilerin elenmesinden sonra, veri kümesi 8.972 adet orman yangını kaydını içermektedir.

Çalışmada, sınıflandırıcı tasarlanırken bulanık mantık da uygulanmıştır. Hedeflenen çıktı olan orman yangını sonucu kaybedilen yani yanan alan için bir bulanık model oluşturulmuş, çıktı parametresi oluşturulan bu modele göre yeniden ifade edilmiştir. İlk önce, doğru bir bulanık model oluşturmak açısından, bulanık modelin kaç tane bulanık kümeye sahip olması gerektiğini belirlemek için çıktı parametresi üzerinde farklı öbekler analiz edilmiştir. Öbekleme sonuçları ve veri kümesi içerisinde bulunan yangın sonucu yanan alan değerlerinin aralığı dikkate alınarak 5 adet bulanık küme içeren bir bulanık modelin kullanılması kararlaştırılmış ve yanan alan parametresi için Şekil 4.12.'deki bulanık model oluşturulmuştur.




Şekil 4.12. Toplam hektar parametresi için bulanık model

Oluşturulan bu bulanık modele göre, orman yangınında yanan toplam alanın analizi sırasında 5 farklı bulanık küme kullanılmıştır. Böylece bir veri, ait olduğu bulanık küme ya da kümelerdeki üyelik derecesi değerleri ile temsil edilmiştir. Bu yaklaşıma göre, bulanık modelde ikiden fazla kümenin kesişmemesi nedeniyle bir orman yangını en fazla iki bulanık kümenin üyesi olabilir ve bu kümeler tarafından bu kümelere ait üyelik derecesi değerleri ile temsil edilebilir.

Orman yangını verileri yanan toplam alan bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi için üyelik dereceleri hesaplanmış, hangi verinin hangi bulanık küme içerisinde yer alacağı kararlaştırılmıştır. Eğer bir yangın verisi farklı iki bulanık küme için aynı üyelik derecesine sahipse (yukarıdaki bulanık model için bu değer 0,5), bu veri düşük grup sayısına sahip olan bulanık grup içerisinde dahil edilmiştir. Örneğin, bir veri grup 2 ve grup 3 bulanık kümeleri için 0,5 üyelik derecesine sahip ise, bu veri grup 2 bulanık kümesi verisi olarak alınmıştır. Bütün hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 8.313 veriye, grup 2 604 veriye, grup 3 40 veriye, grup 4 10 veriye, ve grup 5 5 veriye sahip olmuştur.

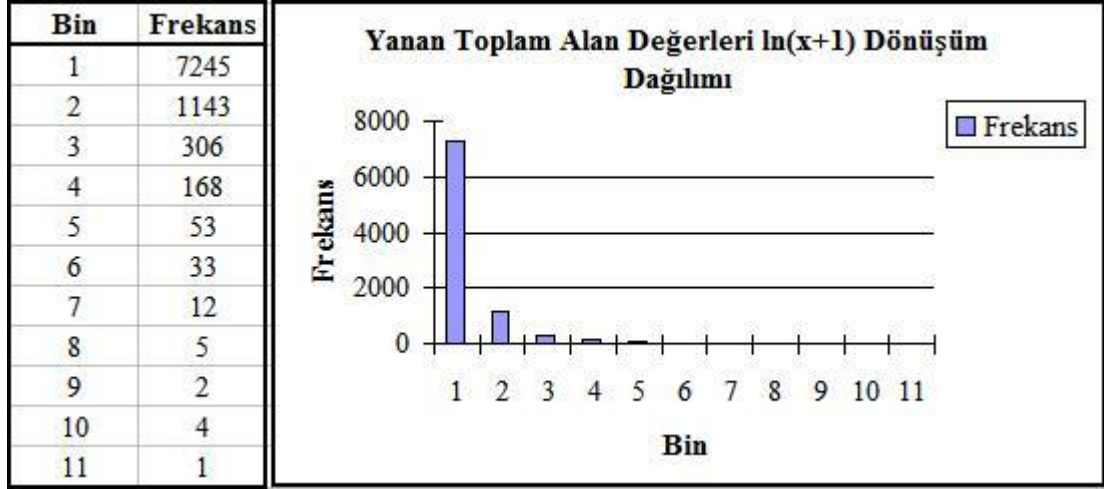
Verilerin analiz edilmesi sırasında, kayıtlı verilerin büyük bir bölümünün küçük orman yangınlarından oluştuğu gözlemlenmiştir. Veri kümesinde kayıtlı orman yangınlarının yaklaşık olarak %78'i, 0 ile 1 hektar arasında orman alanının yanması ile sonuçlanmıştır. Buna rağmen veri kümesinde 26.665 hektarlık alanın yandığı kayıt da mevcuttur. Buna göre yanan alan veri değerleri 0,01 ile 26.665 hektarlık geniş bir aralıkta değişiklik göstermektedir. Şekil 4.13. yangın kayıtlarının yanan hektar değerlerine göre 1 ile 30.000 hektar arasındaki frekans dağılımını göstermektedir.



Şekil 4.13. Yanan toplam alan değerleri dağılımı

Şekil 4.13.'teki dağılım grafiğinden de görüldüğü gibi, 0 ile 1 hektar arasında alanın yandığı kayıt sayısı 6.998, 1 ile 5 hektar arasında alanın yandığı kayıt sayısı 1.315, 20.000 ile 25.000 hektar arasında alanın yandığı kayıt sayısı 2, 25.000 ile 30.000 hektar arasında ormanlık alanın yandığı kayıt sayısı ise sadece 1 adettir.

Yanan alan değerlerinin geniş bir aralığa yayılması ve her aralıkta eşit miktarda temsil edilememesinden dolayı, doğru ve tam bir yapay sinir ağı öğrenmesini gerçekleştirmek için yanan alan değerleri üzerinde logaritmik bir dönüşüm uygulanmıştır. Öğrenme sonuçlarını geliştirmek ve iyileştirmek için, $\ln(x+1)$ logaritmik fonksiyonu yanan alan değerleri üzerinde uygulanmış ve logaritmik dönüşüm sağlanmıştır. Şekil 4.14. logaritmik dönüşüm yapılan yanan toplam hektar değerlerinin frekans dağılımını göstermektedir.



Şekil 4.14. Yanan toplam alan değerleri $\ln(x+1)$ dönüşüm dağılımı


Logaritmik dönüşümden sonra yanan alan veri değerleri 0,005 ile 10,191 ln hektarlık bir aralıkta değişiklik göstermektedir. Şekil 4.14.'deki dağılım grafiğinden de görüldüğü gibi logaritmik dönüşümden sonra 0 ile 1 hektar arasında alanın yandığı kayıt sayısı 7.245, 1 ile 2 ln hektar arasında alanın yandığı kayıt sayısı 1.134, 9 ile 10 ln hektar arasında alanın yandığı kayıt sayısı 4, 10 ile 11 ln hektar arasında alanın yandığı kayıt sayısı ise 1 adet olmuştur.

Yanan alan değerleri üzerinde $\ln(x+1)$ dönüşü uygulanmasından sonra girdi parametreleri ile çıktı parametresi arasında bağıntı katsayısı bulma işlemi logaritmik olarak dönüştürülen yanan alan değerleri için de uygulanmıştır. Çizelge 4.3. $\ln(x+1)$ dönüşüm bağıntı katsayısı sonuçlarını göstermektedir.


Çizelge 4.3. $\ln(x+1)$ dönüşüm bağıntı katsayıları

nem - yanan alan	-0.10192
rüzgar hızı - yanan alan	0.17750
sıcaklık - yanan alan	0.12184
baki - yanan alan	-0.00880
meyil - yanan alan	0.08414
mevsim - yanan alan	-0.01208
saat - yanan alan	0.07471
agaç tipi - yanan alan	-0.20945
birim alandaki ağaç sayısı - yanan alan	-0.05648

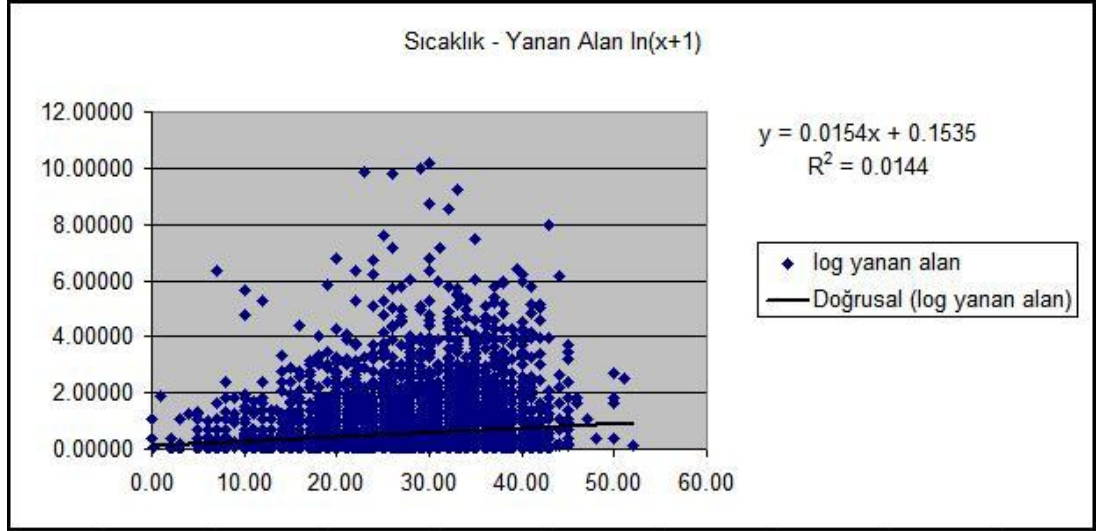
Çizelge 4.1. ile karşılaştırıldığında, girdi parametreleri ile $\ln(x+1)$ dönüşümlü çıktı parametresi arasındaki bağıntı katsayılarının daha yüksek değerlerde çıktığı görülmüştür. Yanan alan değerleri üzerinde $\ln(x+1)$ dönüşüm uygulanmasından sonra her bir girdi parametresi ile çıktı parametresi arasındaki ilişki trend analizi yapılarak incelenmiş ve böylece girdi parametrelerindeki bir değişikliğin çıktı parametresi üzerindeki bir değişiklik olarak görülüp görülemeyeceği logaritmik olarak dönüştürülen yanan alan değerleri ile çıkan sonuçlara göre de yorumlanmıştır. Trend analizi sonuçları Şekil 4.15., Şekil 4.16., Şekil 4.17., Şekil 4.18., Şekil 4.19., Şekil 4.20., Şekil 4.21., Şekil 4.22. ve Şekil 4.23.'te yer almaktadır.



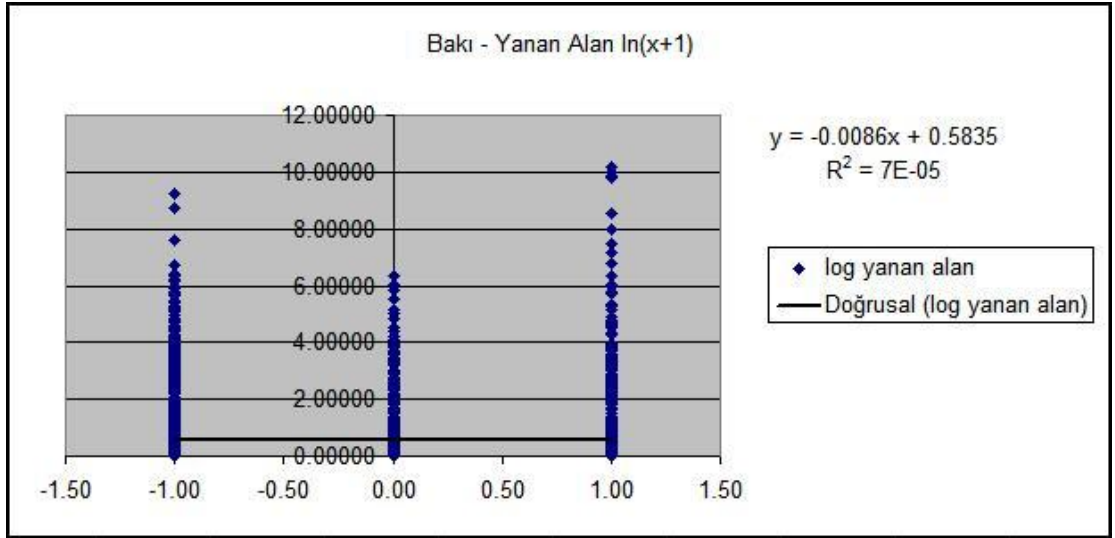
Şekil 4.15. Nem yanan alan $\ln(x+1)$ trend analiz sonucu



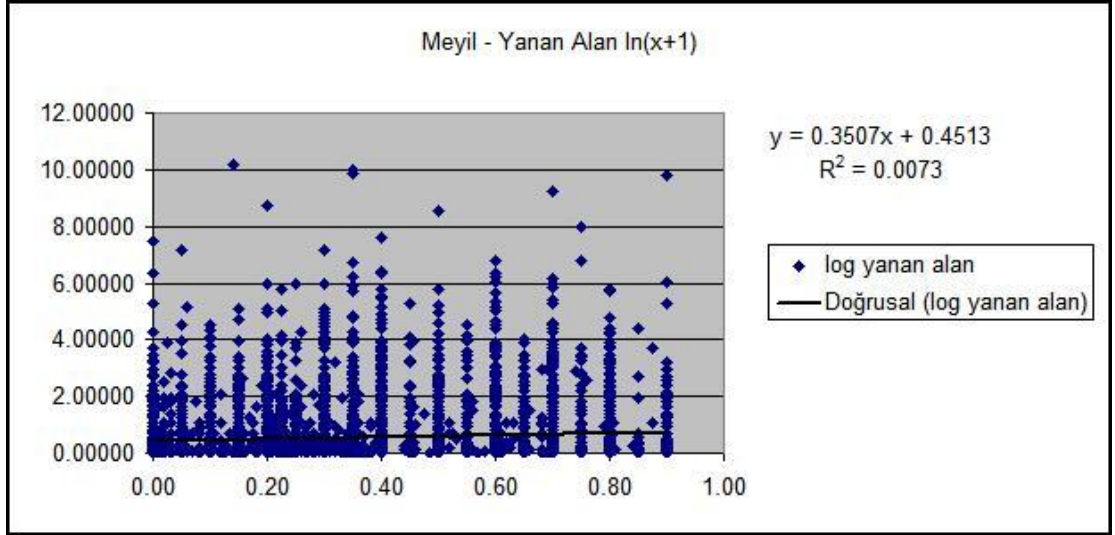
Şekil 4.16. Rüzgar hızı yanan alan $\ln(x+1)$ trend analiz sonucu



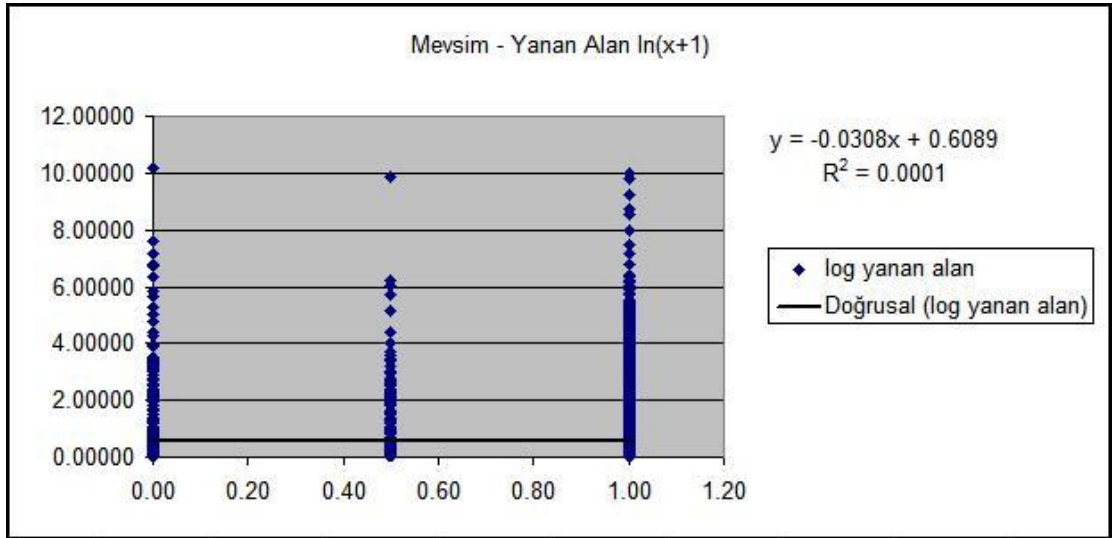
Şekil 4.17. Rüzgar hızı yanan alan $\ln(x+1)$ trend analiz sonucu



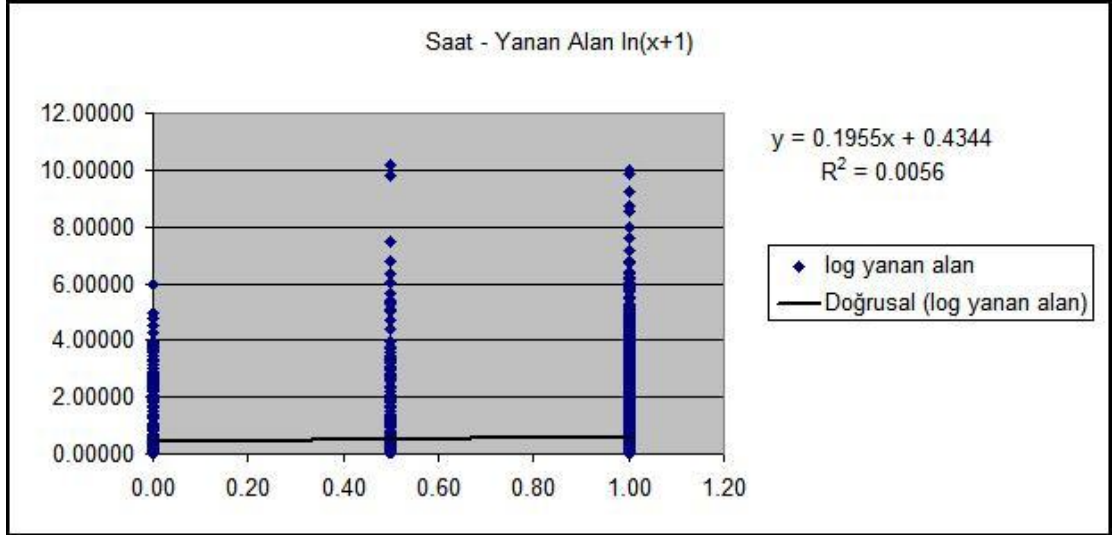
Şekil 4.18. Bakı yanan alan $\ln(x+1)$ trend analiz sonucu



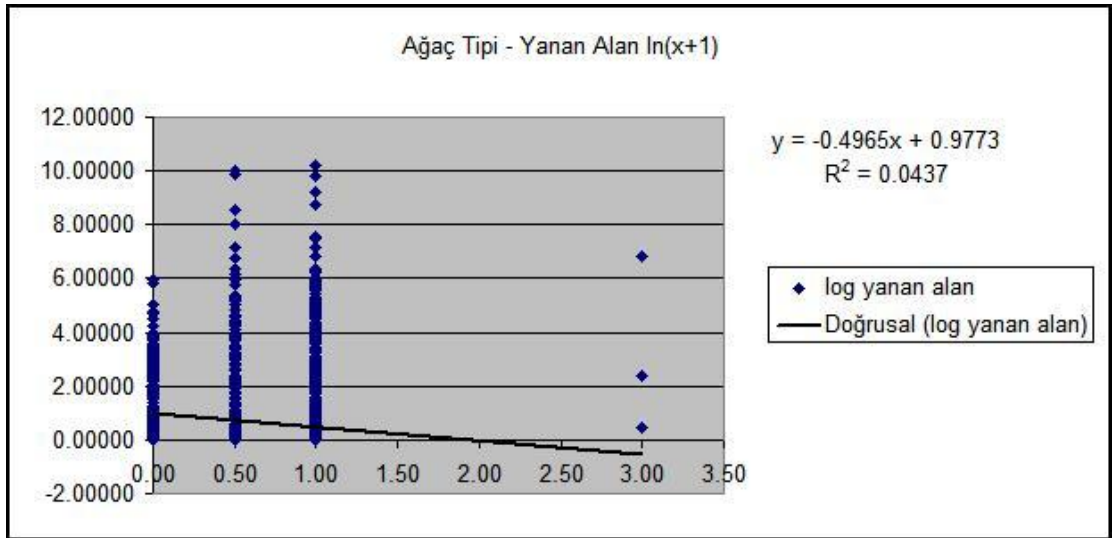
Şekil 4.19. Meyil yanan alan $\ln(x+1)$ trend analiz sonucu



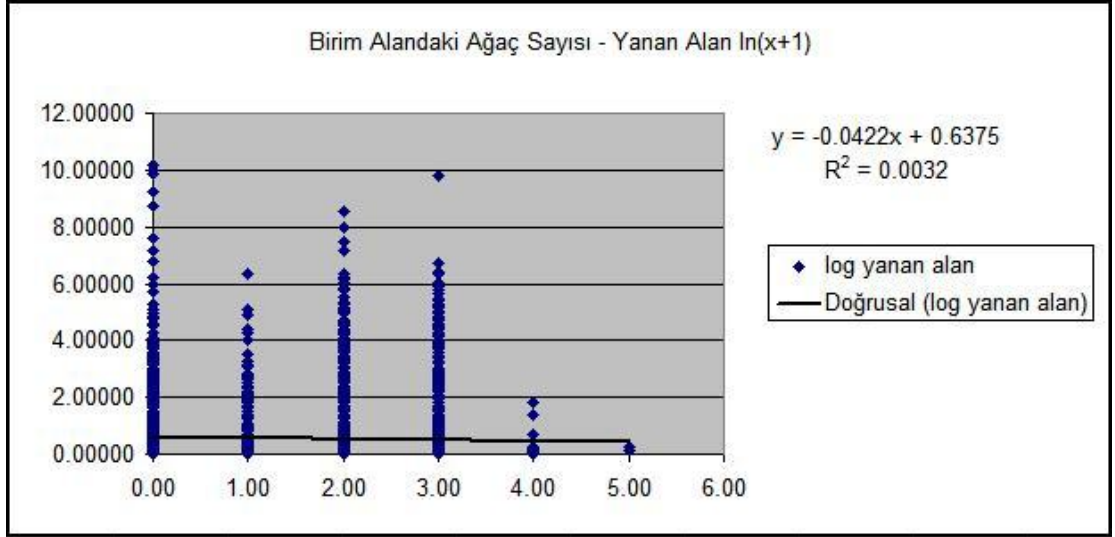
Şekil 4.20. Mevsim yanan alan $\ln(x+1)$ trend analiz sonucu



Şekil 4.21. Saat yanan alan $\ln(x+1)$ trend analiz sonucu



Şekil 4.22. Ağaç tipi yanan alan $\ln(x+1)$ trend analiz sonucu



Şekil 4.23. Birim alandaki ağaç sayısı yanan alan $\ln(x+1)$ trend analiz sonucu

Buna göre trend analizi sonuçları logaritmik dönüşüm değerleri için de düşük değerlerde çıkmıştır. Ancak analiz sonuçlarındaki R^2 değerleri gerçek yanan alan değerleri analiz sonuçlarına göre yüksek çıkmıştır.

5. DENEY VE SONUÇLAR

2000-2009 yılları arasında Türkiye’de gerçekleşen orman yangını kayıtlarını içeren ve çalışmaya temel oluşturan veriler dördüncü bölümde anlatıldığı gibi düzenlendikten sonra, deneylerin yapılabilmesi için üç kümeye ayrılmıştır. Bu kümeler; yapay sinir ağlarının eğitimi için kullanılacak ve toplam veri sayısının %60’ını oluşturan eğitim kümesi, yapay sinir ağında öğrenme aşamasında çapraz doğrulama sağlayacak ve toplam veri sayısının %20’sini oluşturan bağımsız geçerlilik sınaması (cross-validation) kümesi, ve yapay sinir ağının kendisine gösterilen örneklerle öğrenme işlemini tamamlamasından sonra daha önce karşılaşmadığı örnekleri içeren, ağın test edilmesinde kullanılacak ve toplam veri sayısının %20’sini oluşturan test kümesidir.

Veri kümesi içerisinde, eğitim, bağımsız geçerlilik sınaması ve test verilerinin %60, %20 ve %20 oranlarla ayrılmasının yanında ağın, yanan toplam hektar alanı değerlerinin aralığında kalan her veriyi eşit oranla eğitim sırasında görüp, öğrenebilmesi ve test edebilmesini sağlamak açısından, belli bir değer aralığında kalan veriler de eğitim, bağımsız geçerlilik sınaması ve test kümelerine %60, %20 ve %20 oranını doğrulayacak şekilde dağıtılmıştır. Örneğin; 5 hektar alanın yandığı yangın veri sayısı 100 ise, eğitim kümesi 60, bağımsız geçerlilik sınaması kümesi 20 ve test kümesi 20 adet 5 hektar alanın yandığı yangın verisine sahip olacak şekilde dağıtım yapılmıştır.

Bütün bunlar dikkate alındığında, çalışma kapsamında yapılacak ilk deneyde eğitim kümesi 5.384, bağımsız geçerlilik sınaması kümesi 1.794, test kümesi 1.794 veriden oluşmaktadır. Deneyler, yapay zeka uygulamaları için tasarlanan ve simülasyon ortamı oluşturan [32] kullanılarak yapılmıştır. Yapay sinir ağı olarak MP ve RBFN seçimi yapılmış, veri kümeleri bu iki yapay sinir ağı modeli kullanılarak eğitilip test edilmiştir.

Kullanılan MP bir adet gizli katman (hidden layer) içermektedir. Gizli katman içerisinde 50 adet nöron (processing element), transfer fonksiyonu (transfer function) olarak

sigmoid axon, öğrenme kuralı (learning rule) olarak ise conjugate gradient kullanılmıştır. Çıktı katmanında (output layer) ise gizli katman ile aynı transfer fonksiyonu ve öğrenme kuralları uygulanmıştır. MP için maksimum iterasyon (yineleme) değeri 10.000, eşik değeri (threshold) ise 0,0001 ortalama hata olarak belirlenmiştir.

Deneylerde kullanılan RBFN ise bir adet gizli katman ve 70 adet öbek merkezi (cluster center) içermektedir. Rekabet kuralı (Competitive Rule) olarak conscience full, metrik olarak ise Öklid metriği kullanılmıştır. Gizli katmanda 150 adet nöron, transfer fonksiyonu olarak sigmoid axon, öğrenme kuralı olarak ise conjugate gradient kullanılmıştır. Çıktı katmanında ise gizli katman ile aynı transfer fonksiyonu ve öğrenme kuralları uygulanmıştır. Öğretmensiz öğrenmede (unsupervised learning) maksimum iterasyon değeri 100 olarak belirlenmiş, öğrenme oranı ise 0,01'den başlayıp 0,001'e kadar ayarlanmıştır. Öğretmenli öğrenmede (supervised learning) ise maksimum iterasyon değeri 10.000, eşik değeri ise 0,0001 ortalama hata olarak belirlenmiştir.

Yapay sinir ağı sonuçları Ortalama Hata Karesi (Mean Square Error-MSE) [(5.1)], Ortalama Mutlak Hata (Mean Absolute Error-MAE) [(5.2)], Ortalama Mutlak Oransal Hata (Mean Absolute Percentage Error-MAPE) [(5.3)] ve Ortalama Hata Karesinin Kökü (Root Mean Square Error-RMSE) [(5.4)] başarımlar ölçüm yöntemleri kullanılarak analiz edilmiştir.

$$MSE = \frac{\sum_{i=1}^n (x_{1,i} - x_{2,i})^2}{n} \quad (5.1)$$

Denklem içerisindeki $x_{1,i}$ değeri verinin gerçek değerini, $x_{2,i}$ değeri hesaplama sonucunda bulunan yani tahmin edilen değerini, n sayısı ise veri sayısını temsil etmektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_{1,i} - x_{2,i}| \quad (5.2)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{x_{1,i} - x_{2,i}}{x_{1,i}} \right| \quad (5.3)$$

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{i=1}^n (x_{1,i} - x_{2,i})^2}{n}} \quad (5.4)$$

Veri kümesinde, çıktı parametresi olarak toplam yanan alan parametresinin alındığı, MP ve RBFN kullanılarak yapılan deneylerin, yukarıda açıklanan performans ölçüm yöntemleri kullanılarak yapılan analiz sonuçları Çizelge 5.1.'de yer almaktadır.

Çizelge 5.1. Yanan alan MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	236136.33	20.33	22.14	485.94
RBFN	236110.65	20.59	32.10	485.91

Çıktı parametresi olarak toplam yanan alan logaritmik dönüşüm parametresinin alındığı test analiz sonuçları aşağıda Çizelge 5.2.'de yer almaktadır.

Çizelge 5.2. Yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	236155.54	19.94	9.82	485.96
RBFN	236148.36	19.97	11.94	485.95

Yapılan ilk MP ve RBFN test sonuçlarının yer aldığı Çizelge 5.1. ve Çizelge 5.2. incelendiğinde, yanan alan üzerinde logaritmik dönüşüm yapılarak yapay sinir ağlarında eğitim ve test işleminin bu şekilde gerçekleştirildiği örnek sonuçlarının, yanan alan gerçek değerlerinin kullanıldığı örnek sonuçlarından MAE ve MAPE başarı ölçüm yöntemleri bakımından daha iyi çıktığı gözlemlenmiştir.

Bir başka test ise, yanan alan değerlerinin Şekil 4.4.'teki bulanık modele göre 5 kümeye ayrıldığı ve yanan alan gerçek değerleri yerine, her bir veri için, verinin bu 5 adet bulanık kümeye ait olduğu üyelik dereceleriyle temsil edildiği 5 adet çıktı parametresinin kullanıldığı veri kümesinin MP ve RBFN yapay sinir ağı modellerinde denenmesi ile yapılmıştır. Bu çalışma içerisinde verilerin eğitim, bağımsız geçerlilik sınaması ve test kümeleri içerisindeki dağıtım oranı sadece bütün veriye uygulanmamış, bütün bulanık grup kümelerine uygulanmış ve böylece bulanık kümeler kendi verileri için eğitim, bağımsız geçerlilik sınaması ve test kümeleri içerisinde aynı dağıtım oranına sahip olmuşlardır. Çalışma dahilinde test işlemi gerçekleştirildikten sonra elde edilen yapay sinir ağı çıktısının veriyi dahil ettiği bulanık küme ile verinin gerçekte dahil olduğu bulanık kümenin tutarlılığı incelenmiş, her grup için doğru gruplandırılan ve yanlış gruplandırılan veri sayıları ile doğru ve yanlış gruplandırılma oranları, toplam doğru ve yanlış grup tahmin edilme sayıları ile doğru ve yanlış tahmin oranları analiz edilmiştir. Bu analiz sonuçları Çizelge 5.3.'te görülmektedir.

Çizelge 5.3. Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1647	0	100.00	0.00	1	1647	0	100.00	0.00
2	0	134	0.00	100.00	2	0	134	0.00	100.00
3	0	9	0.00	100.00	3	0	9	0.00	100.00
4	0	3	0.00	100.00	4	0	3	0.00	100.00
5	0	1	0.00	100.00	5	0	1	0.00	100.00
Toplam	1647	147			Toplam	1647	147		
%	91.81	8.19			%	91.81	8.19		

Çizelge 5.3. incelendiğinde, bulanık dönüşüm gerçekleştirilerek yapılan test sonuçlarına göre yapay sinir ağlarının doğru gruplandığı veri sayısı 1.647 ve doğru gruplandırma oranı %91,81 olarak görülmüştür. Ancak burada dikkat edilmesi gereken nokta, hem MP hem de RBFN'ün sadece 1.bulanık grup verilerini ayırt edebilmiş olmasıdır. Sonuçlar 1.bulanık grup verilerinin tamamının doğru olarak gruplandırıldığını ve doğru

gruplandırma oranlarının %100 olduğunu göstermektedir. Ancak buna rağmen 2, 3, 4 ve 5.bulanık grup verilerinin tamamı yanlış olarak gruplandırılmıştır. Bu da bu grupların yapay sinir ağları tarafından öğrenilemediğini göstermektedir.

Yanlış gruplandırmanın gerçekleşme nedeninin, 1.bulanık grup dışında kalan grup verilerinin eğitim ve bağımsız geçerlilik sınaması veri kümeleri içinde yeteri kadar temsil edilememesi olduğu öngörülmüştür. Yapılan bulanık dönüşüm sonrasında grup 1 8.313 veriye, grup 2 604 veriye, grup 3 40 veriye, grup 4 10 veriye, ve grup 5 5 veriye sahip olmuştur. Bu durumda %60 eğitim, %20 bağımsız geçerlilik sınaması ve %20 test veri ayrımı yapıldığında eğitim veri kümesi içerisinde yer alan 5.382 verinin 4.987 adeti 1.bulanık grup verisi iken 6 adeti 4.grup ve sadece 3 adeti 5. grup verisi olmuştur. Yine aynı şekilde bağımsız geçerlilik sınaması veri kümesi içerisinde yer alan 1.795 verinin 1.663 adeti 1.bulanık grup verisi iken 2 adeti 4.grup ve sadece 1 adeti 5.grup verisi olmuştur. Dolayısıyla grup verileri arasında dengesiz dağılımın gerçekleşmesi ve yapay sinir ağlarının eğitimi sırasında kendilerine gösterilen örnekler arasında 1.bulanık grup veri sayısının diğerleri karşısında büyük miktarda olması nedeniyle sadece 1.grup verilerini öğrenebilmişler, öğrenme işlemini sadece 1.grup verilerini kullanarak gerçekleştirmişler ve bunun sonucunda test için kullanılan diğer grup verilerini 1.grup içerisine dahil etmişlerdir.

Bu sorunu ortadan kaldırmak için bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle “1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı” kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiş ve adil öğrenme gerçekleştirilmiştir. Aynı çoğaltma yöntemiyle bağımsız geçerlilik sınaması veri kümesi de az önce belirtildiği gibi yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 24.935 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 4.987 adet olmuştur. Bağımsız geçerlilik sınaması kümesi ise

8.315 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 1.663 adet olmuştur. Bu veri sayıları ile yapılan testin analiz sonuçları Çizelge 5.4.'te yer almaktadır.

Çizelge 5.4. Yanan alan bulanık çoğaltılmış veriler MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	36	1627	2.16	97.84	1	425	1238	25.56	74.44
2	15	106	12.40	87.60	2	45	76	37.19	62.81
3	3	5	37.50	62.50	3	1	7	12.50	87.50
4	0	2	0.00	100.00	4	0	2	0.00	100.00
5	1	0	100.00	0.00	5	1	0	100.00	0.00
Toplam	55	1740			Toplam	472	1323		
%	3.06	96.94			%	26.30	73.70		

Analiz sonuçlarına göre, MP toplamda 55 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %3,06 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 3.grup 8 veriden 3'ünün doğru tahmin edilmesi ve böylece %37,50 doğru tahmin oranının yakalanması ile ön plana çıkmaktadır. 2.grup 15 doğru tahmin ve %12,40 doğru oranı, 1.grup ise 36 doğru tahmin ve %2,16 doğru oranına sahip olurken, 4.grupta yer alan verilerin tamamı yanlış olarak gruplandırılmıştır. RBFN'te ise tahmin sonuçlarına göre 472 veri doğru gruplarda yer almış, doğru oranı %26,30'lara kadar çıkmıştır. Burada 2.grup verilerin %37,19'u, 1.grup verilerin %25,56'sı, 3.grup verilerin %12,50'si doğru gruplandırılırken, MP sonucunda olduğu gibi 4.grup verilerin tamamı yanlış gruplar içerisine dahil edilmiştir.

İlk sonuçların elde edilmesinden sonra, daha iyi yapay sinir ağı öğrenmesi gerçekleştirmek ve böylece test sonuçlarını iyileştirmek, kalitesini arttırmak amacıyla veri kümesinin yeniden düzenlenmesi yoluna gidilmiştir. Bir önceki çalışmada, çalışmaya başlamadan önce verilerin düzenlenmesi, bozuk, eksik ve hatalı verilerin elenmesi, ve böylece üzerinde çalışılan 2000-2009 yıllarına ait orman yangını kayıtlarını

içeren veri kümesinin doğruluğunun sağlanabilmesi amacıyla yapılan düzenlemelere rağmen, veri kümesi içerisinde hala düzensiz ve bozuk kayıtların olduğu gözlemlenmiştir. Bu bozuklukların kaynağı, orman yangını kayıtlarının değişik bölgelerden, değişik kişiler tarafından farklı koşul ve biçimlerde tutulması olabileceği gibi verilerin kendi doğası da olabilmektedir.

Bu bağlamda hatalı ya da genel veri özellikleri ile bağdaşmadığı düşünülen verilerin açığa çıkarılması için tüm veriler girdi parametrelerine göre 350 adet öbeğe ayrılmıştır. Her verinin hangi öbek içerisinde yer aldığı kaydı tutulmuştur. Aynı öbekte yer alan tüm noktalar, yanan toplam hektar alanlarına göre kontrol edilmiştir. Girdi parametrelerine göre aynı öbekte bulunmalarına rağmen, yanan alan miktarları bakımından öbekteki diğer noktalara göre büyük farklılıklar içeren, düzensiz, bozuk ve öbekteki diğer noktalara göre tutarsız olduğu gözlemlenen veriler silinmiştir. Örneğin, öbekleme işlemi sonucunda 1.öbekte yer alan toplam 10 veri ve bu verilerin çıktı parametreleri olan yanan alan değerleri sırasıyla 7, 114, 11, 5, 3, 8, 180, 15, 6 ve 17 olsun. Bu durumda girdi parametrelerine göre aynı öbekte olmalarına rağmen, yanan alan değerleri 114 ve 180 olan iki veri, öbekteki diğer verilerle karşılaştırıldığında tutarsızlık göstermektedirler. Bu iki nokta aynı öbekte olmalarına rağmen diğer verilerden farklılık gösterdiklerinden eleneceklerdir. Veri kümesi içerisinde bütün bu eleme işlemi sonrasında 8.350 adet veri bulunmaktadır. Bu veriler %60 eğitim, %20 bağımsız geçerlilik sınavası ve %20 test verileri şeklinde dağıtıldıklarında 5.010 eğitim, 1.670 bağımsız geçerlilik sınavası ve 1.670 test verisi elde edilmiştir. Bu veri kümeleri kullanılarak MP ve RBFN ile yapılan testlerin analiz sonuçları Çizelge 5.5.'te bulunmaktadır.

Çizelge 5.5. Veri eleme MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	672.67	6.91	89.72	25.94
RBFN	674.73	5.77	69.7	25.98

Veri kümesinin yeniden düzenlenmesi için kullanılan bir başka yöntem ise, verilerin yine girdi parametrelerine göre öbeklenmesi, ancak bu sefer gerçek veri noktalarının değil öbekleme işlemi sonucunda oluşan öbek merkezlerinin ve bunlara bağlı oluşan girdi parametrelerinin yeni veriler olarak kullanılması olmuştur. Çıktı parametreleri olan yanan alan değerleri ise, her öbek için öbekte bulunan diğer tüm noktaların yanan alan değerlerinin ortalaması olarak alınmıştır.

Uygulama için veriler 400 adet öbeğe ayrılmıştır. Her öbek merkezi, merkezi olduğu öbeğin temsilci noktası olarak seçilmiş, bu noktanın girdi değerleri yeni girdi parametreleri olarak alınmış, çıktı parametreleri olan yanan alan değerleri ise yukarıda anlatıldığı gibi belirlenmiştir. Böylece 400 öbeğe karşılık 400 adet yeni veri elde edilmiştir. Bu veriler %60 eğitim, %20 bağımsız geçerlilik sınaması ve %20 test oranını sağlayacak şekilde dağıtılmış. Çizelge 5.6. bu yönteme ait analiz sonuçlarını göstermektedir.

Çizelge 5.6. Öbekleme ile yeni veri elde edilmesi MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	10983.87	26.1	13.11	104.8
RBFN	10843.9	25.72	14.97	104.13

Verilerin yeniden düzenlenmesi ile elde edilen analiz sonuçları ile Çizelge 5.1.'deki hata analiz tablosu karşılaştırıldığında hata oranlarının dikkate değer bir şekilde düştüğü, kullanılan verilerin yeniden düzenlenmesinin yapay sinir ağlarının öğrenme başarısını arttırdığı görülmüştür. Özellikle, öbekleme sonucu hatalı verilerin elenmesi yönteminin


kullanıldığı ve buna ait analiz sonuçlarının Çizelge 5.5.'te verildiği düzenleme büyük oranda başarı sağlamış, hata değerlerini alt seviyelere çekmiştir.

Başarı oranını arttırmak adına yapılan bir diğer çalışma, yanan toplam hektar alanı üzerinde yeni bir bulanık model tanımlayarak test aşamasında yapay sinir ağlarının gruplandırma sonuçlarını iyileştirmek olmuştur. Bunun için daha önce hatalı veya tutarsız olduğu düşünülerek elenmiş ve 8.350 sayısına düşürülmüş veri kümesi kullanılmıştır. Bu veri kümesi yanan toplam hektar değerlerine göre 5 adet öbeğe ayrılmıştır. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.7.'de verilmiştir.

Çizelge 5.7. 5 adet öbek sonucu oluşan merkez değerleri

öbek numarası	merkez değeri
1	1.24
2	58.30
3	273.05
4	773.17
5	5661.00

Oluşan öbek merkezleri çalışmamıza göre direkt olarak bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Bu değerler kullanılarak yanan toplam hektar parametresi için oluşturulan bulanık model aşağıda Şekil 5.1.'de görülmektedir.



Şekil 5.1. Toplam hektar parametresi için bulanık model

Elenmiş ve 8.350 adete düşürülmüş orman yangını verileri Şekil 5.1.'deki yanan toplam alan bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi için üyelik dereceleri hesaplanmış, hangi verinin hangi bulanık küme içerisinde yer alacağı kararlaştırılmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 8.240 veriye, grup 2 91 veriye, grup 3 14 veriye, grup 4 3 veriye, ve grup 5 2 veriye sahip olmuştur. Verilerin %60 eğitim, %20 bağımsız geçerlilik sınaması ve %20 test kümelerine dağıtımından sonra, daha önce karşılaşılan adil öğrenmenin sağlanamaması ve yapay sinir ağının sadece veri sayısı fazla grup verileri ile öğrenmesini gerçekleştirmesi sorununu önlemek açısından bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle “1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı” kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınaması veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 24.720 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 4.944 adet olmuştur. Bağımsız geçerlilik sınaması kümesi ise 6.592 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 1.648 adet olmuştur (5.bulanık grup sadece 2 adet veriye sahip olduğundan, bu veriler eğitim ve test veri kümelerinde kullanılmışlardır, dolayısıyla bağımsız geçerlilik sınaması kümesi 5.bulanık grup verisi içermemektedir). Bu veri sayıları ile yapılan testin analiz sonuçları Çizelge 5.8.'de yer almaktadır.

Çizelge 5.8. Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu


MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1347	301	81.74	18.26	1	0	1648	0.00	100.00
2	5	13	27.78	72.22	2	0	18	0.00	100.00
3	0	3	0.00	100.00	3	3	0	100.00	0.00
4	0	1	0.00	100.00	4	0	1	0.00	100.00
5	1	0	100.00	0.00	5	0	1	0.00	100.00
Toplam	1353	318			Toplam	3	1668		
%	80.97	19.03			%	0.18	99.82		

Çizelge 5.8.'deki grup analiz tablosu dikkate alındığında, MP toplamda 1.353 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %80,97 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.648 veriden 1.347 adet veriyi doğru tahmin etmiş ve böylece %81,74 doğru tahmin oranını yakalamıştır. 2.grup 5 doğru tahmin ve %27,78 doğru oranına, 5.grup ise 1 doğru tahmin ve %100,00 doğru oranına sahip olurken, 3. ve 4.gruplarda yer alan verilerin tamamı yanlış olarak gruplandırılmıştır. RBFN'te ise tahmin sonuçlarına göre sadece 3.grupta yer alan 3 veri doğru olarak gruplandırılabilmiştir.

Bu aşamaya kadar yapılan deneyler nem, rüzgar hızı, sıcaklık, mevsim parametresi için 2 grup, saat parametresi için 4 grup, bakı parametresi için 2 alan, ağaç tipi ve birim alandaki ağaç sayısını içeren toplam 14 adet girdi parametresi kullanılarak yapılmıştır. Girdi parametre sayısının fazla olması nedeniyle bundan sonra yapılacak olan deneylerde parametre sayısının azaltılması ve böylece yapay sinir ağı sonuçlarının iyileştirilmesi hedeflenmiştir.

İlk olarak toplam parametre sayısını arttıran mevsim ve saat verilerinin daha az sayıda parametre kullanarak ifade edilmesine çalışılmıştır. Bu bağlamda her iki girdi için yeni bulanık modeller oluşturulmuş, mevsim ve saat parametreleri birer alanda temsil


edilmişlerdir. Aşağıdaki Şekil 5.2.'de mevsim parametresi oluşturulan yeni bulanık model görülmektedir.



Şekil 5.2. Mevsim parametresi için yeni bulanık model

Bu bulanık modele göre, mevsim değeri, yangının meydana geldiği tarihteki aya göre aldığı üyelik derecesi kullanılarak tek bir alan ile temsil edilmiştir. Örneğin; 1 ile 4'üncü ay arasında gerçekleşen yangınların mevsim parametreleri 0 iken, 7 ve 8'nci aydaki yangınların mevsim parametreleri 1, 12'inci ayda gerçekleşen yangınların mevsim parametreleri 0, diğer aylarınki ise $[0,1]$ aralığındadır.

Saat parametresi için oluşturulan yeni bulanık model kullanılarak saat girdisi 4 alanla değil sadece 1 alan ile temsil edilmiştir. Oluşturulan bulanık model Şekil 5.3.'te görülmektedir.



Şekil 5.3. Saat parametresi için oluşturulan yeni bulanık model

Mevsim ve saat parametrelerinin yeniden düzenlenmelerinin dışında, bakı parametresi tamamen uygulamadan çıkartılmıştır. Bu düzenlemeler sonucunda yeni veri kümesi

nem, rüzgar hızı, sıcaklık, meyil, mevsim, saat, ağaç tipi ve birim alandaki ağaç sayısını içeren toplam 8 adet girdi parametresi ile yanan toplam alanı içeren 1 adet çıktı parametresine sahip olmuştur.


Veri kümesinin yeniden düzenlenmesinden sonra, daha önce yapılan ve veri kümesinin girdi parametrelerine göre 350 adet öbeğe ayrılması ve öbek sonuçlarına göre düzensiz, hatalı ya da tutarsız görünen verilerin veri kümesinden çıkarılmasını kapsayan ilk çalışma tekrar edilmiştir. Bu çalışma kapsamında daha önce de ifade edildiği gibi aynı öbekte yer alan tüm noktalar, yanan toplam hektar alanlarına göre kontrol edilmiş, girdi parametrelerine göre aynı öbekte bulunmalarına rağmen yanan alan miktarları bakımından büyük farklılıklar içeren veriler silinmiştir.

Veri kümesi içerisinde bütün bu eleme işlemi sonrasında 7.920 adet veri bulunmaktadır. Bu veriler %60 eğitim, %20 bağımsız geçerlilik sınaması ve %20 test verileri şeklinde dağıtıldıklarında 4.752 eğitim, 1.584 bağımsız geçerlilik sınaması ve 1.584 test verisi elde edilmiştir. Bu veri kümeleri kullanılarak MP ve RBFN ile yapılan testlerin analiz sonuçları Çizelge 5.9.'da bulunmaktadır.

Çizelge 5.9. Azaltılmış girdiler ile veri eleme MP ve RBFN hata analiz tablosu


	MSE	MAE	MAPE	RMSE
MP	16264.65	14.02	154.59	127.53
RBFN	16326.99	13.37	154.38	127.78

Bu aşamada daha önce test edilen ve gerçek yanan alan parametrelerinin kullanılmasına göre daha iyi sonuç verdiği gözlemlenen yanan alan değerleri üzerinde logaritmik dönüşüm yapılması yöntemi azaltılmış parametreler ile elde edilen veri kümesine de denenmiştir. Veri girdi parametrelerinin azaltılması ve öbekleme işlemi ile bazı verilerin elenmesi ile elde edilen veri kümesinde yangın kayıtlarının yanan toplam hektar değerlerine göre frekans dağılımları Şekil 5.4.'te verilmiştir.



Şekil 5.4. Azaltılmış parametreler yanan toplam alan değerleri dağılımı

Yanan alan değerlerinin geniş bir aralığa yayılmasından dolayı, verilerin her aralıkta eşit miktarda temsil edilmesini ve böylece doğru öğrenmenin gerçekleştirilebilmesini sağlamak açısından yanan alan değerleri daha önce yapıldığı gibi $\ln(x+1)$ logaritmik fonksiyonu kullanılarak yeniden düzenlenmiştir. Şekil 5.5. logaritmik dönüşüm yapılan yanan toplam hektar değerlerinin frekans dağılımını göstermektedir.



Şekil 5.5. Azaltılmış parametreler yanan toplam alan $\ln(x+1)$ dönüşüm dağılımı

Logaritmik dönüşüm öncesi yanan alan değerleri 1 ile 10.000 hektar arasında değer alırken, logaritmik dönüşüm sonrası bu aralık 1 ile 9 ln hektar arasına indirgenmiştir. Girdi parametrelerinin azaltılması, bazı verilerin öbekleme sonucu elenmesi ve çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm verilerinin kullanılması sonucu yapılan test analiz sonuçları Çizelge 5.10.'da yer almaktadır.

Çizelge 5.10. Azaltılmış parametreler veri eleme $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16285.33	5.65	8.58	127.61
RBFN	16300.42	5.72	9.58	127.67


Yukarıdaki hata analiz tablosu incelendiğinde sonuçların Çizelge 5.2.'deki hata sonuçlarına oranla daha iyi çıktığı görülmüştür.

Azaltılmış girdi parametreleri ile yapılan bir diğer çalışma daha önce yapılan, verilerin girdi parametrelerine göre öbeklenmesi, öbek merkezlerinin yeni veriler olarak alınması, çıktı parametrelerinin ise öbekteki verilerin yanan alan değerlerinin ortalaması olarak tespit edilmesini içeren çalışma olmuştur. Bunu gerçekleştirmek için veri kümesi 400 adet öbeğe ayrılmış, öbek merkezleri temsilci noktalar olarak seçilmiş, yanan alan değerleri ortalama değer olarak atanmıştır. Bu işlem sonucunda eğitim, bağımsız geçerlilik sınaması ve test veri kümeleri sırasıyla 270, 90 ve 90 veri içerecek şekilde ayrılmıştır. MP ve RBFN ile çıktı parametresi olarak yanan alan gerçek değerlerinin kullanılması ile yapılan test sonuçları Çizelge 5.11. hata analiz tablosunda görülmektedir.

Çizelge 5.11. Azaltılmış parametreler öbekleme ile yeni veri elde edilmesi
MP ve RBFN hata analiz tablosu


	MSE	MAE	MAPE	RMSE
MP	302.10	7.23	5.71	17.38
RBFN	379.75	4.58	1.58	19.49

400 adet öbeğe ayırma işlemi sonucunda elde edilen yeni verilerin yanan alan değerleri üzerinde de $\ln(x+1)$ logaritmik dönüşümü yapılmıştır. Logaritmik dönüşüm öncesinde yanan alan değerleri ile elde edilen frekans dağılımı Şekil 5.6.'da yer almaktadır.



Şekil 5.6. Yeni veriler yanan toplam alan değerleri dağılımı

Logaritmik dönüşüm öncesi yanan alan değerleri 1 ile 600 arasında dağılmaktadır. Örneğin; 1 ile 5 arasında 238 adet veri, 5 ile 10 arasında 167 adet veri bulunmaktadır. En yüksek yangın değeri ise 500 ile 600 arasında bir veri ile temsil edilmektedir. Yanan alan değerlerinin aralığının daraltılması ve aralıklarda mümkün olduğu kadar eşit temsil edilmesini sağlamak açısından logaritmik dönüşüm yapılmıştır. Yapılan $\ln(x+1)$ dönüşümü sonrası oluşan yanan alan değerleri frekans dağılımı Şekil 5.7.'de gösterilmiştir.



Şekil 5.7. Yeni veriler yanan toplam alan $\ln(x+1)$ dönüşüm dağılımı

Öbekleme sonucu elde edilen yeni veri yanan alan değerleri üzerinde yapılan logaritmik dönüşüm sonrası bu veriler kullanılarak yapılan MP ve RBFN test sonucu aşağıdaki Çizelge 5.12.'de görülmektedir.

Çizelge 5.12. Yeni veriler $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	368.95	4.10	0.51	19.21
RBFN	336.81	4.05	0.54	18.35

Yukarıdaki sonuçlara göre hata oranları, Çizelge 5.2. ve Çizelge 5.10.'a kıyasla dikkate değer şekilde düşük çıkmıştır.


Parametre sayısının azaltılması ile oluşturulan veri kümesi üzerinde yapılan diğer çalışma ise yanan toplam hektar alanı üzerinde yeni bir bulanık model tanımlamak olmuştur. Bunun için öbeklenerek elenmiş 7.920 adet orman yangını kaydını içeren veri kümesi kullanılmıştır. Veri kümesi öncelikle 5 adet öbeğe ayrılmıştır. Oluşan öbek merkezleri, yeni oluşturulacak bulanık modelde kullanılacak bulanık grup değerlerini

oluşturmuştur. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.13.'te yer almaktadır.

Çizelge 5.13. Azaltılmış parametreler 5 adet öbek sonucu oluşan merkez değerleri

öbek numarası	merkez değeri
1	1.32
2	63.86
3	273.05
4	773.17
5	5661.00

Buna göre yanan toplam hektar değerleri için oluşturulan yeni bulanık model Şekil 5.8.'de görülmektedir.



Şekil 5.8. Toplam hektar parametresi için bulanık model

Elenerek 7.920 adete düşürülmüş orman yangını verileri Şekil 5.8.'deki yanan toplam alan bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 7.825 veriye, grup 2 76 veriye, grup 3 14 veriye, grup 4 3 veriye, ve grup 5 2 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümelerine veri dağıtımından sonra bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması

nedeniyle “1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı” kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınavası veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 23.475 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 4.695 adet olmuştur. Bağımsız geçerlilik sınavası kümesi ise 6.260 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınavası kümesi içerisindeki veri sayıları 1.565 adet olmuştur (5.bulanık grup sadece 2 adet veriye sahip olduğundan, bu veriler eğitim ve test veri kümelerinde kullanılmışlardır, dolayısıyla bağımsız geçerlilik sınavası kümesi 5.bulanık grup verisi içermemektedir). Buna göre test analiz sonuçları Çizelge 5.14.’te yer almaktadır.

Çizelge 5.14. Yanan alan bulanık model kullanılan MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1228	337	78.45	21.55	1	1565	0	100.00	0.00
2	8	7	53.33	46.67	2	0	15	0.00	100.00
3	1	2	33.33	66.67	3	0	3	0.00	0.00
4	0	1	0.00	100.00	4	0	1	0.00	100.00
5	1	0	100.00	0.00	5	0	1	0.00	100.00
Toplam	1238	347			Toplam	1565	20		
%	78.11	21.89			%	98.74	1.26		


Çizelge 5.14.’teki grup analiz tablosu dikkate alındığında, MP toplamda 1.238 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %78,11 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.565 veriden 1.228 adet veriyi doğru tahmin etmiş ve böylece %78,45 doğru tahmin oranını yakalamıştır. 2.grup 8 doğru tahmin ve %53,33 doğru oranına, 3.grup 1 doğru tahmin ve %33,33 doğru oranına, 5.grup ise 1 doğru tahmin ve %100,00 doğru oranına sahip olurken, 4.grupta yer alan 1 adet veri yanlış olarak gruplandırılmıştır. RBFN’te ise tahmin sonuçlarına göre sadece 1.grupta yer alan 1.565 adet verinin tamamı doğru olarak gruplandırılmış ve böylece doğru tahmin oranı %98,74 olmuştur.

Aynı çalışma kapsamında, 7.920 adet orman yangını verisine sahip olan veri kümesi içerisinde bu kez yanan alan değerlerinin $\ln(x+1)$ logaritmik dönüşüme uğraması sonucu elde edilen yanan alan logaritmik dönüşüm değerlerinin 5 adet öbeğe ayrılması ile elde edilen öbek merkezlerinin yeni bulanık model oluşturulmasında kullanılması deneyi yürütülmüştür. Veri kümesi öncelikle yanan alan logaritmik dönüşüm değerlerine göre 5 adet öbeğe ayrılmıştır. Oluşan öbek merkezleri, yeni oluşturulacak bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.15.'te yer almaktadır.

Çizelge 5.15. Azaltılmış parametreler yanan alan $\ln(x+1)$ dönüşüm 5 adet öbek sonucu oluşan merkez değerleri

öbek numarası	merkez değeri
1	0.0253
2	0.1595
3	0.5958
4	1.5148
5	3.5240

Buna göre yanan alan logaritmik dönüşüm değerleri için oluşturulan bulanık model Şekil 5.9.'te görülmektedir.



Şekil 5.9. Toplam hektar $\ln(x+1)$ dönüşüm parametresi için bulanık model

7.920 adete düşürülmüş orman yangını verileri Şekil 5.9.'daki yanan toplam alan logaritmik dönüşüm bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 1.871 veriye, grup 2 2.615 veriye, grup 3 1.916 veriye, grup 4 1.254 veriye, ve grup 5 264 veriye sahip olmuştur. Burada dikkat edilecek nokta bulanık model uygulanması sonrasında verilerin gruplara neredeyse eşit oranda dağılmış olmalarıdır. Grup dağılımından sonra eğitim, bağımsız geçerlilik sınavı ve test kümeleri oluşturulmuştur. Eğitim kümesinde 1.123 1.grup, 1.569 2.grup, 1.150 3.grup, 752 4.grup ve 158 5.grup verisi olmak üzere toplam 4.752 adet veri bulunmaktadır. Bağımsız geçerlilik sınavı ve test kümelerinde 374 1.grup, 523 2.grup, 383 3.grup, 251 4.grup ve 53 5. grup olmak üzere toplam 1.584'er veri bulunmaktadır. Veri dağılımından sonra bütün grupların, eğitim ve bağımsız geçerlilik sınavı veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 2.grup veri sayısının fazla olması nedeniyle “2.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı” kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınavı veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 7.845 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 1.569 adet olmuştur. Bağımsız geçerlilik sınavı kümesi ise 2.615 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınavı kümesi içerisindeki veri sayıları 523 adet olmuştur. Buna göre MP ve RBFN ile yapılan test analiz sonuçları Çizelge 5.16.'da yer almaktadır.

Çizelge 5.16. Yanan alan $\ln(x+1)$ dönüşüm bulanık model kullanılarak MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	290	84	77.54	22.46	1	254	120	67.91	32.09
2	76	447	14.53	85.47	2	70	453	13.38	86.62
3	10	373	2.61	97.39	3	32	351	8.58	91.42
4	65	186	25.90	74.10	4	75	176	29.88	70.12
5	29	24	54.72	45.28	5	20	33	37.74	62.26
Toplam	470	1114			Toplam	451	1133		
%	29.67	70.33			%	28.47	71.53		

Çizelge 5.16.'daki grup analiz tablosu dikkate alındığında, MP toplamda 470 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %29,67 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 290 adet veriyi doğru tahmin etmiş ve böylece %77,54 doğru tahmin oranını yakalamıştır. 2.grup 523 veriden 76 adet veriyi doğru tahmin ederek %14,53 doğru tahmin oranına, 3.grup 383 veriden 10 adet veriyi doğru tahmin ederek %2,61 doğru tahmin oranına, 4.grup 251 veriden 65 adet veriyi doğru tahmin ederek %25,90 doğru tahmin oranına ve 5.grup 53 veriden 29 adet veriyi doğru tahmin ederek %54,72 doğru tahmin oranına ulaşmıştır. Burada MP için dikkat edilecek nokta, grup bazında doğru sınıflandırılan veri sayısının ve böylece doğru tahmin oranının artmış olmasıdır. RBFN toplamda 451 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %28,47 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 254 adet veriyi doğru tahmin etmiş ve böylece %67,91 doğru tahmin oranını yakalamıştır. 2.grup 553 veriden 70 adet veriyi doğru tahmin ederek %13,38 doğru tahmin oranına, 3.grup 383 veriden 32 adet veriyi doğru tahmin ederek %8,58 doğru tahmin oranına, 4.grup 251 veriden 75 adet veriyi doğru tahmin ederek %29,88 doğru tahmin oranına ve 5.grup 53 veriden 20 adet veriyi doğru tahmin ederek %37,74 doğru tahmin oranına ulaşmıştır. RBFN 3. ve 4.gruplar için daha başarılı bir sınıflandırma yapmış olmasına rağmen toplamda MP performansını geçememiştir. Ancak RBFN kullanılarak diğer yöntemlerle

yapılan test sonuçları göz önüne alındığında, RBFN performansı bu yöntem için en iyi sonucu vermiştir.

Azaltılmış parametreler ile yapılan test işlemlerinden sonra aynı deneylerin, yapay sinir ağlarını test etmek için kullanılan test veri kümeleri yerine, ağları eğitmekte kullanılan eğitim veri kümeleri kullanılarak tekrarlanması ve böylece ağın öğrenme kabiliyetinin kendisine daha önce gösterilen verilerin test verisi olarak kullanımı ile kontrol edilmesi işlemi gerçekleştirilmiştir.

Bu amaçla ilk önce öbekleme sonucunda elenerek 7.920 adete indirilen verilerin MP ve RBFN ile test işlemi, test verileri yerine eğitim verileri kullanılarak gerçekleştirilmiştir. Buna ilişkin hata analiz tablosu Çizelge 5.17.'de görülmektedir.

Çizelge 5.17. Test yerine eğitim veri kümesi kullanımı hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	8719.83	12.41	153.08	93.38
RBFN	8749.36	9.24	108.28	93.54

Elenmiş 7.920 adet verinin kullanılmasıyla aynı test işlemi bu kez yanan alan değerleri üzerinde $\ln(x+1)$ dönüşümü yapılarak tekrar edilmiş, bu deneye ait test sonuçları ise Çizelge 5.18.'de gösterilmiştir.

Çizelge 5.18. Test yerine eğitim veri kümesi kullanılması yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	8703.87	3.87	9.40	93.29
RBFN	8703.61	3.90	10.51	93.29

Daha sonra verilerin girdi parametrelerine göre 400 adet öbeğe ayrılması ve öbekleme sonucu ortaya çıkan öbek merkezlerinin yeni veriler olarak alınması, çıktı parametreleri olarak her öbek içerisindeki yanan alan değerleri ortalamalarının bulunmasına ait çalışma, test veri kümesi yerine eğitim kümesi kullanılıp yapay sinir ağının öğrenme becerisinin bu yolla tespit edilmesi açısından tekrar edilmiştir. Çizelge 5.19. çıktı olarak yanan alan değerlerinin kullanılması ile yapılan bu çalışmaya ait sonuçları içermektedir.

Çizelge 5.19. Yeni verilerin elde edilmesi ile test yerine eğitim veri kümesi kullanımı hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	1093.59	6.55	4.77	33.07
RBFN	1153.91	5.59	4.18	33.97

Yapılan bu deney, çıktı parametresi olarak yanan alan değerlerinin logaritmik dönüşümlerinin kullanılması ile tekrar edilmiştir. Buna ait hata analiz tablosu Çizelge 5.20.'de verilmiştir.

Çizelge 5.20. Yeni verilerin elde edilmesi ile test yerine eğitim veri kümesi kullanımı yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	1169.10	3.78	0.53	34.19
RBFN	1177.73	3.79	0.56	34.32

Hata oranları incelendiğinde öbekleme sonucu yeni elde edilen verilerin gerçek orman yangını verilerine oranla bu test için MAE ve MAPE bakımından daha iyi sonuç verdiği gözlemlenmiştir.

Aynı amaçla son test işlemi, yanan alan değerlerinin Şekil 5.8.'deki bulanık model kullanılarak 5 adet bulanık gruba ayrıldığı veri kümesinde yapılmış, eğitim veri kümesi hem ağı eğitiminde hem de test aşamasında yapay sinir ağına gösterilmiş, ağı çıktıkları

kaydedilmiştir. Bu çıktılarla bulanık modele göre doğru ve yanlış gruplandırılan veri sayıları hesaplanmıştır. Çizelge 5.21. MP ve RBFN kullanılarak elde edilen sonuçların grup analiz tablosunu içermektedir.

Çizelge 5.21. Bulanık model ile test yerine eğitim veri kümesi kullanımı MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	2147	2548	45.73	54.27	1	3956	739	84.26	15.74
2	2653	2042	56.51	43.49	2	0	4695	0.00	100.00
3	2934	1761	62.49	37.51	3	1760	2935	37.49	62.51
4	4695	0	100.00	0.00	4	4695	0	100.00	0.00
5	4695	0	100.00	0.00	5	0	4695	0.00	100.00
Toplam	17124	6351			Toplam	10411	13064		
%	72.95	27.05			%	44.35	55.65		

Son olarak yanan alan değerlerinin $\ln(x+1)$ logaritmik dönüşümünden sonra Şekil 5.9.'daki bulanık model kullanılarak 5 adet bulanık gruba ayrıldığı veri kümesi üzerinde yapılan test sonuçları ise Çizelge 5.22.'deki grup analiz tablosunda görülmektedir.

Çizelge 5.22. Bulanık model ile test yerine eğitim veri kümesi kullanımı yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1315	254	83.81	16.19	1	1109	460	70.68	29.32
2	128	1441	8.16	91.84	2	235	1334	14.98	85.02
3	60	1509	3.82	96.18	3	121	1448	7.71	92.29
4	602	967	38.37	61.63	4	531	1038	33.84	66.16
5	259	1310	16.51	83.49	5	457	1112	29.13	70.87
Toplam	2364	5481			Toplam	2453	5392		
%	30.13	69.87			%	31.27	68.73		


Çizelge 5.21. ve Çizelge 5.22'den de görüldüğü gibi yapılan testler, verilerin gerçek yanan alan değerlerinin kullanıldığı zaman daha iyi sonuç vermiş, toplam doğru tahmin oranı MP için %72,95'e kadar çıkmıştır. Yanan alan değerleri üzerinde logaritmik dönüşüm yapıldığında en iyi sonuç RBFN ile elde edilmiş, doğru tahmin oranı toplamda %31,27 olmuştur. Burada dikkat edilecek husus test amaçlı kullanılan eğitim veri sayılarının farklılığıdır. Çizelge 5.21. ve Çizelge 5.22.'de eğitim veri kümesindeki toplam veri sayısı ile aynı gruplara giren verilerin farklı sayılarda olmasının nedeni; daha önce verilen Şekil 5.8.'e göre yanan alan değerlerinin ve Şekil 5.9.'a göre ise logaritmik dönüşüm uygulanan yanan alan değerlerinin gruplara dağıtılmasıdır. Şekil 5.8.'e göre en fazla veri sayısı 1.grupta toplam 7.825 veri ile olmuş ve bu verilerin 4.695 adeti eğitim veri kümesine girmiştir. Eğitim kümesinde tüm grup veri sayıları adil öğrenmeyi sağlamak açısından en fazla veri sayısına sahip 1.gruba göre eşitlendiğinden toplam veri sayısı 23.475 olmuştur. Şekil 5.9.'a göre ise en fazla veri sayısı 2.grupta toplam 2.615 veri ile olmuş ve bu verilerin 1.569 adeti eğitim veri kümesine girmiştir. Eğitim kümesinde tüm grup veri sayıları adil öğrenmeyi sağlamak açısından 2.grup verilerine göre eşitlendiğinden toplam veri sayısı 7.845 olmuştur.

Kullanılan yapay sinir ağları ile öğrenme başarı oranının uygulanan yöntemlere göre nasıl bir değişime sahip olduğunu gözlemleyebilmek ve başarı oranını arttırmak adına yapılan diğer bir çalışmada, yangın kayıtlarının yanan alan değerleri için tanımlanan bulanık modelin 5 bulanık grup değil 3 gruptan oluşması sağlanmıştır. Bunun için eleme yöntemi ile daha önce elde edilen 7.920 adet kayıttan oluşan veri kümesi kullanılmıştır. Veri kümesi yanan alan değerlerine göre 3 adet öbeğe ayrılmıştır. Öbikleme sonucu oluşan merkez değerleri Çizelge 5.23.'te verilmiştir.

Çizelge 5.23. 3 adet öbek sonucu oluşan merkez değerleri

öbek numarası	merkez değeri
1	2.06
2	457.45
3	5661.00

Oluşan öbek merkezleri, çalışma için bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Bu değerler kullanılarak yanan toplam hektar parametresi için oluşturulan bulanık model aşağıda Şekil 5.10.'da görülmektedir.



Şekil 5.10. Yanan alan parametresi için bulanık model

7.920 adet orman yangını verisi Şekil 5.10.'daki yanan toplam alan için 3 bulanık grup içeren bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 7.907 veriye, grup 2 11 veriye ve grup 3 2 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümelerine veri dağıtımından sonra bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle "1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı" kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınaması veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 14.235 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 4.745 adet

olmuştur. Bağımsız geçerlilik sınaması kümesi ise 3.162 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 1.581 adet olmuştur (3.bulanık grup sadece 2 adet veriye sahip olduğundan, bu veriler eğitim ve test veri kümelerinde kullanılmışlardır, dolayısıyla bağımsız geçerlilik sınaması kümesi 3.bulanık grup verisi içermemektedir). Verilerin dağıtımından sonra test işlemi gerçekleştirilmiş, elde edilen yapay sinir ağı çıktısının veriyi dahil ettiği bulanık küme ile verinin gerçekte dahil olduğu bulanık kümenin tutarlılığı incelenmiş, her grup için doğru gruplandırılan ve yanlış gruplandırılan veri sayıları ile doğru ve yanlış gruplandırılma oranları, toplam doğru ve yanlış grup tahmin edilme sayıları ile doğru ve yanlış tahmin oranları analiz edilmiştir. Buna göre çıktı parametresi olarak yanan alan değerleri kullanılarak MP ve RBFN ile yapılan test grup analiz sonuçları Çizelge 5.24.'te yer almaktadır.

Çizelge 5.24. Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1402	179	88.68	11.32	1	1581	0	100.00	0.00
2	2	0	100.00	0.00	2	0	2	0.00	100.00
3	0	1	0.00	100.00	3	0	1	0.00	100.00
Toplam	1404	180			Toplam	1581	3		
%	88.63	11.37			%	99.81	0.19		

Çizelge 5.24.'teki grup analiz tablosu dikkate alındığında, MP toplamda 1.404 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %88,63 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.581 veriden 1.402 adet veriyi doğru tahmin etmiş ve böylece %88,68 doğru tahmin oranını yakalamıştır. 2.grup ise 2 doğru tahmin ve %100,00 doğru oranına sahip olurken, 3.grupta yer alan 1 adet veri yanlış olarak gruplandırılmıştır. RBFN toplamda 1.581 adet veriyi doğru grup içerisine koymuş, doğru tahmin oranı %99,81 olmuştur. Doğru tahmin edilen verilerin


tamamı 1.gruba ait olup, 2. ve 3.gruptaki verilerin tamamı yanlış olarak gruplandırılmıştır.

Yanan alan değerlerinin test edilmesinden sonra, 7.920 adet orman yangını verisine sahip olan veri kümesi içerisinde bu kez yanan alan değerlerinin $\ln(x+1)$ logaritmik dönüşüme uğraması sonucunda yanan alan logaritmik dönüşüm değerlerinin 3 adet öbeğe ayrılması ile elde edilen öbek merkezlerinin yeni bulanık model oluşturulmasında kullanılması çalışması yürütülmüştür. Veri kümesi yanan alan logaritmik dönüşüm değerlerine göre 3 adet öbeğe ayrılmıştır. Oluşan öbek merkezleri, yeni oluşturulacak bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.25.'te yer almaktadır.

Çizelge 5.25. Yanan alan $\ln(x+1)$ dönüşüm 3 adet öbek merkez değerleri

öbek numarası	merkez değeri
1	0.1604
2	1.0882
3	3.0294

Buna göre yanan alan logaritmik dönüşüm değerleri için oluşturulan bulanık model Şekil 5.11.'de görülmektedir.



Şekil 5.11. Yanan alan $\ln(x+1)$ dönüşüm parametresi için bulanık model

Orman yangını verileri Şekil 5.11.'deki yanan alan logaritmik dönüşüm bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 5.412 veriye, grup 2 2.076 veriye ve grup 3 432 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümeleri oluşturulmuştur. Eğitim kümesinde 3.260 1.grup, 1.240 2.grup ve 254 3.grup verisi olmak üzere toplam 4.754 adet veri bulunmaktadır. Bağımsız geçerlilik sınaması ve test kümelerinde 1.076 1.grup, 418 2.grup ve 89 3.grup olmak üzere toplam 1.583'er veri bulunmaktadır. Veri dağıtımından sonra daha önceki çalışmalarda olduğu gibi bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle "1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı" kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınaması veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 9.780 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 3.260 adet olmuştur. Bağımsız geçerlilik sınaması kümesi ise 3.228 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 1.076 adet olmuştur. Buna göre MP ve RBFN ile yapılan test analiz sonuçları Çizelge 5.26.'da yer almaktadır.

Çizelge 5.26. Yanan alan $\ln(x+1)$ dönüşüm bulanık model kullanılarak MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	856	220	79.55	20.45	1	1064	12	98.88	1.12
2	40	378	9.57	90.43	2	7	411	1.67	98.33
3	37	52	41.57	58.43	3	0	89	0.00	100.00
Toplam	933	650			Toplam	1071	512		
%	58.94	41.06			%	67.66	32.34		

Çizelge 5.26.'daki grup analiz tablosu dikkate alındığında, MP toplamda 933 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %58,94 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.076 veriden 856 adet veriyi doğru tahmin etmiş ve böylece %79,55 doğru tahmin oranını yakalamıştır. 2.grup 418 veriden 40 adet veriyi doğru tahmin ederek %9,57 doğru tahmin oranına ve 3.grup 89 veriden 37 adet veriyi doğru tahmin ederek %41,57 doğru tahmin oranına ulaşmıştır. RBFN toplamda 1.076 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %67,97 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.076 verinin tamamını doğru tahmin etmiş ve böylece %100,00 doğru tahmin oranını yakalamıştır. Fakat 2. ve 3.grup verilerinden hiç birini doğru olarak gruplandıramamıştır. Sonuçlara göre bu çalışma için MP, RBFN'e oranla daha iyi bir performans göstermiştir. Genel sonuçlarla karşılaştırıldığında ise MP grup bazında doğru tahmin oranları ve toplamda %58,94'lük doğru tahmin oranı ile diğer deneylerden daha iyi sonuç vermiştir.

Bu deneylerden sonra yapay sinir ağı modellerinin öğrenme kalitesini arttırmak amacıyla başka bir yöntem üzerinde çalışılmıştır. Bu yöntem ile 8 adet girdi parametresi Temel Bileşenler Analizi (Principal Component Analysis-PCA) kullanılarak yeniden düzenlenmiştir. PCA temel olarak karmaşık bir veri kümesini düşük boyutlara indirgemeyi, eldeki veriyi daha az sayıda bileşen ile ifade edebilecek en iyi dönüşümü belirlemeyi hedefler. 8 adet girdi parametresinin PCA uygulanması ile yeni uzayda karşılıkları bulunmuştur.

PCA sonucu oluşan bu yeni girdi parametrelerinin tamamı kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde MP ve RBFN ile test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.27. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.27. PCA ile yanan alan MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16377.22	9.61	85.90	127.97
RBFN	16321.83	10.74	106.21	127.76

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.28.'de verilmiştir.

Çizelge 5.28. PCA ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16300.87	5.74	11.43	127.67
RBFN	16303.10	5.74	11.60	127.68

Deney sonuçları analiz edildiğinde yapılan bu ilk çalışma için parametreler üzerinde PCA kullanılmasının dikkate değer bir iyileştirme sağlamadığı gözlemlenmiştir. Daha sonra PCA sonucu oluşan 8 adet yeni girdi parametresi, veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi kullanılarak tekrar edilmiştir. İlgili ilk test çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.29.'da sonuç hata analiz tablosu görülmektedir.

Çizelge 5.29. PCA yeni veri elde edilmesi MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	543.63	10.08	9.31	23.32
RBFN	394.71	8.37	7.94	19.87

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.30. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.30. PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	382.52	4.27	0.66	19.56
RBFN	386.37	4.42	0.82	19.66

Yeni verilerin elde edilmesi ve PCA sonrası 8 parametrenin kullanılması sonuçları daha önce yapılan ve hata analiz sonuçları Çizelge 5.11. ve Çizelge 5.12.'de bulunan testler ile karşılaştırıldığında görüldüğü gibi iyileşme açısından bir ilerleme kaydedilememiştir.

PCA sonucu oluşan 8 adet yeni girdi parametresi, yanan alan değerlerinin Şekil 5.8.'de görülen 5 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.31'de yer almaktadır.

Çizelge 5.31. PCA yanan alan bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	0	1565	0.00	100.00	1	591	974	37.76	62.24
2	14	1	93.33	6.67	2	6	9	40.00	60.00
3	0	3	0.00	100.00	3	0	3	0.00	100.00
4	0	1	0.00	100.00	4	0	1	0.00	100.00
5	0	1	0.00	100.00	5	0	1	0.00	100.00
Toplam	14	1571			Toplam	597	988		
%	0.88	99.12			%	37.67	62.33		

Çizelge 5.31.'deki grup analiz tablosunda görüldüğü gibi, MP toplamda sadece 2.gruba dahil olan 14 adet veriyi doğru grup içerisine koymuş, geri kalan tüm verileri yanlış olarak gruplandırmış ve bu toplam doğru gruplandırma oranının %0,88 olmasını sağlamıştır. Bu oran, PCA uygulanmadan kullanılan girdi parametreleri ile yapılan eşdeğer deneyde Çizelge 5.14.'te görüldüğü üzere %78,11'dir. RBFN ise 1.grupta 591 doğru tahmin sayısı ile %37,76 doğru tahmin oranı, 2.grupta 6 doğru tahmin sayısı ile %40,00 doğru tahmin oranı elde etmiş, diğer grup verilerini yanlış olarak gruplandırmış ve sonuç olarak toplam %37,67'lik doğru tahmin oranını yakalamıştır. Bu sonuç Çizelge 5.14.'te görülmekte olan RBFN test sonucundan daha iyi bir performans ortaya koymuştur.

Aynı çalışma kapsamında diğer deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.9.'daki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Aşağıdaki Çizelge 5.32. grup analiz sonuçlarını içermektedir.

Çizelge 5.32. PCA yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	181	193	48.40	51.60	1	300	74	80.21	19.79
2	16	507	3.06	96.94	2	0	523	0.00	100.00
3	22	361	5.74	94.26	3	40	343	10.44	89.56
4	69	182	27.49	72.51	4	0	251	0.00	100.00
5	8	45	15.09	84.91	5	13	40	24.53	75.47
Toplam	296	1288			Toplam	353	1231		
%	18.69	81.31			%	22.29	77.71		

Çizelge 5.32.'deki grup analiz tablosu dikkate alındığında, MP toplamda 296 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %18,69 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 181 adet

veriyi doğru tahmin etmiş ve böylece %48,40 doğru tahmin oranını yakalamıştır. 2.grup 523 veriden 16 adet veriyi doğru tahmin ederek %3,06 doğru tahmin oranına, 3.grup 383 veriden 22 adet veriyi doğru tahmin ederek %5,74 doğru tahmin oranına, 4.grup 251 veriden 69 adet veriyi doğru tahmin ederek %27,49 doğru tahmin oranına ve 5.grup 53 veriden 8 adet veriyi doğru tahmin ederek %15,09 doğru tahmin oranına ulaşmıştır. Çizelge 5.16.'daki tablo ile karşılaştırıldığında MP sonuçlarının, bu test için sadece 3. ve 4. gruplarda bir iyileşme sağladığı gözlemlenmiştir. RBFN toplamda 353 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %22,29 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 300 adet veriyi doğru tahmin etmiş ve böylece %80,21 doğru tahmin oranını yakalamıştır. 3.grup 383 veriden 40 adet veriyi doğru tahmin ederek %10,44 doğru tahmin oranına ve 5.grup 53 veriden 13 adet veriyi doğru tahmin ederek %24,53 doğru tahmin oranına ulaşmıştır. 2.gruptaki 523 verinin ve 4.gruptaki 251 verinin tamamı yanlış olarak gruplandırmıştır. Çizelge 5.16. değerleri ile karşılaştırıldığında, RBFN 1. ve 3.gruplar için daha başarılı bir sınıflandırma yapmış olmasına rağmen, 5.grup için doğru tahmin oranını %24,53'e düşürmüş, 2. ve 4.gruplarda hiç doğru tahmin yapamamıştır.

PCA sonucu oluşan 8 adet yeni girdi parametresi, bu kez yanan alan değerlerinin Şekil 5.10.'da görülen 3 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.33.'te yer almaktadır.

Çizelge 5.33. PCA yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	998	583	63.12	36.88	1	615	966	38.90	61.10
2	0	2	0.00	100.00	2	0	2	0.00	100.00
3	1	0	100.00	0.00	3	0	1	0.00	100.00
Toplam	999	585			Toplam	615	969		
%	63.07	36.93			%	38.83	61.17		

Çizelge 5.33.'teki grup analiz tablosu dikkate alındığında, MP toplamda 999 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %63,07 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.581 veriden 998 adet veriyi doğru tahmin etmiş ve böylece %63,12 doğru tahmin oranını yakalamıştır. 3.grup ise 1 doğru tahmin ve %100,00 doğru oranına sahip olurken, 2.grupta yer alan 2 adet veri yanlış olarak gruplandırılmıştır. Buna göre Çizelge 5.24.'teki sonuçlarla karşılaştırıldığında, MP'nin 3 gruplu bulanık model için PCA parametreleriyle daha iyi sonuç vermediği toplam doğru tahmin oranının %63,07'ye düştüğü görülmüştür. RBFN toplamda 615 adet veriyi doğru grup içerisine koymuş, doğru tahmin oranı %38,83 olmuştur. Doğru tahmin edilen verilerin tamamı 1.gruba ait olup, 2. ve 3.gruptaki verilerin tamamı yanlış olarak gruplandırılmıştır. RBFN için de Çizelge 5.24. dikkate alındığında sonuçlarda iyileşme olmamıştır.

Aynı çalışma kapsamında diğer deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.11.'deki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Çizelge 5.34. grup analiz sonuçlarını içermektedir.

Çizelge 5.34. PCA yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	630	446	58.55	41.45	1	1011	65	93.96	6.04
2	75	343	17.94	82.06	2	3	415	0.72	99.28
3	32	57	35.96	64.04	3	18	71	20.22	79.78
Toplam	737	846			Toplam	1032	551		
%	46.56	53.44			%	65.19	34.81		

Çizelge 5.34.'teki grup analiz tablosu dikkate alındığında, MP toplamda 737 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %46,56 olmuştur. Grup

bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 630, 2.grup 75 ve 3.grup 32 adet veriyi doğru olarak tahmin etmiştir. Böylece MP açısından Çizelge 5.26.'daki grup analiz sonuçlarına göre sadece 2.grup doğru tahmin oranında bir iyileşme görülmüştür. RBFN toplamda 1.032 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %65,19 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.076 veriden 1.011 adet veriyi doğru tahmin etmiş ve %93,96 tahmin oranına ulaşmıştır. 2.grup 418 veriden 3 adet veriyi doğru tahmin edip %0,72 doğru tahmin oranına, 3.grup 89 veriden 18 adet veriyi doğru tahmin edip %20,22 doğru tahmin oranına sahip olmuştur. Çizelge 5.26. sonuçları ile karşılaştırıldığında RBFN 1.grup için daha kötü bir sonuç vermiş olsa da, daha önce hiçbir verinin tahmin edilemediği 2. ve 3.grup verilerinde doğru tahmin yakalamıştır.

Girdi parametreleri üzerinde PCA uygulanması, bu yöntemle yeni 8 adet girdi parametresinin oluşturulması ve bunların tamamının kullanılmasıyla yapılan deneylerden sonra, daha az sayıda parametre kullanılarak test sonuçlarındaki değişimin gözlemlenmesi amaçlanmıştır. Bu bağlamda PCA sonucu oluşan sadece 3 adet girdi parametresi kullanılmış, çıkan sonuçlar daha önceki deneylerle karşılaştırılmıştır.

PCA sonucu oluşan yeni girdi parametrelerinden sadece 3 tanesi kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde MP ve RBFN ile test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.35. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.35. PCA ile yanan alan MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16458.84	10.50	99.93	128.29
RBFN	16564.75	22.85	303.43	128.70

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.36.'da verilmiştir.

Çizelge 5.36. PCA ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16307.60	5.83	12.59	127.70
RBFN	16298.60	5.78	12.39	127.67

Deney sonuçları analiz edildiğinde, daha önce yapılan ve sonuçları Çizelge 5.27. ve Çizelge 5.28.'de görülen testlere oranla PCA sonucu 3 parametrenin kullanılması ile yapılan bu testlerde bir iyileşme sağlanmadığı gözlemlenmiştir. Daha sonra PCA sonucu oluşan 3 adet yeni girdi parametresi, veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi kullanılarak tekrar edilmiştir. İlgili ilk test, çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.37.'de sonuç hata analiz tablosu görülmektedir.

Çizelge 5.37. PCA yeni veri elde edilmesi MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	485.79	8.78	8.04	22.04
RBFN	355.56	8.47	7.26	18.86

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.38. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.38. PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	385.48	4.39	0.82	19.63
RBFN	367.23	4.31	0.80	19.16

Yeni verilerin elde edilmesi ve PCA sonrası 3 parametrenin kullanılması sonuçları Çizelge 5.29. ve Çizelge 5.30. ile karşılaştırıldığında daha az sayıda parametre kullanımının daha iyi sonuçlar vermediği gözlemlenmiştir.

PCA sonucu oluşan 3 adet yeni girdi parametresi, yanan alan değerlerinin Şekil 5.8.'de görülen 5 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.39.'da yer almaktadır.

Çizelge 5.39. PCA yanan alan bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1565	0	100.00	0.00	1	1561	4	99.74	0.26
2	0	15	0.00	100.00	2	0	15	0.00	100.00
3	0	3	0.00	100.00	3	0	3	0.00	100.00
4	0	1	0.00	100.00	4	0	1	0.00	100.00
5	0	1	0.00	100.00	5	0	1	0.00	100.00
Toplam	1565	20			Toplam	1561	24		
%	98.74	1.26			%	98.49	1.51		

Çizelge 5.39.'daki grup analiz tablosunda görüldüğü gibi, MP toplamda sadece 1.gruba dahil olan 1.565 adet veriyi doğru grup içerisine koymuş, geri kalan tüm verileri yanlış olarak gruplandırmış ve bu toplam doğru gruplandırma oranının %98,74 olmasını sağlamıştır. Bu oran, PCA uygulanmadan kullanılan girdi parametreleri ile yapılan eşdeğer deneyde Çizelge 5.14.'te görüldüğü üzere %78,11'dir. Yine aynı oran PCA

sonucu 8 adet girdi parametresinin tamamının kullanıldığı deneyde Çizelge 5.31.'de görüldüğü gibi %0,06 olarak bulunmuştur. Burada sadece 5.gruba giren 1 adet veri doğru gruplandırılmış, diğer tüm veriler yanlış gruplara sokulmuşlardır. RBFN ise 1.grupta 1.561 doğru tahmin sayısı ile %99,74 doğru tahmin oranı elde edilirken diğer verilerin tamamı yanlış gruplara dahil edilmişlerdir ve böylece toplamda doğru tahmin oranı %98,49 olmuştur. Bu sonuç toplam doğru tahmin oranı ile Çizelge 5.31.'de görülmekte olan RBFN test sonucundan daha iyi bir performans ortaya koymuş olsa bile, grup bazında doğru oranları ile daha kötü bir performans sergilemiştir. Yüksek doğru oranının ise sadece 1.grup verilerinin tahmin edilmiş olmasından kaynaklandığı görülmektedir.

Aynı çalışma kapsamında diğer deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.9.'daki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Çizelge 5.40. grup analiz sonuçlarını içermektedir.

Çizelge 5.40. PCA yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	183	191	48.93	51.07	1	236	138	63.10	36.90
2	0	523	0.00	100.00	2	85	438	16.25	83.75
3	1	382	0.26	99.74	3	26	357	6.79	93.21
4	20	231	7.97	92.03	4	1	250	0.40	99.60
5	12	41	22.64	77.36	5	6	47	11.32	88.68
Toplam	216	1368			Toplam	354	1230		
%	13.64	86.36			%	22.35	77.65		

Çizelge 5.40.'daki grup analiz tablosu dikkate alındığında, MP toplamda 216 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %13,64 olmuştur. Çizelge 5.32.'deki tablo ile karşılaştırıldığında MP sonuçlarının toplam doğru tahmin oranı

azalmış olsa da 1. ve 5.grup doğru tahmin oranlarının arttığı görülmüştür. RBFN toplamda 354 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %22,35 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 236 adet veriyi doğru tahmin etmiş ve böylece %63,10 doğru tahmin oranını yakalamıştır. 2.grup 523 veriden 85 adet veriyi doğru tahmin ederek %16,25 doğru tahmin oranına, 3.grup 383 veriden 26 adet veriyi doğru tahmin ederek %6,79 doğru tahmin oranına, 4.grup 251 veriden 1 adet veriyi doğru tahmin ederek %0,40 doğru tahmin oranına ve 5.grup 53 veriden 6 adet veriyi doğru tahmin ederek %11,32 doğru tahmin oranına ulaşmıştır. Çizelge 5.32. değerleri ile karşılaştırıldığında, RBFN 2. ve 4.gruplar için başarı oranını arttırmıştır.

PCA sonucu oluşan 3 adet yeni girdi parametresi, bu kez yanan alan değerlerinin Şekil 5.10.'da görülen 3 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.41.'de yer almaktadır.

Çizelge 5.41. PCA yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	947	634	59.90	40.10	1	1281	300	81.02	18.98
2	0	2	0.00	100.00	2	0	2	0.00	100.00
3	1	0	100.00	0.00	3	0	1	0.00	100.00
Toplam	948	636			Toplam	1281	303		
%	59.85	40.15			%	80.87	19.13		

Çizelge 5.41.'deki grup analiz tablosu dikkate alındığında, MP toplamda 948 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %59,85 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.581 veriden 947 adet veriyi doğru tahmin etmiş ve böylece %59,90 doğru tahmin oranını yakalamıştır. 3.grup ise 1 doğru tahmin ve %100,00 doğru oranına sahip olurken, 2.grupta yer alan 2 adet

veri yanlış olarak gruplandırılmıştır. Buna göre Çizelge 5.33.’teki sonuçlarla karşılaştırıldığında, MP’nin 1.grup için doğru tahmin oranını %59,90’a düşürdüğü, 2. ve 3.gruplar için bir iyileşme sağlayamadığı gözlemlenmiştir. RBFN toplamda 1.281 adet veriyi doğru grup içerisine koymuş, doğru tahmin oranı %80,87 olmuştur. Doğru tahmin edilen verilerin tamamı 1.gruba ait olup, 2. ve 3.gruptaki verilerin tamamı yanlış olarak gruplandırılmıştır. RBFN için de Çizelge 5.33. dikkate alındığında sadece 1.grup tahmin oranının arttığı görülmüştür.

Deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.11.’deki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Çizelge 5.42. grup analiz sonuçlarını içermektedir.

Çizelge 5.42. PCA yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	844	232	78.44	21.56	1	911	165	84.67	15.33
2	1	417	0.24	99.76	2	93	325	22.25	77.75
3	29	60	32.58	67.42	3	0	89	0.00	100.00
Toplam	874	709			Toplam	1004	579		
%	55.21	44.79			%	63.42	36.58		

Çizelge 5.42.’deki grup analiz tablosu dikkate alındığında, MP toplamda 874 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %55,21 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 844 adet veriyi doğru tahmin ederek ve %78,44 doğru tahmin oranına, 2.grup 1 adet veriyi doğru tahmin ederek %0,24 doğru tahmin oranına ve 3.grup 29 adet veriyi doğru tahmin ederek %32,58 doğru tahmin oranına ulaşmıştır. Böylece MP açısından Çizelge 5.34.’teki grup analiz sonuçlarına göre 1. ve 2.grup ile toplam doğru tahmin oranlarında artış görülmüş, 3.grup tahmin oranı azalmıştır. RBFN toplamda 1.004 adet veriyi doğru grup içerisine

koyarken, doğru gruplandırma oranı %63,42 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.076 veriden 911 adet veriyi doğru tahmin etmiş ve %84,67 tahmin oranına ulaşmıştır. 2.grup 418 veriden 93 adet veriyi doğru tahmin edip %22,25 doğru tahmin oranını yakalamıştır. 3.grup ise tüm verileri yanlış gruplandırmıştır. Çizelge 5.34. sonuçları ile karşılaştırıldığında RBFN 1. ve 3.gruplar için daha kötü bir sonuç vermiş olsa da, 2.grup için daha iyi bir sonuç yakalamıştır.

Yapılan diğer bir çalışmada daha az sayıda girdi parametresi kullanılarak test sonuçlarındaki değişimin gözlemlenmesi amaçlanmıştır. Bu bağlamda nem, rüzgar hızı, sıcaklık, meyil, mevsim, saat, ağaç tipi ve birim alandaki ağaç sayısını içeren toplam 8 adet girdi parametresi yerine sadece nem ve rüzgar hızını içeren 2 adet girdi parametresi kullanılmış ve yapılan testlere ait çıkan sonuçlar daha önceki deneylerle karşılaştırılmıştır.

Nem ve rüzgar hızı girdi parametreleri kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde MP ve RBFN ile test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.43. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.43. 2 parametre ile yanan alan MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16216.53	7.15	38.76	127.34
RBFN	16152.11	18.66	227.28	127.09

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.44.'te verilmiştir.

Çizelge 5.44. 2 parametre ile yanan alan $\ln(x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16274.58	5.69	10.41	127.57
RBFN	16266.06	5.69	10.20	127.54

Deney sonuçları analiz edildiğinde, daha önce yapılan ve sonuçları Çizelge 5.9. ve Çizelge 5.10.'da görülen testlere oranla 2 parametrenin kullanılması ile yapılan bu testlerde bir iyileşme sağlanmadığı gözlemlenmiştir. Daha sonra 2 adet girdi parametresi, veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi kullanılarak tekrar edilmiştir. İlgili ilk test çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.45.'te sonuç hata analiz tablosu görülmektedir.

Çizelge 5.45. 2 parametre yeni veri elde edilmesi MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	251.07	6.89	5.21	15.85
RBFN	287.07	6.37	4.09	16.94

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.46. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.46. 2 parametre yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	344.82	4.11	0.56	18.57
RBFN	357.50	4.19	0.63	18.91

Sadece 2 parametrenin kullanılması ve yeni verilerin elde edilmesi sonuçları Çizelge 5.11. ve Çizelge 5.12. ile karşılaştırıldığında daha az sayıda parametre kullanımının dikkate değer bir iyileşme sağlamadığı gözlemlenmiştir.

2 adet girdi parametresi, yanan alan değerlerinin Şekil 5.8.'de görülen 5 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.47.'de yer almaktadır.

Çizelge 5.47. 2 parametre yanan alan bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	0	1565	0.00	100.00	1	43	1522	2.75	97.25
2	10	5	66.67	33.33	2	0	15	0.00	100.00
3	2	1	66.67	33.33	3	2	1	66.67	33.33
4	1	0	100.00	0.00	4	0	1	0.00	100.00
5	1	0	100.00	0.00	5	0	1	0.00	100.00
Toplam	14	1571			Toplam	45	1540		
%	0.88	99.12			%	2.84	97.16		

Çizelge 5.47.'deki grup analiz tablosunda görüldüğü gibi, MP 2. grupta 10 doğru tahmin sayısı ile %66,67 doğru tahmin oranı, 3.grupta 2 doğru tahmin sayısı ile %66,67 doğru tahmin oranı, 4.grupta 1 doğru tahmin sayısı ve %100,00 doğru tahmin oranı ve 5.grupta 1 doğru tahmin sayısı ile %100,00 doğru tahmin oranı elde etmiştir. Bununla birlikte 1.gruba giren 1.565 verinin tamamını yanlış grup içerisine koymuştur. Buna göre Çizelge 5.14. ile karşılaştırıldığında 1.grup için daha kötü bir sonuç elde edilmişken diğer gruplar için sonuçlarda iyileşme olmuş, 1.grup dışındaki grupların doğru tahmin edilme sayı ve oranları artmıştır. RBFN ise 1.grupta 43 doğru tahmin sayısı ile %2,75 doğru tahmin oranı ve 3.grupta 2 doğru tahmin sayısı ile %66,67 doğru tahmin oranı elde edilirken diğer verilerin tamamı yanlış gruplara dahil edilmişlerdir ve böylece toplamda doğru tahmin oranı %2,84 olmuştur. Bu sonuç toplam ve 3.grup doğru tahmin

oranı ile Çizelge 5.14.'te görülmekte olan RBFN test sonucundan daha iyi bir performans ortaya koymuştur.

Aynı çalışma kapsamında diğer deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.9.'daki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Çizelge 5.48. grup analiz sonuçlarını içermektedir.

Çizelge 5.48. 2 parametre yanan alan $\ln(x+1)$ dönüşümü bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	320	54	85.56	14.44	1	288	86	77.01	22.99
2	0	523	0.00	100.00	2	21	502	4.02	95.98
3	0	383	0.00	100.00	3	22	361	5.74	94.26
4	11	240	4.38	95.62	4	3	248	1.20	98.80
5	29	24	54.72	45.28	5	25	28	47.17	52.83
Toplam	360	1224			Toplam	359	1225		
%	22.73	77.27			%	22.66	77.34		

Çizelge 5.48.'deki grup analiz tablosu dikkate alındığında, MP 1.grupta 320 doğru tahmin sayısı ile %85,56 doğru tahmin oranı, 4.grupta 11 doğru tahmin sayısı ile %4,38 doğru tahmin oranı ve 5.grupta 29 doğru tahmin sayısı ile %54,72 doğru tahmin oranı elde edilmiş, 2. ve 3.gruplardaki veriler yanlış gruplandırılmışlardır. Çizelge 5.16.'daki tablo ile karşılaştırıldığında MP sonuçlarının, sadece 1.grup için iyileşme sağladığı, toplam doğru tahmin oranı ile diğer grup tahmin oranlarının daha kötü sonuç verdiği gözlemlenmiştir. RBFN toplamda 359 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %22,66 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 374 veriden 288 adet veriyi doğru tahmin etmiş ve böylece %77,01 doğru tahmin oranını yakalamıştır. 2.grup 523 veriden 21 adet veriyi doğru tahmin ederek %4,02 doğru tahmin oranına, 3.grup 383 veriden 22 adet veriyi doğru tahmin

ederek %5,74 doğru tahmin oranına, 4.grup 251 veriden 3 adet veriyi doğru tahmin ederek %1,20 doğru tahmin oranına ve 5.grup 53 veriden 25 adet veriyi doğru tahmin ederek %47,17 doğru tahmin oranına ulaşmıştır. Çizelge 5.16. değerleri ile karşılaştırıldığında, RBFN 1. ve 5.gruplar için daha başarılı bir sınıflandırma yapmış olmasına rağmen, toplam ve diğer gruplar için doğru tahmin oranını düşürmüştür.

2 adet girdi parametresi, bu kez yanan alan değerlerinin Şekil 5.10.'da görülen 3 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır. Bu prensibe dayanarak yapılan test analiz sonuçları Çizelge 5.49.'da yer almaktadır.

Çizelge 5.49. 2 parametre yanan alan 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1532	49	96.90	3.10	1	1581	0	100.00	0.00
2	0	2	0.00	100.00	2	0	2	0.00	100.00
3	1	0	100.00	0.00	3	0	1	0.00	100.00
Toplam	1533	51			Toplam	1581	3		
%	96.78	3.22			%	99.81	0.19		

Çizelge 5.49.'daki grup analiz tablosu dikkate alındığında, MP toplamda 1.533 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %96,78 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.581 veriden 1.532 adet veriyi doğru tahmin etmiş ve böylece %96,90 doğru tahmin oranını yakalamıştır. 3.grup ise 1 doğru tahmin ve %100,00 doğru oranına sahip olurken, 2.grupta yer alan 2 adet veri yanlış olarak gruplandırılmıştır. Buna göre Çizelge 5.24.'teki sonuçlarla karşılaştırıldığında, MP'nin 1.grup için doğru tahmin oranını %96.90'a çıkardığı, 3.grup verisini doğru olarak gruplandığı, fakat 2.grup verilerini yanlış gruplara dahil ettiği gözlemlenmiştir. RBFN toplamda 1.581 adet veriyi doğru grup içerisine koymuş, doğru

tahmin oranı %99,81 olmuştur. Doğru tahmin edilen verilerin tamamı 1.gruba ait olup, 2. ve 3.gruptaki verilerin tamamı yanlış olarak gruplandırılmıştır. RBFN için de Çizelge 5.24. dikkate alındığında aynı sonuca ulaşıldığı görülmüştür.

Deney bu kez yanan alan $\ln(x+1)$ logaritmik dönüşüm değerlerinin kullanılması ile yapılmıştır. Bu veriler için Şekil 5.11.'deki bulanık modele göre üyelik derecelerinin hesaplanması yapılmıştır. Çizelge 5.50. grup analiz sonuçlarını içermektedir.

Çizelge 5.50. 2 parametre yanan alan $\ln(x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	881	195	81.88	18.12	1	916	160	85.13	14.87
2	16	402	3.83	96.17	2	19	399	4.55	95.45
3	32	57	35.96	64.04	3	24	65	26.97	73.03
Toplam	929	654			Toplam	959	624		
%	58.69	41.31			%	60.58	39.42		

Çizelge 5.50.'deki grup analiz tablosu dikkate alındığında, MP toplamda 929 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %58,69 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 881 adet veriyi doğru tahmin ederek ve %81,88 doğru tahmin oranına, 2.grup 16 adet veriyi doğru tahmin ederek %3,83 doğru tahmin oranına ve 3.grup 32 adet veriyi doğru tahmin ederek %35,96 doğru tahmin oranına ulaşmıştır. Böylece MP açısından Çizelge 5.26.'daki grup analiz sonuçlarına göre 1.grup doğru tahmin oranında artış görülmüş, toplam doğru tahmin ile 2. ve 3.grup tahmin oranları azalmıştır. RBFN toplamda 959 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %60,58 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.076 veriden 916 adet veriyi doğru tahmin etmiş ve %85,13 tahmin oranına ulaşmıştır. 2.grup 418 veriden 19 adet veriyi doğru tahmin edip %4,55 doğru tahmin oranına ve 3.grup 89 veriden 24 adet

veriyi doğru tahmin edip %26,97 doğru tahmin oranına ulaşmıştır. Çizelge 5.26. sonuçları ile karşılaştırıldığında RBFN 1.grup için daha kötü bir sonuç vermiş olsa da, 2. ve 3.grup verilerinde doğru gruplandırma yapabilmektedir.

Bu deneylerden sonra SVM kullanılarak veri kümeleri üzerinde test işlemleri yapılmıştır. Veri sayısının 7.920 adete indirildiği veri kümesi üzerinde yapılan test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.51. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.51. SVM ile yanan alan hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16077.65	9.11	79.05	126.80

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.52.'de verilmiştir.

Çizelge 5.52. SVM ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16172.00	5.58	6.06	127.17

Deney sonuçları ile daha önce elde edilen sonuçlar karşılaştırıldığında, dikkate değer bir iyileştirme sağlanamadığı gözlemlenmiştir. Daha sonra veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi kullanılarak tekrar edilmiştir. İlgili ilk test çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.53.'te sonuç hata analiz tablosu görülmektedir.

Çizelge 5.53. SVM yeni veri elde edilmesi hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	268.29	5.77	3.39	16.38

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.54. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.54. SVM yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	371.30	4.16	0.55	19.27

Yeni verilerin elde edilmesi ve SVM kullanılması sonuçları daha önce yapılan ve hata analiz sonuçları Çizelge 5.11. ve 5.19.'da bulunan testler ile karşılaştırıldığında, bazı sonuçlar için bir miktar iyileşme sağlanmış olsa da genel anlamda bir ilerleme kaydedilememiştir.

Bu deneylerden sonra, PCA sonucu oluşan yeni girdi parametrelerinin tamamı SVM kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde test edilmiş, ilk önce çıktı parametresi olarak gerçek yanan alan değerleri kullanılmıştır. Çizelge 5.55. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.55. SVM ve PCA ile yanan alan hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16290.99	10.45	90.48	127.64

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.56.'da verilmiştir.

Çizelge 5.56. SVM ve PCA ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16305.49	5.83	8.88	127.69

Deney sonuçları, PCA hata sonuçlarını içeren Çizelge 5.27. ve Çizelge 5.28. ile karşılaştırıldığında dikkate değer bir iyileştirme sağlanamadığı gözlemlenmiştir. Daha sonra PCA sonucu oluşan 8 adet yeni girdi parametresi, veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi SVM kullanılarak tekrar edilmiştir. İlgili ilk test çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.57.'de sonuç hata analiz tablosu görülmektedir.

Çizelge 5.57. SVM ve PCA yeni veri elde edilmesi hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	414.47	8.02	6.86	20.36

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.58. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.58. SVM ve PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	380.21	4.57	1.16	19.50

Yeni verilerin elde edilmesi ve PCA sonrası 8 parametrenin SVM ile kullanılması sonuçları, PCA ile daha önce yapılan ve hata analiz sonuçları Çizelge 5.29. ve Çizelge

5.30.'da bulunan testler ile karşılaştırıldığında görüldüğü gibi iyileşme açısından bir ilerleme kaydedilememiştir.

Girdi parametreleri üzerinde PCA uygulanması, bu yöntemle yeni 8 adet girdi parametresinin oluşturulması ve SVM ile bunların tamamının kullanılmasıyla yapılan deneylerden sonra daha az sayıda parametre kullanılarak test sonuçlarındaki değişimin gözlemlenmesi amaçlanmıştır. Bu bağlamda PCA sonucu oluşan sadece 3 adet girdi parametresi SVM ile kullanılmış, çıkan sonuçlar daha önceki deneylerle karşılaştırılmıştır.

PCA sonucu oluşan yeni girdi parametrelerinden sadece 3 tanesi kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde SVM ile test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.59. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.59. SVM ve PCA ile yanan alan hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16268.30	11.35	130.08	127.55

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.60.'da verilmiştir.

Çizelge 5.60. SVM ve PCA ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16271.91	5.70	5.93	127.56

Deney sonuçları, PCA hata sonuçlarını içeren Çizelge 5.35. ve Çizelge 5.36. ile karşılaştırıldığında dikkate değer bir iyileştirme sağlanamadığı gözlemlenmiştir. Daha sonra PCA sonucu oluşan 3 adet yeni girdi parametresi, veri kümesinin girdi

parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi SVM kullanılarak tekrar edilmiştir. İlgili ilk test, çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.61.'de sonuç hata analiz tablosu görülmektedir.

Çizelge 5.61. SVM ve PCA yeni veri elde edilmesi hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	340.24	5.70	3.85	18.45

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.62. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.62. SVM ve PCA yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	378.18	4.47	0.88	19.45

Deney sonuçlarının gerçek alan değerleri üzerinde Çizelge 5.37. ile karşılaştırıldığında daha iyi sonuç verdiği, $\ln(x+1)$ dönüşümü üzerinde Çizelge 5.38. ile karşılaştırıldığında ise bir iyileşme sağlamadığı gözlemlenmiştir.

Yapılan diğer bir çalışmada daha az sayıda girdi parametresi kullanılarak test sonuçlarındaki değişimin gözlemlenmesi amaçlanmıştır. Bu bağlamda 8 adet girdi parametresi yerine sadece nem ve rüzgar hızını içeren 2 adet girdi parametresi SVM ile kullanılmış ve yapılan testlere ait çıkan sonuçlar daha önceki deneylerle karşılaştırılmıştır.

Nem ve rüzgar hızı girdi parametreleri kullanılarak veri sayısının 7.920 adete indirildiği veri kümesi üzerinde SVM ile test işlemi ilk önce çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile gerçekleştirilmiştir. Çizelge 5.63. bu test sonuçlarının hata analiz tablosunu içermektedir.

Çizelge 5.63. SVM 2 parametre ile yanan alan hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16276.09	11.56	135.48	127.58

Daha sonra aynı deney çıktı parametresi olarak yanan alan $\ln(x+1)$ dönüşüm değerleri kullanılarak gerçekleştirilmiş, ilgili hata analiz sonuçları Çizelge 5.64.'te verilmiştir.

Çizelge 5.64. SVM 2 parametre ile yanan alan $\ln(x+1)$ dönüşüm hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	16281.82	5.61	4.49	127.60

Deney sonuçları analiz edildiğinde, daha önce 2 parametre kullanılarak yapılan ve sonuçları Çizelge 5.43. ve Çizelge 5.44.'te görülen testlere oranla, bazı sonuçlar için iyileşme sağlasa da genel olarak dikkate değer bir iyileşme gözlenmemiştir. Daha sonra 2 adet girdi parametresi, veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi SVM kullanılarak tekrar edilmiştir. İlgili ilk test çıktı parametresi olarak gerçek yanan alan değerlerinin kullanılması ile yapılmıştır. Çizelge 5.65.'te sonuç hata analiz tablosu görülmektedir.

Çizelge 5.65. SVM 2 parametre yeni veri elde edilmesi hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	53.68	3.36	6.69	7.33

Aynı yöntem ile diğer deney, yanan alan $\ln(x+1)$ dönüşüm değerlerinin kullanılması ile yapılmıştır. Çizelge 5.66. bu deney ile ilgili sonuçları gösteren hata analiz tablosunu içermektedir.

Çizelge 5.66. SVM 2 parametre yeni veri elde edilmesi yanan alan $\ln(x+1)$ dönüşümü hata analiz tablosu

	MSE	MAE	MAPE	RMSE
SVM	349.25	4.18	0.56	18.69


Deney sonuçlarının gerçek alan değerleri üzerinde Çizelge 5.45. ile karşılaştırıldığında daha iyi sonuç verdiği, $\ln(x+1)$ dönüşümü üzerinde Çizelge 5.46. ile karşılaştırıldığında ise bir iyileşme sağlamadığı gözlemlenmiştir.

Kullanılan yapay sinir ağları ile öğrenme başarı oranının uygulanan yöntemlere göre nasıl bir değişime sahip olduğunu gözlemleyebilmek ve başarı oranını arttırmak adına yapılan diğer bir çalışmada, yangın kayıtlarının yanan alan değerleri için tanımlanan bulanık modelin 2 gruptan oluşması sağlanmıştır. Buna göre yangınlar, küçük ve büyük olmak üzere iki gruba ayrılmışlardır. Bunun için eleme yöntemi ile daha önce elde edilen 7.920 adet kayıttan oluşan veri kümesi kullanılmıştır. Veri kümesi yanan alan değerlerine göre 2 adet öbeğe ayrılmıştır. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.67.'de verilmiştir.

Çizelge 5.67. 2 adet öbek sonucu oluşan merkez değerleri

öbek numarası	merkez değeri
1	2.70
2	5661.00

Oluşan öbek merkezleri, çalışma için bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Bu değerler kullanılarak yanan toplam hektar parametresi için oluşturulan bulanık model aşağıda Şekil 5.12.'de görülmektedir.



Şekil 5.12. Yanan alan parametresi için bulanık model

7.920 adet orman yangını verisi Şekil 5.12.'deki yanan toplam alan için 2 bulanık grup içeren bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 7.918 veriye ve grup 2 2 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümelerine veri dağıtımından sonra bütün grupların, eğitim veri kümesinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle "1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı" kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Bağımsız geçerlilik sınaması veri kümesi sadece 1.grup verilerinden oluştuğundan (2.gruba dahil olan 2 adet veri eğitim ve test veri kümelerinde kullanılmıştır) veri çoğaltma işlemi yapılmamıştır. Bu işlemler sonucunda eğitim kümesi 9.500 adet veriye sahipken, grupların eğitim kümesi içerisindeki veri sayıları 4.750 adet olmuştur.

Bağımsız geçerlilik sınaması kümesi 1.584 adet veriye, test kümesi ise 1.585 adet veriye sahip olmuştur. Verilerin dağıtımından sonra test işlemi gerçekleştirilmiş, elde edilen yapay sinir ağı çıktısının veriyi dahil ettiği bulanık küme ile verinin gerçekte dahil olduğu bulanık kümenin tutarlılığı incelenmiş, her grup için doğru gruplandırılan ve yanlış gruplandırılan veri sayıları ile doğru ve yanlış gruplandırılma oranları, toplam doğru ve yanlış grup tahmin edilme sayıları ile doğru ve yanlış tahmin oranları analiz edilmiştir. Buna göre çıktı parametresi olarak yanan alan değerleri kullanılarak MP ve RBFN ile yapılan test grup analiz sonuçları Çizelge 5.68.'de yer almaktadır.

Çizelge 5.68. Yanan alan bulanık dönüşüm MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1584	0	100.00	0.00	1	1419	165	89.58	10.42
2	0	1	0.00	100.00	2	0	1	0.00	100.00
Toplam	1584	1			Toplam	1419	166		
%	99.94	0.06			%	89.53	10.47		

Aynı deney için SVM kullanılarak yapılan test grup analiz sonuçları Çizelge 5.69.'da yer almaktadır.

Çizelge 5.69. Yanan alan bulanık dönüşüm SVM grup analiz tablosu

SVM				
Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1580	4	99.74	0.26
2	0	1	0.00	100.00
Toplam	1580	5		
%	99.68	0.32		

Çizelge 5.68. ve Çizelge 5.69.'daki grup analiz tabloları dikkate alındığında, MP toplamda 1.584 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %99,94 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında,


1.grup 1.584 verinin tamamını doğru tahmin ederken, 2.grupta yer alan 1 adet veri yanlış olarak gruplandırılmıştır. RBFN toplamda 1.419 adet veriyi doğru grup içerisine koymuş, doğru tahmin oranı %89,53 olmuştur. 1.grup 1.419 adet veriyi doğru tahmin etmiş, 165 adet veriyi yanlış gruplandırmıştır. Doğru tahmin edilen verilerin tamamı 1.gruba ait olup, 2.gruptaki veri yanlış olarak gruplandırılmıştır. SVM ise toplamda 1.580 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %99,68 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.584 veriden 1.580 adetini doğru tahmin ederken, 2.grupta yer alan 1 adet veri yanlış olarak gruplandırılmıştır.

Yanan alan değerlerinin test edilmesinden sonra, 7.920 adet orman yangını verisine sahip olan veri kümesi içerisinde bu kez yanan alan değerlerinin $\ln(x+1)$ logaritmik dönüşüme uğraması sonucunda yanan alan logaritmik dönüşüm değerlerinin 2 adet öbeğe ayrılması ile elde edilen öbek merkezlerinin yeni bulanık model oluşturulmasında kullanılması çalışması yürütülmüştür. Veri kümesi yanan alan logaritmik dönüşüm değerlerine göre 2 adet öbeğe ayrılmıştır. Oluşan öbek merkezleri, yeni oluşturulacak bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.70.'te yer almaktadır.

Çizelge 5.70. Yanan alan $\ln(x+1)$ dönüşüm 2 adet öbek merkez değerleri

öbek numarası	merkez değeri
1	0.2509
2	1.8642

Buna göre yanan alan logaritmik dönüşüm değerleri için oluşturulan bulanık model Şekil 5.13.'te görülmektedir.



Şekil 5.13. Yanan alan $\ln(x+1)$ dönüşüm parametresi için bulanık model

Orman yangını verileri Şekil 5.13.'teki yanan alan logaritmik dönüşüm bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 6.402 veriye ve grup 2 1.518 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümeleri oluşturulmuştur. Eğitim kümesinde 3.842 1.grup ve 910 2.grup verisi olmak üzere toplam 4.752 adet veri bulunmaktadır. Bağımsız geçerlilik sınaması ve test kümelerinde 1.280 1.grup ve 304 2.grup olmak üzere toplam 1.584'er veri bulunmaktadır. Veri dağıtımından sonra daha önceki çalışmalarda olduğu gibi bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle "1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı" kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınaması veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 7.684 adet veriye sahipken, grupların eğitim kümesi içerisindeki veri sayıları 3.842 adet olmuştur. Bağımsız geçerlilik sınaması kümesi ise 2.560 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 1.280 adet olmuştur. Buna göre MP ve RBFN ile yapılan test analiz sonuçları Çizelge 5.71.'de yer almaktadır.

Çizelge 5.71. Yanan alan $\ln(x+1)$ dönüşüm bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1280	0	100.00	0.00	1	1266	14	98.91	1.09
2	0	304	0.00	100.00	2	15	289	4.93	95.07
Toplam	1280	304			Toplam	1281	303		
%	80.81	19.19			%	80.87	19.13		

Aynı deney için SVM kullanılarak yapılan test grup analiz sonuçları Çizelge 5.72.'de yer almaktadır.


Çizelge 5.72. Yanan alan $\ln(x+1)$ dönüşüm bulanık model SVM grup analiz tablosu

SVM				
Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	1077	203	84.14	15.86
2	130	174	42.76	57.24
Toplam	1207	377		
%	76.20	23.80		

Çizelge 5.71.'deki grup analiz tablosu dikkate alındığında, MP toplamda 1.280 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %80,81 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.280 verinin tamamını doğru tahmin etmiş ve böylece %100,00 doğru tahmin oranını yakalamıştır. 2.grup ise 304 verinin tamamını yanlış olarak gruplandırmıştır. RBFN toplamda 1.281 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı %80,87 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.280 veriden 1.266 tanesini doğru tahmin etmiş ve böylece %98,91 doğru tahmin oranını yakalamıştır. 2.grup ise 304 veriden 15 tanesini doğru tahmin etmiş ve böylece %4,93 doğru tahmin oranını yakalamıştır. Çizelge 5.72.'deki grup analiz tablosu dikkate alındığında, SVM toplamda 1.207 adet veriyi doğru grup içerisine koyarken, doğru gruplandırma oranı

%76,20 olmuştur. Grup bazında doğru tahmin sayısına ve oranlarına bakıldığında, 1.grup 1.280 veriden 1.077 tanesini doğru tahmin etmiş ve böylece %84,14 doğru tahmin oranını yakalamıştır. 2.grup ise 304 veriden 130 tanesini doğru tahmin etmiş ve böylece %42,76 doğru tahmin oranını yakalamıştır. Buna göre genel olarak SVM toplamda %76,20 ile daha düşük bir oran vermiş olmasına rağmen, 2.grup verilerinin doğru ayırt edilmesi bakımından MP ve RBFN'e göre daha iyi sonuç vermiştir.

Daha öncede belirtildiği gibi, çalışmada kullanılan veri kümesinde kayıtlı orman yangınlarının yaklaşık olarak %78'i 0 ile 1 hektarlık bir alanın yanması ile sonuçlanmıştır. Bu kayıtlardaki yanan alan parametre değerleri ise 0 ile 26.665 hektar arasında değişmektedir. Buna göre yanan alan değerlerinin geniş bir aralığa yayılması ve her aralıkta eşit miktarda temsil edilememesinden dolayı bu parametrede, şu ana kadar yapılan çalışmalarda öğrenme sonuçlarını geliştirmek ve iyileştirmek için $\ln(x+1)$ logaritmik dönüşümü uygulanmış ve testler elde edilen logaritmik olarak dönüştürülen yanan alan değerleri üzerinde de yapılmıştır. Bu aşamada ise, bu dağılımın daha da dengelenebilmesini sağlamak ve böylece başarı oranını arttırmak için yanan alan değerleri üzerinde bir de $\log(100x+1)$ logaritmik dönüşümü gerçekleştirilmiş, şu ana kadar en iyi sonuç veren testler yeni elde edilen yanan alan değerleri ile de yapılmış, elde edilen sonuçlar mevcut sonuçlarla karşılaştırılmış ve başarı oranındaki muhtemel artışlar gözlemlenmeye çalışılmıştır. Şekil 5.14. $\log(100x+1)$ kullanılarak logaritmik dönüşüm yapılan yanan toplam hektar değerlerinin frekans dağılımını göstermektedir.



Şekil 5.14. Yanan toplam alan değerleri $\log(100x+1)$ dönüşüm dağılımı

Logaritmik dönüşümden sonra yanan alan veri değerleri 0,301 ile 5,798 log hektarlık bir aralıkta değişiklik göstermektedir. Şekil 5.14.'teki dağılım grafiğinden de görüldüğü gibi logaritmik dönüşümden sonra 0 ile 1 log hektar arasında alanın yandığı kayıt sayısı 1.871, 1 ile 2 log hektar arasında alanın yandığı kayıt sayısı 3.553, 4 ile 5 log hektar arasında alanın yandığı kayıt sayısı 27, 5 ile 6 log hektar arasında alanın yandığı kayıt sayısı ise 2 adet olmuştur.

Logaritmik dönüşüm sonrasında elde edilen yanan alan değerleri kullanılarak daha önceki testlerde başarımlı ölçüm yöntemlerine göre en iyi performansı gösteren ve sonuçları Çizelge 5.12.'de verilen test işlemi tekrarlanmıştır. Bu test işleminde 8 adet girdi parametresi kullanılarak veri kümesi 400 adet öbeğe ayrılmış, öbek merkezleri temsilci noktalar olarak seçilmiş, yanan alan değerleri ortalama değer olarak atanmıştır. Bu işlem sonucunda eğitim, bağımsız geçerlilik sınaması ve test veri kümeleri sırasıyla 270, 90 ve 90 veri içerecek şekilde ayrılmıştır. $\log(100x+1)$ logaritmik dönüşüm yapılan yanan alan değerleri kullanılarak yapılan MP ve RBFN test sonuçları Çizelge 5.73.'te görülmektedir.

Çizelge 5.73. Yeni veriler $\log(100x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	331.34	3.92	0.73	18.20
RBFN	284.43	3.94	1.02	16.86

Çizelge 5.73'teki sonuçlar dikkate alındığında, çıkan başarımlar ölçüm yöntemleri sonuçlarının Çizelge 5.12'deki sonuçlardan MSE, MAE ve RMSE açısından daha iyi, MAPE açısından daha kötü olduğu gözlemlenmiştir.


Daha sonra, logaritmik dönüşüm sonrasında elde edilen yanan alan değerleri kullanılarak daha önceki testlerde grup bazında en iyi ortalama doğruluk değerine sahip olan ve sonuçları Çizelge 5.49.'da verilen benzer test işlemi tekrarlanmıştır. Bu test işleminde 2 adet girdi parametresi, yanan alan değerlerinin 3 adet bulanık grup içeren bir bulanık modele bağlı olarak dönüştürülmesi prensibini içeren çalışmada kullanılmıştır.

Bu çalışma kapsamında ilk olarak, yanan alan $\log(100x+1)$ logaritmik dönüşüm değerlerinin 3 adet öbeğe ayrılması ile elde edilen öbek merkezlerinin yeni bulanık model oluşturulmasında kullanılması çalışması yürütülmüştür. Oluşan öbek merkezleri, yeni oluşturulacak bulanık modelde kullanılacak bulanık grup değerlerini oluşturmuştur. Öbekleme sonucu oluşan merkez değerleri Çizelge 5.74.'te yer almaktadır.

Çizelge 5.74. Yanan alan $\log(100x+1)$ dönüşüm 3 adet öbek merkez değerleri

öbek numarası	merkez değeri
1	0.7320
2	1.7015
3	2.7028

Buna göre yanan alan logaritmik dönüşüm değerleri için oluşturulan bulanık model Şekil 5.15.'te görülmektedir.



Şekil 5.15. Yanan alan $\log(100x+1)$ dönüşüm parametresi için bulanık model

Orman yangını verileri Şekil 5.15.'teki yanan alan logaritmik dönüşüm bulanık modeli kullanılarak yeniden düzenlenmiştir. Her yangın verisi yanan alan değeri için üyelik dereceleri hesaplanmıştır. Hesaplamalar ve verilerin gruplara dağıtılmasından sonra, grup 1 3.222 veriye, grup 2 3.159 veriye ve grup 3 1.539 veriye sahip olmuştur. Eğitim, bağımsız geçerlilik sınaması ve test kümeleri oluşturulmuştur. Eğitim kümesinde 1.934 1.grup, 1.895 2.grup ve 923 3.grup verisi olmak üzere toplam 4.752 adet veri bulunmaktadır. Bağımsız geçerlilik sınaması ve test kümelerinde 644 1.grup, 632 2.grup ve 308 3.grup olmak üzere toplam 1.584'er veri bulunmaktadır. Veri dağıtımından sonra daha önceki çalışmalarda olduğu gibi bütün grupların, eğitim ve bağımsız geçerlilik sınaması veri kümelerinde aynı sayıda veriye sahip olmaları sağlanmıştır. Grupların eğitim verileri kopyalanmış, eğitim kümesinde 1.grup veri sayısının fazla olması nedeniyle "1.grup eğitim veri sayısı / ilgili grubun eğitim veri sayısı" kadar eğitim kümesi verilerine eklenmiştir. Böylece her grup ile ilişkili eğitim veri sayısı eşitlenmiştir. Aynı şekilde bağımsız geçerlilik sınaması veri kümesi de yeniden düzenlenmiştir. Bu işlemler sonucunda eğitim kümesi 5.802 adet veriye sahipken, bütün grupların eğitim kümesi içerisindeki veri sayıları 1.934 adet olmuştur. Bağımsız geçerlilik sınaması kümesi ise 1.932 adet veriye sahipken, bütün grupların bağımsız geçerlilik sınaması kümesi içerisindeki veri sayıları 644 adet olmuştur. Buna göre, yanan alan üzerinde $\log(100x+1)$ dönüşümü uygulanarak 3 adet bulanık grubun kullanıldığı MP ve RBFN ile yapılan test analiz sonuçları Çizelge 5.75.'te yer almaktadır.

Çizelge 5.75. 2 parametre yanan alan $\log(100x+1)$ dönüşümü 3 grup bulanık model MP ve RBFN grup analiz tablosu

MP					RBFN				
Grup	Doğru	Yanlış	Doğru%	Yanlış%	Grup	Doğru	Yanlış	Doğru%	Yanlış%
1	0	644	0.00	100.00	1	148	496	22.98	77.02
2	467	165	73.89	26.11	2	443	189	70.90	29.91
3	134	174	43.51	56.49	3	32	276	10.39	89.61
Toplam	601	983			Toplam	623	961		
%	37.94	62.06			%	39.33	60.67		

Çizelge 5.75.'teki grup analiz tablosu dikkate alındığında, $\log(100x+1)$ dönüşümü ile yapılan test sonuçlarının Çizelge 5.49.'daki en iyi ortalama doğruluk değeri sonuçlarından daha iyi olmadığı gözlemlenmiştir.

Son olarak, 2 adet girdi parametresi ve yanan alan $\log(100x+1)$ dönüşüm değerleri bu kez başarımlı ölçüm yöntemlerinin testinde kullanılmıştır. İlk test 7.920 adet verinin kullanılmasıyla MP ve RBFN ile yapılmıştır. İlgili test sonuçları Çizelge 5.76.'da verilmiştir.

Çizelge 5.76. 2 parametre ile yanan alan $\log(100x+1)$ dönüşüm MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	16298.50	5.62	4.38	127.67
RBFN	16295.35	5.62	4.63	127.65

Deney sonuçları analiz edildiğinde, elde edilen sonuçların Çizelge 5.12. ve Çizelge 5.73.'ten iyi olmadığı görülmüştür. Daha sonra aynı deney veri kümesinin girdi parametrelerine göre 400 adet öbeğe ayrılması, her öbek merkezinin yeni veri olarak seçilip ait oldukları öbeğin temsilci noktası olarak belirlenmesi, çıktı parametresinin ise her öbekteki noktaların çıktı parametrelerinin ortalamasının alınması ile belirlenmesi yöntemi kullanılarak tekrar edilmiştir. İlgili sonuçlar Çizelge 5.77.'de verilmiştir.

Çizelge 5.77. 2 parametre yeni veri elde edilmesi yanan alan $\log(100x+1)$ dönüşümü
MP ve RBFN hata analiz tablosu

	MSE	MAE	MAPE	RMSE
MP	264.02	3.90	0.92	16.25
RBFN	256.49	3.94	0.89	16.02

Deney sonuçları analiz edildiğinde MSE, MAE ve RMSE başarımlar ölçüm yöntemleri açısından diğer çalışmalara göre daha iyi sonuç elde edildiği görülmüştür.

6. SONUÇ VE TARTIŞMA

Bu çalışmada, daha önce gerçekleşmiş orman yangını kayıtlarındaki ortamın coğrafi ve meteorolojik parametrelerine bağlı olarak orman yangınlarının verdiği zararın yapay zeka yöntemleriyle tespiti yapılmıştır. Çalışmaya temel teşkil eden veri kümesi, Türkiye Cumhuriyeti Orman ve Su İşleri Bakanlığı Orman Genel Müdürlüğü tarafından tutulan 2000-2009 yıllarına ait Türkiye genelinde meydana gelen orman yangını kayıtlarını içermektedir. Bu yangın kayıtlarındaki ilgili yangının meydana geldiği ortamdaki nem, rüzgar hızı, sıcaklık, bakı, meyil, mevsim, saat, ağaç tipi ve birim alandaki ağaç sayısı parametreleri girdi olarak kullanılırken, yangın sonucu yanan alan ise çıktı parametresi olarak ele alınmıştır. Bu çalışma sonucunda belirli coğrafi ve meteorolojik koşullarda meydana gelen orman yangınlarında beklenen kayıplar önceden tahmin edilmiş ve böylece yangınla mücadele ve kaynak yönetiminin yapılması konularında yol gösterici olunmuştur.

Orman yangınlarının başlaması ve seyrine etki eden ve çalışmada kullanılan girdi parametrelerinin Orman Genel Müdürlüğü uzmanları ile birlikte tespit edilmesine rağmen, çalışma kapsamında ilk olarak bu parametrelerin çıktı parametresi üzerindeki etkileri sayısal olarak da gözlemlenebilmesi için korelasyon ve trend analizleri ile incelenmiş, girdi ve çıktı parametreleri arasındaki bağıntı katsayıları belirlenmiştir. Fakat korelasyon ve trend analiz sonuçları, mevcut bağıntı katsayılarının beklenildiğinin aksine oldukça düşük olduğunu ortaya çıkarmıştır. Orman yangınlarında yangın büyüklüğü ve dolayısıyla yanan alan üzerinde, kullanılan girdi parametrelerinin doğrudan bir etkisi olmasına rağmen, analiz sonuçlarının düşük değerde çıkması ise kullanılan veri kümesinin aslında istikrarsız bir veri kümesi olduğunu göstermektedir. Bunun temel nedeni ise, yangın verilerinin Türkiye'nin her bölgesinden farklı kişiler tarafından kaydedilmesi ve mevcut veri kümesinin farklı biçimlerde oluşturulması olarak tespit edilebilir. Buna bağlı olarak yangın kayıtları içerisinde tutarsızlıklar ve/veya eksiklikler gözlemlenmiştir. Örneğin veri kümesi içerisinde aynı ya da benzer girdi

parametrelerine sahip olmalarına rağmen, farklı çıktı parametresi veren kayıt örnekleri bulunduğu gibi sadece bir girdi parametresinde farklılık olup aynı çıktı parametresini veren kayıtlar da bulunmaktadır. Çizelge 6.1.'de bazı kayıt örnekleri görülmektedir.

Çizelge 6.1. Yangın kayıt örnekleri

nem	ruzgar hızı	sıcaklık	meyl	mevsim	saat	ağaç tipi	ağaç sayısı	yanan alan
60.00	30.00	37.00	0.55	1.00	1.00	1.00	2.00	0.50
60.00	30.00	37.00	0.50	1.00	1.00	1.00	2.00	324.00
40.00	48.00	37.00	0.25	1.00	0.00	0.00	0.00	6.00
40.00	48.00	37.00	0.25	1.00	0.00	0.00	0.00	47.00
40.00	40.00	26.00	0.55	0.75	1.00	1.00	3.00	25.00
40.00	40.00	26.00	0.50	0.75	1.00	1.00	3.00	6.00
10.00	112.00	30.00	0.50	1.00	0.43	0.00	0.00	50.00
10.00	112.00	30.00	0.50	1.00	0.43	0.00	0.00	6.00
40.00	60.00	30.00	0.20	1.00	1.00	1.00	0.00	6285.00
40.00	50.00	30.00	0.10	1.00	0.99	1.00	0.00	1.00
10.00	30.00	30.00	0.40	1.00	1.00	1.00	3.00	0.03
10.00	30.00	30.00	0.60	1.00	1.00	1.00	3.00	2.00
11.00	17.00	35.00	0.20	0.75	1.00	0.00	0.00	12.00
11.00	17.00	35.00	0.20	0.75	1.00	0.00	0.00	28.00
15.00	2.00	36.00	0.30	1.00	1.00	1.00	3.00	1.00
15.00	1.80	36.00	0.30	1.00	1.00	1.00	3.00	110.00
30.00	30.00	35.00	0.03	0.66	1.00	1.00	3.00	16.00
30.00	30.00	35.00	0.03	0.66	1.00	1.00	2.00	16.00
35.00	35.00	11.00	0.40	0.00	0.54	1.00	1.00	4.50
35.00	35.00	11.00	0.40	0.00	0.54	1.00	2.00	4.50
40.00	29.00	30.00	0.40	1.00	0.00	1.00	3.00	1.00
40.00	29.00	30.00	0.40	1.00	0.00	1.00	3.00	0.50
10.00	112.00	40.00	0.80	1.00	0.50	0.00	2.00	6.00
10.00	112.00	40.00	0.80	1.00	0.50	0.00	0.00	26.50

Çizelge 6.1.'de ilk örnekte görüldüğü gibi tüm girdi parametreleri aynı olduğu halde sadece %5'lik bir eğim farkı olan 2 kayıttan birinde 0,50 hektarlık yangın, diğerinde ise 324,00 hektarlık bir yangın oluşmuştur. Başka bir örnekte girdi parametrelerine göre

aralarında sadece %10'luk bir meyil farkı olan iki kayıttan biri 1,00 hektar diğeri ise 6.285,00 hektar ormanlık alanın yanması ile sonuçlanmıştır.

Örnek kayıtlarda gösterilen çelişkinin dışında, Çizelge 6.1.'de yer alan bazı kayıt örneklerine ait nem, rüzgar hızı ve sıcaklık parametreleri ile ilgili yangının oluştuğu yer ve zamanda ölçüm istasyonlarından elde edilen gerçek hava durumu verileri karşılaştırılmış, hem veri kümesinde kayıtlı değerler hem de [33]'ten elde edilen hava durumu değerleri Çizelge 6.2.'de gösterilmiştir.

Çizelge 6.2. Örnek kayıtlar için ölçülen hava durumu değerleri

nem	rüzgar hızı	sıcaklık	nem ölçüm	rüzgar hızı ölçüm	sıcaklık ölçüm	yanan alan
60,00	30,00	37,00	12,00	9,30	31,00	0,50
60,00	30,00	37,00	78,00	5,60	25,00	324,00
40,00	48,00	37,00	16,00	14,80	23,00	6,00
40,00	48,00	37,00	7,00	11,10	32,00	47,00
40,00	40,00	26,00	25,00	11,10	21,00	25,00
40,00	40,00	26,00	33,00	22,20	23,00	6,00
40,00	60,00	30,00	9,00	24,10	41,00	6285,00
40,00	50,00	30,00	29,00	44,40	30,00	1,00
10,00	30,00	30,00	15,00	37,00	31,00	0,03
10,00	30,00	30,00	21,00	9,30	28,00	2,00
11,00	17,00	35,00	7,00	20,40	37,00	12,00
11,00	17,00	35,00	14,00	25,90	34,00	28,00
30,00	30,00	35,00	12,00	22,20	33,00	16,00
30,00	30,00	35,00	12,00	22,20	33,00	16,00
35,00	35,00	11,00	24,00	37,00	9,00	4,50
35,00	35,00	11,00	24,00	37,00	9,00	4,50
40,00	29,00	30,00	44,00	11,10	26,00	1,00
40,00	29,00	30,00	12,00	14,80	30,00	0,50

Çizelge 6.2.'de görüldüğü gibi, yangının oluştuğu anda ölçüm istasyonlarından elde edilen gerçek hava durumu verileri ile veri kümesinde kayıtlı hava durumu verileri arasında farklılıklar bulunmaktadır. Bu da, veri kümesinde tutulan kayıtların doğruluğu

ve istikrarı konusunda sorun olduğunu göstermektedir. Bu ise yapılan veri analizi ve tahmin modelini olumsuz olarak etkilemektedir.

Çizelge 6.1. ve Çizelge 6.2. incelendiğinde, çalışmada kullanılan mevcut veri kümesinin çelişkili sonuçlara sahip olduğu anlaşılmaktadır. Çalışmada kullanılan girdilerin haricinde başka parametrelere ihtiyaç duyulduğu görülmektedir. Fakat çalışmada bu şekilde bir parametrik yapı bulunmamaktadır. Kaldı ki, verilerin manuel olarak girilmesinden ötürü, burada oluşabilecek tutarsızlıklar, tüm olası parametrelerin, fiziksel durumların, doğa şartlarının, topografik yapının kullanılması durumunda bile sonuçların sağlıklı bir girdi-çıkıta bağıntısı oluşturabilecek bir yapılandırmaya dönüştürülebileceği kesin değildir. Çizelge 6.1. ve Çizelge 6.2’de verilen örnekler problemin temel bir veri analizi ve modelleme problemi olmadığını göstermektedir.

Çalışma dahilinde, güvenilir bir tahmin modeli oluşturmak için farklı yöntemler geliştirilip çok katmanlı algılayıcı ağları ve merkezci tabanlı fonksiyon ağları ile birlikte kullanılmış, girdi parametreleri üzerinde temel bileşenler analizi uygulanmış, bunların yanında destek vektör makineleri de kullanılarak test sonuçlarında iyileşmeler gözlemlenmiş ve farklı çıktılar analiz edilmiştir. Yapılan tüm testler, çıktı parametresi olan yanan alan değerlerinin $\ln(x+1)$ logaritmik dönüşüme uğraması ile elde edilen değerler üzerinde de denenmiştir. Ayrıca elde edilen en iyi sonuçlar yanan alan değerlerinin $\log(100x+1)$ logaritmik dönüşüme uğraması ile de test edilmiş, dağılımın biraz daha dengelenmesinin sonuçlardaki iyileşmeler üzerindeki etkileri gözlemlenmiştir.

Yanan alan değerleri, yanan alan $\ln(x+1)$ logaritmik dönüşüm değerleri, yanan alan $\log(100x+1)$ logaritmik dönüşüm değerleri test sonuçlarına göre, analiz edilen başarımlar ölçüm sonuçlarında elde edilen en iyi performans değerleri ve bunların ait oldukları testlerin sonuçlarını içeren çizelge numaraları Çizelge 6.3.’te görülmektedir.

Çizelge 6.3. En iyi başarıml ölçüm sonuçları

Yanan Alan Değerleri					
Çizelge		MSE	MAE	MAPE	RMSE
5.11.	RBFN	379.75	4.58	1.58	19.49
5.65.	SVM	53.68	3.36	6.69	7.33
Yanan Alan $\ln(x+1)$ Logaritmik Dönüşüm Değerleri					
Çizelge		MSE	MAE	MAPE	RMSE
5.12.	MP	368.95	4.10	0.51	19.21
5.12.	RBFN	336.81	4.05	0.54	18.35
Yanan Alan $\log(100x+1)$ Logaritmik Dönüşüm Değerleri					
Çizelge		MSE	MAE	MAPE	RMSE
5.73.	MP	331.34	3.92	0.73	18.20
5.77.	MP	264.02	3.90	0.92	16.25
5.77.	RBFN	256.49	3.94	0.89	16.02
Sonuç					
Çizelge		MSE	MAE	MAPE	RMSE
5.12.	MP	368.95	4.10	0.51	19.21
5.65.	SVM	53.68	3.36	6.69	7.33

Çizelge 6.3. incelendiğinde en iyi MAE sonucuna göre bir yangın oluşumu nedeni ile yanabilecek alan büyüklüğü 3.36 hektar hata ile tespit edilebilmiştir. MAPE sonucu ise bir yangının %51 hata ile tespit edildiğini bize göstermektedir.

Ağın eğitimi için kullanılan eğitim veri kümesinin ağın testinde de kullanıldığı çalışma sonuçlarına göre, eğitim verileri hataları test verileri hatalarından daha iyi değildir. Çıkan en iyi sonuçlar Çizelge 6.4.'te verilmiştir.

Çizelge 6.4. Test verisi yerine eğitim verisi kullanılması sonucu

Test Verisi Yerine Eğitim Verisi Kullanılması Sonuç					
Çizelge		MSE	MAE	MAPE	RMSE
5.19.	MP	1093.59	6.55	4.77	33.07
5.20.	MP	1169.1	3.78	0.53	34.1

Çalışmada kullanılan veri kümesinin istikrarlı bir veri kümesi olup olmadığını tespit etmek için, 5 adet bulanık grubun kullanıldığı deneylerde ağın eğitimi için kullanılan eğitim veri kümesi aynı zamanda ağın testinde de aynen kullanılmış, ağın test işlemi daha önce kendisine gösterilen veriler ile yapılmış ve böylece ağın daha önce gördüğü veriler ile başarıyı gözlenmiştir. Bu deney ile ilgili elde edilen en iyi tahmin oranı ve grup bazında en iyi ortalama doğruluk değeri Çizelge 6.5.'te verilmiştir.

Çizelge 6.5. Test verisi yerine eğitim verisi kullanılması sonuçları

Test Verisi Yerine Eğitim Verisi Kullanılması 5 Bulanık Grup Sonuç								
Çizelge		Toplam%	Grup1	Grup2	Grup3	Grup4	Grup5	Ortalama Doğruluk%
5.21.	MP	72.95	45.73	56.51	62.49	100.00	100.00	72.95

Çizelge 6.4.'teki sonuçlara göre, eğitim verilerinin test işleminde de kullanılması ile daha yüksek çıkması beklenen toplam en iyi tahmin oranı ile en iyi ortalama doğruluk değeri sonuçları düşük değerlerde kalmıştır. Bu sonuç çalışmada kullanılan veri kümesinin istikrarsız olduğunu bir kez daha göstermektedir.

Çalışma içerisinde bulanık gruplar ile yapılan testler sonucunda, grup bazında en iyi sonucun kaç adet bulanık grup kullanılarak hangi deneyde elde edildiğinin kararlaştırılması için, her deneyde gruplara göre elde edilen doğru tahmin oranları, ilgili deneydeki mevcut grup sayısına bölünmüş ve böylece ortalama doğru tahmin oranı elde edilmiştir.

5 adet bulanık grup oluşturularak yanan alan değerleri ve yanan alan $\ln(x+1)$ logaritmik dönüşüm değerleri kullanılarak yapılan testlerde elde edilen en iyi toplam doğru tahmin oranı ile grup bazında en iyi ortalama doğruluk değeri sonuçları Çizelge 6.6.'da görülmektedir.

Çizelge 6.6. 5 bulanık grup sonuçları

5 Bulanık Grup Sonuçları								
Çizelge		Toplam%	Grup1	Grup2	Grup3	Grup4	Grup5	Ortalama Doğruluk%
5.14.	RBFN	98.74	100.00	0.00	0.00	0.00	0.00	20.00
5.39.	MP	98.74	100.00	0.00	0.00	0.00	0.00	20.00
5.47.	MP	0.88	0.00	66.67	66.67	100.00	100.00	66.67

3 adet bulanık grup oluşturularak yanan alan değerleri ve yanan alan $\ln(x+1)$ logaritmik dönüşüm değerleri kullanılarak yapılan testlerde elde edilen en iyi toplam doğru tahmin oranı ile grup bazında en iyi ortalama doğruluk değeri sonuçları Çizelge 6.7.'de görülmektedir.

Çizelge 6.7. 3 bulanık grup sonuçları

3 Bulanık Grup Sonuçları						
Çizelge		Toplam%	Grup1	Grup2	Grup3	Ortalama Doğruluk%
5.24.	RBFN	99.81	100.00	0.00	0.00	33.33
5.49.	RBFN	99.81	100.00	0.00	0.00	33.33
5.49.	MP	96.78	96.90	0.00	100.00	65.63

2 adet bulanık grup oluşturularak yanan alan değerleri ve yanan alan $\ln(x+1)$ logaritmik dönüşüm değerleri kullanılarak yapılan testlerde elde edilen en iyi toplam doğru tahmin oranı ile grup bazında en iyi ortalama doğruluk değeri sonuçları Çizelge 6.8.'de görülmektedir.

Çizelge 6.8. 2 bulanık grup sonuçları

2 Bulanık Grup Sonuçları					
Çizelge		Toplam%	Grup1	Grup2	Ortalama Doğruluk%
5.68.	MP	99.94	100.00	0.00	50.00
5.72.	SVM	76.20	84.14	42.76	63.45

5, 3 ve 2 bulanık grup ile yapılan testlerin genel sonuçları analiz edildiğinde en iyi toplam doğru tahmin oranı ile grup bazında en iyi ortalama doğruluk değeri sonuçları Çizelge 6.9.'da yer almaktadır.

Çizelge 6.9. Bulanık gruplar genel sonuçları

Bulanık Gruplar Genel Sonuçları						
Çizelge		Toplam%	Grup1	Grup2	Grup3	Ortalama Doğruluk%
5.68.	MP	99.94	100.00	0.00	-	50.00
5.49.	MP	96.78	96.90	0.00	100.00	65.63

En iyi ortalama doğruluk değeri 5 bulanık grubun oluşturulduğu gerçek yanan alan değerleri üzerinde MP kullanılarak yapılan deneyde %66,67 olarak (Çizelge 5.47.) elde edilmiştir. Ancak bu deney sonucu incelendiğinde, yangınların büyük bir bölümünü içine alan 1.grup için hiç bir verinin doğru olarak gruplandırılmadığı görülmüştür. Bu nedenle en iyi ortalama doğruluk değeri MP kullanılarak yapılan deneyde %66,67 çıkmasına rağmen, ikinci en iyi ortalama doğruluk değerine sahip olan 3 bulanık grubun oluşturulduğu gerçek yanan alan değerleri üzerinde MP kullanılarak yapılan deneyde %65,63 değeriyle (Çizelge 5.49.) elde edilen sonuç en iyi ortalama doğruluk değeri olarak alınmış ve Çizelge 6.9.'da bu sonuca yer verilmiştir.

Bulanık mantık kullanılarak yapılan deney sonuçları incelendiğinde iyi bir doğru sınıflandırmanın gerçekleşmemesinin temel nedeni olarak, oluşturulan gruplar içindeki veri sayılarının çoğaltılarak eşit sayıda temsil yapılması ve böylece adil öğrenmenin

sağlanmaya çalışılması yöntemi gösterilebilir. Bu yöntem ile aynı veri, ağıın eğitiminde defalarca kullanılmış ve bu durumda ilgili verinin hatalı olması durumunda ortaya çıkan hata da büyümüşür, doğru sınıflandırma gerçekleşmemiştir.

Bu çalışma kapsamında güvenilir bir tahmin modeli oluşturmak için farklı çıktılar analiz edilmiş, optimum sonuca ulaşmaya çalışılmıştır. Bazı sonuçların beklenildiği gibi çıkmamasının temel nedeni olarak kullanılan veri kümesinin tutarsız bir yapıda olması görülmüşür. Verilerin bu şekilde istikrarsız ve tutarsız olması yapılan bu çalışmada problemin temel bir veri analizi ve modelleme problemi olmadığını göstermektedir. Yapılan bu çalışma, orman yangını zararlarının ve buna bağılı olarak yangın sonucunda yanabilecek alanın önceden tespiti ile ilgili daha önce yapılmış çalışmalarla, kullanılan özgün veri kümesi, veri kümesi içerisindeki girdi parametreleri ve yöntem bakımından bir benzerlik taşımasa da, çalışma sonucunda, kullanılan girdi parametre sayısının fazla olması da göz önüne alındığında orman yangını kayıpları ile ilgili yapılan geçmiş çalışmalar ile karşılaştırılabilir tahmin performansı elde edilmiştir.

Bundan sonra yapılacak çalışmalarda, kullanılan veri kümesinin iyileştirilmesi, veri kümesindeki mevcut hataların en aza indirilmesi sağlanarak daha iyi sonuçların elde edilmesi düşünülmektedir. Bu çalışmada olduğu gibi, geniş bir coğrafi bölgeden manuel olarak elde edilen kayıtlar yerine, otomatik gözlem istasyonu verilerine bağılı kalınması ve böylece insan faktörünün devre dışı bırakılması, sağlıklı verilerin elde edilip kullanılmasını sağlayacaktır. Bununla birlikte, koordinat bilgisi gibi farklı girdi parametrelerinin yapılacak çalışmalara dahil edilmesi, daha fazla girdi parametresinin kullanılması, yangın olma durumu ile olmama durumu arasında net bir ayırım yapabilecek veri ve parametre kombinasyonlarının oluşturulması üzerinde çalışılması, ya da genel bir sınıflandırma yerine sadece belli bölgeler seçilip, seçilen bu bölgeler için daha detaylı ve özel çalışmalar yapılması sonucu tahmin başarımının arttırılması düşünülebilir. Ayrıca farklı yapay sinir ağı modelleri ve yöntemleri kullanılarak başarıım oranı arttırılabilir.

KAYNAKLAR

- [1] Doğan N., Orman Yangın Yönetimi ve Yangın Silvikültürü, OGM Yayınları, 2009.
- [2] A.Garcia-Diez, L. Rivas-Soriano, F. De Pablo-Davila, E.L. Garcia-Diez, Incendios forestales: Modelo predictivo, Investigacion y Ciencia, 32-34, 2001.
- [3] Alonso-Betanzos, A., Fontenla-Romero, O., Guijarro-Berdinas, B., Hernandez-Pereira, E., Inmaculada Paz-Andrade, M., Jimenez, E., Luis Legido Soto, J., Carballas, T., An intelligent system for forest fire risk prediction and fire fighting management in Galicia, Expert Systems with Applications, 25, 545-554, 2003.
- [4] Moore, P.F., Trevitt, A.C.F., Computers in fire management: Limitations of the mechanistic approach, In Proceedings of the Eleventh Conference on Fire and Forest Meteorology, Missoula, Montana, 98-108, 1991.
- [5] Saigal, P.M., A suggested classification of forest fires in India by types and causes, In Proceedings of the National Seminar on Forest Fire Fighting, Kulamaru, Kerala, India, 1989.
- [6] Bianchinia, G., Denhama, M., Cortésa, A., Margalefa, T., Luquea, E., Improving forest-fire prediction by applying a statistical approach, Forest Ecology and Management, 234(S1), 210, 2006.
- [7] Amil, M., Forest fires in Galicia (Spain): Threats and challenges for the future, Journal of Forest Economics, 13, 1-5, 2007.
- [8] “Canada Large Fire Database” erişim adresi: <http://cwfis.cfs.nrcan.gc.ca/lfdb>
- [9] “EFFIS 2006 European Forest Fire Information System” erişim adresi: <http://effis.jrc.it/wmi/viewer.html>
- [10] Cheng, T., Wang, J., Integrated spatio-temporal data mining for forest fire prediction, Transactions in GIS, 12, 591-611, 2008.
- [11] Stocks, B., Lynham, T., Lawson, B., Alexander, M., Wagner, C.V., McAlpine, R., Dube, D., The Canadian forest fire danger rating system: an overview, The Forestry Chronicle, 65, 450-457, 1989.
- [12] Deeming, J., Burgan, R., Cohen, J., The national fire danger rating system-1978, US Department of Agriculture Forest Service General Technical Report, INT-39, 63, 1977.
- [13] McArthur, A., Weather and grassland fire behaviour, Australian Forest and Timber Bureau Leaflet 100, 1966.
- [14] Fiorucci, P., Gaetani, F., Minciardi, R., Development and application of a system for dynamic wildfire risk assessment in Italy, Environmental Modelling and Software, 23, 690-702, 2008.
- [15] Brillinger, D.R., Preisler, H.K., Benoit, J.W., Risk assessment: a forest fire example. In Goldstein, D., Speed, T. (Eds.), Statistics and Science: a Festschrift for Terry Speed, IMS Lecture Notes Monograph Series, vol. 40, Institute of Mathematical Statistics, Beachwood, OH, 177-196, 2003.
- [16] Jaiswal, R., Saumitra, M., Kumaran, D., Rajesh, S., Forest fire risk zone mapping from satellite imagery and GIS, International Journal of Applied Earth Observation and Geo-information, 4, 1-10, 2002.

- [17] Iliadis, L., A decision support system applying an integrated fuzzy model for long term forest fire risk estimation, *Environmental Modeling and Software*, 20, 613-621, 2005.
- [18] Cheng, T., Wang, J., Applications of spatio-temporal data mining and knowledge for forest fire, In *Proceedings of the ISPRS Technical Commission VII Mid Term Symposium*, Enschede, The Netherlands, 148-153, 2006.
- [19] Ntaimo, L., Khargharia, B., Two-dimensional fire spread decomposition in cellular DEVS models, *Simulation Series*, 38, 103, 2006.
- [20] Cortez, P., Morais, A., A data mining approach to predict forest fires using meteorological data, In *Proceedings of the 13th Portugese Conference on Artificial Intelligence*, 512-523, 2007.
- [21] George E. Sakr, Imad H. Elhajj, George Mitri, Efficient forest fire occurrence prediction for developing countries using two weather parameters, *Engineering Applications of Artificial Intelligence*, 24, 888-894, 2011.
- [22] Haykin, S., *Neural Networks-A Comprehensive Foundation*, *Prentice Hall*, New Jersey, 2nd Edition, 1999.
- [23] Mark J. L. Orr, *Introduction to Radial Basis Function Networks*, Centre for Cognitive Science, University of Edinburgh, 2 Buccleuch Place, Edinburgh EH8 9LW, Scotland, 1999.
- [24] Theodoridis, S., Koutroumbas, K., *Pattern Recognition*, Elsevier, USA, 3rd Edition, 2006.
- [25] Russell, S., Norvig, P., *Artificial Intelligence A Modern Approach*, *Prentice Hall*, 2nd Edition, 2003.
- [26] Çilli, M., 2007, İnsan Hareketlerinin Modellenmesi ve Benzeşiminde Temel Bileşenler Analizi Yönteminin Kullanılması, *Doktora Tezi*, Hacettepe Üniversitesi Sağlık Bilimleri Enstitüsü, Ankara.
- [27] Yazar, I., Yavuz H.S., Çay M.A., Temel Bileşen Analizi Yönteminin Ve Bazı Klasik Ve Robust Uyarlamalarının Yüz Tanıma Uygulamaları, *Eskişehir Osmangazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi Cilt:XXII, Sayı:1*, Eskişehir, 2009.
- [28] Koç San, D., Türker. M., Destek Vektör Makineleri İle Yüksek Çözünürlüklü Görüntülerden Binaların Belirlenmesi, *TMMOB Harita ve Kadastro Mühendisleri Odası Ankara Şubesi I. CBS Günleri Sempozyumu*, Kasım 2008, Ankara.
- [29] Smola, A., Scholkopf, B., A tutorial on support vector regression, *Technical Report NC2- TR-1998-030*, University of London, UK, 1998.
- [30] Barzilay, O., Brailovsky, V.L., On Domain Knowledge And Feature Selection Using A Support Vector Machine, *Pattern Recognition Letters*, 20, 475-484, 1999.
- [31] "T.C. Orman ve Su İşleri Bakanlığı Orman Genel Müdürlüğü" erişim adresi: <http://www.ogm.gov.tr/>
- [32] "Tanagra V.1.4.38" erişim adresi: <http://data-miningtutorials.blogspot.com/2011/02/tanagra-version-1438.html>
- [33] "Weather Underground" erişim adresi: <http://turkish.wunderground.com>

ÖZGEÇMİŞ

Kişisel Bilgiler

Soyadı, adı : BOZER, Recep
Uyruđu : T.C.
Dođum tarihi ve yeri : 08.03.1985 Eskişehir
Medeni hali : Bekar
Telefon : 0 (554) 251 65 81
Faks : 0 (312) 201 67 97
e-mail : rbozer@etu.edu.tr

Eđitim

Derece	Eđitim Birimi	Mezuniyet tarihi
Lisans	Eskişehir Osmangazi Üniversitesi Bilgisayar Mühendisliđi	2008

İş Deneyimi

Yıl	Yer	Görev
2009-2010	TOBB Ekonomi ve Teknoloji Üniversitesi	Araştırma Görevlisi
2010-	T.C. Gümrük ve Ticaret Bakanlığı	Uzman Yardımcısı

Yabancı Dil

İngilizce