

**T.C.
ONDOKUZ MAYIS ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANA BİLİM DALI**



**UZUN-KISA SÜRELİ BELLEK VE UYARLAMALI SİNİRSEL
BULANIK ÇIKARIM SİSTEMİ İLE DEPREM BÜYÜKLÜĞÜ
TAHMİNİ**

Yüksek Lisans Tezi

İlker GÜR

Danışman

Dr. Öğr. Üyesi Gökhan KAYHAN

SAMSUN
2023

TEZ KABUL VE ONAYI

İlker GÜR tarafından, **Dr. Öğr. Üyesi Gökhan KAYHAN** danışmanlığında hazırlanan “**UZUN-KISA SÜRELİ BELLEK VE UYARLAMALI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ İLE DEPREM BÜYÜKLÜĞÜ TAHMİNİ**” başlıklı bu çalışma, jürimiz tarafından 22.3.2023 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak Yüksek Lisans Tezi olarak kabul edilmiştir.

	Unvanı Adı Soyadı Üniversitesi Ana Bilim/Ana Sanat Dalı	Sonuç
Başkan	Doç. Dr. Abdulkadir KARACI Samsun Üniversitesi Yazılım Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi Gökhan KAYHAN Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret
Üye	Dr. Öğr. Üyesi İsmail İŞERİ Ondokuz Mayıs Üniversitesi Bilgisayar Mühendisliği Ana Bilim Dalı	☒ Kabul ☐ Ret

Bu tez, Enstitü Yönetim Kurulunca belirlenen ve yukarıda adları yazılı jüri üyeleri tarafından uygun görülmüştür.

Prof. Dr. Ahmet TABAK
Enstitü Müdürü

BİLİMSEL ETİĞE UYGUNLUK BEYANI

Hazırladığım Yüksek Lisans tezinin bütün aşamalarında bilimsel etiğe ve akademik kurallara riayet ettiğimi, çalışmada doğrudan veya dolaylı olarak kullandığım her alıntıya kaynak gösterdiğimi ve yararlandığım eserlerin Kaynaklar'da gösterilenlerden oluştuğunu, her unsurun enstitü yazım kılavuzuna uygun yazıldığını ve TÜBİTAK Araştırma ve Yayın Etiği Kurulu Yönetmeliği'nin 3. bölüm 9. maddesinde belirtilen durumlara aykırı davranılmadığını taahhüt ve beyan ederim.

Etik Kurul Gerekli mi ?

Evet ☐ (Gerekli ise ekler kısmına ekleyiniz)

Hayır ☒

17 / 04 / 2023

İlker GÜR

TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI

Tez Başlığı : UZUN-KISA SÜRELİ BELLEK VE UYARLAMALI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ İLE DEPREM BÜYÜKLÜĞÜ TAHMİNİ

Yukarıda başlığı belirtilen tez çalışması için şahsım tarafından 17.04.2023 tarihinde intihal tespit programından alınmış olan özgünlük raporu sonucunda;

Benzerlik oranı : % 7

Tek kaynak oranı : % 1 çıkmıştır.

17 / 04 / 2023

Dr. Öğr. Üyesi Gökhan KAYHAN

ÖZET

UZUN-KISA SÜRELİ BELLEK VE UYARLAMALI SİNİRSEL BULANIK ÇIKARIM SİSTEMİ İLE DEPREM BÜYÜKLÜĞÜ TAHMİNİ

İlker GÜR

Ondokuz Mayıs Üniversitesi

Lisansüstü Eğitim Enstitüsü

Bilgisayar Mühendisliği Ana Bilim Dalı

Yüksek Lisans, Nisan/2023

Danışman: Dr. Öğr. Üyesi Gökhan KAYHAN

Aniden oluşan ve yıkıcı faaliyeti yüksek olan doğal afetlerden olan depremin sebebiyet vereceği kayıplar olabilir. Bu kayıpları önlemek ve tedbir alabilmek için deprem tahmini, üzerine çalışılan bir konu olmuştur. Depremin ne zaman, nerede ve ne büyüklükte olacağının tahmin edilmesi, deprem tahmini üzerine yapılan çalışmalardır. Bu tez çalışmasında deprem büyüklüğü tahmini için iki model önerilmiştir. Bunlar, barındırdığı hafıza mekanizması sayesinde tahmin problemlerinde başarılı sonuçlar veren uzun-kısa süreli bellek (UKSB) ve kural tabanlı yapısıyla tahminleme problemlerinde başarılı sonuçlar veren uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS)dir. Son 20 yıllık deprem verileri filtrelenerek toplanmıştır. Literatürde deprensellik göstergeleri olarak adlandırılan özellik çıkarma yöntemleriyle veri işlenmiştir. Burada hesaplamalar 4.0, 4.5 ve 5.0 olarak seçilen eşik büyüklüklerine göre yapılmıştır ve 3 yeni veri kümesi elde edilmiştir. Modellerde kullanmak üzere, değerler 0-1 aralığında olacak şekilde veri normalleştirme işlemi uygulanmıştır. Rastsallığı sağlamak amacıyla veri kümesine bir karıştırma metodu uygulanmıştır. Veri kümesi %80'i model eğitiminde %20'si model testinde kullanılmak üzere ikiye ayrılmıştır. Modellerin başarımını değerlendirmek adına k-katlamalı çapraz doğrulama tekniği de uygulanmıştır. Her iki modelde bu veri kümeleri kullanılmak üzere 6 senaryo oluşturulmuştur. Veri boyutluluğunu azaltmak adına temel bileşenler analizi (TBA) veri kümelerine uygulanmış ve özellik sayısı 7'den 4'e indirilmiştir. Bu şekilde 3 yeni veri kümesi daha türetilmiştir. Bu veri kümeleri de aynı şekilde işlemlere tabi tutulmuş ve 6 yeni senaryo oluşturulmuştur. Tüm bu senaryolarda modellerin hata oranlarını değerlendirmek için KOKH ve OKH ölçütleri, başarımlarını doğrulamak için R^2 skoru hesaplanmıştır. Son 20 yıllık veri kümesinin eşik büyüklüğü 4.0 seçildiği TBA uygulanmış verilerinin kullanıldığı senaryoda 0.99565 R^2 skoru ile UKSB modeli en iyi başarımları göstermiştir. Bu model, deprem büyüklüğü tahminlemede tutarlı sonuçlar üreterek deprem büyüklüğünü tahmin etmeye yardımcı olacaktır.

Anahtar Sözcükler: Deprem tahminleme, Uzun-kısa süreli bellek, Uyarlamalı sinirsel bulanık çıkarım sistemi, Deprensellik göstergeleri

ABSTRACT

EARTHQUAKE MAGNITUDE PREDICTION WITH LONG-SHORT TERM MEMORY AND ADAPTIVE NEURO FUZZY INFERENCE SYSTEM

İlker GÜR

Ondokuz Mayıs University

Institute of Graduate Studies

Department of Computer Engineering

Master, April/2023

Supervisor: Assist. Prof. Dr. Gökhan KAYHAN

There may be losses caused by an earthquake, which is one of the natural disasters that occurs suddenly and has a high destructive activity. In order to prevent these losses and take precautions, prediction of earthquake has been a subject of study. Predicting when, where and how many magnitude an earthquake will occur is the study of earthquake prediction. Two models are proposed in this thesis. These are the long-short-term memory networks (LSTM), which gives successful results in prediction problems thanks to the memory mechanism it contains, and the adaptive neuro-fuzzy inference system (ANFIS), which gives successful results in prediction problems with its rule-based structure. The earthquake data of the last 20 years were collected by filtering. Data were processed by feature extraction methods, which is called seismicity indicators in the literature. The calculations were made according to the threshold magnitude selected as 4.0, 4.5 and 5.0, and 3 new datasets were obtained. To be used in the models, the data normalization process was applied so that the values are in the range of 0-1. A shuffling method was applied to the dataset to ensure randomness. The dataset is divided into two, 80% for model training and 20% for model testing. In order to evaluate the performance of the models, the k-fold cross validation technique was also applied. In both models, 6 scenarios were created to use these datasets. Principal component analysis (PCA) was applied to datasets to reduce data dimensionality and the number of features was reduced from 7 to 4. In this way, 3 new datasets were derived. These datasets were also processed in the same way and 6 new scenarios were created. In these scenarios, RMSE and MSE criteria were calculated to evaluate the error rates of the models, and the R^2 score was calculated to verify their performance. The LSTM model showed the best performance with an R^2 score of 0.99565 in the scenario where the threshold size of the last 20 years data set was selected as 4.0 and the PCA applied data was used. This model will help predict earthquake magnitude by producing consistent results in prediction of earthquake magnitude.

Keywords: Earthquake prediction, Long-short term memory, Adaptive neuro-fuzzy inference systems, Seismicity indicators

ÖN SÖZ VE TEŞEKKÜR

Hayatım boyunca maddi ve manevi destekleriyle her zaman yanımda olan canım aileme, tez çalışması sürecinde verdiği değerli bilgiler, yardımlar ve motivasyon ile desteğini hissettiğim danışmanım, sayın Dr. Öğretim Üyesi Gökhan KAYHAN hocama, eğitim hayatımda sağladıkları katkılar için tüm hocalarıma ve arkadaşlarıma, sonsuz teşekkürlerimi sunarım.

İlker GÜR



İÇİNDEKİLER

TEZ KABUL VE ONAYI	i
BİLİMSEL ETİĞE UYGUNLUK BEYANI	ii
TEZ ÇALIŞMASI ÖZGÜNLÜK RAPORU BEYANI	ii
ÖZET	iii
ABSTRACT	iv
ÖNSÖZ VE TEŞEKKÜR	v
İÇİNDEKİLER	vi
SİMGELER VE KISALTMALAR	vii
ŞEKİLLER DİZİNİ	ix
TABLolar DİZİNİ	xiii
1. GİRİŞ	1
2. KURAMSAL TEMELLER VE KAYNAK ÖZETİ.....	5
2.1. Depremsellik Göstergeleri ile Deprem Büyüklüğü Tahmini	5
2.2. Depremin Sahip Olduğu Özellikler ile Deprem Büyüklüğü Tahmini.....	10
2.3. Diğer Yaklaşımlar ile Deprem Büyüklüğü Tahmini.....	12
3. MATERYAL VE YÖNTEM.....	14
3.1. Depremsellik Göstergeleri	14
3.1.1. Panakkat Depremsellik Göstergeleri.....	14
3.1.2. Reyes Depremsellik Göstergeleri.....	18
3.2. Yapay Zekâ	21
3.3. Makine Öğrenmesi.....	22
3.4. Yapay Sinir Ağları	24
3.4.1. Aktivasyon Fonksiyonları	27
3.4.2. Öğrenme Yöntemleri	30
3.4.3. Hiper Parametre Ayarlaması.....	35
3.5. Tekrarlayan Yapay Sinir Ağları.....	36
3.6. Derin Öğrenme.....	39
3.7. Uzun-Kısa Süreli Bellek	40
3.8. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi.....	43
3.9. Temel Bileşenler Analizi	47
4. BULGULAR VE TARTIŞMA.....	51
4.1. Verinin Hazırlanması	51
4.2. TBA Uygulanmayan Veri Üzerine Çalışma	54
4.2.1. Uzun-Kısa Süreli Bellek Uygulaması	55
4.2.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin Uygulanması	75
4.3. TBA Uygulanan Veri Üzerine Çalışma	89
4.3.1. Uzun-Kısa Süreli Bellek Uygulaması	90
4.3.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin Uygulanması	108
4.4. Tartışma	121
5. SONUÇ	129
KAYNAKLAR.....	131
ÖZ GEÇMİŞ.....	135

SİMGELER VE KISALTMALAR

AdaBoost	: Adaptive Boosting (Uyarlanabilir Artırma)
AdaGrad	: Adaptive Gradient Algorithm (Uyarlanabilir Gradyan Algoritması)
Adam	: Adaptive Momentum (Uyarlanabilir Moment)
AFAD	: Afet ve Acil Durum Yönetimi Başkanlığı
ANFIS	: Adaptive Neuro-Fuzzy Inference System (Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi)
ANOVA	: Analysis of Variance (Varyans Analizi Testi)
AUC	: Area Under The Curve (Eğri Altındaki Alan)
Bi-LSTM	: Bidirectional Long-Short Term Memory (Çift Yönlü Uzun-Kısa Süreli Bellek)
BRBP	: Bayesian Regularization Back Propagation (Bayes Düzenlemesi Geri Yayılım)
CNN	: Convolutional Neural Network (Evrişimsel Sinir Ağı)
DNN	: Deep Neural Network (Derin Sinir Ağı)
DT	: Decision Tree (Karar Ağacı)
ELU	: Exponential Linear Unit (Üstel Doğrusal Birim)
EPNN	: Enhanced Probabilistic Neural Network (Genişletilmiş Olasılıksal Sinir Ağı)
EPSO	: Enhanced Particle Swarm Optimization (Genişletilmiş Parçacık Sürü Optimizasyonu)
FFBP	: Feed Forward Back Propagation (İleri Beslemeli Geri Yayılım)
GP	: Genetic Programming (Genetik Programlama)
HNN	: Hybrid Neural Network (Hibrit Sinir Ağı)
IN	: Information Network (Bilgi Ağı)
KNN	: K-Nearest Neighbors (K-EnYakın Komşu)
KOKH	: Kök Ortalama Karesel Hata
LMBP	: Levenberg-Marquardt Back Propagation (Levenberg-Marquardt Geri Yayılım)
LPBoost	: Linear Programming Boosting (Doğrusal Programlama Artırma)
LSTM	: Long-Short Term Memory (Uzun-Kısa Süreli Bellek)
MIFN	: Multi-Objective Info-Fuzzy Network (Çok Amaçlı Bulanık Bilgi Ağı)
MLP	: Multi Layer Perceptron (Çok Katmanlı Algılayıcı)

MLR	: Multi Layer Regressor (Çok Katmanlı Regresör)
mRMR	: Minimum Redundancy Maximum Relevance (Minimum Artıklık Maksimum Uygunluk)
MSE	: Mean Squared Error (Ortalama Karesel Hata)
NDAP	: Neural Dynamic Optimization of Adeli and Park (Adeli ve Park'ın Sinirsel Dinamik Optimizasyonu)
NDC	: Neural Dynamic Classification (Sinirsel Dinamik Sınıflandırma)
OKH	: Ortalama Karesel Hata
PCA	: Principal Components Analysis (Temel Bileşenler Analizi)
PNN	: Probabilistic Neural Network (Olasılıksal Sinir Ağı)
PRNN	: Pattern Recognition Neural Network (Örüntü Tanıma Sinir ağı)
RBF	: Radial Basis Function (Radyal Tabanlı Fonksiyon)
ReLU	: Rectified Linear Unit (Düzleştirilmiş Doğrusal Birim)
RF	: Random Forest (Rastgele Orman)
RMSE	: Root Mean Squared Error (Kök Ortalama Karesel Hata)
RMSProp	: Root Mean Square Error Propability (Ortalama Karesel Hata Olasılığının Karekökü)
RNN	: Recurrent Neural Network (Tekrarlayan Sinir Ağı)
SNN	: Shallow Neural Network (Sığ Sinir Ağı)
SVM	: Support Vector Machine (Destek Vektör Makinesi)
SVR	: Support Vector Regressor (Destek Vektör Regresörü)
Tanh	: Hyperbolic Tangent (Hiperbolik Tanjant)
TBA	: Temel Bileşenler Analizi
USBÇS	: Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi
UKSB	: Uzun-Kısa Süreli bellek
YSA	: Yapay Sinir Ağı

ŞEKİLLER DİZİNİ

Şekil 3.1. Yapay zeka ve alt kümeleri.....	22
Şekil 3.2. Tek katmanlı algılayıcı	26
Şekil 3.3. Çok katmanlı algılayıcı.....	26
Şekil 3.4. İleri beslemeli ağ.....	27
Şekil 3.5. Geri beslemeli ağ	27
Şekil 3.6. Tekrarlayan sinir ağı mimarisi	38
Şekil 3.7. Tekrarlayan sinir ağı hücresi.....	38
Şekil 3.8. Uzun-kısa süreli bellek mimarisi	41
Şekil 3.9. Uzun-kısa süreli bellek hücresi.....	41
Şekil 3.10. Uyarlamalı sinirsel bulanık çıkarım sistemi	44
Şekil 4.1. Karıştırma metodunun sözde kodu	53
Şekil 4.2. Grafiksel özet.....	54
Şekil 4.3. Modelin blok diyagram gösterimi.....	55
Şekil 4.4. Senaryo-1'deki model eğitimi ve geçerlemede epok başına kayıp grafiği	57
Şekil 4.5. Senaryo-1'deki eğitim verisinin tahmin sonuçları ve hataları	57
Şekil 4.6. Senaryo-1'deki test verisinin tahmin sonuçları ve hataları	58
Şekil 4.7. Senaryo-1'deki eğitim ve test verisinin regresyon doğruları	58
Şekil 4.8. Senaryo-1'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	60
Şekil 4.9. Senaryo-1'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	61
Şekil 4.10. Senaryo-1'deki eğitim verisinin k-katlamalı regresyon doğruları	62
Şekil 4.11. Senaryo-1'deki test verisinin k-katlamalı regresyon doğruları.....	62
Şekil 4.12. Senaryo-2'deki model eğitimi ve geçerlemede epok başına kayıp grafiği	63
Şekil 4.13. Senaryo-2'deki eğitim verisinin tahmin sonuçları ve hataları	63
Şekil 4.14. Senaryo-2'deki test verisinin tahmin sonuçları ve hataları	64
Şekil 4.15. Senaryo-2'deki eğitim ve test verisinin regresyon doğruları	64
Şekil 4.16. Senaryo-2'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	66
Şekil 4.17. Senaryo-2'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	67
Şekil 4.18. Senaryo-2'deki eğitim verisinin k-katlamalı regresyon doğruları	68
Şekil 4.19. Senaryo-2'deki test verisinin k-katlamalı regresyon doğruları.....	68
Şekil 4.20. Senaryo-3'teki model eğitimi ve geçerlemede epok başına kayıp grafiği	69
Şekil 4.21. Senaryo-3'teki eğitim verisinin tahmin sonuçları ve hataları	69
Şekil 4.22. Senaryo-3'teki test verisinin tahmin sonuçları ve hataları.....	70
Şekil 4.23. Senaryo-3'teki eğitim ve test verisinin regresyon doğruları	70
Şekil 4.24. Senaryo-3'teki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	72
Şekil 4.25. Senaryo-3'teki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	73
Şekil 4.26. Senaryo-3'teki eğitim verisinin k-katlamalı regresyon doğruları	74

Şekil 4.27. Senaryo-3'teki test verisinin k-katlamalı regresyon doğruları.....	74
Şekil 4.28. Senaryo-4'teki eğitim verisinin tahmin sonuçları.....	76
Şekil 4.29. Senaryo-4'teki test verisinin tahmin sonuçları	76
Şekil 4.30. Senaryo-4'teki eğitim ve test verisinin regresyon doğruları.....	77
Şekil 4.31. Senaryo-4'teki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları.....	78
Şekil 4.32. Senaryo-4'teki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	78
Şekil 4.33. Senaryo-4'teki eğitim verisinin k-katlamalı regresyon doğruları	79
Şekil 4.34. Senaryo-4'teki test verisinin k-katlamalı regresyon doğruları.....	79
Şekil 4.35. Senaryo-5'teki eğitim verisinin tahmin sonuçları.....	80
Şekil 4.36. Senaryo-5'teki test verisinin tahmin sonuçları	81
Şekil 4.37. Senaryo-5'teki eğitim ve test verisinin regresyon doğruları.....	81
Şekil 4.38. Senaryo-5'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	82
Şekil 4.39. Senaryo-5'teki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	83
Şekil 4.40. Senaryo-5'teki eğitim verisinin k-katlamalı regresyon doğruları	83
Şekil 4.41. Senaryo-5'teki test verisinin k-katlamalı regresyon doğruları.....	84
Şekil 4.42. Senaryo-6'daki eğitim verisinin tahmin sonuçları	85
Şekil 4.43. Senaryo-6'daki test verisinin tahmin sonuçları.....	85
Şekil 4.44. Senaryo-6'daki eğitim ve test verisinin regresyon doğruları.....	86
Şekil 4.45. Senaryo-6'daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	87
Şekil 4.46. Senaryo-6'daki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	87
Şekil 4.47. Senaryo-6'daki eğitim verisinin k-katlamalı regresyon doğruları	88
Şekil 4.48. Senaryo-6'daki test verisinin k-katlamalı regresyon doğruları.....	88
Şekil 4.49. TBA uygulaması ile özellik seçim oranları	90
Şekil 4.50. Senaryo-7'deki model eğitimi ve geçerlemede epok başına kayıp grafiği	90
Şekil 4.51. Senaryo-7'deki eğitim verisinin tahmin sonuçları ve hataları	91
Şekil 4.52. Senaryo-7'deki test verisinin tahmin sonuçları ve hataları.....	91
Şekil 4.53. Senaryo-7'deki eğitim ve test verisinin regresyon doğruları	92
Şekil 4.54. Senaryo-7'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	93
Şekil 4.55. Senaryo-7'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	94
Şekil 4.56. Senaryo-7'deki eğitim verisinin k-katlamalı regresyon doğruları	95
Şekil 4.57. Senaryo-7'deki test verisinin k-katlamalı regresyon doğruları.....	95
Şekil 4.58. Senaryo-8'deki model eğitimi ve geçerlemede epok başına kayıp grafiği	96
Şekil 4.59. Senaryo-8'deki eğitim verisinin tahmin sonuçları ve hataları	97
Şekil 4.60. Senaryo-8'deki test verisinin tahmin sonuçları ve hataları	97
Şekil 4.61. Senaryo-8'deki eğitim ve test verisinin regresyon doğruları	98
Şekil 4.62. Senaryo-8'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	99
Şekil 4.63. Senaryo-8'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	100

Şekil 4.64. Senaryo-8'deki eğitim verisinin k-katlamalı regresyon doğruları	101
Şekil 4.65. Senaryo-8'deki test verisinin k-katlamalı regresyon doğruları.....	101
Şekil 4.66. Senaryo-9'daki model eğitimi ve geçerlemede epok başına kayıp grafiği	102
Şekil 4.67. Senaryo-9'daki eğitim verisinin tahmin sonuçları ve hataları	103
Şekil 4.68. Senaryo-9'daki test verisinin tahmin sonuçları ve hataları.....	103
Şekil 4.69. Senaryo-9'daki eğitim ve test verisinin regresyon doğruları	104
Şekil 4.70. Senaryo-9'daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	105
Şekil 4.71. Senaryo-9'daki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	106
Şekil 4.72. Senaryo-9'daki eğitim verisinin k-katlamalı regresyon doğruları	107
Şekil 4.73. Senaryo-9'daki test verisinin k-katlamalı regresyon doğruları.....	107
Şekil 4.74. Senaryo-10'daki eğitim verisinin tahmin sonuçları.....	108
Şekil 4.75. Senaryo-10'daki test verisinin tahmin sonuçları.....	109
Şekil 4.76. Senaryo-10'daki eğitim ve test verisinin regresyon doğruları	109
Şekil 4.77. Senaryo-10'daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	110
Şekil 4.78. Senaryo-10'daki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	111
Şekil 4.79. Senaryo-10'daki eğitim verisinin k-katlamalı regresyon doğruları	111
Şekil 4.80. Senaryo-10'daki test verisinin k-katlamalı regresyon doğruları.....	112
Şekil 4.81. Senaryo-11'deki eğitim verisinin tahmin sonuçları.....	113
Şekil 4.82. Senaryo-11'deki test verisinin tahmin sonuçları.....	113
Şekil 4.83. Senaryo-11'deki eğitim ve test verisinin regresyon doğruları	114
Şekil 4.84. Senaryo-11'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	115
Şekil 4.85. Senaryo-11'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	115
Şekil 4.86. Senaryo-11'deki eğitim verisinin k-katlamalı regresyon doğruları	116
Şekil 4.87. Senaryo-11'deki test verisinin k-katlamalı regresyon doğruları.....	116
Şekil 4.88. Senaryo-12'deki eğitim verisinin tahmin sonuçları.....	117
Şekil 4.89. Senaryo-12'deki test verisinin tahmin sonuçları.....	118
Şekil 4.90. Senaryo-12'deki eğitim ve test verisinin regresyon doğruları	118
Şekil 4.91. Senaryo-12'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları	119
Şekil 4.92. Senaryo-12'deki test verisinin k-katlamalı tahmin sonuçları ve hataları.....	120
Şekil 4.93. Senaryo-12'deki eğitim verisinin k-katlamalı regresyon doğruları	120
Şekil 4.94. Senaryo-12'deki test verisinin k-katlamalı regresyon doğruları.....	121
Şekil 4.95. Senaryo 1-3 arasındaki test verilerinin R^2 skorları	122
Şekil 4.96. Senaryo 4-6 arasındaki test verilerinin R^2 skorları	123
Şekil 4.97. Senaryo 7-9 arasındaki test verilerinin R^2 skorları	123
Şekil 4.98. Senaryo 10-12 arasındaki test verilerinin R^2 skorları	124
Şekil 4.99. Senaryo 1-3 ve Senaryo 7-9 arasındaki test verilerinin R^2 skorları	124
Şekil 4.100. Senaryo 4-6 ve Senaryo 10-12 arasındaki test verilerinin R^2 skorları	125

Şekil 4.101. Senaryo 1-3 ve Senaryo 4-6 arasındaki test verilerinin R^2 skorları	126
Şekil 4.102. Senaryo 7-9 ve Senaryo 10-12 arasındaki test verilerinin R^2 skorları	126



TABLolar DİZİNİ

Tablo 4.1. Veri kümesi filtreleme kriterleri ve gerekçeleri.....	51
Tablo 4.2. Son 20 yıllık veri için türetilmiş yeni veri kümeleri	52
Tablo 4.3. Izgara arama sonuçlarına göre hiper parametre seçimi.....	56
Tablo 4.4. Senaryo-1 eğitim ve test veri kümelerinin hata oranları ve başarımları	59
Tablo 4.5. Senaryo-1 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	59
Tablo 4.6. Senaryo-2 eğitim ve test veri kümelerinin hata oranları ve başarımları	65
Tablo 4.7. Senaryo-2 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	65
Tablo 4.8. Senaryo-3 eğitim ve test veri kümelerinin hata oranları ve başarımları	71
Tablo 4.9. Senaryo-3 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	71
Tablo 4.10. Senaryo-4 eğitim ve test veri kümelerinin hata oranları ve başarımları	77
Tablo 4.11. Senaryo-4 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	80
Tablo 4.12. Senaryo-5 eğitim ve test veri kümelerinin hata oranları ve başarımları	82
Tablo 4.13. Senaryo-5 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	84
Tablo 4.14. Senaryo-6 eğitim ve test veri kümelerinin hata oranları ve başarımları	86
Tablo 4.15. Senaryo-6 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	89
Tablo 4.16. Senaryo-7 eğitim ve test veri kümelerinin hata oranları ve başarımları	92
Tablo 4.17. Senaryo-7 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	96
Tablo 4.18. Senaryo-8 eğitim ve test veri kümelerinin hata oranları ve başarımları	98
Tablo 4.19. Senaryo-8 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	102
Tablo 4.20. Senaryo-9 eğitim ve test veri kümelerinin hata oranları ve başarımları	104
Tablo 4.21. Senaryo-9 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	108
Tablo 4.22. Senaryo-10 eğitim ve test veri kümelerinin hata oranları ve başarımları	110
Tablo 4.23. Senaryo-10 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	112
Tablo 4.24. Senaryo-11 eğitim ve test veri kümelerinin hata oranları ve başarımları	114
Tablo 4.25. Senaryo-11 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	117
Tablo 4.26. Senaryo-12 eğitim ve test veri kümelerinin hata oranları ve başarımları	119
Tablo 4.27. Senaryo-12 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları	121
Tablo 4.28. Test veri kümelerinde en iyi hata oranları ve başarımları.....	127

Tablo 4.29. Önceki çalışmalar ile önerilen çalışmanın karşılaştırılması.....	128
--	-----



1. GİRİŞ

Doğal afetler, doğanın normal süreçlerinde ortaya çıkan ani olaylardır. İnsanoğlu bu olaylar sonrasında, olayları önceden önlemenin veya kontrol edebilmenin yolunu aramıştır. Doğal afetlerin oluşumunu tahmin etmeyi görev edinmişlerdir. Çünkü doğal afetler, gizli ve ani gelişen olaylar olduğu için bir bölgenin varlığını tehdit edebilir, büyük hasarlara ve kayıplara sebebiyet verebilirler. Ancak insanlar bazı öngörülerde bulunabilirse ve gerekli önlemleri alabilirse, muhtemel can ve mal kayıplarının önüne geçebilirler.

Aniden oluşan ve yıkıcı faaliyeti yüksek olan doğal afetlerden birisi de depremlerdir. Depremler, bariz bir uyarı olmadan meydana gelmesi sonucunda potansiyel can ve mal kayıplarını, bölgenin ekonomik ve sosyal durumu üzerinde olumsuz etkileri oluşturur. Depremler kendi yıkıcı etkisinin yanında, neden olabileceği tsunami, sel, toprak kayması, yangın gibi diğer doğal afetler ile bu kayıpları ve olumsuz etkileri artırır. Bu doğal afetler de ulaşım, iletişim, sağlık gibi kritik faaliyetleri durma noktasına getirebilir (Yousefzadeh et al., 2021). Depremler bu sonuçları doğurur bunun yanı sıra depremlerin sebeplerinden de bahsetmek gerekir. Depremler yer tabakasının hareketi, tektonik plakaların hareketi, kaya tabakasının malzemesi gibi coğrafi sebeplere bağlıdır. Bu sebepler, ortaya bir enerji çıkarır ve bu enerji yer yüzeyinin sallanmasına yani depremlere yol açar. Aslında depremlerin oluşumu yeryüzünde meydana gelen karmaşık jeolojik olaylar arasındadır.

Depremlerin doğrudan veya dolaylı yoldan neden olduğu kayıpları azaltmak ve önlemek, bunlara tedbir almak ve bunlar için hazırlık planı oluşturmak üzere insanlar depremleri tahmin etmeye çalışmışlardır. Zamanında ve doğru bir tahmin, depremlerin yıkıcı etkisinden en az hasarla ayrılmayı sağlamak adına önlem almaya fırsat tanır. Kısacası deprem tahmini insanlık için günün ihtiyacı olan önemli ve değerli bir konudur.

Deprem tahmini, gelecekteki bir depremin ne zaman, nerede ve ne kadar büyüklükte olacağının doğru bir şekilde tahmin edilmesidir. Dolayısıyla basit bir yorum ile deprem tahmini yapabilmek için depremin zaman, konum, büyüklük ve derinlik bilgilerini içeren parametrelere ihtiyaç vardır. Burada mühim olan konu, bu parametrelerin kullanılmasıyla tanımlanan bir yaklaşımın veya modelin gelecekte bir depremi başarılı bir şekilde tahmin edebilmesidir. Tüm bunlar ışığında, deprem

tahmini problemi ekonomik ve sosyal bir etkiye sahip olduğundan insanlık için kritik bir hale gelir. Yıllardır bilim insanları bu probleme çözüm bulabilmek adına mümkün olan en etkili modellerin ve araçların kullanılmasıyla bazı yaklaşımlarda bulunmuşlardır. Deprem tahmini çalışmaları, doğa olaylarından, teorik jeofizikten, sismik bölgelerin kataloglarda kaydedilen deprem parametrelerinin istatistiksel, matematiksel ve hesaplamalı modellemesine kadar uzanır (Adeli and Panakkat, 2009).

Deprem tahmini için ortaya konulan çabaya rağmen henüz tam başarılı bir yöntem bulunamamıştır. Deprem oluşumunun rastgele davranışı ve karmaşık yapısı sebebiyle bunu başaracak tam bir yöntem belki mümkün olmayabilir. Bazı bilim adamları böyle düşünürken bazıları da depremin tahmin edilebilir olduğunu öne sürmüşlerdir (Panakkat and Adeli, 2007). Tahmin edilebilir olduğunu öne süren bilim adamlarının bazı zorlukların üstesinden gelmesi gerekmektedir. Bunlar yer kabuğunun hareketinden kaynaklı sıkışıklık, basınç, sıcaklık gibi değerleri ölçebilecek hassas mekanizmanın yetersizliği ile sismologlar, jeologlar ve bilgisayar bilimciler arasındaki ortaklığın kurulup problemin üstüne çalışamamasıdır. Öte yandan güncel araştırmalar, bilim adamlarının deprem tahmini için çeşitli yaklaşımlarda bulunduğunu göstermektedir. Aslında başarılı tahmin için pratik ve kullanılabilir bir yöntem ortaya konulmadığından bu alanda çalışma yapılması ihtiyacı vardır.

Deprem tahmini için hidrolojik analiz, iyonosferik analiz, hayvan davranışlarının gözlenmesi, radon gazı salınımı gözlenmesi, elektromanyetik alan düzensizliklerinin izlenmesi gibi öncüllere dayanan yöntemler önerilmiştir. Bu yöntemlerin çoğu bu öncüllere bağlıdır ve bu öncüllerin tespit edilmesi zordur (Asim et al., 2016a). Çünkü her deprem oluşumunda bu öncüller ile karşılaşılabilir. Deprem tahmini için sismik tarihsel verilerin kullanıldığı yöntemler de önerilmiştir. Matematiksel, istatistiksel ve hesaplamalı modeller gibi yaklaşımlar kullanılmıştır (Berhich et al., 2021). Yıllardır bilim adamları, başarılı yöntemler için araştırma yapmaktadır ancak buna henüz ulaşamamış olması bu alandaki araştırmaların aktif bir şekilde sürmesi gerekliliğini ortaya koymaktadır.

Deprem tahmini zamana da bağlıdır ve bu nedenle zamana dayalı kategorize edilebilir. Deprem tahmininin bilim adamları tarafından üç farklı zaman diliminde yapılabileceği öne sürülmüştür. Bunlar uzun vadeli, orta vadeli ve kısa vadeli deprem tahminidir. Uzun vadeli deprem tahminleri, 10-100 yıllık süreci kapsayan henüz başarılı tahminler üretememiştir. Orta vadeli deprem tahminleri, 1-10 yıllık süreci

kapsayan başarılı tahminler üretebilmiştir ancak pratikte kullanımı olmamıştır. Kısa vadeli deprem tahminleri ise 1 yıla kadar olan süreci kapsayan günlük, haftalık veya aylık olarak başarılı tahminler üretebilmiştir.

Son yıllarda yapay zekâ alanındaki gelişmeler birçok probleme çözümler üretmektedir. Bu gelişmeler ile birlikte hava tahmini, finansal tahmin, hastalık teşhisi gibi alanlarda başarılı sonuçlar elde edilmiştir. Gelişmelerin yaşandığı alanlarda birisi de deprem tahmini problemidir. İlk başlarda makine öğrenmesi yöntemleri kullanılarak deprem tahmini yapılmaya çalışılmıştır. Makine öğrenmesi yöntemlerinin gelişmesi ve bu yöntemlerin farklı problemlere uygulanmasıyla başarılı neticeler vermesi, bu yöntemlerin deprem tahmini problemine de uygulanmasını mümkün kılmıştır. Buna ek olarak, büyük miktarda verilerin de elde edilmesiyle makine öğrenmesi yöntemleri, deprem tahmini problemine önerilen çözümlerin doğruluklarını ve verimliliklerini artırmaktadır. Sonraları makine öğrenmesi yöntemleri kullanılarak oluşturulan modellerin, verileri ham biçimde işleyememesi nedeniyle sınırlı olduğu görülmüştür. Bu sırada devreye giren derin öğrenme yöntemleri olmuştur. Derin öğrenme yöntemleri kullanılarak oluşturulan modeller ise, ham verilerin aşamalı şekilde katmanlar kullanılarak işlenmesiyle oluşturulan modellerdir. Derin öğrenme yöntemiyle oluşturulmuş bu modellerdeki katmanlar arası bilgi aktarımı yani bir katmanın kendinden önceki katmandan bilgi alarak kendi bilgisini güncellediği bir durum vardır. Bu durum yani katmanlar arası bilgi aktarımı deprem tahmini probleminin verilerinde de kullanılabilir. Bu veriler arasında zamana dayalı ve ardışık olma durumu mevcuttur. Başka bir deyişle, deprem tahmin problemindeki gibi karmaşık veriler ile modelleme sınırlanıyorsa derin öğrenme yaklaşımları başarılı sonuçlar için yararlı olacaktır. Bu gelişmeler neticesinde sismoloji ve bilgisayar bilimi arasında ortaklık kurularak önemli sonuçlar elde edilebilir.

Tez çalışması ile deprem sonrasında ortaya çıkması muhtemel olumsuz tablonun, en az hasar ve kayıp ile atlatılması amacıyla deprem büyüklüğü tahmin edilmeye çalışılmıştır. Deprem büyüklüğü doğru bir şekilde tahmin edilebilirse o bölge için önceden önlemler almaya imkân tanınmış olacak ve sonrasında afetin etkisinin öngörülmesi ve dolayısıyla afet kurtarma süreçlerinin düzeyinin belirlenmesinde kritik bir rol oynayacaktır. Bu çalışmada önerilen deprem büyüklüğü tahmin modeli, deprem sonrası yaralı sayısı, binalardaki hasar ve ekonomik kaybın tahmini gibi başka çalışmaların yapılmasını da mümkün kılacaktır. Ayrıca afet yardım süreçlerinde yerel

ve merkezi yönetim birimleri için etkin müdahale planları oluşturulabilmesi önemli bir durumdur. Bu amaçla deprem büyüklüğü tahmininin, afet yönetimi kapsamında diğer çalışmalarla tümleşik hale getirilmesinin yolu açılmaktadır.

Bu tez çalışması ile deprem büyüklüğü tahmini iki model üzerinde yapılmıştır. Bunlardan ilki geçmiş verileri kullanmayı öğrenebilmesi ve uzun süreli aralık ilişkileri içeren verilerin doğrusal olmayan öğrenme yeteneğine sahip olması sebebiyle tercih edilmiş uzun-kısa süreli bellek ağlarıdır. Diğerisi ise doğrusal olmayan fonksiyonları modellemek ve kaotik zaman serilerini tahmin etmek için kullanılan uyarlamalı sinirsel bulanık çıkarım sistemidir. Bu modeller için kullanılacak verileri içeren deprem kataloğu, yerel kaynaklardan olan Afet ve Acil Durum Yönetimi Başkanlığı veya kısa adıyla AFAD kurumunun deprem kataloğudur. Bu katalogdan elde edilen ham veri literatürde üzerinde fazlaca çalışılmış özellik çıkarım yöntemlerinden olan Panakkat deprensellik göstergeleri kullanılarak yeni veri kümeleri türetilmiştir. Daha sonra Panakkat deprensellik göstergelerinin temelde belirli sismolojik yasalara dayanılarak çıkartılmasından dolayı özellik sayısının düşürülmesi amacıyla temel bileşenler analizi uygulanmıştır. Böylelikle veri boyutunun azaltılmış haliyle yeni veri kümeleri elde edilmiştir. Türkiye coğrafyasının depremlerine ait deprensellik göstergelerinin kullanıldığı bir veri kümesi ve bu veri kümesi üzerine uygulanmış temel bileşenler analizi sonucu elde edilmiş bir veri kümesi literatüre kazandırılmıştır.

Tez çalışmasının akışı şu şekilde düzenlenmiştir: 2. bölümde literatürde deprem tahminlemesine yönelik incelenen çalışmalar özetlenmiştir. 3. bölümde deprem verisi için özellik çıkarma yöntemlerinden olan deprensellik göstergeleri, yapay zekâ, makine öğrenmesi, derin öğrenme konularına değinilmiştir ve tekrarlayan sinir ağları, uzun-kısa süreli bellek ve uyarlamalı sinirsel bulanık çıkarım sistemi hakkında detaylı bilgiler verilmiştir. 4. bölümde kullanılacak veri kümelerinin nasıl elde edildiği ve kullanılacak modellere nasıl verileceği tarif edildikten sonra deneysel sonuçlar sonunda elde edilen bulgular şekiller ve tablolar ile tartışılmıştır. 5. bölümde ise tez çalışmasının sonuçları ve gelecek çalışmalar için öneriler verilmiştir.

2. KURAMSAL TEMELLER VE KAYNAK ÖZETİ

Literatürde, depremin sahip olduğu özellikler temelinde yaklaşımlarda bulunularak ve sismoloji yasalarından elde edilen Eşitlikler kullanılarak yapılmış çalışmalar vardır. Bu bölümde çalışmalarda kullanılan veri kümeleri, önışlemler ve tahminleme için kullanılan yöntemler ile elde edilen sonuçlar özetlenmektedir. Deprem büyüklüğü tahmini için deprensellik göstergeleri ile yapılan çalışmalar, depremin sahip olduğu özellikler ile yapılan çalışmalar ve diğer yaklaşımlar ile yapılan çalışmalar başlıklar halinde verilmektedir.

2.1. Deprensellik Göstergeleri ile Deprem Büyüklüğü Tahmini

Panakkat ve Adeli tarafından, Gutenberg-Richter Yasası ve karakteristik deprem büyüklük dağılımına göre seçilen, matematiksel olarak hesaplanan, deprensellik göstergeleri olarak adlandırılan sekiz parametre ilk kez tanıtılmaktadır. Bu parametreler; önceden tanımlanmış bir eşik değerinden daha büyük büyüklükteki son n olay üzerinde geçen süre, son n olayın ortalama büyüklüğü, salınan sismik enerjinin karekök oranı, b -değeri olarak bilinen Gutenberg-Richter ters kuvvet yasası eğrisinin eğimi, η -değeri olarak bilinen Gutenberg-Richter ters kuvvet yasasına dayalı regresyon doğrusu etrafındaki ortalama sapma karesinin toplamı, büyüklük açığı veya Gutenberg-Richter ters güç yasasına dayalı olarak gözlemlenen ve beklenen büyüklükler arasındaki fark, μ -değeri olarak bilinen karakteristik veya tipik olaylar arasındaki ortalama süre, c -değeri olarak bilinen ortalama zamanın veya ortalamanın periyodikliğinin varyasyon katsayısı olarak tarif edilmektedir. Bu parametreler ileri beslemeli Levenberg-Marquardt geri yayımlımlı sinir ağı (LMBP), tekrarlayan sinir ağı (RNN) ve radyal tabanlı fonksiyon sinir ağı (RBF) modellerine verilmektedir. Buradaki amaç bir sonraki ayda en büyük sismik olayın büyüklüğünü tahmin etmektir. RNN modelinin, LMBP ve RBF ağları ile karşılaştırıldığında en iyi tahmin doğruluğunu verdiği görülmektedir (Panakkat and Adeli, 2007). Panakkat ve Adeli tarafından, bu parametreler kullanılarak sismik bir bölgede önceden tanımlanmış bir gelecek zaman periyodundaki en büyük depremin büyüklüğünü tahmin etmek üzere olasılıksal sinir ağı (PNN) önerilmektedir. Önerilen model, büyüklüğü 4.5-6.0 arasında olan depremleri tahmin etmek için başarılı tahmin sağladığı görülmektedir (Adeli and Panakkat, 2009). Panakkat göstergeleri, depremlerin yerini ve zamanını tahmin etmek için RNN modeli sunulmak üzere de kullanılmıştır. Buradaki amaç ilk olarak depremin

büyükliğini hesaplamak için daha önceki çalışmada önerilmiş olan tekrarlayan sinir ağı modelinin geliştirilmesi, daha sonra da depremin yerini ve zamanını bulmak için geliştirilen bu modelin kullanılması olarak belirlenmiştir (Panakkat and Adeli, 2009). Narayanakumar ve Raja tarafından, Himalaya gibi geniş bir coğrafyanın 128 yıllık deprem kayıtları toplandıktan sonra Panakkat depremsellik göstergeleri hesaplanmıştır. Bu depremsellik göstergeleri, üç katmanlı bir ileri beslemeli geri yayımlı (FFBP) sinir ağı modeline girdi olarak verilmiştir. Modelin büyüklükleri 4.0-6.0 arasındaki depremlerin tahmininde başarılı sonuçlar verdiği görülmektedir (Narayanakumar and Raja, 2016). Asim ve arkadaşları, Hindukush bölgesinin deprem büyüklüğü tahmini için bu depremsellik göstergelerini kullanmaktadır. Örüntü tanıma sinir ağı (PRNN), RNN, rastgele orman (RF) ve doğrusal programlama yükseltme (LPBoost) topluluk sınıflandırıcı olmak üzere dört makine öğrenme tekniği ayrı ayrı uygulanmaktadır. Deprem tahmin problemi ikili sınıflandırma görevi olarak ele alınarak büyüklüğü 5.5 veya daha büyük olan depremler için 1 aylık süre için tahminler yapılmaktadır. LPBoost topluluk sınıflandırıcısı %65 ile diğer modeller içinde en yüksek başarıyı elde etmiştir (Asim et al., 2016a). Asim ve arkadaşları, diğer bir çalışmada depremsellik göstergeleri için bilgi kazanımı tekniği kullanarak sekiz depremsellik göstergesinden daha uygun olan altısı kullanmaktadır. Tahmin problemi sınıflandırma problemi olarak ele alınmıştır ve sınıflandırma algoritmaları olarak ileri beslemeli sinir ağı (FFNN), RNN, RF, çok katmanlı algılayıcı (MLP), RBF ve SVM kullanılmaktadır. Bu algoritmaların doğruluk değerlerinin karşılaştırılmasının yanında istatistiksel testler de uygulanmıştır. İleri beslemeli sinir ağı modeli %75'lik doğruluk oranıyla diğer modeller arasında en yüksek başarı değerine sahiptir (Asim et al., 2017). Rafiei ve Adeli tarafından belirli bir zaman diliminde, önceden tanımlanmış bir büyüklük eşiğinden daha büyük bir deprem olup olmadığını bulmak amacıyla bir sınıflandırma algoritması (Sinirsel Dinamik Sınıflandırma (NDC), PNN, Gelişmiş Olasılıksal Sinir Ağı (EPNN) ve SVM) ve o depremin maksimum gerçekleşme olasılığı ile yerini bulmak amacıyla bir optimizasyon algoritması (Adeli ve Park'ın Sinirsel Dinamik Optimizasyonu (NDAP))nın birlikte kullanılmasıyla bir tahmin modeli geliştirilmiştir. Parametre olarak Panakkat depremsellik göstergeleri kullanılmaktadır. En uygun depremsellik göstergelerini modelde kullanabilmek için bir duyarlılık analizi yapılmıştır. Tüm sınıflandırma algoritmaları doğruluk açısından %90'ın üzerinde doğruluk göstermektedir (Rafiei and Adeli, 2017). Sadhukhan ve arkadaşları, depremsellik göstergeleriyle depremler arasındaki ilişkileri gösterebilmek

için uzun-kısa süreli bellek (LSTM), çift yönlü uzun-kısa süreli bellek (Bi-LSTM) ve öz-dikkat tabanlı transformer olmak üzere üç adet derin öğrenme yöntemini kullanmışlardır. Japonya, Endonezya ve Hindukush-Karakoram-Himalayan bölgelerinin sismik verileri üzerinde yapılan çalışmada en iyi sonuçlar ortalama karesel hata açısından Japonya için LSTM modeli ile 0.006, Endonezya için Bi-LSTM modeli ile 0.009 ve Hindukush-Karakoram-Himalayan bölgesi için transformer modeli ile 0.006 olarak başarılı bir şekilde hesaplanmıştır (Sadhukhan et al., 2023).

Jeofizik ve sismolojiden yararlanılarak elde edilen eşitlikleri depremsellik göstergesi olarak öneren Reyes ve arkadaşları, literatüre yeni depremsellik göstergeleri kazandırmıştır. Bu depremsellik göstergeleri sismoloji ile güçlü bir şekilde ilişkili olan Gutenberg-Richter yasasının bir elemanı b-değeri ile Bath yasası ve Omori-Utsu yasasından elde edilen eşitliklerdir. Bu parametreler kullanılarak bir yapay sinir ağı (YSA) modeli önerilmektedir. Bu çalışmada, iki tahmin sağlanmaktadır. Bunlardan ilki ilerleyen beş gün içinde belirlenen bir eşik değerinden daha büyük bir depremin meydana gelme olasılığını tahmin etmek ve diğeri ise sınırlı bir büyüklük aralığında bir depremin meydana gelme olasılığını tahmin etmektir. Yöntemin doğruluğu, geriye dönük deneylerde istatistiksel testler aracılığıyla değerlendirilmiş ve iyi bilinen makine öğrenmesi sınıflandırıcıları (K-En Yakın Komşu Algoritması, Destek Vektör Makinesi ve K-Ortalama Algoritması) ile karşılaştırılmıştır. Önerilen yapay sinir ağı yönteminin yüksek başarılı olduğu görülmektedir (Reyes et al., 2013). Morales-Esteban ve arkadaşları tarafından, Reyes depremsellik göstergelerinin parametre olarak kullanıldığı bir YSA modeli sunulmaktadır. Bu çalışmada, ilk olarak gelecekteki 7 gün içinde, önceden belirlenmiş bir eşik büyüklüğüne eşit veya ondan daha büyük büyüklükte bir depremin olma olasılığı ve gelecekteki 7 gün içinde sınırlı büyüklükte bir deprem olma olasılığı tahmini yapılmaktadır. Önerilen model farklı modeller (Naive Bayes, M5P Algoritması ve SVM) ile kıyaslanmaktadır. Yöntemin doğruluğu, geriye dönük deneylerde istatistiksel testler aracılığıyla da değerlendirilmiştir. Çalışma sonuçlarının bu alanda araştırma yapmaya teşvik edeceğini iddia edilmektedir (Morales-Esteban et al., 2013).

Öte yandan Zamani ve arkadaşları da başta Gutenberg-Richter yasası ile diğer jeofizik ve sismolojik yasalara dayanan yeni depremsellik göstergeleri hesaplamıştır. Hesaplanan depremsellik göstergeleri mekânsal ve zamansal değişimleri incelemek için RBF ve uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) modellerinde

kullanılmaktadır. RBF ağı, USBÇS modelinden daha yüksek bir performans ile tahminde bulunmaktadır. Bu çalışma, özellikle mekân tahmininde, önerilen diğer çalışmalara göre daha başarılı olduğu öne sürülmektedir (Zamani et al., 2013). Benzer şekilde Berhich ve arkadaşları, Gutenberg-Richter yasası ve Omori-Utsu yasasından elde edilen depremsellik göstergelerini kullanmaktadır. Model olarak uzun kısa vadeli bellek (UKSB) ağları önerilmektedir. Modelin hiper parametre seçimi için grid arama tekniği kullanılmıştır. Önerilen model MLP sinir ağları ile karşılaştırıldığında daha başarılı sonuçlar ortaya koyduğu görülmektedir (Berhich et al., 2021).

Martinez-Alvarez ve arkadaşları, Panakkat ve Reyes depremsellik göstergelerinin birleştirilmesiyle ortaya çıkan veri kümesi içinden en değerli bilgi katkısı olacak depremsellik göstergelerinin seçilmesi için öznitelik seçim tekniklerinden olan bilgi kazanımı yöntemi kullanmaktadır. Bu yöntem sonucu elde edilen veriler YSA modeline uygulanmıştır. Önerilen model farklı sınıflandırma modelleri (Naive Bayes, K-En Yakın Komşu Algoritması, SVM) ile kıyaslanmaktadır. Önerilen modelin diğer sınıflandırma yöntemlerinden farklı olduğunu kanıtlayabilmek için istatistiksel testler (ANOVA-ANalysis Of VAriance Test, Friedman Test) de uygulanmıştır. Önerilen optimize edilmiş modelin yüksek performansa sahip olduğunu öne sürülmektedir (Martínez-Álvarez et al., 2013). Bu birleştirilmiş Panakkat ve Reyes depremsellik göstergelerini içeren veri kümesi Asencio-Cortés ve arkadaşları tarafından da kullanılmıştır. Bu çalışmada, gelecekteki 7 gün içinde büyüklüğü 5.0'dan büyük olan depremlerin olma olasılığı tahmin edilmektedir. Depremlerin büyüklüğünü tahmin etmek için kullanılan yapay sinir ağları ile diğer sınıflandırma modelleri (Naive Bayes, K En Yakın Komşu, C4.5 Algoritması ve SVM)nin doğruluğu karşılaştırılmaktadır. Önerilen modelin doğruluğunun diğer modellerden iyi olduğunu göstermek için istatistiksel testler de yapılmıştır (Asencio-Cortés et al., 2017). Asencio-Cortés ve arkadaşları tarafından, bu veri kümesinde veri boyutluluğunu azaltmak ve yeni veri kümeleri oluşturmak için temel bileşenler analizi (PCA)nin kullanılması önerilmektedir. Bu yöntem sonucu elde edilen veriler, YSA modeline uygulanmıştır. Önerilen model farklı sınıflandırma modelleri (J48 Algoritması ve RF Algoritması) ile kıyaslanmaktadır. Aynı zamanda temel bileşen analizi uygulanmamış haliyle de yapay sinir ağı modeli ve diğer sınıflandırma modelleri kıyaslanmıştır. Temel bileşenler analizi uygulanmış yapay sinir ağının başarılı olduğu öne sürülmektedir (Asencio-Cortés et al., 2015). Bu çalışmalar dışında Asencio-Cortés ve

arkadaşları tarafından, Panakkat ve Reyes depremsellik göstergelerinin kullanılmasıyla yeni depremsellik göstergeleri türetilmiştir. Böylelikle parametrelerin sayısı oldukça artmaktadır. Uygun parametreler ile deprem tahmini yapmak için farklı konfigürasyonlar ile duyarlılık analizleri yapılmıştır (Asencio-Cortés et al., 2016). Yousefzadeh ve arkadaşları tarafından, Panakkat ve Reyes depremsellik göstergelerinin birleştirilmiş hali veri kümesi olarak kullanılmaktadır. Bilgi kazanımı tekniği ile en uygun parametreler seçilmiştir. Deprem aralıklarına göre dört farklı sınıf oluşturulmuştur. Böylelikle deprem tahmini problemi sınıflandırma problemi ile temsil edilmektedir. Model olarak, makine öğrenmesi yöntemlerinden SVM, karar ağacı (DT), sığ sinir ağı (SNN) ve derin öğrenme yöntemlerinden derin sinir ağı (DNN) kullanılmaktadır. Önerilen bu modellerin doğruluk değerleri kıyaslanmaktadır. Sonuçlar, özellikle SVM ve DNN modellerinin daha başarılı olduğunu göstermektedir (Yousefzadeh et al., 2021). Panakkat ve Reyes depremsellik göstergelerinin birleştirilmesiyle oluşturulan veri kümelerinin yanı sıra her iki veri kümesinden bazı göstergelerin alınmasıyla ve bunlara depremin özelliklerini barındıran farklı istatistiksel terimlerin eklenmesiyle oluşturulan veri kümeleri bulunmaktadır. Bu duruma örnek olarak Asim ve arkadaşları, veri kümesini oluştururken depremin belirlenmiş eşik büyüklüğüne erişen iki olay arasında geçen süreyi temsil eden T-değeri, Gutenberg-Richter yasasına dayalı olarak a-değeri ve b-değeri, b-değerinin standart sapması, Habermann'ın çalışmasına dayalı olarak depremsellik oranını değişimi z-değeri ile b-değerine dayanan olasılıksal tekraralama süresi hesaplamaktadır. Deprem tahmin problemi ikili sınıflandırma problemi olarak ele alınmıştır. Dört sınıflandırma algoritması ayrı ayrı uygulanmıştır. Bunlar karar ağacı J48, rastgele orman, rotasyon orman ve RotBoost algoritmalarıdır. Bunlar içinde rotasyon orman 0.96'lık AUC puanı ile diğer algoritmalar arasında en yüksek puana sahiptir (Asim et al., 2016b). Asim ve arkadaşları, yine bu şekilde farklı bir veri kümesi oluşturmaktadır. Maksimum uygunluk ve minimum artıklık (mRMR) kriterlerine göre özellik çıkarımı yapılmaktadır. Ardından deprem tahminlerini elde etmek için destek vektör regresörü (SVR) ve hibrit sinir ağı (HNN) tabanlı bir sınıflandırma modeli oluşturulmuştur. HNN, her katmanda ağırlık optimizasyonu yapmak için Gelişmiş Parçacık Sürü Optimizasyonu (EPSO) tarafından desteklenen üç farklı sinir ağı önerilmiştir. Önceki çalışmalara kıyasla gelişmiş sonuçlar elde edilmektedir (Asim et al.2018a). Asim ve arkadaşları bu sefer yalnızca Panakkat ve Reyes göstergelerinin bazılarını kullanarak bir veri kümesi oluşmaktadır. Önerilen model tahmin problemini

sınıflandırma problemi olarak ele almaktadır. Burada genetik programlama (GP) ve AdaBoost algoritmasını içeren hibrit bir sistem önerilmiştir. Model, depremden on beş gün önce, 5.0 ve üzeri büyüklükteki depremler için tahminler sağlamak üzere oluşturulmuştur. Farklı bölgelerin deprem kataloglarından elde edilen verilere uygulanan model en az %78'lik bir doğruluk oranı yakalamaktadır (Asim et al., 2018b). Yine bunun gibi Last ve arkadaşları, Panakktat deprensellik göstergelerinin yanı sıra istatistiksel temellere dayalı yeni deprensellik göstergelerini de hesaplayıp parametre olarak sunmaktadır. Model olarak, karar ağacı J48, J48-Adaboost ve bilgi ağları (IFN), çok amaçlı bilgi-bulanık ağ (M-IFN), K en yakın komşu (KNN), SVM, geri yayımlı sinir ağı (BPNN) ve RBF sinir ağı kullanmaktadır. Modellere ayrı ayrı olmak üzere hem tüm göstergeler hem de Panakktat göstergeleri parametre olarak verilmiştir. Tüm göstergelerin kullanıldığı durumda çok amaçlı bilgi bulanık ağ modeli 0.698 AUC puanı ile en başarılı model olduğu görülmektedir. Bu çalışmada asıl amaç, bir sonraki yıldaki maksimum deprem büyüklüğünün maksimum yıllık büyüklüklerin medyanını aşip aşmayacağını tahmin etmektir (Last et al., 2016). Öztürk ve Alkan, Van Gölü ve çevresi için güncel deprem tehlikesi ortaya koymaya çalışmış ve gelecek beş yıl içindeki depremler için tahmin yapmaya çalışmışlardır. Bu amaçla deprensellik göstergelerinden b-değeri ve Z-değerinin yanında göreceli yoğunluk ve oluşum bilgisi gibi istatistiksel analiz yapmaya yardımcı olacak verileri kullanmışlardır. 2022 yılının başlarında, düşük b-değeri ve yüksek Z-değeri olan bölgeler birleştirilerek beş yıllık süreçte yani 2022-2027 yılları arasındaki tahmin haritasında olası deprem bölgeleri tespit edilmiştir (Öztürk ve Alkan, 2022).

2.2. Depremin Sahip Olduğu Özellikler ile Deprem Büyüklüğü Tahmini

Külahcı ve arkadaşları, deprem oluşumu sırasında sekiz farklı parametrenin doğrusal olmayan değişimlerinden yola çıkarak bir YSA modeli önermektedir. Bu parametreler depremin konumu, derinliği, basıncı, topraktaki radon miktarı, yerin 5 cm'lik derinliğindeki sıcaklığı, yerin 50 cm'lik derinliğindeki sıcaklığı ve yerin 100 cm'lik derinliğindeki sıcaklığıdır. Doğu Anadolu fay hattının deprem tahmin süreci için üç katmanlı bir LMBP sinir ağı kullanılmaktadır. Sinir ağı tarafından elde edilen depremlerin büyüklükleri ile ölçülen veriler arasındaki ortalama hata yaklaşık %2.3 olarak ölçülmüştür (Külahcı et al., 2009).

Alarifi ve arkadaşları, ham veriden özellik çıkarımı yapıldıktan sonra elde edilen yeni veri kümesini, YSA modelinde kullanarak deprem tahmini yapmaktadır. Modelin

kendi parametrelerinden en uygun olanını bulabilmek için konfigürasyonlar yapılmıştır. İki gizli katmanlı bir model en iyi tahmin doğruluğunda bulunmaktadır. Ayrıca YSA modelinin doğrusal olmayan ilişkileri yakalayabilmesi sebebiyle daha önceden önerilmiş olan istatistiksel modellerden daha iyi olduğu öne sürülmektedir (Alarifi et al., 2012).

Amar ve arkadaşları, meydana gelmiş bir depremin sahip olduğu ay, gün, büyüklük ile sismik ve coğrafi bölgeselleştirme şemasından otomatik olarak oluşturulan FE reg özelliklerini barındıran bir veri kümesi kullanmaktadır. RBF sinir ağı ve BPNN modelleri karşılaştırılmaktadır. RBF sinir ağının daha başarılı sonuçlar ürettiği görülmektedir (Amar et al., 2014).

Mahmoudi ve arkadaşları, depremin sahip olduğu özelliklerden konum, derinlik, tarih, toprak tipi ve arıza mekanizmasını parametre olarak kullanmaktadır. Deprem büyüklüğünü tahmin etmek için MLP sinir ağı kullanılmaktadır. Deprem tahmini problemi, sınıflandırma problemi olarak değerlendirilerek belli aralıktaki depremler dört sınıf etiketiyle etiketlenmektedir. Model, %72 oranında bir doğruluk elde etmektedir (Mahmoudi et al., 2016).

Wang ve arkadaşları, geleneksel makine öğrenmesi yöntemlerinin, deprem olayının dinamik ve öngörülemez olduğu varsayımı ile deprem tahmin probleminde başarılı sonuçlar veremeyeceği iddia etmektedir. Parametre olarak depremin konumu, derinliği, büyüklüğü ve büyüklük türü ele alınmaktadır. Yer kabuğunun hareketi nedeniyle depremlerin oluşumunda mekânsal-zamansal bir ilişki olduğu öne sürülmektedir. Bu nedenle, belirli bir yer için deprem tahmininin, sadece o yerdeki geçmiş verilere göre değil, daha geniş bir alandaki geçmiş verilerine göre yapılması gerektiği ifade edilmektedir. Bunun için deprem tahmin problemine uygulamak üzere UKSB ağları adı verilen bir derin öğrenme modeli önerilmiştir. Deneysel sonuçlar, önerilen modelin mekânsal-zamansal ilişkiyi keşfedebildiğini ve pratikte kullanılabileceğini göstermektedir (Wang et al., 2017).

Murwantara ve arkadaşları, depremin konumu, derinliği ve büyüklüğü özelliklerine sahip, yalnızca kısa vadeli değil aynı zamanda orta ve uzun vadeli deprem geçmişi verilerini içeren bir veri kümesi kullanmaktadır. Bu veriler on ve otuz yıllık veriler şeklinde gruplanarak önerilen modellere verilmektedir. Çok terimli lojistik regresyon (MLR), SVM ve Naive Bayes (NB) makine öğrenme algoritmaları kullanılarak orta-uzun vadeli bir tahminde bulunularak performanslar

karşılaştırılmaktadır. Destek vektör makinesi modelinin daha başarılı bir performans ortaya koyduğu görülmektedir (Murwantara et al., 2020).

Kishore ve arkadaşları, geçmiş tarihli deprem verilerini kullanarak bir tahmin yapmak istemektedir. Parametre olarak depremin zamanı, konumu, büyüklüğü ve derinliği kullanılmaktadır. Model olarak UKSB ağı önerilmiştir. Bunun yanında makine öğrenmesi modellerinden FFNN modeline de aynı veri kümesi sağlanmıştır. Sonuçlar, açıkçası, UKSB modelinin FFNN modelinden R^2 skoru açısından yaklaşık %60 oranında daha başarılı tahminlerde bulunduğunu göstermektedir (Kishore et al., 2019).

Sebatlı-Sağlam ve Çavdur, FFBP ağı ile deprem büyüklüğü, derinliği ve afetzedelerin merkez üssüne olan uzaklıklarına bağlı olarak deprem şiddeti tahmini yapmıştır. Farklı ağ tasarımları ve eğitim algoritmaları ile deneyler yapılmıştır. Özellikle LMBP ve BRBP (Bayes Düzenlemesi Geri Yayılım) eğitim algoritmaları kullanıldığında başarılı sonuçlar elde edildiği ifade edilmiştir. BR algoritması ile R skoru 0.97 ve LMBP algoritması ile R skoru 0.96 olarak başarılı sonuçlar elde ettiği görülmektedir (Sebatlı-Sağlam ve Çavdur, 2022).

Budakoğlu, uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) ve coğrafi bilgi sistemi kullanarak Marmara Bölgesi için deprem büyüklüğü tahmini yapmaya çalışmıştır. Enlem, boylam, logaritmik sismik enerji ve logaritmik sismik moment bilgileri girdi olarak ele alınmış ve deprem büyüklüğü çıktı olarak belirlenerek bir USBÇS yapısı tasarlanmıştır. Deneysel süreçten sonra ızgara bölümlleme yöntemi, hibrit öğrenme algoritması ve iki üyelik fonksiyonu ile tasarlanan USBÇS yapısının R^2 skoru açısından 0.99 ile başarılı bir netice ortaya koyduğu görülmektedir (Budakoğlu, 2022).

2.3. Diğer Yaklaşımlar ile Deprem Büyüklüğü Tahmini

Alexandridis ve arkadaşları, iki sismik olay arasındaki süre ve belirlenen eşik değeri üstüne çıkan bu iki sismik olayın arasında kalan sismik olaylar için çıkarılan deprensellik oranını parametre olarak kullanmaktadır. Bu çalışma, RBF sinir ağına dayalı olarak büyük deprem olayı oluşumunun tahmini için bir model sunmaktadır. Özellik seçimi ve ağı eğitimi için kullanılan tekniklerden sonra RBF sinir ağına başarılı netice aldığı görülmektedir. Bunun kıyaslaması MLP ile yapılmaktadır ve RBF'in başarısı ortaya konulmaktadır (Alexandridis et al., 2014).

Huang ve arkadaşları, tarihsel sismik olayları kullanarak deprem tahmini için bir derin öğrenme yöntemi önermektedir. Bu sismik olaylar bir harita üzerine yansıtılıp, otuz gün içinde büyüklüğü 6'ya eşit veya 6'dan büyük olan depremler '1' etiketiyle, küçük olan depremler '0' etiketiyle etiketlenmektedir. Elde edilen görüntüler ile veri kümesi oluşturulmaktadır. Önceden eğitilmiş modellerden olan CIFAR10 modeli kullanılarak tahminler yapılmıştır. R skoru olarak 0.303 elde edilmiştir (Huang et al., 2018).

González ve arkadaşları tarafından, yaklaşık yirmi yıllık deprem verisinde tek özellik deprem büyüklüğü, zaman serisi olarak ele alınmıştır. Bir saatlik periyotlar halinde en büyük büyüklüğe sahip depremler çerçevelenmektedir. Saatlik periyotlarda büyüklük değeri sıfır olan depremler, en son hangi büyüklük geldiyse onunla eşitlenmektedir. Böylelikle sıfır büyüklüğündeki depremlerin problemi zorlaştırmasının önüne geçilmiş olur. Model olarak, UKSB ağı, çıktı katmanında da klasik sinir ağı kullanılmaktadır. Önerilen modelin tahmin konusunda yeterince başarılı olduğu öne sürülmektedir (González et al., 2019).

Jena ve arkadaşları tarafından, sismik verilerden oluşan deprem kataloğu kullanılarak kartogram ve korokromatik haritalar oluşturulmuştur. Bu görseller evrimsel sinir ağları (CNN) modelinde kullanılmaktadır. Modelin eğitim ve test veri kümelerine dayalı doğruluk değerleri sırasıyla %96 ve %92 olarak ölçülmüştür. Bu da gösteriyor ki önerilen model gayet başarılı sonuçlar üretmektedir (Jena et al., 2020).

3. MATERYAL VE YÖNTEM

3.1. Depremsellik Göstergeleri

Depremsellik parametrelerinin incelenmesi, deprem mekanizmasının daha iyi anlaşılmasını kolaylaştırabilir ve tahmin problemine katkı sağlayabilir. Çoğu durumda, depremsellik parametrelerindeki çeşitlilik, deprem oluşumu ile ilişkilendirilebilir ve gelecekteki güçlü sarsıntılar için bir uyarıcı olarak kabul edilebilir. Bu sebeple, depremlerden öncü uyarıların değişimine dayanan depremsellik göstergeleri, son zamanlarda popüler bir çalışma alanıdır.

Bu depremsellik parametreleri, matematiksel olarak hesaplanır ve iyi bilinen jeofizik ve sismolojik gerçeklere dayanır. Deprem tahmin çalışmaları için literatürde önerilen farklı jeofizik ve sismik parametreler vardır (Panakkat and Adeli, 2007) (Reyes et al., 2013) (Zamani et al., 2013). Göstergelerin bazıları birden fazla yaklaşımla hesaplanabilirken, değişken bir parametreye bağlı olan göstergeler de vardır. Her bölge farklı jeolojik özelliklere sahip olabilir. Dolayısıyla, bir bölge için iyi performans gösteren bir dizi gösterge, diğer bölgeler için benzer performansı gösteremeyebilir.

3.1.1. Panakkat Depremsellik Göstergeleri

Bir bölgenin depremsellik potansiyelini değerlendirmek amacıyla Panakkat ve Adeli tarafından depremsellik göstergeleri olarak adlandırılan matematiksel olarak tanımlanmış sekiz depremsellik parametresi önerilmiştir. Bu göstergeler bir bölge için deprem büyüklüğünün kayıtları ve mevcut verilerin periyodu kullanılarak elde edilmektedir (Panakkat and Adeli, 2007). Bölgenin iç jeolojik durumunu temsil eden öznitelik vektörü sekiz parametreden oluşmakta olup parametreler Gutenberg-Richter yasasının sismik gerçeklerinden, sismik enerji salınımından, depremlerin tekrarlama zamanlarından ve ön şok sıklığından elde edilir.

Elde edilen bu sekiz depremsellik göstergesinin üç tanesi deprem büyüklüğünün zamansal dağılımından bağımsızdır, üç tanesi Gutenberg-Richter ters güç yasası zamansal büyüklük dağılımına ve 2 tanesi karakteristik zamansal deprem büyüklük dağılımına dayanmaktadır.

3.1.1.1. T Değeri

T değeri, büyüklük için seçilen eşik değerine bağlı olarak, öncü depremlerin

sıklığının bir ölçüsüdür. Eşitlik 3.1'de verilen T değeri T_n , n 'inci olayın meydana gelme zamanı ve T_1 , 1'inci olayın meydana gelme zamanı olmak üzere önceden tanımlanmış bir eşik değerinden daha büyük değerdeki son n sayıda olay üzerinden geçen süre olarak tanımlanmaktadır.

$$T = T_n - T_1 \quad (3.1)$$

Küçük bir T değeri, yaklaşan büyük bir sismik olayın meydana gelme olasılığının yüksek olduğunu gösterirken, büyük bir T değeri, yaklaşmakta olan büyük bir sismik olayın meydana gelme olasılığının düşük olduğunu gösterir.

3.1.1.2. Ortalama Büyüklük

Eşitlik 3.2 ile verilen ortalama büyüklük son n tane olayın büyüklüklerinin aritmetik ortalaması biçiminde tanımlanmaktadır.

$$M_{ortalama} = \frac{\sum_i M_i}{n} \quad (3.2)$$

3.1.1.3. Salınan Sismik Enerjinin Karekök Oranı

Sismik enerji her faydan düzenli olarak küçük sismik olaylar biçiminde salınır. Bu enerji salınımı çok uzun süre gerçekleşmezse fayda enerji birikimi oluşur ve bu duruma sismik durgunluk denir. Fayda biriken enerji büyük bir deprem olarak ortaya çıkabilir. Bu durum, aynı zamanda değerli bir sismik öncü olarak kabul edilir (Asim et al., 2017). Eşitlik 3.4'te verilmiş olan Richter büyüklüğünden hesaplanan erg birimindeki enerji(E) kullanılarak T zaman içinde salınan sismik enerjinin karekök oranı Eşitlik 3.3 ile hesaplanmaktadır.

$$dE^{1/2} = \frac{\sum E^{1/2}}{T} \quad (3.3)$$

$$E = 10^{(11.8+1.5M)} \quad (3.4)$$

3.1.1.4. b -değeri

Depremsellik göstergesi olarak kullanılan b -değeri bir bölgedeki depremlerin büyüklüklerinin istatistiksel dağılımını tanımlayan Gutenberg-Richter ters güç

yasasına dayanmaktadır. b -değeri, deprem frekansı-büyüklik eğrisinin logaritmasının eğimi olarak tanımlanmakta olup bir bölgenin tektonik özelliklerini temsil eder (Narayanakumar and Raja,2016). Önemli bir sismik özellik olarak kabul edilen b -değeri deprem tahmini için ve bölgenin sismik çözümlemesi için çok sayıda araştırmacı tarafından kullanılmaktadır.

$$\log_{10} N = a - bM \quad (3.5)$$

Eşitlik 3.5'te N bir bölgedeki belirli bir zaman aralığında gerçekleşen deprem sayısı, M ise o bölgedeki depremlerin büyüklüğü olarak tanımlanmaktadır. a -değeri ise bir katsayı olup o bölgenin genel depremelliğini ifade eder.

a ve b değerleri, M_i , i . olayın büyüklüğü, N_i , büyüklüğü M_i veya daha büyük olan olayların sayısı, n , sismik olayların toplam sayısı olmak üzere doğrusal en küçük kareler regresyon analizi kullanılarak Eşitlik 3.6 ve Eşitlik 3.7'deki gibi hesaplanmaktadır.

$$b = \frac{(n \cdot \sum_i (M_i \cdot \log N_i)) - (\sum_i M_i \cdot \sum_i \log N_i)}{((\sum_i M_i)^2 - (n \cdot \sum_i M_i^2))} \quad (3.6)$$

$$a = \frac{\sum_i (\log N_i + bM_i)}{n} \quad (3.7)$$

a ve b değerleri, $ort(M)$ verilen örneğin ortalama büyüklüğü ve $min(M)$ minimum büyüklüğü olmak üzere Eşitlik 3.8 ve Eşitlik 3.9 ile verilen doğrusal maksimum olabilirlik yöntemi kullanılarak da hesaplanmaktadır.

$$b = \frac{\log e}{ort(M) - min(M)} \quad (3.8)$$

$$a = \log N + b \cdot \min(M) \quad (3.9)$$

3.1.1.5. η -değeri

Bu parametre Gutenberg-Richter ters güç yasasına dayalı regresyon doğrusundan hesaplanan sapmaların karelerinin toplamını ifade eder ve bu regresyon doğrusuna ne kadar iyi uyduğunu ölçmek için kullanılır. Bu parametre ne kadar yüksekse o bölgede daha sık ve büyük depremlerin meydana gelme olasılığı yüksektir

denilebilir. Bu parametre Eşitlik 3.10 ile hesaplanmaktadır. η -değeri düşükse bu durum deprem büyüklüklerinin sıklığının ters güç yasası kullanılarak iyi bir şekilde tahmin edilebileceği anlamına gelir. Eğer η -değeri yüksekse daha yüksek rastgeleliğe karşılık gelir ve deprem büyüklükleri ile sıklıkları arasında ters güç yasasının kullanılması uygun değildir.

$$\eta = \frac{\sum_i (\log N_i - (a - bM_i))^2}{(n - 1)} \quad (3.10)$$

3.1.1.6. Büyüklük Açıklığı

Eşitlik 3.11 ile verilen büyüklük açıklığı Gutenberg-Richter ilişkisine dayalı olarak gözlenen en büyüklük ile beklenen en büyük büyüklük arasındaki fark olarak tanımlanmaktadır.

$$\Delta M = M_{max,gözlenen} - M_{max,beklenen} \quad (3.11)$$

Eşitlik 3.11'de $M_{max,gözlenen}$ gözlemlenen en büyük büyüklük olarak tanımlanır ve bölgedeki tarihsel depremlerin kayıtlarından elde edilen en büyük deprem büyüklüğüdür. Gutenberg-Richter ters güç yasası ilişkisine dayalı olarak o bölgede meydana gelecek en büyük deprem büyüklüğü $M_{max,beklenen}$ olarak tanımlanır. En büyük büyüklükteki bir olay muhtemelen n olay arasında yalnızca bir kez meydana gelir, bu durumda $N = 1$ 'dir ve Eşitlik 3.5'te $\log N = 0$ olduğundan $M_{max,beklenen} = a / b$ biçiminde tanımlanır.

3.1.1.7. μ -değeri

Karakteristik veya tipik olaylar arasındaki ortalama süre olarak tanımlanmakta olup büyük depremlerin daha çok sabit aralıklarla meydana geldiği bir zaman dilimini ifade eder. Bu parametre Eşitlik 3.12'de verilmiştir ve $t_{i,karakteristik}$, M_i büyüklüğündeki karakteristik olaylar arasında gözlemlenen geçen süredir, $n_{karakteristik}$, karakteristik olayların toplam sayısıdır.

$$\mu = \frac{\sum_i t_{i,karakteristik}}{n_{karakteristik}} \quad (3.12)$$

3.1.1.8. c-değeri

Karakteristik olaylar arasındaki ortalama zamanın değişim katsayısı olarak tanımlanan bu parametre, sismik bölgedeki büyüklük dağılımının karakteristik dağılıma yakınlığının bir ölçüsü olarak tanımlanır ve Eşitlik 3.13 ile hesaplanır. σ_t , gözlemlenen zamanın standart sapması ve μ karakteristik olaylar arasındaki ortalama süredir.

$$c = \frac{\sigma_t}{\mu} \quad (3.13)$$

3.1.2. Reyes Depremsellik Göstergeleri

Reyes ve arkadaşları, girdi parametreleri olarak, deprem oluşumuyla ilişkili bilgilere dayanan daha önce hiç kullanılmamış depremsellik göstergeleri kombinasyonu sunmaktadır. Bu göstergeler hesaplanırken, Gutenberg-Richter yasası, Gutenberg-Richter yasasının sismik habercisi b -değeri, artçı sarsıntılarının sıklığı, Omori-Utsu yasası ve Bath yasası kullanılmaktadır (Reyes et al., 2013).

3.1.2.1. Gutenberg-Richter Yasası

Depremlerin büyüklük-frekans dağılımı için Gutenberg-Richter ters güç yasası ile ifade edilen ilişki, Eşitlik 3.5'te bahsedildiği gibi a -değeri ve b -değeri hakkında bilgi vermektedir.

b -değeri, incelenen alanın tektoniğini yansıtan ve alanın fiziksel özellikleri ile ilgili olan bir parametredir. b -değerinin yüksek bir değeri, küçük büyüklükteki depremlerin sayısının daha fazla olduğunu ve dolayısıyla bölgenin düşük bir dirence sahip olduğunu gösterir. Aksine, b -değerinin düşük bir değeri, göreceli küçük ve büyük olayların sayısı arasında daha küçük bir fark gösterir ve bu da malzemenin daha yüksek bir direnci olduğu anlamına gelir (Reyes et al., 2013).

Reyes, b -değerini maksimum olabilirlik yöntemine göre hesaplamaktadır. Deprem kayıtlarında birkaç büyük depremin bile olmasının sonucu önemli ölçüde etkilemesini gerekçe göstererek alternatif olarak bu yöntemi kullanmaktadır.

b -değeri ile ilgili bilim insanları arasında anlaşmazlıklar vardır. Kimileri evrensel ve sabit olması gerektiğini ileri sürmektedir. Kimileri de varyasyonlarının olduğunu belirtmektedir. Büyük bölgeler için ve uzun süreler için $b \approx 1$ olduğu

doğrudur. Ancak, sınırlı bölgelerde ve kısa süreler için önemli farklılıklar gözlemlenmektedir (Reyes et al., 2013).

3.1.2.2. Omori-Utsu Yasası

Artçı şokların zamanla oranı, artçı şok frekansının kabaca ana şoktan sonraki zamanın tersi kadar azaldığı Omori yasası Eşitlik 3.14'te verilmektedir.

$$N(t) = \frac{k}{(c + t)} \quad (3.14)$$

Burada, N artçı şokların oluşma oranını, t ana şoktan beri geçen süreyi, k genliği ve c değeri tipik olarak bir günden çok daha az bir sabit olan zaman ofset parametresini göstermektedir.

Omori yasasının Omori-Utsu yasası olarak bilinen değiştirilmiş hali, Utsu tarafından önerilmiştir ve Eşitlik 3.15'te verilmiştir.

$$N(t) = \frac{k}{(c + t)^p} \quad (3.15)$$

Burada, p değeri, bozulma oranını değiştiren ve tipik olarak 0.8-1.2 aralığında olan uygunluk parametresidir.

3.1.2.3. Bath Yasası

Bath yasası, bir ana şokun büyüklüğü ile en büyük artçı şokun büyüklüğü arasındaki ortalama farkın, ana şokun büyüklüğünden bağımsız olduğunu belirtir.

Reyes'in depremsellik göstergelerini temsil edecek öznitelik vektörü, Gutenberg-Richter yasası, Omori-Utsu yasası ve Bath yasasına dayalı olarak Eşitlik 3.16'da ifade edilmektedir.

$$b_i = \frac{\log e}{\left(\frac{1}{n}\right) \cdot \sum_{j=0}^n M_{i-j} - M_0} \quad (3.16)$$

Burada; M_i , i . depremin büyüklüğü, n , kaydedilen son olayların sayısı ve M_0 referans büyüklüğüdür.

Ardından, i 'nin artışları hesaplanır:

$$\begin{aligned}
\Delta b_{1i} &= b_i - b_{i-4} \equiv x_{1i} \\
\Delta b_{2i} &= b_{i-4} - b_{i-8} \equiv x_{2i} \\
\Delta b_{3i} &= b_{i-8} - b_{i-12} \equiv x_{3i} \\
\Delta b_{4i} &= b_{i-12} - b_{i-16} \equiv x_{4i} \\
\Delta b_{5i} &= b_{i-16} - b_{i-20} \equiv x_{5i}
\end{aligned} \tag{3.17}$$

Eşitlik 3.17’de verilen denklemlerden x_i değerlerini hesaplamak için en az $n + 20$ kadar deprem kaydının olması gerektiğine dikkat edilmelidir.

Altıncı girdi değişkeni x_{6i} , analiz edilen alanda geçen sürede kaydedilen depremlerden elde edilen maksimum büyüklüktür ve Eşitlik 3.18’de verilmiştir.

$$x_{6i} = \max\{M_s\}, \quad t \in [-p, 0) \tag{3.18}$$

Burada, t zamanı gün olarak ölçülür, p , geçen süreyi tarif eder ve M_s büyüklüktür.

Son girdi değişkeni x_{7i} , büyüklüğü belirlenen eşik büyüklüğüne eşit veya daha büyük bir deprem kaydetme olasılığını tanımlar. Bu bilgilerin girdi olarak eklenmesi, Gutenberg-Richter yasasını dinamik olarak dahil etmektir. Olasılık yoğunluk fonksiyonundan Eşitlik 3.19’daki şekilde hesaplanır.

$$x_{7i} = P(M_s \geq M_t) = e^{-3b_i / \log e} = 10^{-3b_i} \tag{3.19}$$

Burada; M_t eşik büyüklüğüdür ve M_s büyüklüktür.

Son olarak, belirlenen sonraki günler içinde analiz edilmek üzere maksimum M_s büyüklüğü olan bir çıktı değişkeni y_i vardır ve Eşitlik 3.20’de ifade edilmektedir.

$$y_i = \max\{M_s\}, t \in (0, f] \tag{3.20}$$

Burada; t zamanı gün olarak ölçülür, f gelecek süreyi tarif eder ve M_s büyüklüktür.

3.2. Yapay Zekâ

1950'li yıllarda Alan Turing'in "Makineler düşünebilir mi?" sorusuyla başlayan, 1956 yılında John McCarthy tarafından terim olarak ismi de konulan yapay zekâ kavramı, 1959 yılında Marvin Minsky tarafından kurulan ilk yapay zekâ laboratuvarı ile üzerine oldukça çaba harcanan bir konu olmuştur. Başlangıcı 20. yüzyılın ortalarına uzanan yapay zekâ kavramına yönelik çalışmalar, günümüzde katma değerli olarak ilerlemektedir.

Yapay zekâ kavramının herkes tarafından kabul edilmiş bir tanımı yoktur ancak yapılan tanımlar ortak bir paydayı işaret etmektedir. Bu kavramı terim olarak ilk kez ortaya atan McCarthy "Akıllı makineler, özellikle akıllı bilgisayar programları yapma bilimi ve mühendisliğidir." şeklinde bir tanım yapmıştır. Öncülerden olan Marvin Minsky'e göre yapay zekâ "İnsanlar tarafından yapılabilen ve zekâ gerektiren şeyleri makinelere yaptırma bilimidir." Bu tanımlar yapay zekâ kavramının ilk olarak ortaya atıldığı dönemdeki tanımlardır. Günümüze geldikçe gelişmelerin de etkisiyle daha kapsamlı ve detaylı tanımlar ortaya çıkmıştır. Genel olarak yapay zekâ, insan gibi akıllı ile karar alabilen, bilgisayar tabanlı cihazlara dayanan bir bilgisayar bilimi alanıdır (Keisner et al., 2015). Yapay zekâ, oluşturulan bir sistemin aldığı verileri doğru olarak yeniden yorumlaması, bu verileri kullanarak öğrenmesi ve esnek bir şekilde uyarlanarak belirlenen görev ve hedeflere ulaşabilmek için bu yeteneğini kullanabilmesidir (Kaplan and Haenlein, 2019). İnsanın anlama kabiliyetinin ve zekasının taklit edilerek çözümleme, anlamlandırma, tecrübe edinerek öğrenme gibi yeteneklerin bilgisayar sistemlerinde modellenmesi ile yapay zekâ oluşmaktadır. (Yılmaz, 2019). Kısacası yapay zekâ, bilgisayarların canlılara özgü hatta insanlar özelinde problem çözme ve öğrenme gibi becerileri taklit etmesidir.

Yalnızca bilgisayar bilimlerinin bir uzantısı gibi görünen yapay zekâ uygulamaları, teknolojinin her geçen gün hızla gelişmesi ve tüm endüstriler tarafından daha kolay erişilebilmesiyle aslında bilişsel bilimler, biyoloji, elektronik, finans, üretim, sağlık hizmetleri gibi disiplinlere dokunan günümüz insanlığını birçok alanda etkileyen uygulamalardır. Bahsedilen bu disiplinler yapar sinir ağları, görüntü işleme, doğal dil işleme, makine öğrenmesi, uzman sistemler, genetik algoritmalar ve bulanık mantık gibi yapay zekânın alt dallarında kullanılmaktadır.



Şekil 3.1. Yapay zeka ve alt kümeleri

3.3. Makine Öğrenmesi

Makine öğrenmesinin kavramı, ilk olarak Arthur Samuel tarafından 1959 yılında tanıtılmıştır. Samuel, “Bilgisayarların doğrudan programlanmadığı durumlarda kendiliğinden öğrenmeyi gerçekleştirebilen bir çalışma alanıdır.” şeklinde bir tanım yapmıştır. Yapay zekâ ile makine öğrenmesi genelde karıştırılarak birbirlerinin yerine kullanılan kavramlardır. Makine öğrenmesi, yapay zekâ sisteminin öğrenilmesi amacına hizmet eden bir yapıdır. Bu tanım, makine öğrenmesinin verileri analiz edip değerlendirerek, veriler üzerinde tahminler yapabilen yapıların oluşturulması ve incelenmesi böylelikle problemlere çözüm bulabilmesi ve bu çözümlerin uygulanması şeklinde daha açık ifade edilebilir. Başka bir tanımla, karşılaşılan bir problem için gerekli olan çözüm adımlarını bilgisayara önceden vermek yerine, bilgisayarın ne yapacağını öğrenmesini sağlayan yöntemlere makine öğrenmesi denilmektedir. Makine öğrenmesi, belirli kurallara göre işleyen değil, öğrenmek için tasarlanan bir yapıdır. Belirli kurallara göre işleyen yapılar sadece aktarılanı yapabilirken makine öğrenmesiyle sürekli öğrenme sağlanır. Mitchell, “Eğer bir bilgisayar programının G görevlerinde P ile ölçülen performansı, deneyim D ile artıyorsa, o bilgisayar programının bazı G görevlerinin sınıflarına ve performans ölçüsü P’ye göre deneyim D’den öğrendiği söylenmektedir.” şeklindeki tanımıyla önceki tecrübelerden öğrenme konusunun makine öğrenmesinin temeli olduğundan bahsetmektedir (Mitchell, 1997). Makine öğrenmesi, mantıksal işlemler gerçekleştirebilen makinelerin, gözlem ve ölçüm yöntemleriyle elde ettiği verileri deneyim olarak kabul etmesi ve bu

deneyimlerden matematiksel aracılığıyla anlamlı ilişkiler üretmesi süreci olarak da tanımlanabilir. Makine öğrenmesinde veri kümeleri geçmiş deneyimlere karşılık gelmektedir, öğrenme algoritmalarıyla veriler arasındaki ilişkilerden çözülmesi istenen probleme uygun bir model oluşturulur ve problemlerin çözümü için modele başvurulur sonuçlar üretilir. Makine öğrenmesi en kısa anlatımla bilgisayarların olayları öğrenmesini sağlayan teknolojidir (Öztemel, 2003).

Yapay zekâ sisteminin öğrenilmesi için bir teknik olarak tanıtılan makine öğrenmesi, günümüzde hastalık teşhisi, görüntü işleme, nesnelerin interneti, doğal dil işleme gibi insanlık faydasına birçok alanda sınıflandırma, regresyon, kümeleme problemlerinde kullanılmaktadır.

Öğrenme paradigmalarının gelişmesiyle zaman içinde makine öğrenmesi, denetimli öğrenme ve denetimsiz öğrenme olarak iki farklı paradigma üzerine yayıldı. Denetimli öğrenmede neyin öğrenilmesi gerektiği ve nasıl öğrenileceği konusundaki talimatlar en başta açık bir şekilde ortaya konulmaktadır. Denetimli öğrenme, önceden gözlemlenmiş ve sonuçları bilinen yani etiketlenmiş verilerin kullanılarak, bu verileri ve sonuçlarını kapsayan modelin ortaya konulma sürecidir. Model oluşturulurken veri kümesi, eğitim ve test veri kümesi olarak ikiye ayrılır. Eğitim veri kümesi ile eğitilen model, test veri kümesi ile sınanır. Eğitim verileriyle yapılan eğitim süreci içerisinde öğrenme işlemi optimize edilerek tahmin edilen çıktılarının doğruluğu artırılmaya çalışılmaktadır. Denetimli öğrenme modelleri, veri kümelerindeki özniteliklere ait girdi değerleri ile hedef değişkene ait öznitelikler arasındaki ilişkiyi bulmaya çalışır. Denetimli öğrenme algoritması türleri arasında sınıflandırma ve regresyon bulunur. Denetimsiz öğrenme, verilerin etiketlenmeden kullanıldığı öğrenme modellerinin oluşturulma sürecidir. Veri kümesindeki benzerlikleri göz önüne alarak, veriler arasındaki ilişkiyi ortaya çıkarıp, veriyi gruplandırarak öğrenme işlemini tamamlar. Bu noktadan yola çıkarak denetimsiz öğrenmede gözleme dayalı bir öğrenme tekniğinden bahsetmek mümkündür. Denetimsiz öğrenmede etiketlenmemiş veriler kullanıldığı için daha önce bilinmeyen kalıpların ve desenlerin bulunması sağlanmaktadır. Bu sayede veriler, anlamlı veri kümelerine dönüştürülmektedir. Denetimsiz öğrenme algoritması türleri arasında kümeleme, ilişkilendirme ve boyut azaltma algoritmaları bulunur. Bu iki öğrenme paradigmasının yanı sıra yarı denetimli öğrenme olarak adlandırılan bir paradigma da vardır. Denetimli ve denetimsiz öğrenme algoritmalarının özellikleri bir arada kullanılmaktadır. Bu durumda hem

etiketli hem de etiketsiz veriler kullanılır ve etiketsiz verilerin sayıca fazla olduğu durumlarda öğrenme başarısının daha fazla olduğu gözlenmektedir.

3.4. Yapay Sinir Ağları

Yapay sinir ağları, ilk olarak McCulloch ve Pitts tarafından 1943 yılında tanıtılmıştır. Yapay sinir ağları, biyolojik sinir ağlarının yapısını dolayısıyla insan beyninin yapısını taklit eden, bilgiyi işlemesi yeteneğini örnek alarak, örneklerden öğrenerek insan beyninin işlevselliğini simüle eden ve problemleri çözmek için birbirine bağlı fazla sayıda bağlantı noktası barındıran matematiksel modellerdir (Maind and Wankar, 2014). Başka bir deyişle, yapay sinir ağları, beyindeki öğrenmeyi sağlayan sinir hücrelerinden ilham alınarak matematiksel olarak geliştirilmiştir, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel ve dağıtılmış bilgi işleme yapılarıdır (Öztemel, 2003). Yapay sinir ağları, özellikle doğrusal olmayan problemler için ortaya koyduğu çözümler ile verdiği başarılı çıktılar sayesinde kullanım alanı ve yaygınlığını artırmıştır. Bilgisayarlar da insanlar gibi öğrenme, ilişkilendirme, genelleme, tahminde bulunma, sınıflandırma gibi işlevleri sağlamak için kullanılmaktadır.

Yapay sinir ağları, sinir sisteminde olduğu gibi birbirine bağlı basit işlem elemanı olan yapay sinir hücrelerinden yani nöronlardan oluşmaktadır. Çok sayıda nörondan oluşan bu ağlarda her nöron başka nöronlara bağlı ve bu bağlantı ile sinyal alışverişi gerçekleşmektedir. Birbirlerine belli ağırlıklarla bağlı olan nöronlar, veri kümesinden gelen bilgileri toplam fonksiyonu ile elde edip, aktivasyon fonksiyonu ile çıktıyı üretmekte ve bağlantılarıyla da diğer nöronlara iletmektedir. Birbirlerine paralel olan katmanlarda; girdi katmanında giren bilgi, ara katmanda işlenip çıktı katmanına ulaşmaktadır. Doğru çıktıya ulaşabilmek için girdilere uygun ağırlık değeri verilmesi gerekmektedir. Tarif edildiği gibi yapay sinir ağları genel yapısıyla girdiler, ağırlıklar, toplam fonksiyonu, aktivasyon fonksiyonu ve çıktı bölümlerinden oluşur.

Girdi, ağın öğrenmesi için kullanılacak veri kümesi elemanıdır. Ağ yapısında ilk katmanda veri kümesinden ham bilgiler olarak kullanılırken sonraki katmanlar için girdi, önceki katmanın çıktısı olacak şekilde kullanılır.

Ağırlık, girdi katmanındaki nörona gönderilen girdilerin sonraki katman üzerindeki etkisinin ayarlanabildiği değerdir. Girdi katmanında keyfi olarak verilen ağırlık değeri, eğitim aşamasında öğrenmenin sağlanması adına çıktının durumuna

göre güncellenmektedir.

Toplam fonksiyonu, önceki nöronlardan girdilerin ağırlıklarla çarpılarak gelen değerleri birleştirme işlemini gerçekleştirmektedir. Bu işlem sonunda ilgili hücrenin net girdisi hesaplanmış olur.

Aktivasyon fonksiyonu, sinir hücresinde hesaplanan toplam net girdi değerini bir aktivasyon işleminden geçirerek bir çıktı değeri üretmektedir. Aktivasyon fonksiyonu, doğrusal olmayan ve kolay türevlenebilir bir fonksiyon olarak seçilmelidir. Aktivasyon fonksiyonu, problemin çözümü ve ağın performansı açısından önemlidir. Doğrusal, sigmoid, tanh, ReLU, sızıntı ReLU, softmax gibi birçok aktivasyon fonksiyonu vardır.


Çıktı, toplam net girdilerinin aktivasyon fonksiyonu vasıtasıyla geçtiği aktivasyon işleminin ürettiği çıktı değeridir.

Ayrıca, bir düğümün yerel noktalara takılıp yanlış sonuç üretmesini önlemek için girdilerle birlikte toplam fonksiyonuna verilen bias değeri de yapay sinir ağına kullanılmaktadır.

Yapay sinir ağları katman yapısı olarak üç ana katmandan oluşur. Bunlar girdi katmanı, gizli(ara) katman(lar), çıktı katmanıdır. Girdi katmanı, veri kümesinde bulunan bilgileri gizli katmana gönderen katmandır. Gizli katman, kendisine girdi katmanından gelen bilgiler üzerinde işlemler gerçekleştirdikten sonra çıktı katmanına iletir. Çıktı katmanı da sonuç bilgisini göstermektedir. Sinir ağı eğitiminde amaç, çıktıları, verilen girdilerle ilişkilendirerek girdiler ile karşılık gelen çıktılar arasında var olan modeli veya ilişkiyi öğrenmektir.


Katmanların değişik şekilde birbirleriyle bağlanmaları ve bağlantı şekillerine göre değişik ağ mimarileri ortaya çıkmaktadır. Yapay sinir ağı modelleri katman sayısına göre tek katmanlı algılayıcılar, çok katmanlı algılayıcılar ve bağlantı yapısına göre ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olarak gruplandırılabilir.

Tek katmanlı sinir ağları ya da diğer adıyla algılayıcı (perceptron)lar, sadece girdi ve çıktı katmanından oluşmaktadır. Doğrusal olmayan problemlerde tercih edilmemektedir. Tek katmanlı algılayıcılarda kullanılan aktivasyon fonksiyonu doğrusaldır. Bu sebeple basit ikili sınıflandırma problemlerinde kullanılabilir. Eğer çıktı 1 ise ilk sınıfa, çıktı -1 ise diğer sınıfa kabul edilmektedir (Öztemel, 2003).



Şekil 3.2. Tek katmanlı algılayıcı


Çok katmanlı sinir ağları ya da diğer adıyla çok katmanlı algılayıcı (multi-layer perceptron, MLP)lar, birden fazla katmandan oluşmaktadır. Çok katmanlı sinir ağları yapısında bir girdi katmanı, probleme göre gizli(ara) katman(lar) ve bir çıktı katmanı içermektedir. Tek katmanlı sinir ağlarının aksine doğrusal olmayan problemlerde kullanılmaktadır. Bunun sebebi kullanılan aktivasyon fonksiyonlarının doğrusal olmamasıdır. Böylelikle daha karmaşık olan problemlere çözümler getirmektedir.



Şekil 3.3. Çok katmanlı algılayıcı


İleri beslemeli ağlar, tek yönlü bilgi akışına sahip ağlardır. Başka bir deyişle, ileri beslemeli ağlar döngüsel olmayan, tekrarlamayan ağlardır. İleri beslemeli yapay sinir ağların ilerleyiş girdi katmanından çıktı katmanına doğru düzenli şekildedir. Bir

katmandan sadece kendinden sonraki katmana aktarım yapılmaktadır. İleri beslemeli sinir ağları genelde örüntü tanımda yaygın olarak kullanılmaktadır.



Şekil 3.4. İleri beslemeli ağ

Geri beslemeli ağlar, bilgi akışının nöronun kendisinin bulunduğu katmana veya kendisinden önceki katmana da yönünün olduğu ağlardır. Bir başka deyişle geri beslemeli ağlar döngüsel, tekrarlayan ağlardır. Bu yapı ile geri beslemeli ağlar doğrusal olmayan, dinamik bir davranış göstermektedir. Genellikle zaman serilerinde ve sıralı (sekans) görevlerde kullanılırlar.



Şekil 3.5. Geri beslemeli ağ

3.4.1. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları, bir sinir ağında girdilerin ve bias değerlerinin ağırlıklı toplamalarını hesaplamak için kullanılan fonksiyonlardır. Bu şekilde bir sinir ağı hücresinin etkinleştirilip etkinleştirilmeyeceğine karar verilmektedir. Modele uygun aktivasyon fonksiyonları seçilirken, optimizasyon amacıyla ağırlıklara göre monoton, türevlenebilir ve hızlı bir şekilde yakınsayan olmalı kriterleri dikkate alınmalıdır. Çok

fazla parametrelili derin sinir ağılarında aktivasyon fonksiyonları kullanılmadığında girdiler doğrusal olarak ilerler ve bu durumda veri kümesinde bulunan ayırt edici özelliklere ulaşmayı kısıtlar.

3.4.1.1. Doğrusal Fonksiyon

Doğrusal aktivasyon fonksiyonu, girdi değerlerinin değiştirmeden çıktı olarak veren aktivasyon fonksiyonudur. Diğer bir deyişle aktivasyon, girişle orantılıdır. Doğrusal aktivasyon fonksiyonunun türevi bir sabit olduğundan ve x girişiyle ilişkisi olmadığı için geri yayılımı kullanmak mümkün değildir. Fonksiyon aralığı $[-\infty, +\infty]$ şeklinde ifade edilir ve Eşitlik 3.21’de verilmiştir.

$$f(x) = x \quad (3.21)$$

3.4.1.2. Sigmoid Fonksiyonu

Eşitlik 3.22’de verilen sigmoid aktivasyon fonksiyonu, girdi olarak gerçek değerleri alır ve 0-1 aralığına çeviren aktivasyon fonksiyonudur. Sigmoid aktivasyon fonksiyonu matematiksel açıdan, sınırlı, türevlenebilir, tüm gerçek girdi değerleri için tanımlanan ve her noktada negatif olmayan bir türevi olan gerçek fonksiyonlar olarak tarif edilmektedir. Girdi değeri ne kadar büyük olursa, çıktı değeri 1’e o kadar yakın olur, girdi değeri ne kadar küçük olursa, çıktı 0’a o kadar yakın olur. Olasılığın çıktı olarak tahmin edilmesi gereken problemlerde kullanılması uygun olur. Çünkü, bir olayın olasılığı 0-1 aralığında olduğu için sigmoid fonksiyonu doğru seçim olacaktır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (3.22)$$

3.4.1.3. Tanh (Hiperbolik Tanjant) Fonksiyonu

Eşitlik 3.23’te verilen tanh aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonuna benzer bir fonksiyondur. Girdi olarak aldığı gerçek değerleri (-1,1) aralığına çeviren aktivasyon fonksiyonudur. Böylelikle negatif girdilerin daha doğru bir şekilde negatif olarak da eşlenmesi ve sıfır girdilerinin de sıfıra yakın olarak eşlenmesi sağlanmaktadır. Daha farklı bir deyişle, tanh aktivasyon fonksiyonunda, girdi ne kadar büyük olursa, çıktı değeri o kadar 1’e yakın olur, girdi ne kadar küçük olursa, çıktı -1’e o kadar yakın olur.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.23)$$

3.4.1.4. ReLU Fonksiyonu

ReLU aktivasyon fonksiyonu, girdi olarak aldığı değerler arasında negatif değerler varsa 0 değerine çeviren ve pozitif değerler varsa doğrusal fonksiyonda olduğu gibi değiştirmeden çıktı olarak veren aktivasyon fonksiyonudur. Doğrusal bir fonksiyon gibi görünmesine rağmen, ReLU türevlenebilirdir ve geriye yayılımına izin verir. Yalnızca belirli sayıda nöron etkinleştirilmesine imkân verdiği için, ReLU fonksiyonu, sigmoid ve tanh fonksiyonlarıyla karşılaştırıldığında hesaplama açısından daha verimlidir. Eşitlik 3.24'te verilmiştir.

$$f(x) = \max(0, x) = \begin{cases} x, & x > 0 \\ 0, & x < 0 \end{cases} \quad (3.24)$$

3.4.1.5. Sızdıran ReLU Fonksiyonu

Eşitlik 3.25'te verilen sızdıran ReLU aktivasyon fonksiyonu, ReLU fonksiyonunun girdi olarak alınan değerler arasında negatif değerler varsa 0 değerine dönüştürmesi sebebiyle ortaya çıkan ölü ReLU problemini çözmek için kullanılan bir aktivasyon fonksiyonudur. Bu negatif girdi değerlerini 0'a değil de 0.01'e dönüştürür. Böylelikle bu değerlerin de geri yayılımına izin verir.

$$f(x) = \max(\alpha x, x) = \begin{cases} x, & x > 0 \\ \alpha x, & x < 0 \end{cases} \quad (3.25)$$

3.4.1.6. ELU Fonksiyonu

Eşitlik 3.26'da tanımlanan ELU aktivasyon fonksiyonu, negatif girdi değerlerin dönüşümü için logaritmik bir eğri kullanan ReLU fonksiyonunun bir çeşidi olan aktivasyon fonksiyonudur. Sızdıran ReLU gibi ölü ReLU problemini çözmek için kullanılır. Dahil edilen üstel işlemler nedeniyle hesaplama süresi artar.

$$f(x) = \begin{cases} x, & x > 0 \\ \alpha(e^x - 1), & x < 0 \end{cases} \quad (3.26)$$

3.4.1.7. Softmax Fonksiyonu

Softmax aktivasyon fonksiyonu, sigmoid fonksiyonunun çok sınıflı sınıflandırma problemleri için kullanılmak adına genelleştirilmiş bir versiyonu olan aktivasyon fonksiyonudur ve Eşitlik 3.27'deki şekilde tanımlanmaktadır.

$$\text{softmax}(x_i) = \frac{\exp(x_i)}{\sum_j \exp(x_j)} \quad (3.27)$$

3.4.2. Öğrenme Yöntemleri

Makine öğrenmesi ve derin öğrenmenin temel amacı, tahmin edilen çıktı değerleri ile gerçek çıktı değerleri arasındaki farkı minimum düzeye indirmektir. Bu farka maliyet fonksiyonu veya kayıp fonksiyonu denilmektedir. Optimizasyon algoritmaları, bir maliyet fonksiyonunu en aza indirmek için kullanılan algoritmalarlardır. Optimizasyon algoritmaları, modelin öğrenilebilir parametrelerine, yani ağırlıkları ve bias değerleri ile öğrenme hızı parametresine bağlı olan matematiksel fonksiyonlardır. Bu nedenle tercih edilecek optimizasyon algoritması, modelin performansı açısından oldukça önemli bir konudur.

3.4.2.1. Gradyan İniş Algoritması

Bir maliyet fonksiyonun yerel minimum değerini en aza indirmek için parametreleri yinelemeli olarak ayarlayan bir optimizasyon algoritmasıdır. Bilinen en temel optimizasyon algoritmasıdır. Sınıflandırma ve regresyon problemlerinden kullanılmaktadır. Bu yöntemin dezavantajları, tüm veri kümesi için tek bir yinelemede hesaplama yaptığı için yavaştır, büyük bellek gerektirmektedir ve hesaplama maliyetlidir. Gradyan inişinin yerel minimum yönünde attığı adımların ne kadar olduğu, ağırlıklara doğru ne kadar hızlı veya yavaş ilerlendiğini belirleyen öğrenme oranı tarafından belirlenir. Küçük bir öğrenme oranı, minimum noktaya ulaşmadan önce birçok güncelleme gerektirir yani yavaş çalışır. Büyük bir öğrenme oranı ise, farklı davranışlara yol açarak yerel minimum noktasını atlamaya sebebiyet verir.

θ maliyet fonksiyonun parametresi olmak üzere, $J(\theta)$ maliyet fonksiyonu olarak temsil edilmektedir. Buradaki amaç, θ parametresinin optimal değerini bularak maliyet fonksiyonunu minimize etmektir. Buradan gradyan inişi Eşitlik 3.28'deki biçimde hesaplanır.

$$\theta_{yeni} = \theta_{eski} - \eta \cdot \nabla_{\theta} J(\theta) \quad (3.28)$$

Burada, θ_{yeni} güncellenmiş değer, θ_{eski} eski değer, η öğrenme oranı ve $\nabla_{\theta} J(\theta)$ maliyet fonksiyonu $J(\theta)$ 'nın θ parametresine göre türevidir.

3.4.2.2. Stokastik Gradyan İniş Algoritması

Gradyan iniş algoritmasının bir türüdür. Model parametreleri daha sık güncellenmektedir. Daha az bellek gerektirmektedir. Çok büyük veri kümeleri için öğrenme ve hızlıdır, yerel minimuma takılmadan global minimuma daha rahat ulaşır. Öte yandan sık parametre güncellemesi sebebiyle fazla miktarda parametre varyansına sebebiyet verdiği için hatanın azalması yerine artmasını ortaya çıkartacak gürültülü gradyanları oluşturur. Her eğitim örneği ve etiketi için bir parametre güncellemesi gerçekleştirilmektedir. Stokastik gradyan iniş Eşitlik 3.29'daki şekilde hesaplanır.

$$\theta_{yeni} = \theta_{eski} - \eta \cdot \nabla_{\theta} J(\theta; x^i, y^i) \quad (3.29)$$

3.4.2.3. AdaGrad Algoritması

Çoğu optimizasyon algoritmasında öğrenme hızı, tüm parametreler ve yinelemeler için sabit ele alınır. AdaGrad optimizasyon algoritmasında ise öğrenme hızı, öğrenme oranına göre değişmektedir. Sık olmayan parametreler için daha büyük güncellemelere ve sık kullanılan parametreler için daha küçük güncellemelere imkân sağlamaktadır. AdaGrad, öğrenme oranını elle ayarlama ihtiyacını ortadan kaldırır.

$g_{t,i}$, t zaman adımındaki θ_i parametresine göre amaç fonksiyonunun gradyanı olmak üzere Eşitlik 3.30'daki

$$g_{t,i} = \nabla_{\theta_i} J(\theta_{t,i}) \quad (3.30)$$

Stokastik gradyan inişine göre t zaman adımındaki her θ_i parametresi Eşitlik 3.31'deki şekilde güncellenir.

$$\theta_{t+1,i} = \theta_{t,i} - \eta \cdot g_{t,i} \quad (3.31)$$

AdaGrad algoritmasına göre her t zamanında öğrenme oranı Eşitlik 3.32'deki biçimde değişmektedir.

$$\theta_{t+1,i} = \theta_{t,i} - \frac{\eta}{\sqrt{G_{t,ii}} + \epsilon} \cdot g_{t,i} \quad (3.32)$$

Burada, G_t , t zamanındaki (i, i) konumundaki köşegen matrisidir. Buradaki elemanlar θ_i 'ye göre gradyanların kareleri toplamıdır. ϵ , sıfıra bölmeyi önleyen bir terimdir ve 10^{-5} değerini alır.

Eşitlik 3.33 ile G_t ve g_t arasında eleman bazlı bir matris vektör çarpımı yapılarak vektörleştirilir ve AdaGrad formülüne ulaşılır.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{G_t} + \epsilon} \odot g_{t,i} \quad (3.33)$$

3.4.2.4. AdaDelta Algoritması

AdaDelta optimizasyon algoritması, AdaGrad algoritmasının bir uzantısıdır. AdaGrad algoritmasında bulunan öğrenme hızı azalması problemine çözüm olarak geliştirilmiştir. Bunu monoton bir şekilde öğrenme oranını düşürmeye çalışarak yapmaktadır.

AdaDelta, geçmişteki tüm kareli gradyanları toplamak yerine birikmiş (kümülatif) geçmiş gradyanların penceresini sabit w boyutuyla sınırlandırır. Böylelikle, gradyanların toplamı, geçmişteki tüm kareleri alınmış gradyanların azalan bir ortalaması olarak yinelemeli şekilde tanımlanır. t zamanındaki hareketli ortalama $E[g^2]_t$, yalnızca önceki ortalamaya ve mevcut gradyana bağlıdır ve Eşitlik 3.34'te verilmektedir.

$$E[g^2]_t = E[g^2]_{t-1} + (1 - \gamma)g_t^2 \quad (3.34)$$

Burada, γ , momentum terimi olarak kabul edilir. AdaDelta, AdaGrad'ın uzantısı olduğu için AdaGrad formülündeki G_t yerine $E[g^2]_t$ Eşitlik 3.35'te olduğu gibi yazılabilir.

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t} + \epsilon} \cdot g_t \quad (3.35)$$

Payda kısmı kök ortalama karesi (Root Mean Square – RMS) olduğu için formül Eşitlik 3.36'daki gibi yeniden yazılabilir.

$$\theta_t = - \frac{\eta}{RMS[g]_t} \cdot g_t \quad (3.36)$$

Bu güncellemelerde, parametre ile aynı varsayılan birimlerin olması gerektiği belirtilmektedir. Bu sebeple, önce üstel olarak azalan başka bir ortalama tanımlanır, bu şekilde karesi alınmış gradyanlardan değil kareli parametre güncellemelerinden oluşur ve Eşitlik 3.37’de ifade edilir.

$$E[\Delta\theta^2]_t = \gamma E[\Delta\theta^2]_{t-1} + (1 - \gamma)\Delta\theta_t^2 \quad (3.37)$$

Buradan Eşitlik 3.38’de olduğu gibi

$$RMS[\Delta\theta]_t = \sqrt{E[\Delta\theta^2]_t + \epsilon} \quad (3.38)$$

olarak elde edilir. $RMS[\Delta\theta]_t$, bilinmeyen ve önceki zaman adımlarına göre değişen olduğu için öğrenme oranı η ile yer değiştirebilir. Böylelikle, AdaDelta yönteminin formülü Eşitlik 3.39’da olduğu biçimde elde edilmiş olur.

$$\Delta\theta_t = - \frac{RMS[\Delta\theta]_t - 1}{RMS[g]_t} \cdot g_t \quad (3.39)$$

$$\theta_{t+1} = \theta_t + \Delta\theta_t$$

3.4.2.5. RMSprop Algoritması

RMSprop optimizasyon algoritması, AdaGrad algoritmasının özel bir sürümüdür. AdaGrad algoritmasındaki öğrenme hızı azalması problemine çözüm olarak önerilmiştir. Buradaki farklılık öğrenme oranının hesaplanmasıyla ortaya koyulur. AdaGrad algoritmasında karesi alınmış gradyanların kümülatif toplamı üzerinden hesaplanırken, RMSprop algoritmasında ise gradyanların üstel bir ortalaması alınarak hesaplanır. RMSprop algoritmasında öğrenme oranı otomatik olarak ayarlanmaktadır ve her parametre için farklı bir öğrenme oranı seçilmektedir.

RMSprop algoritmasının formülü yazılırken, AdaGrad algoritmasının özel bir sürümü ve AdaDelta algoritması da AdaGrad algoritmasının bir uzantısı olduğu için buradaki formüllere benzer şekilde Eşitlik 3.40 ve Eşitlik 3.41’deki şekilde yazılmaktadır.

$$E[g^2]_t = 0.9E[g^2]_{t-1} + 0.1g_t^2 \quad (3.40)$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{E[g^2]_t + \epsilon}} \cdot g_t \quad (3.41)$$

3.4.2.6. Adam Algoritması

Adam optimizasyon algoritması, popüler gradyan iniş optimizasyon algoritmalarından biridir. Her parametre için öğrenme oranlarını hesaplayan bir yöntemdir. Hem momentuma benzer şekilde geçmiş gradyanların azalan ortalamasını hem de RMSprop ve Adadelata'ya benzer şekilde geçmiş karesi alınmış gradyanların azalan ortalamasını saklar. Böylece, her iki yöntemin avantajlarını birleştirir. Kaybolan öğrenme oranı ve yüksek varyans problemlerine çözüm getirmektedir.

m_t , momentuma benzer şekilde geçmiş gradyanların üstel olarak azalan ortalaması ve v_t , geçmiş kareli gradyanların üstel olarak azalan ortalaması olarak ifade edilir ve Eşitlik 3.42'de olduğu şekilde tanımlanır.

$$\begin{aligned} m_t &= \beta_1 m_{t-1} + (1 - \beta_1) g_t \\ v_t &= \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \end{aligned} \quad (3.42)$$

m_t ve v_t sıfır vektörleri olarak başlatıldığı için ilk adımlarda ve bozulma oranları çok düşük olduğunda (bu durumda β_1 ve β_2 , 1'e yakın değerler alır) m_t ve v_t sıfıra doğru eğilimli (biaslanmış) olduğu görülmektedir. Bu eğilimliliği önlemek için eğilimliliği düzeltilmiş birinci ve ikinci moment tahminleri hesaplanır. Adam yönteminin adı da buradan gelmektedir ve Eşitlik 3.43'te verilmektedir.

$$\begin{aligned} \widetilde{m}_t &= \frac{m_t}{1 - \beta_1^t} \\ \widetilde{v}_t &= \frac{v_t}{1 - \beta_2^t} \end{aligned} \quad (3.43)$$

Varsayılan β_1 değeri 0.9, β_2 değeri 0.999 ve ϵ değeri 10^{-8} olmak üzere yöntemin formülü Eşitlik 3.44'teki gibi yazılmaktadır:

$$\theta_{t+1} = \theta_t - \frac{\eta}{\sqrt{\widetilde{v}_t + \epsilon}} \cdot \widetilde{m}_t \quad (3.44)$$

3.4.2.7. Adamax Algoritması

AdaMax optimizasyon algoritması, optimizasyon sürecini hızlandırmak için tasarlanmış olan bir algoritmadır. Gradyan iniş algoritmasının Adam versiyonunun bir uzantısıdır. AdaMax algoritması, yaklaşımı sonsuz norma yani maksimuma genelleştiren ve böylelikle bazı problemlerde daha etkili bir optimizasyonla sonuçlanabilecek sonuçlar ortaya koyan bir algoritmadır. Genellikle, optimizasyon problemlerindeki her bir parametre için ayrı bir öğrenme oranını otomatik olarak uyarlar.

Maksimuma genelleştirmeye dayanan ve Adam algoritmasının v_t faktörü ile ilişkili bir ifade olan u_t hesaplandıktan sonra Adam algoritmasının v_t faktörü yerine kullanılarak AdaMax yönteminin formülü ortaya çıkartılır ve Eşitlik 3.45 ile 3.46'da verilmektedir.

$$\begin{aligned} v_t &= \beta_2 v_{t-1} + (1 - \beta_2) |g_t|^2 \\ v_t &= \beta_2^p v_{t-1} + (1 - \beta_2^p) |g_t|^p \\ u_t &= \beta_2^\infty v_{t-1} + (1 - \beta_2^\infty) |g_t|^\infty \\ &= \max(\beta_2 v_{t-1}, |g_t|) \end{aligned} \tag{3.45}$$

$$\theta_{t+1} = \theta_t - \frac{\eta}{u_t} \cdot \widetilde{m}_t \tag{3.46}$$

3.4.3. Hiper Parametre Ayarlaması

Makine öğrenmesi ve derin öğrenme modellerinde, modelin belirli bir görev veya veri kümesi için özelleştirilmesine izin veren seçimlere veya konfigürasyon noktalarına hiper parametre denir. Hiper parametreler öğrenme sürecini yönlendirmeye yardımcı olabilmek için manuel olarak ayarlanır. Genellikle bir veri kümesinde bir modelin en iyi performansıya sonuçlanan bir dizi hiper parametrenin aranmasına veya farklı bir deyişle model için optimum parametrelerin aramasına hiper parametre optimizasyonu, hiper parametre ayarı veya hiper parametre araması denir. Hiper parametre ayarlama süreci, bir arama uzayı tanımlamayı gerektirir. Bu, geometrik olarak n boyutlu bir hacim olarak düşünülebilir. Burada, her bir hiper parametre farklı bir boyutu ve her nokta bir model konfigürasyonunu temsil eder. Arama uzayındaki her bir nokta, hiper parametre değeri için belirli değerlere sahip bir vektördür. Hiper parametre ayarlama sürecinin amacı, maksimum doğruluk ve

minimum hata prensibiyle öğrenmeden sonra modelin en iyi performansı ile sonuçlanan vektörü bulmaktır (Brownlee, 2020). Hiper parametre ayarlaması için basit ve yaygın yöntemler olarak ızgara arama (grid search) ve rastgele arama (random search) algoritmaları kullanılmaktadır.

3.4.3.1. Izgara Arama Algoritması

Hiper parametre değerlerinin ızgarası olarak arama uzayı manuel olarak tanımlanır. Izgaraadaki her konum için değerlendirme yani arama yapılır. En uygun hiper parametreler seçilir. Izgara arama algoritması tüm değerler için arama yaptığı için bir kaba kuvvet algoritması denilebilir. Bu sebeple yürütülmesi uzun sürer. Öte yandan tüm kombinasyonlar denendiği için en uygun hiper parametrelerin geçilmesini garanti eder.

3.4.3.2. Rastgele Arama Algoritması

Hiper parametre değerlerinin sınırlı bir alanı olarak bir arama uzayı tanımlanır. Belirlenen iterasyon sayısına ulaşıncaya kadar rastgele arama yapılır. Bu sınırlandırmalar çerçevesinde en uygun hiper parametreler seçilir. Bu şekilde optimum hiper parametrelere yaklaşıp bile olası tüm kombinasyonları denemediği için en iyi performans gösteren hiper parametreleri bulmayı garanti edemez.

3.5. Tekrarlayan Yapay Sinir Ağları

Tekrarlayan sinir ağları, bağlantı yapısına göre geliştirilmiş bir yapay sinir ağı topolojisidir. Tekrarlayan sinir ağlarını özel kılan durum, yapısal olarak, tekrarlayan katman(lar)ın varlığı ile birlikte nöronlar arasında yönlendirilmiş döngünün olmasıdır. İleri beslemeli ağların bağlantı yapısı gereği bazı sınırlamaları vardır. Bu sınırlamalardan birisi geri besleme bağlantısının olmamasıdır. Bunun üstesinden gelebilmek için önerilmiş yapılardan birisi olan tekrarlayan sinir ağları, nöronların bağlantılarındaki döngülerin varlığı ile bilgi akışının çift yönlü olmasına olanak sağlar. Tekrarlayan sinir ağlarında geri besleme tek bir katmanda olabileceği gibi birden fazla katmanda da olabilir. Tekrarlayan katmanlar, model çıktısından geri besleme bağlantılarına sahiptir.


İleri beslemeli sinir ağlarında, eğitim veri kümesindeki girdilerin ve çıktıların birbirinden bağımsız olduğu varsayılır. Öte yandan tekrarlayan sinir ağlarında ise çıktı, önceki girdilere bağlıdır. Bu durumda yani önceki girdilerin kullanılmasıyla ve katmanların önceki bilgileri hatırlamasıyla tekrarlayan sinir ağlarında hafıza yapısından bahsedilmektedir. Bunu yaparken de zaman gecikmesi ekleyerek hafıza

yapısını somut bir şekilde ortaya çıkarır. Bir sonraki adımı tahmin edebilmek için hafızasını kullanarak girdiler arasında ilişki kurulur ve eğitim sürecinde bu ilişkiler hem kullanılır hem de geliştirilir.

Tekrarlayan sinir ağları, zaman serisi barındıran verileri modellemek için uygundur. Çünkü çıktı katmanı ile önceki katmanlar arasındaki geri besleme bağlantısıyla zaman gecikmesi içermektedir. Her yinelemede ağın çıktısı tekrarlayan bir katmandan geçirilir ve tekrarlayan katmanın çıktısı gizli katmanın çıktısına eklenir. Elde edilen toplam sonraki yinelemede ağın çıktısını elde etmek için toplam fonksiyonun parametresi olarak kullanılır (Panakkat and Adeli, 2009).


Tekrarlayan sinir ağları katmanlardaki nöron sayısına göre birdenbire, birden çoğa, çoktan bire ve çoktan çoğa olmak üzere dört farklı türde temsil edilebilir. Birdenbire olan sinir ağları vanilya sinir ağları olarak adlandırılır ve tek girdi-tek çıktı olan makine öğrenmesi problemlerinde kullanılır. Birden çoğa olan sinir ağları, tek girdi-çok çıktı problemlerinde kullanılır. Çoktan bire olan sinir ağları, bir dizi girdi-tek çıktı olan problemlerde kullanılır. Bu ağın kullanılabileceği problem için duygu analizi tespiti problemi örnek olarak verilebilir. Çoktan çoğa sinir ağları, bir dizi girdi-bir dizi çıktı olan problemlerde kullanılır. Bu ağın kullanılabileceği problem olarak dil çevirici örnek verilebilir (Biswal, 2022).

Tekrarlayan sinir ağları topolojilerine ve eğitim algoritmalarına göre de farklı türlerde temsil edilebilir. Hopfield sinir ağları, tekrarlayan sinir ağlarının ilk ortaya çıkan türlerindendir ve simetrik bağlantılı Hebbian öğrenme paradigmasını kullanır. Elman sinir ağları, basit tekrarlayan sinir ağları olarak da adlandırılır, gizli katmanlarda yeterli sayıda nöron kullanıldığında herhangi bir dinamik girdi-çıkı ilişkisini keyfi olarak iyi öğrenmeyi sağlar. Bunu bir bağlam katmanında tekrarlayan gizli katman bağlantılarına eklediği gecikmeler ile yapar. Jordan sinir ağları, Elman sinir ağlarına benzerdir, ancak bağlam katmanında gizli katman yerine çıktı katmanına bağlıdır. Tekrarlayan sinir ağlarının modern versiyonları, derin öğrenmenin temelini oluşturur. Örnek olarak, zaman ve katmanlar boyunca yayılabilen hatayı korumaya yardımcı olan uzun-kısa süreli bellek verilebilir (Florido et al., 2016).



Şekil 3.6. Tekrarlayan sinir ağı mimarisi

Tekrarlayan sinir ağları, sıralı verileri ve zaman serilerini kullanmasıyla ve sahip olduğu hafıza yapısıyla genellikle doğal dil işleme problemleri olan konuşma tanıma, dil çevirisinde, dil işleminde, resim yazısı oluşturmada, el yazısı tanıma başarılı sonuçlar vermektedir. Öte yandan duygu analizi, anomali tespiti ve borsa tahmini problemlerinde de kullanılmaktadır.



Şekil 3.7. Tekrarlayan sinir ağı hücresi

Tekrarlayan yapay sinir ağlarının hücreleri girdi vektörü, çıktı vektörü ve geçmiş bilgilerden elde edilen bilgileri saklayan h vektörünü barındırır. Aslında yalnızca x ve y vektörleri ele alınırsa ileri beslemeli bir yapay sinir ağı gibi davrandığı görülmektedir. Tekrarlayan sinir ağlarının özelliğini gösterdiği nokta ise her bir x_t

girdi vektörü için önceki verilerden elde edilen bilgileri içeren h_{t-1} vektörünün ağırlık dahil olmasıdır. Tekrarlayan yapay sinir ağlarının hücrelerinin işlemleri şu şekildedir:

Adım 1: Eşitlik 3.47’de verildiği gibi a_t vektörü t zamanındaki ve t zamandan önce öğrenilen bilgileri içeren vektördür. a_t vektörü $t - 1$ zaman verisinden elde edilen h_{t-1} vektörü kendisi üzerindeki w ağırlığı ile çarpılarak ve güncel bilgiyi barındıran x_t vektörü ise kendisi üzerindeki u ağırlığı ile çarpılarak hesaplanır.

$$a_t = u \cdot x_t + w \cdot h_{t-1} + b_a \quad (3.47)$$

Adım 2: Elde edilen a_t vektörü bir aktivasyon fonksiyonuna (tanh, relu, vb.) verilerek Eşitlik 3.48’de olduğu gibi h_t elde edilir.

$$h_t = \tanh(a_t) \quad (3.48)$$

Adım 3: Elde edilen h_t vektörü kendisi üzerindeki v ağırlığı ile çarpılarak bir diğer vektör olan o_t Eşitlik 3.49’daki şekilde hesaplanır.

$$o_t = v \cdot h_t + b_o \quad (3.49)$$

Adım 4: Elde edilen o_t vektörü bir aktivasyon fonksiyonuna (tanh, softmax, vb.) verilerek çıktı vektörü olan y_t Eşitlik 3.50’de olduğu gibi elde edilir.

$$y_t = \text{softmax}(o_t) \quad (3.50)$$

3.6. Derin Öğrenme


Temelinde yapay sinir ağları olan derin öğrenme, bir makine öğrenmesi alt dalıdır. Bir makine öğrenmesi alt dalı olarak, öğrenebilen ve karar alabilen bir yapıdadır. Yapay sinir ağlarını temel almasıyla da henüz yapılandırılmamış yani etiketlenmemiş verileri kullanarak öğrenme süreci oluşturmaktadır. Öte yandan derin öğrenme modelleri yapay sinir ağlarını temel aldığı için insan beyninin yapısını ve işlevlerini örnek alarak geliştirilmiştir. Derin öğrenme büyük miktarda veri ile çalışmaktadır. Bu veriler üzerinde karmaşık hesaplamaların yapılabilmesine imkân sağlamaktadır. Bunu yaparken yapay sinir ağlarının daha fazla birimli ve daha fazla katmanlı haliyle yaparak derinlik oluşur. Böylelikle bu yapılara derin öğrenme denilmiştir. Bu derinlikli yapı ile karmaşık ve maliyetli işlem yükü birimlere ve katmanlara dağıtılır. Farklı katmanlardaki bilgi düşük seviyeli anlamlardan yüksek

seviyeli anlamlara taşınır. Bu süreçte de öğrenme gerçekleşmiş olur.

Makine öğrenmesinde veriler analiz edilerek, veriler üzerinde tahminler yapılarak, veri üzerindeki kalıplar ortaya çıkarılarak öğrenme gerçekleşir. Ancak derin öğrenmede makine öğrenmesinin aksine verinin temsilinden öğrenme işlemi gerçekleşmektedir. Makine öğrenmesinde verilerden özellik çıkarmak gerekirken derin öğrenmede ise bu özellikler verinin temsilinden elde edilir. Makine öğrenmesinde gerekli olan özellik çıkarma işlemi için ayrı bir uzmanlık gerekmektedir. Çünkü eğitilen modelin performansı ile doğrudan ilgilidir (LeCun et al., 2015). Karmaşık ve maliyetli işlemleri yürütebilen derin öğrenme, ön işlemi ve katmanlar arasındaki yapıyla ağ içinde istenen yapıya ait özelliklerin belirlendiği özellik çıkarımını veri temsillerinden otomatik olarak gerçekleştirmektedir. Bu sebeple fazla sayıda veriye ihtiyaç duyulmamaktadır. Fazla miktarda veri ile de daha iyi eğitim performansı elde edilebilir ve daha doğru tahminlerde bulunabilirler. Günümüzde grafik işlemcilerinin de gelişmesiyle derin öğrenme algoritmaları çok yüksek miktarda parametrelili problemleri hesaplayabilmektedir. Derin öğrenme günümüzde görüntü işleme, doğal dil işleme, nesne tanıma, gerçek zamanlı görüntü analizi, metin madenciliği, otonom sürüş, sağlık, tarım, havacılık ve savunma gibi birçok alanda kullanılmaktadır.


3.7. Uzun-Kısa Süreli Bellek

Derin öğrenmenin temelini oluşturan tekrarlayan sinir ağı modellerinden uzun-kısa süreli bellek, Sepp Hochreiter ve Jürgen Schmidhuber tarafından 1997 yılında önerilmiştir. Uzun-kısa süreli bellek, tekrarlayan sinir ağlarının en etkili türlerinden birisidir. Uzun-kısa süreli bellek, standart tekrarlayan sinir ağlarından daha iyi bilgi depolama ve bu bilgiye erişim özelliğine sahiptir. Geleneksel yapay sinir ağlarından farklı olarak, zaman serisi verileri gibi veriler sıralı olduğunda gayet başarılı neticeler vermektedir. Uzun-kısa süreli bellek, tekrarlayan sinir ağlarının bir alt türü olduğu için eğitim sürecinde geçmiş verileri kullanmayı öğrenebilir. Uzun-kısa süreli bellek, uzun süreli aralık ilişkileri içeren verilerin bu sorununu önlemek için gelişmiş bir tekrarlayan sinir ağı olarak tasarlanmıştır ve bu veriler üzerinde güçlü doğrusal olmayan öğrenme yeteneğine sahiptir (Parameswaran et al., 2018). Tekrarlayan sinir ağlarında uzun süreli aralık ilişkileri içeren veriler tekrarlamalar ilerledikçe en baştaki kritik bilgileri dışarıda bırakabilir. Uzun-kısa süreli bellek, bu sorunu kısa süreli bellek çözüm ile giderir.



Şekil 3.8. Uzun-kısa süreli bellek mimarisi

Uzun-kısa süreli bellek, kapı adı verilen iç mekanizmalarla bilgi akışını ayarlayabilir (Abri and Artuner, 2022). Uzun-kısa süreli bellek blokları, hafıza bloğu içerisinde bulunan girdi kapısı, unutma kapısı ve çıktı kapısı denilen kapı birimlerinden oluşmaktadır. Girdi kapısı, hafıza hücresine veri girişini kontrol eder. Çıktı kapısı, hafıza hücresinin diğer bloklara çıkışını kontrol eder. Unutma kapısı ise önceki blok çıktıların mevcut blok içerisinde ne derecede etkili olacağını belirler.



Şekil 3.9. Uzun-kısa süreli bellek hücresi

Bu kapılar, hücreye erişimi kontrol eder. Ağ, kapıları kontrol etmeyi öğrenir ve herhangi bir zamanda ağın ağırlık değerini güncellemeye veya kullanmaya karar verir (González et al., 2019). Uzun-kısa süreli bellek hücresinin işlemleri şu şekildedir:

Adım 1: Uzun-kısa süreli bellek hücresindeki ilk adım, belirli bir zaman adımında hangi bilginin hücreden çıkarılacağına karar vermektir. Sigmoid fonksiyonu bunu belirler. Geçerli giriş ile birlikte önceki duruma bakar ve fonksiyonu Eşitlik 3.51'deki şekilde hesaplar.

$$f_t = \sigma(W_{f,x} \cdot X_t + W_{f,h} \cdot h_{t-1} + b_f) \quad (3.51)$$

Adım 2: İkinci adımda iki kısım bulunmaktadır. Biri Eşitlik 3.52’de verilen sigmoid fonksiyonu, diğeri Eşitlik 3.53’te verilen tanh fonksiyonudur. Sigmoid fonksiyonunda, hangi değerlerin geçeceğine karar verilir. tanh fonksiyonu, önem düzeyine karar vererek iletilen değerlere ağırlık verir.

$$i_t = \sigma(W_{i,x} \cdot X_t + W_{i,h} \cdot h_{t-1} + b_i) \quad (3.52)$$

$$\tilde{C}_t = \tanh(W_{c,x} \cdot X_t + W_{c,h} \cdot h_{t-1} + b_c) \quad (3.53)$$

Adım 3: Üçüncü adımda yeni bilgiler oluşturulur. Eşitlik 3.54’te olduğu gibi unutma ve girdi kapıları, yeni ve eski durumun hangi kısımlarının dâhil edileceğini seçerek yeni hücre durumuna karar vermektedir.

$$C_t = C_{t-1} \cdot f_t + i_t \cdot \tilde{C}_t \quad (3.54)$$

Adım 4: Dördüncü adımda, çıktının ne olacağına karar verilir. İlk olarak, hücre durumunun hangi bölümlerinin çıktıya ulaştığına karar veren bir sigmoid fonksiyonu Eşitlik 3.55’teki şekliyle kullanılır. Ardından Eşitlik 3.56’daki gibi, hücre durumu tanh fonksiyonuna verilir ve sigmoid fonksiyonunu çıktısı ile çarpılır.

$$o_t = \sigma(W_{o,x} \cdot X_t + W_{o,h} \cdot h_{t-1} + b_o) \quad (3.55)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (3.56)$$

Buradaki ifadeler şu şekilde tarif edilmektedir:

i_t : girdi kapısı, $\tilde{C}_t$: hücre girdi aktivasyonu, f_t : unutma kapısı, o_t : çıktı kapısı,

C_t : hücre durumu, h_t : gizli katman durumu,

$W_{f,x}$, $W_{i,x}$, $W_{c,x}$ ve $W_{o,x}$ ağırlıklar ve b_f , b_i , b_c ve b_o bias değerleri,

X_t : girdi, h_{t-1} : son gizli katmanın durumu, h_t : iç durumu ve σ : sigmoid fonksiyonu


3.8. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi

Geleneksel matematiksel tekniklere dayanan sistem modelleme, iyi tanımlanmamış ve belirsiz sistemlerle uğraşmak için uygun değildir. Buna karşılık olarak, bulanık eğer-öyleyse kurallarını kullanan bir bulanık çıkarım sistemi kesin sayısal analizler kullanmadan, insan bilgisinin ve akıl yürütme süreçlerinin nitelikli yönlerini modelleyebilir (Jang, 1993). Yapay sinir ağları ve bulanık mantığın kısıtlarını ortadan kaldırmak için, uyarlamalı sinirsel bulanık çıkarım sistemleri (USBÇS) olarak adlandırılan, bu yapıların güçlü yönleri birleştirilerek hibrit bir akıllı sistem geliştirilmiştir. USBÇS, ilk olarak Jang tarafından önerilmiştir. USBÇS, uyarlanabilir ağlar çerçevesinde bir bulanık çıkarım sistemidir. USBÇS modeli, bir hibrit öğrenme prosedürü kullanarak, hem bulanık kurallar biçimindeki insan bilgisine hem de şart koşulan girdi-çıkı veri çiftlerine dayalı bir girdi-çıkı eşlemesi oluşturmak üzere tasarlanmıştır (Jang, 1993). USBÇS, öngörülen girdi-çıkı çiftlerini oluşturmak için uygun üyelik fonksiyonlarına sahip bir dizi bulanık eğer-öyleyse kuralı oluşturmak adına bir temel olarak hizmet edebilir. USBÇS, öğrenmeyi ve uyumu kolaylaştıran uyarlanabilir bir sistem çerçevesi olarak nitelendirildiğinde bu çerçeve USBÇS modelini sistematik ve insan bilgisine daha az bağımlı hale getirir.

USBÇS, yapay sinir ağları ve bulanık mantık yapılarının ortaya çıkardığı bir model olarak katmanlı uyarlanabilir ağ tabanlı bulanık çıkarım sistemi olarak da tarif edilebilir. Bu tarif ile insan benzeri davranış ve akıl yürütme becerilerini iyi şekilde gösterir ve geliştirir. USBÇS, bir öğrenme süreciyle girdi-çıkı verileri arasındaki ilişkiyi araştırıp analiz edebilir. Öğrenme sürecinde üyelik fonksiyonlarının uygun dağılımını hesaplamak için bir prosedür geliştirilir. Üyelik fonksiyonunun parametrelerini tanımlamak için doğrudan kurallar yoktur. Bu, ileri yayılım veya geri yayılım ya da en küçük kareler yöntemi ile ayarlanabilir. Uyarlamalı sinirsel bulanık çıkarım sistemleri yani USBÇS modelinin bulanık mantık kısmı tasarlanırken bulanık kural tabanlı Takagi-Sugeno bulanık çıkarım sistemi temel alınmıştır. Yapay sinir ağı kısmında ise yapay sinir ağlarından türetilen öğrenme algoritmaları kullanılarak bulanık çıkarım sisteminin eğitilmesi ele alınır. Kullanılan öğrenme algoritmaları hibrit öğrenmedir. USBÇS, doğrusal olmayan fonksiyonları modellemek ve kaotik zaman serilerini tahmin etmek için kullanılmaktadır (Jang, 1993).

USBÇS mimarisi beş katmandan oluşur. Her katman düğümler içermektedir. Bu düğümler, uyarlanabilir düğümler ve sabit düğümler şeklinde iki türden oluşur.

Uyarlanabilir düğümler kare şeklinde sembollerle, sabit düğümler ise daire şeklinde sembollerle gösterilirler. Uyarlanabilir düğümler, öğrenme süreci nedeniyle değişebilen parametrelerdir.



Şekil 3.10. Uyarlamalı sinirsel bulanık çıkarım sistemi

X ve Y girişli, F çıkışlı, Takagi-Sugeno kural tabanlı iki bulanık EĞER-ÖYLEYSE kuralları 3.57'deki biçimde tanımlanabilir.

$$\text{Kural} - 1: \text{EĞER } x, A_1 \text{ ve } y, B_1, \text{ÖYLEYSE } f_1 = p_1x + q_1y + r_1 \quad (3.57)$$

$$\text{Kural} - 2: \text{EĞER } x, A_2 \text{ ve } y, B_2, \text{ÖYLEYSE } f_2 = p_2x + q_2y + r_2$$

Bu kurallarda, x ve y girdilerdir; A_i ve B_i bulanık kümelerdir; f_i , bulanık kural tarafından belirtilen bulanık bölge içindeki çıktıdır; ve p_i , q_i ve r_i eğitim sürecinde belirlenen tasarım parametreleridir.

Şekil 3.10 da gösterilen ANFIS mimarisi için katmanların işleyişleri şu şekilde tarif edilebilir:

Katman-1: Bu katmandaki her i düğümü bir işleve sahip olup uyarlanabilir biçimdedir.

$$\begin{aligned} O_i^1 &= \mu_{A_i}(x), \quad i = 1, 2 \\ O_i^1 &= \mu_{B_i}(y), \quad i = 1, 2 \end{aligned} \quad (3.58)$$

Burada, x ve y , i düğümlerinin girdisi olup A_i ve B_i , bu düğüm işleviyle ilişkili

dilsel etiketlerdir. O_i^1 katmanın çıktısı olup Eşitlik 3.58 ile verilen $\mu_{A_i}(x)$, $\mu_{B_i}(y)$ bulanık üyelik fonksiyonlarından elde edilir. Bu üyelik fonksiyonları ise Eşitlik 3.59'da verilen genellikle çan biçimli değişen işlevler ile temsil edilir. Bu işlevdeki a_i , b_i ve c_i parametreleri, öncül parametreler olarak tanımlanır ve bu parametrelerin değerlerine bağlı olarak çan şeklindeki işlevler değişir.

$$\mu_{A_i}(x) = \frac{1}{1 + [(\frac{x - c_i}{a_i})^2]^{b_i}} \quad (3.59)$$

Katman-2: Bu katmandaki düğümler, sabit düğümü temsil eder. Bu katman, Katman-1'den gelen çıktıları girdi olarak alır ve bu girdileri çarparak sonuç üretir. Bu katmandaki her bir düğümün çıktısı bir kuralın ateşleme gücünü temsil eder ve Eşitlik 3.60 ile verildiği biçimde hesaplanır. Aslında ağırlıkların üretildiği katmandır.

$$O_i^2 = w_i = \mu_{A_i}(x) \cdot \mu_{B_i}(y), \quad i = 1, 2 \quad (3.60)$$

Katman-3: Bu katmandaki düğümler, uyarlanabilir düğümü temsil eder. Bu katmana normalleştirme katmanı denir ve i . kuralın tetikleme gücünün tüm kuralların tetikleme güçlerinin toplamına oranını Eşitlik 3.61 ile verildiği biçimde hesaplar. Bu katmanın çıktısına normalleştirilmiş ateşleme gücü denir.

$$O_i^3 = \overline{w}_i = \frac{w_i}{w_1 + w_2}, \quad i = 1, 2 \quad (3.61)$$

Katman-4: Bu katmandaki her i düğümü bir uyarlanabilir düğümü temsil eder ve bir düğüm işlevine sahiptir. Katmanın çıktısı Eşitlik 3.62'deki gibi hesaplanır.

$$O_i^4 = \overline{w}_i \cdot f_i = \overline{w}_i(p_i x + q_i y + r_i), \quad i = 1, 2 \quad (3.62)$$

$\overline{w}_i$, Katman-3'ün çıktısıdır ve $\{p_i, q_i, r_i\}$ parametre setidir. Bu katmandaki parametreler sonuç parametreleri olarak kabul edilir.

Katman-5: Bu katmandaki tek düğüm, uyarlanabilir düğümü temsil eder ve Katman-4'ten gelen tüm sinyalleri toplayarak Eşitlik 3.63'te verildiği şekilde hesaplar

$$O_i^5 = \sum_i \overline{w}_i \cdot f_i = \frac{\sum_i w_i \cdot f_i}{\sum_i w_i} \quad (3.63)$$

Bu mimari için öğrenme algoritmasının görevi, $\{a_i, b_i, c_i\}$ ve $\{p_i, q_i, r_i\}$ gibi tüm değiştirilebilir parametreleri USBÇS çıktısını eğitim verileriyle eşleştirecek şekilde ayarlamaktır. Bu mimaride, değiştirilebilir sonuç parametreleri olan p_1, q_1, r_1, p_2, q_2 ve r_2 'nin doğrusal bir birleşimidir. Bu parametrelerin optimal değerlerinin belirlenmesinde en küçük kareler yöntemi kolaylıkla kullanılabilir. Öncül parametreler değişken olduğunda arama uzayı büyür ve eğitimin yakınsaması yavaşlar. Bu durumun üstesinden gelmek için en küçük kareler yöntemi ile gradyan iniş yöntemini birleştiren hibrit bir öğrenme algoritması benimsenmiştir.

Hibrit algoritma, bir ileri ve geri geçişten oluşmaktadır. Sabit öncül parametreleriyle sonuç parametrelerini optimize etmek için ileri geçiş ile en küçük kareler yöntemi kullanılmaktadır. Optimal sonuç parametreleri bulunduğunda geri geçiş başlamaktadır. Giriş alanındaki bulanık kümeler karşılık gelen öncül parametreleri en uygun şekilde ayarlamak için geri geçiş ile gradyan iniş yöntemi kullanıldı. USBÇS ağının çıktısı, ileri geçişte bulunan sonuç parametreleri kullanılarak hesaplanmıştır. Çıktı hatası, standart bir geri yayılım algoritması aracılığıyla öncül parametreleri ayarlamak için kullanılmıştır. Bu hibrit algoritmanın USBÇS eğitiminde oldukça verimli olduğu kanıtlanmaktadır (Jang, 1993). Başka bir deyişle, ileri beslemede girdi parametreleri sabit olarak alınır ve sonuç parametrelerinin değerleri en küçük kareler yöntemi ile belirlenir. Sonuç parametreleri geri beslemede sabit olarak alınır ve geri yayılım öğrenme algoritması girdi parametrelerini hesaplar. Bu döngü hata küçük olana kadar devam eder.

USBÇS uygulanırken, çok fazla girdi değişkeni, sistemin karmaşıklaşmasına ve verimliliğinin düşmesine neden olur. Bu durumun üstesinden gelebilmek adına en uygun çıktıyı bulmak için ızgara bölümlleme veya çıkarmalı kümeleme tekniği kullanılarak bir çerçeveleme yapılır. Bu çerçevelmeler, ızgara bölümlleme (grid partition) ve çıkarıcı kümeleme (subtractive clustering) teknikleridir. Izgara bölümlleme tekniği, rastgele bir parametre seti ile üyelik fonksiyonları tarafından tanımlanmış ve üyelik fonksiyonlarının sayısı ve türüne göre veri kümesini dikdörtgen alt alanlara bölen bir tekniktir (Pandit and Panda, 2021). Veri kümesindeki girdi değişkenleri için kurallar oluşturma temeline dayanır. Girdi sayısı arttıkça kural sayısı da artmaktadır. Çıkarıcı kümeleme tekniği, küme sayısını ve küme konumlarını tahmin edebilen ve USBÇS ağları ile sentezleyebilen bir yöntemdir. Burada her veri bir küme merkezi olarak kabul edilir. Kümenin yarıçapı, kümeyi oluşturan tüm noktalar ile

merkez arasındaki en önemli mesafe olarak ifade edilir. Bir veri noktasının potansiyeli, diğer tüm veri noktalarından olan mesafelerin bir fonksiyonu olarak belirlenir. Bu yöntemde küme sayısının belirlenmesinde kümenin etki yarıçapı önemlidir. Küme çapı küçük seçilirse çok sayıda küme ortaya çıkacak ve bunun sonucunda kural sayısı artacaktır (Mirrashid, 2014).

3.9. Temel Bileşenler Analizi

Temel bileşenler analizi, orijinal verileri azaltılmış boyutlu ve farklı yapısal özelliklere sahip bir veri kümesine dönüştürmek için kullanılan istatistiksel bir tekniktir. Veri boyutluluğu sorunu, aşırı sayıda özelliğin genellikle daha kötü sonuçlara yol açtığını göstermektedir. Bu nedenle temel bileşenler analizi, yeterli sayıda koordinat ile uygun vektör uzayları oluşturmak için uygun bir metodolojidir (Asencio-Cortés et al., 2015). Temel bileşenler analizi, verilerdeki kalıpları tanımlamanın ve verileri benzerliklerini-farklılıklarını vurgulayacak şekilde ifade etmenin bir yoludur. Verilerdeki örüntüleri, grafik gösterim imkanının bulunmadığı yüksek boyutlu verilerde bulmak zor olabileceğinden, temel bileşenler analizi, verileri analiz etmek için güçlü bir araçtır. Öte yandan verilerde bu kalıpları bulduktan sonra verileri çok fazla bilgi kaybı olmadan sıkıştırılmasıdır (Smith, 2002). Temel bileşenler analizi, özellikle, yüz tanıma ve görüntü sıkıştırma gibi problemlerde kullanılmaktadır.

Temel bileşenler analizini açıklamadan önce, ilk olarak temel bileşenler analizinde kullanılacak matematiksel ve istatistiksel kavramlardan bahsetmek gerekir. Bu kavramlar standart sapma, varyans, kovaryans, özvektörler ve özdeğerler kavramlarıdır.

Standart sapma, veri kümesinin ortalamasından bir noktaya olan ortalama mesafe olarak tanımlanabilir.

$$\bar{X} = \frac{\sum_{i=1}^n X_i}{n} \quad (3.64)$$

$$s = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n - 1)}} \quad (3.65)$$

Burada; Eşitlik 3.64'te verilen $\bar{X}$, veri kümesinin ortalaması ve Eşitlik 3.65'te verilen s standart sapma miktarıdır.

Eşitlik 3.66'daki gibi hesaplanan varyans, bir veri kümesindeki verilerin yayılmasının istatistiksel bir ölçüsüdür.

$$s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})^2}{(n - 1)} \quad (3.66)$$

Burada; s^2 varyans ölçüsüdür ve standart sapma miktarının karesi şeklinde ifade edilir.

Standart sapma ve varyans yalnızca 1 boyutlu veri kümelerinde çalışır. Birçok veri kümesinin ise birden fazla boyutu vardır. Veri kümeleri üzerindeki istatistiksel analizlerin amacı genellikle bu boyutlar arasında herhangi bir ilişki olup olmadığını bulmaya çalışmaktır. Bu nedenle veri kümesinin her boyutu için standart sapma, diğer boyutlardan bağımsız olarak hesaplanabilir. Fakat bu durumda boyutlar arasındaki ilişkiyi bulmak çabası için yeterli olmayabilir. Bu durumda boyutların birbirine göre ortalamadan ne kadar farklılaştığını bulmak için benzer bir ölçüm yapmakta fayda vardır. Kovaryans bu durum için kullanılabilecek bir ölçüdür. Kovaryans, her zaman 2 boyut arasında ölçülür. Bir boyut ile kendisi arasındaki kovaryansı hesaplanırsa, varyansı elde edilir. Yani, 3 boyutlu bir veri kümesi (x, y, z) varsa, o zaman x ve y boyutları, x ve z boyutları ve y ve z boyutları arasındaki kovaryansı ölçülür. x ve x veya y ve y veya z ve z arasındaki kovaryansı ölçmek, sırasıyla x, y, z boyutlarının varyansını verir.

Eşitlik 3.67'de verilen varyans formülüne benzer şekilde kovaryans formülü Eşitlik 3.68'teki gibi hesaplanmaktadır.

$$var(X) = s^2 = \frac{\sum_{i=1}^n (X_i - \bar{X})(X_i - \bar{X})}{(n - 1)} \quad (3.67)$$

$$cov(X, Y) = \frac{\sum_{i=1}^n (X_i - \bar{X})(Y_i - \bar{Y})}{(n - 1)} \quad (3.68)$$

İkiden fazla boyutlu bir veri kümesi varsa, hesaplanacak birden fazla kovaryans ölçümü vardır. Örneğin, 3 boyutlu bir veri kümesinden (x, y, z) boyutları $cov(x, y)$, $cov(x, z)$, $cov(y, z)$ hesaplanacaktır. Buradan bir genellemeyle n -boyutlu bir veri kümesi için $\frac{n!}{(n-2)!*2}$ farklı kovaryans değerleri hesaplanabilir. Tüm boyutlar arasındaki olası tüm kovaryans değerlerini saklamanın bir yolu, hepsini hesaplayıp ve bir matriste tutmaktır. Dolayısıyla, n boyutlu bir veri kümesi için kovaryans matrisinin tanımı

Eşitlik 3.69'daki tarif edilmektedir.

$$C^{n \times n} = (c_{i,j}, c_{i,j} = \text{cov}(\text{Dim}_i, \text{Dim}_j)) \quad (3.69)$$

Boyutları uyumlu olmak şartıyla iki matrise çarpma işlemi uygulanabilir ve özvektörler bunun özel bir durumudur. Bir vektör ile bir matrisin çarpma işlemine tabi tutulmasından sonra, vektörün hem büyüklüğü hem de yönü değişebilir. Bazı durumlarda bu işlem sonucunda vektörler, skaler bir sayı ile çarpılmış gibi sadece büyüklüğünün değiştiği yönünün değişmediği gibi davranır. Bu vektörlere o matrisin özvektörleri denir. Özvektörler yalnızca kare matrisler için çıkarılabilir. $n \times n$ boyutlu bir kare matrisin n adet özvektörü vardır. Diğer yandan her kare matrisin özvektörü olma durumu yoktur. Bir matrisin tüm özvektörleri, kaç boyuta sahip olursa olsun birbirine diktir. Burada önemli olan konu, verilerin xy ekseninde değil de bu birbirine dik özvektörler ekseninde konumlanmasıdır.

Özdeğer kavramı, özvektör kavramı ile ilgilidir. Özvektörler yalnızca kare matrisler için çıkarılabildiği için özdeğer elde etmek için kovaryans matrisler kullanılmaktadır. İlk başta vektörün kare matrisle çarpıldıktan sonra vektörün büyüklüğünü değiştiren değer, özdeğerdir. Kare matrisle çarpmadan önce özvektörün hangi katı alınırsa alınsın, sonuç olarak her zaman ölçekli vektörün özdeğer katı elde edilir.

Temel bileşenler analizinin adımları bahsedilen matematiksel ve istatistiksel kavramlar kullanılarak sırasıyla şu şekilde tarif edilebilir:

Adım 1: Standartlaştırma

Bu adımın amacı, başlangıç değişkenlerinin aralığını, her birinin analize eşit katkıda bulunacak şekilde standartlaştırmaktır. Bunun nedeni, temel bileşen analizinin başlangıç değişkenlerinin varyansları konusunda hassas olmasıdır. Bu değişkenler aralıkları arasındaki fark büyükse, daha geniş aralıklara sahip değişkenler, küçük aralıklara sahip olanlara göre baskın olacağından yanlış sonuçlara yol açacaktır. Dolayısıyla verilerin karşılaştırılabilir ölçeklere dönüştürülmesiyle bu sorunun üstesinden gelinebilir. İşlemsel olarak bu, her değişkenin değerlerini her değişkenin ortalamasından çıkardıktan sonra, her değişkenin standart sapmasına bölerek yapılabilir.

$$z = \frac{(X_i - \bar{X})}{s}, i = 1, 2, \dots, n \quad (3.70)$$

Eşitlik 3.70’te verilen z , standart değer, X_i , gerçek değer, $\bar{X}$, veri kümesinin ortalaması ve s veri kümesinin standart sapma miktarıdır.

Adım 2: Kovaryans Matrisin Hesaplanması

Bu adımın amacı, girdi veri kümesindeki değişkenlerin birbirlerine göre ortalamadan nasıl farklılaştığını anlamak, başka bir deyişle aralarında herhangi bir ilişki olup olmadığını görmektir. Çünkü bazen değişkenler, gereksiz bilgiler içerecek şekilde yüksek oranda ilişkilidir. Dolayısıyla, bu korelasyonları belirlemek için kovaryans matrisi hesaplanır.

Adım 3: Temel Bileşenleri Belirlemek İçin Kovaryans Matrisin Özvektörlerinin ve Özdeğerlerinin Hesaplanması

Özvektörler ve özdeğerler, verilerin temel bileşenlerini belirlemek için kovaryans matrisinden hesaplanması gereken matematiksel kavramlardır.

Adım 4: Temel Bileşenleri Seçme ve Özellik Vektörü Oluşturma

Adım 5: Verilerin Temel Bileşenler Eksenine Taşınarak Yeni Veri Kümesinin Türetilmesi

4. BULGULAR VE TARTIŞMA

4.1. Verinin Hazırlanması

Bu çalışmada kullanılan veri kümesi, depremler hakkında bilgi sağlayan Afet ve Acil Durum Yönetimi Başkanlığı'nın (AFAD) deprem kataloğundan elde edilmiştir. Veriler, geriye dönük olarak son 5 yıl, son 10 yıl ve son 20 yıla ait depremler için tarih, büyüklük, derinlik ve konum (enlem ve boylam) özellikleri üzerinde filtrelendi. Bu filtreleme işlemi, Tablo 4.1'de belirtilen kriterler ve gerekçeler dikkate alınarak gerçekleştirilmiştir. Böylece, son 5 yıl içinde 3238, son 10 yıl içinde 5813 ve son 20 yıl içinde 6830 kayıt elde edilmiştir.

Tablo 4.1. Veri kümesi filtreleme kriterleri ve gerekçeleri

Özellik	Kriter	Gerekçe
Tarih	01.01.2016 – 31.12.2020	Türkiye’de Son 5 Yılda Oluşan Depremler
	01.01.2010 – 31.12.2020	Türkiye’de Son 10 Yılda Oluşan Depremler
	01.01.2001 – 31.12.2020	Türkiye’de Son 20 Yılda Oluşan Depremler
Büyüklük	3.0 – 9.0	Hissedilen Depremin Büyüklük Aralığı
Derinlik	0 – 150 km	Türkiye’de Oluşan Depremlerin Derinliği
Enlem	36.00° – 42.00°	Türkiye’nin Matematiksel Konumu
Boylam	26.00° – 45.00°	

Elde edilen ham veri kümelerinden özellik çıkarma işlemleri kullanılarak yeni veri kümeleri türetilmiştir. Panakkat depremsellik göstergeleri kullanılarak yeni özellikleri barındıran veri kümeleri elde edilmiştir. Son 5 yıllık deprem kayıtlarını barındıran veri kümesinde eşik büyüklüğü ilk olarak 4.0 seçilmiştir. Bu seçime göre depremsellik göstergeleri hesaplanmıştır. Yine aynı veri kümesinde eşik büyüklüğü sırasıyla 4.5 ve 5.0 seçilerek depremsellik göstergeleri hesaplanmıştır. Böylelikle bir ham veri kümesinden 3 farklı yeni veri kümesi elde edilmiştir. Bu işlem son 10 yıllık ve son 20 yıllık deprem kayıtlarını barındıran veri kümeleri için de yapılmıştır. Bunların içerisinde tez çalışmasında en kapsayıcı veri kümesi olan son 20 yıllık veri

kümesi kullanılmıştır. Bu depremsellik göstergeleri hesaplanırken temel sismolojik yasalar kullanılmıştır. Bu şekilde girdi vektörü 7 elemanlı bir vektör olarak elde edilmiştir. Bu doğrultuda temel bileşenler analizi (TBA) kullanılmasıyla veri boyutunun azaltıldığı yeni veri kümeleri de deneysel çalışmalarda kullanılmıştır. Temel bileşenler analizi uygulandığında elde edilen yeni veri kümelerinin girdi eleman sayısı 4'e düşürülmüştür. Böylelikle temel bileşenler analizi uygulanmış 3 yeni veri kümesi daha elde edilmiştir. Nihayetinde 6 farklı veri kümesi elde edilmiştir. Bu veri kümeleri Tablo 4.2'de gösterilmiştir.

Tablo 4.2. Son 20 yıllık veri için türetilmiş yeni veri kümeleri

Eşik Büyükliği	TBA Yapılmamış Yeni Veri Kümesi	TBA Yapılmış Yeni Veri Kümesi
4.0	Veri Kümesi – 1	Veri Kümesi – 4
4.5	Veri Kümesi – 2	Veri Kümesi – 5
5.0	Veri Kümesi – 3	Veri Kümesi – 6

Bu veri kümeleri kullanılmadan önce yani modellere verilmeden önce son bir ön işleme tabi tutulmuştur. Bu işlem Eşitlik 4.1'de verilen veri normalleştirme işlemidir. Minimum-Maksimum ölçeklemeye dayalı olarak veriler, 0-1 aralığında normalleştirilmiştir.

$$X_{normalize} = \frac{(X_i - X_{min})}{(X_{max} - X_{min})} \quad i = 1, 2, \dots, n \quad (4.1)$$

$$X_{ölçekli} = X_{normalize} \cdot (max - min) + min$$

Burada, X_i , veri kümesinin i . elemanını, X_{min} , veri kümesinin en küçük değerini, X_{max} , veri kümesinin en büyük değerini ve (min, max) ölçeklenecek aralığı temsil eder.

Elde edilmiş veri kümeleri modellere verilirken ilk önce rastgeleliği sağlamak adına tüm veri önerilen bir metot ile karıştırılmıştır. Şekil 4.1'de bir sözde kod ile açıklanmıştır.

```

ALGORITMA degistokus(dizi_verikumesi)
GİRİŞ:
    dizi_verikumesi: değiştirilecek dizi veri kümesi
ÇIKIŞ:
    Değiştirilmiş dizi veri kümesi

    dizi_uzunluk = UZUNLUK(dizi_verikumesi)
    DÖNGÜ i = 0'dan dizi_uzunluk'a kadar ADIM 1:
        rastgele_indis = RASTGELE(0, dizi_uzunluk)
        gecici_deger = dizi_verikumesi[rastgele_indis]
        dizi_verikumesi[rastgele_indis] = dizi_verikumesi[-rastgele_indis]
        dizi_verikumesi[-rastgele_indis] = gecici_deger
    DÖNGÜ_SONU


    DÖNDÜR dizi_verikumesi
ALGORITMA_SONU

```

Şekil 4.1. Karıştırma metodunun sözde kodu

Karıştırılan verinin %80'lik kısmı eğitim için kalan %20'lik kısmı ise test için kullanılmıştır. Modellemelerde verideki aşırı uyum riskinin önüne geçilmesi amacıyla k-katlamalı çapraz doğrulama (k-fold cross validation) tekniği kullanılmaktadır. K-katlama, bir veri kümesini model eğitiminde kullanmak üzere k adet parçaya (fold) ayırır. Böylelikle, veri kümesinin bir kısmı modelin eğitiminde kullanılırken diğer kısmı test etmek için kullanılır. Bu amaçla oluşturulan modelin genelleştirilebilirliği arttırmak aynı zamanda karıştırılarak oluşturulan verideki rastsal seçim sonuçlarını desteklemek için k-katlamalı çapraz doğrulama sonuçları da elde edilmiştir.

Bu noktaya kadar veri kümesinin hazırlanmasından bahsedilmiştir. Bundan sonra bu veri kümelerinin modeller üzerine uygulanması ve elde edilen bulgulardan bahsedilecektir. Deneysel süreçler ile ilgili çalışmanın grafiksel özeti Şekil 4.2'de verilmiştir.




Şekil 4.2. Grafıksel özet

4.2. TBA Uygulanmayan Veri Üzerine Çalışma

Toplanan ham deprem verisinden Panakkat depremsellik göstergeleri kullanarak çıkarılan özellikleri barındıran Veri Kümesi-1, Veri Kümesi-2 ve Veri Kümesi-3 kullanılarak yapılan çalışmalarda elde edilen bulgulara bu bölümde yer verilmiştir. Model olarak ilk önce uzun-kısa süreli bellek (UKSB) uygulaması yapılmıştır, sonra da uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) uygulaması yapılmıştır. Veri kümelerinin %80'lik kısmı eğitim için kalan kısmı da test için kullanılmıştır. Ayrıca k-katlamalı çapraz doğrulama tekniği uygulanmıştır ve k-katlama değeri 5 olarak seçilmiştir.

4.2.1. Uzun-Kısa Süreli Bellek Uygulaması

Python programlama dili kullanılarak uzun-kısa süreli bellek modelinin tasarımı yapılmıştır. Bu tasarım sırasında, Keras adlı açık kaynak kodlu sinir ağı kütüphanesi kullanılmıştır. Tasarım, 64 nörondan oluşan bir girdi katmanı, 0.1 değerli bir bırakma katmanı, 64 nörondan oluşan bir gizli katman ve son olarak tek nöronlu yoğun katmandan oluşan bir mimariye sahiptir. İlk ağırlıklar, girdi ve gizli katmanlarda glorot_normal ve yoğun katmanda random_normal olarak belirlenmiştir. Bias değerleri için, girdi ve gizli katmanlarda bias_regularizer kullanılmış ve değeri 0.01 olarak ayarlanmıştır. Tüm katmanlarda sızdıran ReLU aktivasyon fonksiyonu kullanılmıştır. Ağın eğitimi için RMSprop öğrenme kullanılmıştır ve öğrenme oranı 0.002, momentum değeri 0.8 olarak belirlenmiştir. Alt örneklerin sayısı (batch_size) eğitim sırasında 64 olarak belirlenmiştir ve eğitim 200 epokta tamamlanmıştır. Tüm bu hiper parametrelerin seçimi, ızgara arama tekniği kullanılarak yapılmıştır ve elde edilen sonuçlar Tablo 4.3'te verilmiştir. Eğitim sürecindeki hata, ortalama karesel hata olarak hesaplanmıştır. Modelin blok diyagram gösterimi Şekil 4.3'te verilmiştir.



Şekil 4.3. Modelin blok diyagram gösterimi

Önerilen UKSB ağı modeline oluşturulan veri kümeleri tek tek verilerek 3 farklı senaryo için modelin sonuçları elde edilmiştir. Değerlendirme ölçütleri olarak eğitim ve test veri kümeleri için hata oranları Kök Ortalama Karesel Hata (KOKH) ve Ortalama Karesel Hata (OKH) hesaplanarak ortaya konulmuştur. Düşük KOKH ve

OKH değerleri daha uyumlu bir model olduğunu gösterir ve daha yüksek değerler ise uyumsuz bir model olduğunu gösterir. Ayrıca modelin başarımını göstermek adına R^2 skoru hesaplanmıştır. R^2 skoru, verinin modele ne kadar uyduğunu gösterir. R^2 skoru 1'e yaklaştıkça, modele uygunluk artar ve 0'a yaklaştıkça, modele uygunluk azalır.

Tablo 4.3. Izgara arama sonuçlarına göre hiper parametre seçimi


Hiper Parametre	En İyi Hiper Parametre Değeri	Diğer Hiper Parametre Değerleri
Nöron Sayısı	'units': 64	'units': {16, 32, 64, 128}
Bırakma Oranı	'dropout_rate': 0.1	'dropout_rate': {0.1, 0.2, 0.3, 0.4, 0.5}
Girdi ve Gizli Katman için Başlangıç Ağırlıkları	'kernel_initializer': 'glorot_normal'	'kernel_initializer': {'glorot_normal', 'glorot_uniform', 'random_normal', 'random_uniform'}
Yoğun Katman için Başlangıç Ağırlıkları	'kernel_initializer': 'random_normal'	'kernel_initializer': {'glorot_normal', 'glorot_uniform', 'random_normal', 'random_uniform'}
Aktivasyon Fonksiyonu	'activation': 'leaky_relu'	'activation': {'leaky_relu', 'relu', 'elu', 'gelu', 'tanh', 'sigmoid', 'softmax', 'swish', 'linear'}
Öğrenme Yöntemi	'optimizer': 'RMSprop'	'optimizer': {'RMSprop', 'Adam', 'SGD', 'Adamax', 'Adagrad', 'Adadelat'
Öğrenme Oranı ve Momentum	'learning_rate': 0.002, 'momentum': 0.8	'learning_rate': {0.1, 0.01, 0.0001, 0.2, 0.02, 0.0002} 'momentum': {0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9}
Alt Örnek Sayısı	'batch_size': 64	'batch_size': {16, 32, 64, 128}
Epok Sayısı	'epochs': 200	'epochs': {100, 200, 300}

Veri kümeleri oluşturulurken son 20 yıllık deprem verileri eşik büyüklüğü 4.0 seçildiğinde Veri Kümesi-1, eşik büyüklüğü 4.5 seçildiğinde Veri Kümesi-2 ve eşik büyüklüğü 5.0 seçildiğinde Veri Kümesi-3 elde edilmiştir.

Senaryo-1, Veri Kümesi-1 kullanıldığı durumdur. Veri Kümesi-1, ham veri


kümesinde eşik büyüklüğünün 4.0 seçildiği durumdaki depremsellik göstergeleri hesaplandıktan sonra elde edilen yeni veri kümesidir. Toplam 1498 kayıt elde edilmiştir; eğitim veri kümesi 1198 ve test veri kümesi 300 kayıt içermektedir.

Senaryo-1 gerçekleştiğinde, modelin eğitim süreci ile ilgili olarak modelin eğitimdeki hatası ve geçerlemenin hatası Şekil 4.4'te gösterilmiştir. Şekle bakıldığında modelin küçük hata oranında eğitim sürecini tamamladığı görülmektedir.




Şekil 4.4. Senaryo-1'deki model eğitimi ve geçerlemede epok başına kayıp grafiği

Senaryo-1'de eğitim süreci tamamlandıktan sonra eğitim ve test veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesinde yapılan tahminler modelin başarılı tahminler ortaya çıkardığını göstermektedir. Bu durum ile ilgili grafik, Şekil 4.5'te verilmiştir. Eğitim veri kümesinin büyük bir kısmında tahmin edilen değerler, gerçek değerlerin altında bir kısmında da gerçek değerlerin üstünde tahmin edilmiştir. Burada hem negatif yönlü hem de pozitif yönlü hatalar olduğu görülmektedir.




Şekil 4.5. Senaryo-1'deki eğitim verisinin tahmin sonuçları ve hataları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.6'da gösterildiği ve eğitim veri kümesindeki tahminlerde olduğu gibi başarılı sonuçlar elde edilmiştir. Eğitim veri kümesinde tahmin edilen değerler gibi test veri kümesinin neredeyse tamamında tahmin edilen değerler, gerçek değerlerin altında tahmin edilmiştir. Yani negatif yönlü hatalar olduğu görülmektedir.



Şekil 4.6. Senaryo-1'deki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.7'de görüldüğü gibi güçlü bir ilişki elde edilmiştir.



Şekil 4.7. Senaryo-1'deki eğitim ve test verisinin regresyon doğruları

Senaryo-1'in hata ve başarımlar oranları Tablo 4.4'te sunulmuştur. Hata ve başarımlar oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.

Tablo 4.4. Senaryo-1 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.02560	0.00066	0.99678
Test Veri Kümesi	0.04406	0.00194	0.99139


Senaryo-1'de k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.8'de ve test veri kümesi için Şekil 4.9'da verilmiştir.

Senaryo-1'de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.10'da ve test veri kümesi için Şekil 4.11'de verilmiştir.


Senaryo-1'de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar oranları Tablo 4.5'te verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.5. Senaryo-1 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.02854	0.00103	0.99402
Test Veri Kümesi	0.02949	0.00115	0.99347




Şekil 4.8. Senaryo-1'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.9. Senaryo-1’deki test verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.10. Senaryo-1’deki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.11. Senaryo-1’deki test verisinin k-katlamalı regresyon doğruları


Senaryo-2, Veri Kümesi-2 kullanıldığı durumdur. Veri Kümesi-2, ham veri kümesinde eşik büyüklüğünün 4.5 seçildiği durumdaki depremsellik göstergeleri hesaplandıktan sonra elde edilen yeni veri kümesidir. Toplam 524 kayıt elde edilmiştir; eğitim veri kümesi 419 ve test veri kümesi 105 kayıt içermektedir.

Senaryo-2 gerekleřtiėinde, modelin eėitim sureci ile ilgili olarak modelin eėitimdeki hatası ve geerlemenin hatası řekil 4.12'de gsterilmiřtir. řekil incelendiėinde modelin kk hata oranında eėitim surecini tamamladıėı grlmektedir.




řekil 4.12. Senaryo-2'deki model eėitimi ve geerlemede epok bařına kayıp grafiėi

Senaryo-2'de eėitim tamamlandıktan sonra eėitim ve test veri kmeleri zerinde tahminlemeler yapılmıřtır. Eėitim veri kmesinde yapılan tahminler modelin bařarılı tahminler ortaya ıkardıėını gstermektedir. Bu durum ile ilgili grafiė, řekil 4.13'te verilmiřtir. Eėitim veri kmesinin tamamında tahmin edilen deėerler, gerek deėerlerin altında tahmin edilmiřtir. Yani negatif ynl hatalar olduėu grlmektedir.




řekil 4.13. Senaryo-2'deki eėitim verisinin tahmin sonuları ve hataları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.14'te gösterildiği ve eğitim veri kümesindeki tahminlerde olduğu gibi başarılı sonuçlar elde edilmiştir. Eğitim veri kümesinde tahmin edilen değerler gibi test veri kümesinin de tamamında tahmin edilen değerler, gerçek değerlerin altında tahmin edilmiştir. Yani negatif yönlü hatalar görülmektedir.



Şekil 4.14. Senaryo-2'deki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.15'de görüldüğü gibi güçlü bir ilişki elde edilmiştir.



Şekil 4.15. Senaryo-2'deki eğitim ve test verisinin regresyon doğruları

Senaryo-2 için hata oranları ve başarımlar Tablo 4.6’da verilmiştir. Hata oranlarının düşük olduğu ve başarımların yüksek olduğu görülmektedir. Eğitim veri kümesinin tahminlemedeki hata oranlarının test veri kümesinin tahminlemedeki hata oranlarına yakın olduğu görülmektedir. Eğitim veri kümesindeki başarımların ve test veri kümesindeki başarımların neredeyse aynı sonuçlara sahip olduğu görülmektedir.

Tablo 4.6. Senaryo-2 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.05341	0.00285	0.98270
Test Veri Kümesi	0.06627	0.00439	0.97895


Senaryo-2’de k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.16’da ve test veri kümesi için Şekil 4.17’de verilmiştir.

Senaryo-2’de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.18’de ve test veri kümesi için Şekil 4.19’da verilmiştir.


Senaryo-2’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar Tablo 4.7’de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.7. Senaryo-2 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.03732	0.00144	0.99121
Test Veri Kümesi	0.04530	0.00219	0.98695




Şekil 4.16. Senaryo-2’deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.17. Senaryo-2’deki test verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.18. Senaryo-2'deki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.19. Senaryo-2'deki test verisinin k-katlamalı regresyon doğruları


Senaryo-3, Veri Kümesi-3 kullanıldığı durumdur. Veri Kümesi-3, ham veri kümesinde eşik büyüklüğünün 5.0 seçildiği durumdaki depremsellik göstergeleri hesaplandıktan sonra elde edilen yeni veri kümesidir. Toplam 167 kayıt elde edilmiştir; eğitim veri kümesi 133 ve test veri kümesi 34 kayıt içermektedir.

Senaryo-3 gerekleřtiėinde, modelin eėitimi sureci ile ilgili olarak modelin eėitimdeki hatası ve geerlemenin hatası řekil 4.20'de gsterilmiřtir. řekil incelendiėinde modelin kk hata oranında eėitimini tamamladıėı grlmektedir.



řekil 4.20. Senaryo-3'teki model eėitimi ve geerlemede epok bařına kayıp grafiėi


Senaryo-3 iin eėitim sureci tamamlandıktan sonra eėitim ve test veri kmeleri zerinde tahminlemeler yapılmıřtır. Eėitim veri kmesinde yapılan tahminler modelin bařarılı tahminler ortaya ıkardıėını gstermektedir. Bu durum ile ilgili grafik, řekil 4.21'de verilmiřtir. Eėitim veri kmesinin bk bir ksımında tahmin edilen deėerler, gerek deėerlerin altında tahmin edilmiřtir. Yani negatif ynl hatalar olduėu grlmektedir.



řekil 4.21. Senaryo-3'teki eėitim verisinin tahmin sonuları ve hataları


Test veri kmesi zerinde tahminler yapıldıėında řekil 4.22'de gsterildiėi ve eėitim veri kmesindeki tahminlerde olduėu gibi bařarılı sonular elde edilmiřtir. Eėitim veri kmesinde tahmin edilen deėerler gibi test veri kmesinin de bk bir

kısımında tahmin edilen değerler, gerçek değerlerin altında tahmin edilmiştir. Yani negatif yönlü hatalar görülmektedir.



Şekil 4.22. Senaryo-3'teki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.23'te görüldüğü gibi güçlü bir ilişki elde edilmiştir.



Şekil 4.23. Senaryo-3'teki eğitim ve test verisinin regresyon doğruları

Senaryo-3 için hata oranları ve başarımlar Tablo 4.8'de verilmiştir. Hata oranlarının düşük olduğu ve başarımların yüksek olduğu görülmektedir.

Tablo 4.8. Senaryo-3 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.02626	0.00069	0.99441
Test Veri Kümesi	0.03347	0.00112	0.99259


Senaryo-3'te k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.24'te ve test veri kümesi için Şekil 4.25'te verilmiştir.

Senaryo-3'te her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.26'da ve test veri kümesi için Şekil 4.27'de verilmiştir.


Senaryo-3'te eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar Tablo 4.9'da verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.9. Senaryo-3 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.03326	0.00114	0.98913
Test Veri Kümesi	0.03533	0.00139	0.98669




Şekil 4.24. Senaryo-3'teki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.25. Senaryo-3'teki test verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.26. Senaryo-3'teki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.27. Senaryo-3'teki test verisinin k-katlamalı regresyon doğruları


4.2.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin Uygulanması

Verinin modellenmesi amacıyla Matlab R2019a yazılımı kullanılarak uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) tasarlanmıştır. USBÇS mimarisi olarak Sugeno tipi yapı kullanılmıştır ve 7 adet depremsellik göstergesi için 7 girdi ve deprem büyüklüğü için 1 çıktı değişkeni kullanılmıştır. Her girdi değeri için iki dilsel etiket atanmıştır ve bu yapıda 128 (2^7) kural içeren bir ağ yapısı oluşturulmuştur. Bulanık çıkarım sistemi için ızgara bölümlene yöntemi tercih edilmiştir. Girdi üyelik fonksiyonu olarak gaussmf ve çıktı üyelik fonksiyonu olarak doğrusal fonksiyon kullanılmıştır. Geri yayılım algoritması, öğrenme yöntemi olarak seçilmiş ve eğitim 100 epokta tamamlanmıştır.

Önerilen USBÇS modeli, oluşturulan veri kümeleri üzerinde test edilmiştir. 3 farklı senaryo için eğitim ve test veri kümeleri kullanılmış ve modelin tahminleri elde edilmiştir. Kök Ortalama Karesel Hata (KOKH) ve Ortalama Karesel Hata (OKH) hesaplanarak eğitim ve test veri kümeleri için hata oranları belirlenmiştir. Ayrıca, modelin başarımını ölçmek amacıyla R^2 skoru hesaplanmıştır.


Veri kümeleri oluşturulurken son 20 yıllık deprem verileri eşik büyüklüğü 4.0 seçildiğinde Veri Kümesi-1, eşik büyüklüğü 4.5 seçildiğinde Veri Kümesi-2 ve eşik büyüklüğü 5.0 seçildiğinde Veri Kümesi-3 elde edilmiştir.

Senaryo-4, modelde Veri Kümesi-1 kullanıldığı durumdur. Senaryo-4 için eğitim tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümelerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.28'de gösterildiği gibi modelin başarılı bir tahminleme yapabildiği görülmektedir.




Şekil 4.28. Senaryo-4'teki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.29'da gösterildiği ve genel olarak başarılı sonuçlar elde edilmiştir.



Şekil 4.29. Senaryo-4'teki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.30'da görüldüğü gibi güçlü bir ilişki elde edilmiştir.



Şekil 4.30. Senaryo-4'teki eğitim ve test verisinin regresyon doğruları


Senaryo-4 için hata oranları ve başarımlar Tablo 4.10'da verilmiştir. Hata oranlarının düşük olduğu ve başarımların yüksek olduğu görülmektedir.

Tablo 4.10. Senaryo-4 eğitim ve test veri kümelerinin hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.13525	0.01829	0.89949
Test Veri Kümesi	0.15822	0.02503	0.85718

Senaryo-4'te k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.31'de ve test veri kümesi için Şekil 4.32'de verilmiştir.


Senaryo-4'te her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.33'te ve test veri kümesi için Şekil 4.34'te verilmiştir.




Şekil 4.31. Senaryo-4'teki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.32. Senaryo-4'teki test verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.33. Senaryo-4'teki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.34. Senaryo-4'teki test verisinin k-katlamalı regresyon doğruları

Senaryo-4'te eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar oranları Tablo 4.11'de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.11. Senaryo-4 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.13372	0.01789	0.90058
Test Veri Kümesi	0.14766	0.02574	0.86905

Senaryo-5, modelde Veri Kümesi-2 kullanıldığı durumdur. Senaryo-5 için eğitim süreci tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.35'te gösterildiği gibi modelin gayet başarılı bir tahminleme yaptığı görülmektedir.




Şekil 4.35. Senaryo-5'teki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.36'da gösterilmiştir ve yaklaşık olarak eğitim veri kümesindeki gibi başarılı sonuçlar elde edilmiştir.



Şekil 4.36. Senaryo-5'teki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.37'de görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.37. Senaryo-5'teki eğitim ve test verisinin regresyon doğruları

Senaryo-5'in hata ve başarımları Tablo 4.12'de sunulmuştur. Hata ve başarımlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.12. Senaryo-5 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.06824	0.00465	0.97133
Test Veri Kümesi	0.14596	0.02130	0.83441

Senaryo-5'te k-katlamalı çapraz doğrulama modelin başarımını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.38'de ve test veri kümesi için Şekil 4.39'da verilmiştir.




Şekil 4.38. Senaryo-5'deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.39. Senaryo-5'teki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-5'te her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.40'ta ve test veri kümesi için Şekil 4.41'de verilmiştir.



Şekil 4.40. Senaryo-5'teki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.41. Senaryo-5'teki test verisinin k-katlamalı regresyon doğruları

Senaryo-5'te eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar oranları Tablo 4.13'te verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.13. Senaryo-5 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.08224	0.00685	0.95615
Test Veri Kümesi	0.09150	0.01029	0.94031

Senaryo-6, modelde Veri Kümesi-3 kullanıldığı durumudur. Senaryo-6 için eğitim süreci tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.42'de gösterildiği gibi modelin genel olarak başarılı bir tahminleme yapabildiği görülmektedir.




Şekil 4.42. Senaryo-6'daki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.43'te gösterilmiştir. Eğitim veri kümesindeki tahminlerden daha az başarılı sonuçlar elde edilmiştir.



Şekil 4.43. Senaryo-6'daki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.44'te görüldüğü gibi güçlü bir ilişki elde edilmiştir.



Şekil 4.44. Senaryo-6'daki eğitim ve test verisinin regresyon doğruları


Senaryo-6'nın hata ve başarımlar oranları Tablo 4.14'te sunulmuştur. Hata ve başarımlar oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.

Tablo 4.14. Senaryo-6 eğitim ve test veri kümelerinin hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.06873	0.00472	0.96883
Test Veri Kümesi	0.06799	0.00462	0.93465

Senaryo-6'da k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.45'te ve test veri kümesi için Şekil 4.46'da verilmiştir.


Senaryo-6'da her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.47'de ve test veri kümesi için Şekil 4.48'de verilmiştir.




Şekil 4.45. Senaryo-6'daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.46. Senaryo-6'daki test verisinin k-katlamalı tahmin sonuçları ve hataları



Şekil 4.47. Senaryo-6'daki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.48. Senaryo-6'daki test verisinin k-katlamalı regresyon doğruları


Senaryo-6’da eğitim ve test veri kümeleri için ortalama hata oranları ve başarımları Tablo 4.15’te verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.15. Senaryo-6 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.06698	0.00449	0.96744
Test Veri Kümesi	0.15003	0.03341	0.77513

4.3. TBA Uygulanan Veri Üzerine Çalışma

Toplanan ham deprem verisinden Panakkat depremsellik göstergeleri kullanılarak çıkarılan özellikleri barındıran Veri Kümesi-1, Veri Kümesi-2 ve Veri Kümesi-3 elde edilmiştir. Bu veri kümeleri 7 özelliğe sahiptir. Bu veri boyutunun azaltılması amacıyla uygulanan temel bileşenler analizi ile veri kümesindeki özellik sayısı 4’e düşürülmüştür. TBA uygulamasında özellik sayısı belirlenirken özellik kabul oranı en az %95 olarak belirlenmiştir ve sonuçlar Şekil 4.49’da verilmiştir. Bu şekilde yeni veri kümeleri elde edilmiştir. Veri kümeleri oluşturulurken son 20 yıllık deprem verileri eşik büyüklüğü 4.0 seçildiğinde Veri Kümesi-4, eşik büyüklüğü 4.5 seçildiğinde Veri Kümesi-5 ve eşik büyüklüğü 5.0 seçildiğinde Veri Kümesi-6 elde edilmiştir. Bu veri kümeleri kullanılarak yapılan çalışmalarda elde edilen bulgulara bu bölümde yer verilmiştir. Model olarak ilk önce uzun-kısa süreli bellek (UKSB) uygulaması yapılmıştır, sonra da uyarlamalı sinirsel bulanık çıkarım sistemi (USBÇS) uygulaması yapılmıştır. Veri kümelerinin %80’lik kısmı eğitim için kalan kısmı da test için kullanılmıştır. Ayrıca k-katlamalı çapraz doğrulama tekniği uygulanmıştır ve k-katlama değeri 5 olarak seçilmiştir.




Şekil 4.49. TBA uygulaması ile özellik seçim oranları

4.3.1. Uzun-Kısa Süreli Bellek Uygulaması


Önerilen UKSB modeli, Şekil 4.3'te blok diyagramı verilen ve Tablo 4.3'te verilen parametrelere göre tasarlanmıştır. Oluşturulan veri kümeleri tek tek verilerek 3 farklı senaryo için modelin sonuçları elde edilmiştir. Değerlendirme ölçütleri olarak yine eğitim ve test veri kümeleri için hata oranları Kök Ortalama Karesel Hata (KOKH) ve Ortalama Karesel Hata (OKH) hesaplanarak ortaya konulmuştur. Ayrıca modelin başarımını göstermek adına R^2 skoru hesaplanmıştır.

Senaryo-7, Veri Kümesi-4 kullanıldığı durumdur. Senaryo-7 gerçekleştiğinde, modelin eğitim süreci ile ilgili olarak modelin eğitimdeki hatası ve geçerlemenin hatası Şekil 4.50'de gösterilmiştir. Şekle bakıldığında modelin küçük hata oranında eğitim sürecini tamamladığı görülmektedir.




Şekil 4.50. Senaryo-7'deki model eğitimi ve geçerlemede epok başına kayıp grafiği

Senaryo-7'de eğitim süreci tamamlandıktan sonra eğitim ve test veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesinde yapılan tahminler modelin başarılı tahminler ortaya çıkardığını göstermektedir. Bu durum ile ilgili grafik, Şekil 4.51'de verilmiştir. Eğitim veri kümesinin büyük bir kısmında tahmin edilen değerler, gerçek değerlerin altında bir kısmında da gerçek değerlerin üstünde tahmin edilmiştir. Burada hem negatif yönlü hem de pozitif yönlü hatalar olduğu görülmektedir.




Şekil 4.51. Senaryo-7'deki eğitim verisinin tahmin sonuçları ve hataları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.52'de gösterildiği ve eğitim veri kümesindeki tahminlerde olduğu gibi başarılı sonuçlar elde edilmiştir. Test veri kümesinin neredeyse tamamında tahmin edilen değerler, küçük hatalarla tahmin edilmiştir. Hem negatif hem de pozitif yönlü hatalar olduğu görülmektedir.



Şekil 4.52. Senaryo-7'deki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.53'te görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.53. Senaryo-7'deki eğitim ve test verisinin regresyon doğruları

Senaryo-7'nin hata ve başarımlar oranları Tablo 4.16'da sunulmuştur. Hata ve başarımlar oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.16. Senaryo-7 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R^2
Eğitim Veri Kümesi	0.02236	0.00050	0.99708
Test Veri Kümesi	0.03055	0.00093	0.99565

Senaryo-7'de k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.54'te ve test veri kümesi için Şekil 4.55'te verilmiştir.




Şekil 4.54. Senaryo-7’deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.55. Senaryo-7’deki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-7’de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.56’da ve test veri kümesi için Şekil 4.57’de verilmiştir.



Şekil 4.56. Senaryo-7’deki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.57. Senaryo-7’deki test verisinin k-katlamalı regresyon doğruları

Senaryo-7’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımları Tablo 4.17’de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.17. Senaryo-7 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.05039	0.00373	0.97882
Test Veri Kümesi	0.06013	0.00540	0.97242

Senaryo-8, Veri Kümesi-5 kullanıldığı durumdur. Senaryo-8 gerçekleştiğinde, modelin eğitim süreci ile ilgili olarak modelin eğitimdeki hatası ve geçerlemenin hatası Şekil 4.58'de gösterilmiştir. Şekil incelendiğinde modelin küçük hata oranında eğitim sürecini tamamladığı görülmektedir.




Şekil 4.58. Senaryo-8'deki model eğitimi ve geçerlemede epok başına kayıp grafiği

Senaryo-8'de eğitim tamamlandıktan sonra eğitim ve test veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesinde yapılan tahminler modelin başarılı tahminler ortaya çıkardığını göstermektedir. Bu durum ile ilgili grafik, Şekil 4.59'da verilmiştir. Eğitim veri kümesinin tamamında tahmin edilen değerler, gerçek değerlerin altında tahmin edilmiştir. Yani negatif yönlü hatalar olduğu görülmektedir.




Şekil 4.59. Senaryo-8'deki eğitim verisinin tahmin sonuçları ve hataları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.60'ta gösterildiği ve eğitim veri kümesindeki tahminlerde olduğu gibi başarılı sonuçlar elde edilmiştir. Eğitim veri kümesinde tahmin edilen değerler gibi test veri kümesinin de tamamında tahmin edilen değerler, gerçek değerlerin altında tahmin edilmiştir. Yani negatif yönlü hatalar görülmektedir.



Şekil 4.60. Senaryo-8'deki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.61'de görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.61. Senaryo-8'deki eğitim ve test verisinin regresyon doğruları

Senaryo-8'in hata ve başarımları Tablo 4.18'de sunulmuştur. Hata ve başarımlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.18. Senaryo-8 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R^2
Eğitim Veri Kümesi	0.05686	0.00323	0.97751
Test Veri Kümesi	0.07151	0.00511	0.97485

Senaryo-8'de k-katlamalı çapraz doğrulama modelin başarımını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.62'de ve test veri kümesi için Şekil 4.63'te verilmiştir.




Şekil 4.62. Senaryo-8’deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.63. Senaryo-8’deki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-8’de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.64’te ve test veri kümesi için Şekil 4.65’te verilmiştir.



Şekil 4.64. Senaryo-8’deki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.65. Senaryo-8’deki test verisinin k-katlamalı regresyon doğruları

Senaryo-8’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımları Tablo 4.19’de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.19. Senaryo-8 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.04491	0.00233	0.98505
Test Veri Kümesi	0.04931	0.00274	0.97996

Senaryo-9, Veri Kümesi-6 kullanıldığı durumdur. Senaryo-9 gerçekleştiğinde, modelin eğitim süreci ile ilgili olarak modelin eğitimdeki hatası ve geçerlemenin hatası Şekil 4.66'da gösterilmiştir. Şekil incelendiğinde modelin küçük hata oranında eğitimi tamamladığı görülmektedir.




Şekil 4.66. Senaryo-9'daki model eğitimi ve geçerlemede epok başına kayıp grafiği

Senaryo-9 için eğitim süreci tamamlandıktan sonra eğitim ve test veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesinde yapılan tahminler modelin başarılı tahminler ortaya çıkardığını göstermektedir. Bu durum ile ilgili grafik, Şekil 4.67'de verilmiştir. Eğitim veri kümesinin büyük bir kısmında tahmin edilen değerler, gerçek değerlerin üstünde tahmin edilmiştir. Yani pozitif yönlü hatalar olduğu görülmektedir.




Şekil 4.67. Senaryo-9'daki eğitim verisinin tahmin sonuçları ve hataları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.68'de gösterildiği ve eğitim veri kümesindeki tahminlerde olduğu gibi başarılı sonuçlar elde edilmiştir. Eğitim veri kümesinde tahmin edilen değerler gibi test veri kümesinin de büyük bir kısmında tahmin edilen değerler, gerçek değerlerin üstünde tahmin edilmiştir. Yani pozitif yönlü hatalar görülmektedir.



Şekil 4.68. Senaryo-9'daki test verisinin tahmin sonuçları ve hataları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.69'da görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.69. Senaryo-9'daki eğitim ve test verisinin regresyon doğruları

Senaryo-9'un hata ve başarımlar oranları Tablo 4.20'de sunulmuştur. Hata ve başarımlar oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.20. Senaryo-9 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.03317	0.00110	0.99105
Test Veri Kümesi	0.04173	0.00174	0.99098

Senaryo-9'da k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.70'te ve test veri kümesi için Şekil 4.71'de verilmiştir.




Şekil 4.70. Senaryo-9'daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.71. Senaryo-9'daki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-9’da her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.72’de ve test veri kümesi için Şekil 4.73’te verilmiştir.



Şekil 4.72. Senaryo-9’daki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.73. Senaryo-9’daki test verisinin k-katlamalı regresyon doğruları

Senaryo-9’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar Tablo 4.21’de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.


Tablo 4.21. Senaryo-9 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.03548	0.00145	0.98893
Test Veri Kümesi	0.03939	0.00174	0.98601

4.3.2. Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin Uygulanması


Bu bölümde kullanılan USBÇS modeli, TBA uygulaması ile elde edilen 4 özellik olduğu için 4 girdi ve deprem büyüklüğü için 1 çıktı değişkeni kullanılmıştır. Her girdi değeri için iki dilsel etiket atanmıştır ve bu yapıda 16 (2^4) kural içeren bir ağ yapısı oluşturulmuştur. Modele oluşturulan veri kümeleri tek tek verilerek 3 farklı senaryo için eğitim ve test veri kümeleri üzerinde tahminler yapılmıştır ve modelin sonuçları elde edilmiştir. Eğitim ve test veri kümeleri için hata oranları KOKH ve OKH hesaplanmıştır ve modelin başarımını göstermek adına R² skoru hesaplanmıştır.

Senaryo-10, modelde Veri Kümesi-4 kullanıldığı durumdur. Senaryo-10 için eğitim tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümelerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.74'te gösterildiği gibi modelin başarılı bir tahminleme yapabildiği görülmektedir.




Şekil 4.74. Senaryo-10'daki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.75'te gösterildiği ve genel olarak başarılı sonuçlar elde edilmiştir.



Şekil 4.75. Senaryo-10'daki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.76'da görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.76. Senaryo-10'daki eğitim ve test verisinin regresyon doğruları

Senaryo-10'un hata ve başarı oranları Tablo 4.22'de sunulmuştur. Hata ve başarı oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.22. Senaryo-10 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.11672	0.01362	0.92224
Test Veri Kümesi	0.13595	0.01848	0.90891

Senaryo-10’da k-katlamalı çapraz doğrulama modelin başarımını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.77’de ve test veri kümesi için Şekil 4.78’de verilmiştir.




Şekil 4.77. Senaryo-10’daki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.78. Senaryo-10'daki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-10'da her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.79'da ve test veri kümesi için Şekil 4.80'de verilmiştir.



Şekil 4.79. Senaryo-10'daki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.80. Senaryo-10'daki test verisinin k-katlamalı regresyon doğruları

Senaryo-10'da eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar oranları Tablo 4.23'te verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.23. Senaryo-10 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R^2
Eğitim Veri Kümesi	0.11013	0.01214	0.93275
Test Veri Kümesi	0.11794	0.01540	0.91821

Senaryo-11, modelde Veri Kümesi-5 kullanıldığı durumdur. Senaryo-11 için eğitim süreci tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.81'de gösterildiği gibi modelin gayet başarılı bir tahminleme yaptığı görülmektedir.




Şekil 4.81. Senaryo-11'deki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.82'de gösterilmiştir ve eğitim veri kümesindeki tahminler gibi başarılı sonuçlar elde edilmiştir.



Şekil 4.82. Senaryo-11'deki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.83'te görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.83. Senaryo-11'deki eğitim ve test verisinin regresyon doğruları

Senaryo-11'in hata ve başarımlar oranları Tablo 4.24'te sunulmuştur. Hata ve başarımlar oranlarının doğrultusunda başarılı bir model olduğu görülmektedir.


Tablo 4.24. Senaryo-11 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.06130	0.00375	0.97603
Test Veri Kümesi	0.09253	0.00856	0.94450

Senaryo-11'de k-katlamalı çapraz doğrulama modelin başarımlarını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.84'te ve test veri kümesi için Şekil 4.85'te verilmiştir.




Şekil 4.84. Senaryo-11’deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.85. Senaryo-11’deki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-11’de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.86’da ve test veri kümesi için Şekil 4.87’de verilmiştir.



Şekil 4.86. Senaryo-11’deki eğitim verisinin k-katlamalı regresyon doğruları




Şekil 4.87. Senaryo-11’deki test verisinin k-katlamalı regresyon doğruları

Senaryo-11’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımları Tablo 4.25’te verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.25. Senaryo-11 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları


	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.06423	0.00413	0.97350
Test Veri Kümesi	0.08332	0.00804	0.95349

Senaryo-12, modelde Veri Kümesi-6 kullanıldığı durumdur. Senaryo-12 için eğitim süreci tamamlandıktan sonra, eğitim ve test olarak ayrılmış veri kümeleri üzerinde tahminlemeler yapılmıştır. Eğitim veri kümesi üzerinde tahminlemeler yapıldığında Şekil 4.88’de gösterildiği gibi modelin genel olarak başarılı bir tahminleme yapabildiği görülmektedir.




Şekil 4.88. Senaryo-12’deki eğitim verisinin tahmin sonuçları

Test veri kümesi üzerinde tahminler yapıldığında Şekil 4.89’da gösterilmiştir. Eğitim veri kümesindeki tahminlerden daha az başarılı sonuçlar elde edilmiştir.



Şekil 4.89. Senaryo-12'deki test verisinin tahmin sonuçları

Verilerin arasındaki ilişkiyi göstermek için regresyon doğrusu çizildiğinde sırasıyla eğitim ve test veri kümeleri için Şekil 4.90'da görüldüğü gibi güçlü bir ilişki elde edilmiştir.




Şekil 4.90. Senaryo-12'deki eğitim ve test verisinin regresyon doğruları

Senaryo-12 için hata oranları ve başarımları Tablo 4.26'da verilmiştir. Eğitim veri kümesinin sonuçlarına göre hata oranlarının düşük olduğu ve başarımlarının yüksek olduğu öte yandan test veri kümesindeki hata oranlarının ve başarımlarının eğitim veri kümesindeki sonuçlara göre düşük olduğu görülmektedir.


Tablo 4.26. Senaryo-12 eğitim ve test veri kümelerinin hata oranları ve başarımları

	KOKH	OKH	R ²
Eğitim Veri Kümesi	0.05100	0.00260	0.97491
Test Veri Kümesi	0.13879	0.01926	0.92423

Senaryo-12’de k-katlamalı çapraz doğrulama modelin başarımını değerlendirmek için kullanılmıştır. Bu amaçla k-katlama değeri 5 olarak seçilmiştir ve her bir katlamaya ait tahminleme sonuçları eğitim veri kümesi için Şekil 4.91’de ve test veri kümesi için Şekil 4.92’de verilmiştir.




Şekil 4.91. Senaryo-12’deki eğitim verisinin k-katlamalı tahmin sonuçları ve hataları




Şekil 4.92. Senaryo-12’deki test verisinin k-katlamalı tahmin sonuçları ve hataları

Senaryo-12’de her bir katlamaya ait regresyon doğruları eğitim veri kümesi için Şekil 4.93’te ve test veri kümesi için Şekil 4.94’te verilmiştir.



Şekil 4.93. Senaryo-12’deki eğitim verisinin k-katlamalı regresyon doğruları



Şekil 4.94. Senaryo-12’deki test verisinin k-katlamalı regresyon doğruları

Senaryo-12’de eğitim ve test veri kümeleri için ortalama hata oranları ve başarımlar oranları Tablo 4.27’de verilmiştir. Modelin tutarlı sonuçlar ürettiği görülmektedir.

Tablo 4.27. Senaryo-12 eğitim ve test veri kümeleri k-katlamalı ortalama hata oranları ve başarımları

	KOKH	OKH	R^2
Eğitim Veri Kümesi	0.05454	0.00298	0.97831
Test Veri Kümesi	0.07498	0.00688	0.94310


4.4. Tartışma

Tez çalışması kapsamında son 5 yıllık, son 10 yıllık ve son 20 yıllık veri kümeleri şeklinde alınan ham veriler, literatürde depremsellik göstergeleri olarak adlandırılan özellik çıkarma yöntemi kullanılarak deprem büyüklük yasalarına dayanan yeni özellikleri barındıran yeni veri kümeleri elde edilmiştir. Bu veri kümeleri eşik büyüklüğünün 4.0, 4.5 ve 5.0 seçildiği durumlara göre hesaplanan depremsellik göstergeleri ile oluşturulmuştur. Bu veri kümelerinden tez çalışmasında daha kapsamlı olan son 20 yıllık veri kümesi kullanılmıştır. Ayrıca veri boyutluluğunu azaltmak için

elde edilen veri kümelerine TBA uygulaması ile yeni veri kümeleri türetilmiştir. Veri kümeleri rastsalılığı sağlamak adına Şekil 4.1'de sözde kodu gösterilen karıştırma fonksiyonu kullanılmıştır. Böylelikle önerilen modellerin gelecek zamanlarda karşılaşacağı veriler karşısında da tutarlı sonuçlar üretebilmesine yardımcı olunmak istenmiştir. Bu çalışma kapsamında, önerilen UKSB ve USBÇS modelleri ile kullanılan veri kümeleri üzerinde tahminler yapılmıştır. Kullanılan veri kümelerinin %80'lik kısmı eğitim veri kümesi kalan kısmı da test veri kümesi olarak kullanılmıştır. Ayrıca k-katlamalı çapraz doğrulama modellerin başarımını değerlendirmek için kullanılmıştır ve k-katlama değeri 5 olarak seçilmiştir.


Bu bölümde test veri kümeleri üzerinde yapılan tahminlerle elde edilen bulgular için değerlendirmeler yapılmıştır.

UKSB modelinin TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı ve k-katlamalı çapraz doğrulama tekniği uygulandığında yapılan tahminlerin aritmetik ortalaması alındığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.95'te verilmiştir.




Şekil 4.95. Senaryo 1-3 arasındaki test verilerinin R^2 skorları

USBÇS modelinin TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı ve k-katlamalı çapraz doğrulama tekniği uygulandığında yapılan tahminlerin aritmetik ortalaması alındığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.96'da verilmiştir.




Şekil 4.96. Senaryo 4-6 arasındaki test verilerinin R^2 skorları

UKSB modelinin TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı ve k-katlamalı çapraz doğrulama tekniği uygulandığında yapılan tahminlerin aritmetik ortalaması alındığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.97’de verilmiştir.



Şekil 4.97. Senaryo 7-9 arasındaki test verilerinin R^2 skorları


USBÇS modelinin TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı ve k-katlamalı çapraz doğrulama tekniği uygulandığında yapılan tahminlerin aritmetik ortalaması alındığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.98’de verilmiştir.



Şekil 4.98. Senaryo 10-12 arasındaki test verilerinin R^2 skorları

k-Katlamalı çapraz doğrulama tekniği ile Senaryo-6 hariç tüm senaryolarda R^2 skorları açısından tutarlı olduğu görülmektedir. Hariç tutulan bu senaryoda kullanılan veri kümesinin niceliksel özelliği ile ilgilidir. Bu veri kümesinin eleman sayısı az olduğu için karşılaşılan örneklem sayısı da düşük olmuştur. Bu sebeple bu senaryonun sonuçlarının diğerlerine göre başarısız olduğu çıkarımı yapılabilir.


UKSB modelinin TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı ve TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırılması Şekil 4.99'da verilmiştir.



Şekil 4.99. Senaryo 1-3 ve Senaryo 7-9 arasındaki test verilerinin R^2 skorları

UKSB modeli için Şekil 4.99 incelendiğinde, veri boyutluluğunu azaltmak için veri kümelerine TBA uygulaması ile türetilen yeni veri kümeleri için de tahminler yapıldığında elde edilen sonuçların tutarlı olduğu görülmektedir. Burada TBA uygulamasının başarılı bir şekilde gerçekleştirildiği çıkarımı yapılabilir.


USBÇS modelinin TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı ve TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.100'de verilmiştir.



Şekil 4.100. Senaryo 4-6 ve Senaryo 10-12 arasındaki test verilerinin R^2 skorları

USBÇS modeli için Şekil 4.100 incelendiğinde, veri boyutluluğunu azaltmak için veri kümelerine TBA uygulaması ile türetilen yeni veri kümeleri için de tahminler yapıldığında elde edilen sonuçların daha stabil hale geldiği görülmektedir. Burada TBA uygulamasının verileri daha uygun hale getirmesi açısından başarılı bir şekilde gerçekleştirildiği çıkarımı yapılabilir.


UKSB ve USBÇS modelinin TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.101'de verilmiştir.



Şekil 4.101. Senaryo 1-3 ve Senaryo 4-6 arasındaki test verilerinin R^2 skorları

TBA uygulanmamış test veri kümeleri üzerinde tahminler yapıldığı sonuçların gösterildiği Şekil 4.101 incelendiğinde, UKSB modelinin sonuçların daha iyi olduğu görülmektedir. Bu modelin mevcut veriler ile deprem büyüklüğü tahmini problemine çözüm getirebileceği çıkarımı yapılabilir.

UKSB ve USBÇS modelinin TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı senaryolarda ortaya çıkan R^2 skorlarının karşılaştırıldığı grafik Şekil 4.102’de verilmiştir.



Şekil 4.102. Senaryo 7-9 ve Senaryo 10-12 arasındaki test verilerinin R^2 skorları

TBA uygulanmış test veri kümeleri üzerinde tahminler yapıldığı sonuçların

gösterildiği Şekil 4.102 incelendiğinde, modellerin başarılı sonuçlar ortaya görülmektedir. TBA uygulandığında türetilen yeni veri kümeleri için tahminler yapıldığında elde edilen sonuçların daha stabil hale geldiği görülmektedir. Bu modellerin TBA uygulandığı mevcut veriler ile deprem büyüklüğü tahmini problemine çözüm getirebileceği çıkarımı yapılabilir.

Bu noktaya kadar tüm senaryolar için k-katlamalı çapraz doğrulama tekniğinin ve TBA uygulamasının veri kümeleri ve modeller üzerine olan etkileri elde edilen bulgular vasıtasıyla değerlendirilmiştir. Modeller için en iyi sonuçların TBA uygulanmamış ve TBA uygulanmış veri kümelerinin kullanıldığı senaryolara ait hata oranları ve başarımlar Tablo 4.28’de verilmiştir.

Tablo 4.28. Test veri kümelerinde en iyi hata oranları ve başarımları

Senaryo No	Kullanılan Veri Kümesi	Test Veri Kümeleri Hata Oranları ve Başarımları		
		KOKH	OKH	R ²
3	Veri Kümesi – 3	0.03347	0.00112	0.99259
6	Veri Kümesi – 3	0.06799	0.00462	0.93465
7	Veri Kümesi – 4	0.03055	0.00093	0.99565
11	Veri Kümesi – 5	0.09253	0.00856	0.94450

Senaryo-3, Veri Kümesi-3’ün kullanıldığı UKSB modelidir. Veri Kümesi-3, son 20 yıldaki eşik büyüklüğü 5.0 seçildiği durumda elde edilen TBA uygulanmamış verileri içeren veri kümesidir. TBA uygulanmamış veriler ile en iyi sonuçları veren UKSB modeli için, daha çok tarihsel verinin barındığı nispeten yüksek eşik büyüklüğündeki depremleri tahmin etmede başarılı olduğu çıkarımı yapılabilir.

Senaryo-6, Veri Kümesi-3’ün kullanıldığı USBÇS modelidir. Veri Kümesi-3, son 20 yıldaki eşik büyüklüğü 5.0 seçildiği durumda elde edilen TBA uygulanmamış verileri içeren veri kümesidir. TBA uygulanmamış veriler ile en iyi sonuçları veren USBÇS modeli için, uzun vadeli verilerde nispeten yüksek eşik büyüklüğündeki depremleri tahmin etmede başarılı olduğu çıkarımı yapılabilir.

Senaryo-7, Veri Kümesi-4’ün kullanıldığı UKSB modelidir. Veri Kümesi-4,

son 20 yıldaki eşik büyüklüğü 4.0 seçildiği durumda elde edilen TBA uygulanmış verileri içeren veri kümesidir. TBA uygulanmış veriler ile en iyi sonuçları veren UKSB modeli için, daha çok tarihsel veri ile düşük eşik büyüklüğündeki depremleri tahmin etmede başarılı olduğu çıkarımı yapılabilir.

Senaryo-11, Veri Kümesi-5'in kullanıldığı USBÇS modelidir. Veri Kümesi-5, son 20 yıldaki eşik büyüklüğü 4.5 seçildiği durumda elde edilen TBA uygulanmış verileri içeren veri kümesidir. TBA uygulanmış veriler ile en iyi sonuçları veren USBÇS modeli için, daha çok tarihsel verilerde nispeten orta dereceli eşik büyüklüğündeki depremleri tahmin etmede başarılı olduğu çıkarımı yapılabilir.

Öte yandan literatürde yapılan çalışmalar ile bu çalışmanın karşılaştırılması kullanılan yöntem ve depremsellik göstergeleri açısından Tablo 4.29'da yapılmıştır.

Tablo 4.29. Önceki çalışmalar ile önerilen çalışmanın karşılaştırılması

Çalışma	Kullanılan Yöntemler	Performans Ölçütü
Wang et al., 2017	LSTM	Doğruluk: %85.59
Asim et al., 2018a	SVR-HNN	Doğruluk: %90.6
Asim et al., 2018b	GP-Adaboost	Doğruluk: %86.6
Yousefzadeh et al., 2021	DNN, SNN, SVM, DT	DT için Doğruluk: %100 SVM için Duyarlılık: %97.7
Sebatlı-Sağlam and Çavdur, 2022	LMBP, BRBP	LMBP için R-skor: 0.96 BRBP için R-skor: 0.97
Budakoğlu, 2022	ANFIS	R ² -skor: 0.99
Sadhukhan et al., 2023	LSTM, Bi-LSTM, Transformer	LSTM için OKH: 0.006 Bi-LSTM için OKH: 0.009 Transformer için OKH: 0.006
Önerilen Model	LSTM, ANFIS	LSTM için R ² -skor: 0.99 ANFIS için R ² -skor: 0.94

5. SONUÇ

Doğal afetlerin en yıkıcılarından biri olan ve zamanı belirsiz biçimde oluşan deprem, olduğu bölgede ekonomik ve sosyal kayıplara yol açabilmektedir. Bu durum, depremi önceden tahminlemeyi önemli bir araştırma konusu haline getirmekte olup depremin ne zaman, nerede ve ne kadar büyük olacağı öngörülmeye çalışılmaktadır. Son yıllarda, teknolojik gelişmeler sayesinde birçok hayati soruna çözümler sunulduğu gibi bu sorunlardan biri deprem için de çözüm önerileri getirilmiştir. Henüz tam bir tahmin sistemi oluşturulmamış olsa da yapay zekâ alanındaki ilerlemeler, gelecekte daha etkili çözümlerin mümkün olabileceğine işaret etmektedir.

Bu tez çalışmasında UKSB ve USBÇS yöntemleri ile meydana gelebilecek deprem büyüklüğü tahminleme yapılması hedeflenmiştir. Bu amaçla ilk olarak, deprem verileri katalogdan elde edilmiştir. Bu veriler, belirli filtreleme işlemleri uygulanarak son 5 yıla, son 10 yıla ve son 20 yıla ait deprem kayıtlarına ulaşılmıştır. Daha sonra, depremsellik göstergeleri olarak adlandırılan özellik çıkarma yöntemleri kullanılarak hesaplamalar yapılmıştır. Bu hesaplamalar, yıllık bazda yapılan filtrelemelere göre her 5, 10 ve 20 yıllık veriler için belirli eşik büyüklükleri seçilerek gerçekleştirilmiştir. Bu çalışmada daha kapsayıcı olan son 20 yıllık verilerin kullanılmasına karar verilmiştir. Verilerin daha iyi analiz edilebilmesi için, 0-1 aralığında normalleştirme işlemi uygulanmıştır. Böylelikle 3 yeni veri kümesi oluşturulmuştur. Önerilen yöntemler bu 3 veri kümesi üzerinde uygulanmıştır. Her bir uygulama bir senaryo olarak nitelendirilmiştir. Senaryo 1-3 arası UKSB ağırları yöntemi için, Senaryo 4-6 arası USBÇS yöntemi için oluşturulmuştur. Senaryolarda k-katlamalı çapraz doğrulama modellerin başarımını değerlendirmek için kullanılmıştır. Veri kümelerinin boyutluluğunu azaltmak için her bir veri kümesine TBA uygulanmıştır. Yedi özellik TBA uygulanmasıyla özellik kabul oranı %95 seçilerek dört özelliğe indirilmiştir. Bu özellikler ile yeni 3 veri kümesi türetilmiştir. Bu yeni veri kümeleri için de yeni senaryolar oluşturulmuştur. Senaryo 7-9 arası TBA uygulanarak elde edilmiş yeni veri kümelerinin kullanıldığı UKSB yöntemi için, Senaryo 10-12 arası TBA uygulanarak elde edilmiş yeni veri kümelerinin kullanıldığı USBÇS yöntemi için oluşturulmuştur. Burada da her bir senaryo için k-katlamalı çapraz doğrulama tekniği uygulanmıştır.

Önerilen iki modelin de değerlendirme ölçütleri KOKH, OKH ve R^2 skoru

olarak belirlenmiştir ve değerlendirmeler yapılmıştır. Yapılan değerlendirmeler doğrultusunda daha düşük eşik büyüklüğündeki TBA uygulanmış verilerde UKSB modelinin başarılı sonuçlar elde ettiği görülmüştür. Bu tarife en uygun senaryonun Senaryo-7 olduğu görülmüştür. Bu senaryodaki R^2 skoru 0.99565 olarak ölçülmüştür. Nispeten daha yüksek eşik büyüklüğündeki TBA uygulanmamış verilerde yine UKSB yönteminin başarılı sonuçlar elde ettiği görülmüştür. Buradaki senaryo, Senaryo-3'tür. Bu senaryodaki R^2 skoru 0.99259 olarak ölçülmüştür.

Gelecek çalışmalarda Türkiye coğrafyası için farklı deprem kataloglarının kullanılmasıyla daha fazla sayıda tarihsel verinin elde edilmesi ve bu verilere farklı özellik çıkarma yöntemlerinin uygulanmasıyla elde edilen yeni verinin yöntemlere uygulanmasıyla geliştirilen modellerin deprem tahminine faydalı sonuçlar üreteceği ve daha sonrasında daha geniş bir etki alanında kullanılması düşünülmektedir.

Deprem büyüklüğü tahmini, afet sonrası etkinin öngörülmesi ve dolayısıyla afet kurtarma süreçlerinin düzeyinin belirlenmesinde kritik bir rol oynamaktadır. Bu çalışmada önerilen model, deprem sonrası yaralı sayısı, binalardaki hasar ve ekonomik kaybın tahmini gibi başka çalışmaların yapılmasını da mümkün kılmaktadır. Ayrıca afet yardım süreçlerinde yerel ve merkezi yönetim birimleri için etkin planlar oluşturulabilmesi önemli bir durumdur. Bu amaçla gelecekteki bir diğer araştırma alanı da deprem büyüklüğü tahmininin, afet yönetimi kapsamında diğer çalışmalarla tümleşik hale getirilmesidir. Böylelikle yardım tesislerinin konumlandırılması ve kapasitelerinin belirlenmesi önceden yapılabilir ve dağıtılacak yardım malzemelerinin talep miktarları, büyüklük tahmin modeli ile birleştirilerek bütünsel bir yapı oluşturulabilir.

KAYNAKLAR

- Abri, R., & Artuner, H. (2022). LSTM-based deep learning methods for prediction of earthquakes using ionospheric data. *Gazi University Journal of Science*, 35(4), s. 1417-1431. doi:10.35378/gujs.950387
- Adeli, H., & Panakkat, A. (2009). A probabilistic neural network for earthquake magnitude prediction. *Neural Networks*, 22(7), s. 1018-1024. doi:10.1016/j.neunet.2009.05.003
- Alarifi, A., Alarifi, N., & Al-Humidan, S. (2012). Earthquakes magnitude predication using artificial neural network in northern Red Sea area. *Journal of King Saud University - Science*, 24(4), s. 301-313. doi:10.1016/j.jksus.2011.05.002
- Alexandridis, A., Chondrodima, E., Efthimiou, E., Papadakis, G., Vallianatos, F., & Triantis, D. (2014). Large Earthquake Occurrence Estimation Based on Radial Basis Function Neural Networks. *IEEE Transactions on Geoscience and Remote Sensing*, 52(9), s. 5443-5453. doi:10.1109/TGRS.2013.2288979
- Amar, E., Khattab, T., & Zada, F. (2014). Earthquake prediction system based on neural network. *International Journal of Civil and Environmental Engineering*, 8(12), s. 874-878. doi:10.5281/zenodo.1337607
- Asencio-Cortés, G., Martínez-Álvarez, F., Morales-Esteban, A., & Reyes, J. (2016). A sensitivity study of seismicity indicators in supervised learning to improve earthquake prediction. *Knowledge-Based Systems*, 101, s. 15-30. doi:10.1016/j.knosys.2016.02.014
- Asencio-Cortés, G., Martínez-Álvarez, F., & Troncoso, A. (2017). Medium-large earthquake magnitude prediction in Tokyo with artificial neural networks. *Neural Computing and Applications*, 28, s. 1043-1055. doi:10.1007/s00521-015-2121-7
- Asencio-Cortés, G., Martínez-Álvarez, F., Reyes, J., Troncoso, A., & Morales-Esteban, A. (2015). Improving earthquake prediction with principal component analysis: Application to Chile. *Hybrid Artificial Intelligent Systems*, 9121, s. 393-404. doi:10.1007/978-3-319-19644-2_33
- Asim, K., Awais, M., Martínez-Álvarez, F., & Iqbal, T. (2017). Seismic activity prediction using computational intelligence techniques in northern Pakistan. *Acta Geophysica*, 65(5), s. 919-930. doi:10.1007/s11600-017-0082-1
- Asim, K., Idris, A., Iqbal, T., & Martinez-Alvarez, F. (2018a). Earthquake prediction model using support vector regressor and hybrid neural networks. *PLoS ONE*, 13(7). doi:10.1371/journal.pone.0199004
- Asim, K., Idris, A., Iqbal, T., & Martínez-Álvarez, F. (2018b). Seismic indicators based earthquake predictor system using Genetic Programming and AdaBoost classification. *Soil Dynamics and Earthquake Engineering*, 111, s. 1-7. doi:10.1016/j.soildyn.2018.04.020
- Asim, K., Idris, A., Martínez-Álvarez, F., & Iqbal, T. (2016b). Short Term Earthquake Prediction in Hindukush Region Using Tree Based Ensemble Learning. *International Conference on Frontiers of Information Technology* (s. 365-370). Islamabad: IEEE. doi:doi.org/10.1109/FIT.2016.073
- Asim, K., Martínez-Álvarez, F., Basit, A., & Iqbal, T. (2016a). Earthquake magnitude prediction in Hindukush region using machine learning techniques. *Natural Hazards*, 85, s. 471-486. doi:10.1007/s11069-016-2579-3
- Berhich, A., Belouadha, F.-Z., & Kabbaj, M. I. (2021). LSTM-based earthquake prediction: enhanced time feature and data representation. *International Journal of High Performance Systems Architecture*, 10, s. 1-11. doi:10.1504/IJHPSA.2021.115499

- Biswal, A. (2022, 11 22). Recurrent Neural Network (RNN) Tutorial: Types, Examples, LSTM and More. <https://www.simplilearn.com/tutorials/deep-learning-tutorial/rnn> adresinden alındı
- Brownlee, J. (2020). Hyperparameter Optimization With Random Search and Grid Search. 10 15, 2022 tarihinde <https://machinelearningmastery.com/hyperparameter-optimization-with-random-search-and-grid-search/> adresinden alındı
- Budakoğlu, E. (2022). Prediction of earthquake magnitude using adaptive neuro-fuzzy inference system (ANFIS) and analysis with GIS: the case of Marmara Region (NW Turkey). *Arabian Journal of Geosciences*, 15(9). doi:10.1007/s12517-022-10200-8
- Florido, E., Aznarte, J., Morales-Esteban, A., & Martínez-Álvarez, F. (2016). Earthquake magnitude prediction based on artificial neural networks: A survey. *Croatian Operational Research Review*, 7(2), s. 159-169. doi:<https://www.proquest.com/docview/1869046696?pq-origsite=gscholar&fromopenview=true>
- González, J., Yu, W., & Telesca, L. (2019). Earthquake Magnitude Prediction Using Recurrent Neural Networks. *Proceedings*, 24. doi:10.3390/IECG2019-06213
- Huang, J., Wang, X., Zhao, Y., Xin, C., & Xiang, H. (2018). Large Earthquake Magnitude Prediction In Taiwan Based On Deep Learning Neural Network. *Neural Network World*, 28(2), s. 149-160. doi:10.14311/NNW.2018.28.009
- Jang, J.-S. R. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 23(3), s. 665-685. doi:10.1109/21.256541
- Jena, R., Pradhan, B., Al-Amri, A., Lee, C. W., & Park, H. J. (2020). Earthquake Probability Assessment for the Indian Subcontinent Using Deep Learning. *Sensors*, 20(16). doi:10.3390/s20164369
- Kaplan, A., & Haenlein, M. (2019). Siri, Siri, in my hand: Who's the fairest in the land? On the interpretations, illustrations, and implications of artificial intelligence. *Business Horizons*, 62(6), s. 679-681. doi:10.1016/j.bushor.2018.08.004
- Keisner, A., Raffo, J., & Wunsch-Vincent, S. (2015). Breakthrough Technologies- Robotics, Innovation and Intellectual Property. *Economic Research Working Paper*, 30. 11 12, 2020 tarihinde https://www.wipo.int/edocs/pubdocs/en/wipo_pub_econstat_wp_30.pdf adresinden alındı
- Kishore, V., Bhandarkar, T., Satish, N., Sridhar, S., Sivakumar, R., & Ghosh, S. (2019). Earthquake trend prediction using long short-term memory RNN. *International Journal of Electrical and Computer Engineering*, 9(2), s. 1304-1312. doi:10.11591/ijece.v9i2.pp1304-1312
- Külahcı, F., İnceöz, M., Doğru, M., Aksoy, E., & Baykara, O. (2009). Artificial neural network model for earthquake prediction with radon monitoring. *Applied Radiation and Isotopes*, 67(1), s. 212-219. doi:10.1016/j.apradiso.2008.08.003
- Last, M., Rabinowitz, N., & Leonard, G. (2016). Predicting the maximum earthquake magnitude from seismic data in Israel and its neighboring countries. *PLoS ONE*, 11(3). doi:10.1371/journal.pone.0146101
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, s. 436-444. doi:10.1038/nature14539
- Mahmoudi, J., Arjomand, M. A., Rezaei, M., & Mohammadi, M. H. (2016). Predicting the earthquake magnitude using the multilayer perceptron neural network with two hidden layers. *Civil Engineering Journal*, 2(1), s. 1-12. doi:doi.org/10.28991/cej-2016-00000008

- Maind, S., & Wankar, P. (2014). Research Paper on Basic of Artificial Neural Network. International Journal on Recent and Innovation Trends in Computing and Communication, 2(1), s. 96-100. 11 16, 2022 tarihinde <https://ijritcc.org/index.php/ijritcc/article/view/2920/2920> adresinden alındı
- Martínez-Álvarez, F., Reyes, J., Morales-Esteban, A., & Rubio-Escudero, C. (2013). Determining the best set of seismicity indicators to predict earthquakes. Two case studies: Chile and the Iberian Peninsula. Knowledge-Based Systems, 50, s. 198-210. doi:doi.org/10.1016/j.knosys.2013.06.011
- Mirrashid, M. (2014). Earthquake magnitude prediction by adaptive neuro-fuzzy inference system (ANFIS) based on fuzzy C-means algorithm. Natural Hazards, 74, s. 1577-1593. doi:10.1007/s11069-014-1264-7
- Mitchell, T. (1997). Machine Learning. McGraw-Hill Science.
- Morales-Esteban, A., Martínez-Álvarez, F., & Reyes, J. (2013). Earthquake prediction in seismogenic areas of the Iberian Peninsula based on computational intelligence. Tectonophysics(593), s. 121-134. doi:10.1016/j.tecto.2013.02.036
- Murwantara, I. M., Yugopusito, P., & Hermawan, R. (2020). Comparison of machine learning performance for earthquake prediction in Indonesia using 30 years historical data. Telkomnika, 18, s. 1331-1342. doi:10.12928/telkomnika.v18i3.14756
- Narayanakumar, S., & Raja, K. (2016). A BP artificial neural network model for earthquake magnitude prediction in Himalayas, India. Circuits and Systems, 7(11), s. 3456-3468. doi:10.4236/cs.2016.711294
- Öztemel, E. (2003). Yapay Sinir Ağları. Papatya Yayıncılık.
- Öztürk, S., & Alkan, H. (2022). Van Gölü ve Civarı (Türkiye) İçin Deprem Tahmini ve Tehlikesi Üzerine İstatistiksel Bir Analiz ve Değerlendirme. Türk Deprem Araştırma Dergisi, 4(2), s. 191-209. doi:10.46464/tdad.1108730
- Panakkat, A., & Adeli, H. (2007). Neural network models for earthquake magnitude prediction using multiple seismicity indicators. International Journal of Neural Systems, 17, s. 13-33. doi:10.1142/S0129065707000890
- Panakkat, A., & Adeli, H. (2009). Recurrent neural network for approximate earthquake time and location prediction using multiple seismicity indicators. Computer-Aided Civil and Infrastructure Engineering, 24(4), s. 280-292. doi:10.1111/j.1467-8667.2009.00595.x
- Pandit, A., & Panda, S. (2021). Prediction of earthquake magnitude using soft computing techniques: ANN and ANFIS. Arabian Journal of Geosciences, 14. doi:10.1007/s12517-021-07594-2
- Parameswaran, S., Gopal, A. N., Revathi, D., & Senthamarai, M. (2018). Earthquake Prediction System by LSTM. International Journal of Intellectual Advancements and Research in Engineering Computations, 6(2), s. 1955-1960. <https://ijiarec.com/ijiarec/article/view/762> adresinden alındı
- Rafiei, M. H., & Adeli, H. (2017). NEEWS: A novel earthquake early warning model using neural dynamic classification and neural dynamic optimization. Soil Dynamics and Earthquake Engineering, 100, s. 417-427. doi:10.1016/j.soildyn.2017.05.013
- Reyes, J., Morales-Esteban, A., & Martínez-Álvarez, F. (2013). Neural networks to predict earthquakes in Chile. Applied Soft Computing, 13(2), s. 1314-1328. doi:10.1016/j.asoc.2012.10.014
- Sadhukhan, B., Chakraborty, S., & Mukherjee, S. (2023). Predicting the magnitude of an impending earthquake using deep learning techniques. Earth Science Informatics, 16(1), s. 803-823. doi:10.1007/s12145-022-00916-2

- Sebatlı-Sağlam, A., & Çavdur, F. (2022). Yapay sinir ağı ile deprem şiddeti tahmini: Farklı ağ tasarımlarının ve eğitim algoritmalarının incelenmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 37(4), s. 2133-2145. doi:10.17341/gazimmfd.791337
- Smith, L. I. (2002). A Tutorial on Principal Components Analysis. 12 12, 2022 tarihinde http://www.iro.umontreal.ca/~pift6080/H09/documents/papers/pca_tutorial.pdf adresinden alındı
- Wang, Q., Guo, Y., Yu, L., & Li, P. (2017). Earthquake Prediction Based on Spatio-Temporal Data Mining: An LSTM Network Approach. *Transactions on Emerging Topics in Computing*, 8(1), s. 148-158. doi:10.1109/TETC.2017.2699169
- Yılmaz, A. (2019). Yapay Zeka. İstanbul: Kodlab Yayınları.
- Yousefzadeh, M., Hosseini, S. A., & Farnaghi, M. (2021). Spatiotemporally explicit earthquake prediction using deep neural network. *Soil Dynamics and Earthquake Engineering*, 144, s. 106663. doi:10.1016/j.soildyn.2021.106663.
- Zamani, A., Sorbi, M. R., & Safavi, A. A. (2013). Application of neural network and ANFIS model for earthquake occurrence in Iran. *Earth Science Informatics*, 6, s. 71-85. doi:10.1007/s12145-013-0112-8

ÖZ GEÇMİŞ

İlker GÜR, Samsun Aziz Atik Anadolu Öğretmen Lisesi'ni bitirdikten sonra Çankaya Üniversitesi Mühendislik Fakültesi, Bilgisayar Mühendisliği(İngilizce) bölümünden 08.10.2018 tarihinde mezun oldu. 2019 yılında OMÜ LEE Bilgisayar Mühendisliği Ana Bilim Dalı Tezli Yüksek Lisans programına girdi. Şubat 2022'den bu yana Samsun Üniversitesi Yazılım Mühendisliği bölümünde araştırma görevlisi olarak görev yapan İlker GÜR, iyi derecede İngilizce bilmektedir (YÖKDİL: 73,75). Temel ilgi alanları, veri bilimi, makine öğrenmesi ve derin öğrenme konularıdır. (05.01.2023).

İletişim Bilgileri

ORCID ID : 0000-0002-0773-2891

Yayınlar:

1. Gür, İ., ve Kayhan, G. (2022). Uzun-Kısa Vadeli Bellek Ağlarının Deprem Tahminleme Problemine Uygulanması. 7. Uluslararası Akademik Araştırmalar Kongresi (ICAR) (s. 176-186). Asos Yayınevi.
2. Gür, İ., ve Kayhan, G. (2023). Depremsellik Göstergeleri ile LSTM ve ANFIS Modelleri Kullanarak Deprem Büyüklüğü Tahminleme. Editör A. Polat, Ö. Yıldırım. *Güncel Mühendislik Bilimleri Araştırmaları Kavramlar, Araştırmalar ve Uygulamalar* (s. 1-25). 1.Baskı. Lyon: Livre de Lyon.