

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



ÜNİVERSİTELERİN TWİTTER KULLANIM ANALİZİ VE TAHMİNİ

YÜKSEK LİSANS TEZİ

Yasin KIZILBAKIR

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

Mart, 2021

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



ÜNİVERSİTELERİN TWİTTER KULLANIM ANALİZİ VE TAHMİNİ

YÜKSEK LİSANS TEZİ

Yasin KIZILBAKIR

(Y1813.010014)

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Dr. Öğr. Üyesi PERİ GÜNEŞ

Mart, 2021

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “Üniversitelerin Twitter kullanım analizi ve tahmini” adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadar ki bütün süreçlerde bilimsel ahlak ve etik geleneklere aykırı düşecek bir davranışımın olmadığını, tezdeki bütün bilgileri akademik ve etik kurallar içinde elde ettiğimi, bu tez çalışmasıyla elde edilmeyen bütün bilgi ve yorumlara kaynak gösterdiğimi ve yararlandığım eserlerin bibliyografyada gösterilenlerden oluştuğunu, bunlara atıf yaparak yararlanmış olduğumu belirtir ve onurumla beyan ederim.(01.03.2021)

Yasin KIZILBAKIR

ÖNSÖZ

Bu yüksek lisans tez çalışmasında, Twitter üzerinde belirlemiş olduğumuz beş üniversiteye ait Twitter verilerine göre tahmin analizi yapılmıştır. Bu verileri analiz ederken tahmin problemini çözmek ve iyi bir sonuç alabilmemiz için model olarak LSTM (Uzun Kısa Süreli Bellek) ağı ve Tekrarlayan Sinir Ağı (RNN) modeli, tahmin problemini çözmek için ise RMSE (Kök Ortalama Kare Hatası) kullanılmıştır. Çıkan Sonuçlar ARIMA Modeli ile karşılaştırılmıştır. Yapılan çalışma sonucunda belirlemiş olduğumuz üniversitelerin geriye dönük zaman bazında verilerine göre %67 eğitim %33 oranında test verileri üzerinde tahmin yapılmıştır. Tahmin sonuçları; İstanbul Aydın Üniversitesi, İstanbul Üniversitesi, İstanbul Teknik Üniversitesi, Yıldız Teknik Üniversitesi, Marmara Üniversitesi sırayla RMSE değerleri 0.06,0.04,0.09,0.07, 0.05 ve R2 değerleri sırayla 0.92,0.96,0.90,0.93,0.95 sonuçları elde edilmiştir. LSTM modeli tahmin değerleri ARIMA tahmin değerlerine göre daha iyi sonuçlar vermiştir. Derin öğrenme metotlarından LSTM modeli ile yapılan çalışmada, tahmin uygulamalarında başarılı ve etkili sonuçlar elde edileceği gösterilmiştir. Çalışmam boyunca beni her konuda destekleyen aileme, iş arkadaşlarıma gerek akademik bilgisi gerek değerli yönlendirmeleri ile bu tezi tamamlamamı sağlayan tez danışmanım Dr. Öğr. Üyesi Peri Güneş ve tüm hocalarım Prof. Dr. ALİ GÜNEŞ ve Doç. Dr. Metin ZONTUL hocalarıma teşekkürlerimi bir borç bilirim.

Mart 2021

Yasin KIZILBAKIR

İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	iv
İÇİNDEKİLER	v
KISALTMALAR	vii
ÇİZELGE LİSTESİ.....	ix
ŞEKİL LİSTESİ.....	x
ÖZET.....	xi
ABSTRACT.....	xii
1. GİRİŞ	1
1.1 Kaynak Araştırması.....	2
1.2 Amaç	10
2. BİLGİ TEKNOLOJİLERİNİN HAYATIMIZDAKİ ETKİLERİ	11
2.1 Bilgi Sistemlerinin Bileşenleri	13
2.2 Riskler	13
3. TANIMLAR	15
3.1 Yapay Zeka	15
3.1.1 Tarihçe	15
3.1.2 Yapay Zekâ Tanım.....	16
3.1.3 Yapay Zekâ kullanım alanları	17
3.1.3.1 Öğrenme.....	17
3.1.3.2 Muhakeme.....	17
3.1.3.3 Etkileşim	17
3.1.3.4 Problem çözme.....	17
3.1.3.5 Algı.....	17
3.2 Makine Öğrenmesi nedir?	18
3.2.1 Denetimli Öğrenim (Supervised Learning).....	18
3.2.2 Denetimsiz Öğrenme (Unsupervised Learning).....	19
3.2.3 Yarı Denetimli Öğrenim (Semi-Supervised Learning).....	19
3.2.4 Regresyon Algoritmaları (Regression Algorithms).....	20
3.2.5 Örnek tabanlı algoritmalar (Instance-based Algorithms).....	21
3.2.6 Düzenleme Algoritmaları (Regularization Algorithms)	21
3.2.7 Karar Ağacı Algoritmaları (Decision Tree Algorithms).....	22
3.2.8 Bayes Algoritmaları (Bayesian Algorithms).....	23
3.2.9 Küme algoritmaları(Clustering Algorithms).....	24
3.2.10 Birliktelik Kural Çıkarımı (Association Rule Learning Algorithms)	25
3.2.11 Yapay sinir ağı algoritmaları (Artificial Neural Network Algorithms) ..	25
3.2.12 Boyut İndirgeme Algoritmaları (Dimensionality Reduction Algorithms)	
.....	26
3.2.13 Topluluk Algoritmaları (Ensemble Algorithms).....	27
3.2.14 Diğer Makine Öğrenme Algoritmaları.....	28
3.2.15 Derin Öğrenme Algoritmaları (Deep Learning Algorithms)	28

3.3 RNN Tekrarlayan Sinir ağı Nedir?.....	29
3.3.1 Tekrarlayan Sinir Ağının Avantajları?.....	31
3.3.2 Tekrarlayan Sinir Ağının Dezavantajları?	31
3.3.3 Neden RNN?	31
3.4 Zaman Seri Analizi Nedir?.....	32
3.5 LSTM Nedir?	32
3.5.1 LSTM'lerin Arkasındaki Temel Fikir?.....	34
3.5.2 LSTM Uygulamaları	34
3.6 Lstm ile Rnn arasındaki farklar nedir?	35
4. KAPSAM	38
5. YÖNTEM.....	39
5.1 Algoritma seçimi ve projeye uyarlama aşamaları	39
5.1.1 Verilerin API üzerinden alınması c# kod bloğu.....	40
5.1.2 Analiz verilerinin analize uygun formata çevrilmesi	41
5.1.3 Python dili ile verilerin analiz ve ön işleme kod bloğu.....	43
5.1.4 Twitter API ile geliştiren web uygulaması	43
5.1.5 Modelin Eğitilmesi ve Tahmin	44
5.1.6 Verilerin normalizasyon ve transform işlemleri.	45
5.1.7 Epoch değerlerinin oluşturulması, İstanbul aydın Üniversitesi'ne ait epoch değerleri	46
5.1.8 RMSE,R2 ve MSE değerlerinin hesaplanması kod bloğu	49
5.1.9 ARIMA Örneği kod bloğu	49
5.1.10 ARIMA p, d, q, P, D, Q değerlerini elde etmek için auto_arima () işlevi kod bloğu.....	50
5.1.11 SARIMAX Verileri eğitime ve test setine ayırma işlemi	50
5.1.12 ARIM Tahmin Kod bloğu.....	50
5.1.13 Üniversitelerin Twitter kullanım istatistikleri ve kümelmiş sütun grafığı	51
5.1.14 RMSE ve R2 değerleri	51
5.1.15 Twitter Sayı Grafikleri	52
5.1.16 Epochs Grafikleri	53
5.1.17 Sezonluk değişim grafikleri	54
5.1.18 LSTM Tahmin grafikleri.....	55
5.1.19 ARIMA Tahmin grafikleri	56
5.1.20 Tahmin sonuçları.....	57
5.1.21 Grafiksiz Sonuçlar ve yorumlar	62
6. SONUÇ.....	67
KAYNAKÇA	68
ÖZGEÇMİŞ.....	70

KISALTMALAR

LSTM	:Uzun Kısa Süreli Bellek (Long short term memory)
RMSE	: Kök ortalama kare hatası (Root-mean-square deviation)
RNN	: Tekrarlayan sinir ağı (Recurrent Neural Network)
DSA	: Dijital imza algoritması (Digital Signature Algorithm)
ARIMA	: Autoregressive Integrated Moving Average
BT	: Bilgi teknolojileri
İAÜ	: İstanbul Aydın Üniversitesi
İÜ	: İstanbul Üniversitesi
İTÜ	: İstanbul Teknik Üniversitesi
YTÜ	: Yıldız Teknik Üniversitesi
AI	: Yapay Zeka
DNN	: A deep neural network
CNN	: Convolutional neural network
ANN	: Artificial neural network
C-LSTM	: CNN and LSTM
ARIMA	: Autoregressive integrated moving average
ANN	: Artificial Neural Network
ML	: Machine Learning
OLSR	: Ordinary Least Squares Regression
MARS	: Multivariate Adaptive Regression Splines
LOESS	: Locally Estimated Scatterplot Smoothing
KNN	: k-Nearest Neighbor
LVQ	: Learning Vector Quantization
SOM	: Self-Organizing Map
LWL	: Locally Weighted Learning
SVM	: Support Vector Machines
LASSO	: Least Absolute Shrinkage and Selection Operator
LARS	: Least-Angle Regression
CART	: Classification and Regression Tree
ID3	: Iterative Dichotomiser 3
CHAID	: Chi-squared Automatic Interaction Detection
AODE	: Averaged One-Dependence Estimators
BBN	: Bayesian Belief Network
BN	: Bayesian Network
EM	: Expectation Maximisation (EM)
MLP	: Multilayer Perceptrons
RBFN	: Radial Basis Function Network
DBM	: Deep Boltzmann Machine
DBN	: Deep Belief Networks
PCA	: Principal Component Analysis

PCR	: Principal Component Regression
PLSR	: Partial Least Squares Regression
MDS	: Multidimensional Scaling
LDA	: Linear Discriminant Analysis
MDA	: Mixture Discriminant Analysis
QDA	: Quadratic Discriminant Analysis
FDA	: Flexible Discriminant Analysis
BAGGING	: Bootstrapped Aggregation
BLENDING	: Weighted Average
STACKING	: Stacked Generalization
GBM	: Gradient Boosting Machines
GBRT	: Gradient Boosted Regression Trees
FNN	: Feedforward Neural Networks (ileri beslemeli ağlar)

ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 5.1: Analiz verilerinin girdiye uyarlanması.....	42
Çizelge 5.2: Modelde kullanılan parametreler.....	44
Çizelge 5.3: Tüm üniversitelere ait sütun grafiği	51
Çizelge 5.4: Üniversitelere ait tahmin sonuçlarının karşılaştırılması.....	51
Çizelge 5.7: Üniversitelere ait Mean değerleri	52
Çizelge 5.5: İstanbul Aydın Üniversitesi.....	57
Çizelge 5.6: İstanbul Üniversitesi Tahmin Değerleri	58
Çizelge 5.7: İstanbul Teknik Üniversitesi Tahmin Değerleri.....	59
Çizelge 5.8: Marmara Üniversitesi Tahmin Değerleri	60
Çizelge 5.9: Yıldız Teknik Üniversitesi Tahmin Değerleri.....	61

ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 3.1: Denetimli öğrenme Algoritmaları	18
Şekil 3.2: Denetimsiz Öğrenme	19
Şekil 3.3: Semi-Supervised Learning	20
Şekil 3.4: Instance-based Algorithms	21
Şekil 3.5: Instance-based Algorithms	21
Şekil 3.6: Regularization Algorithms	22
Şekil 3.7: Decision Tree Algorithms	23
Şekil 3.8: Bayesian Algorithms	24
Şekil 3.9: Clustering Algorithms	24
Şekil 3.10: Association Rule Learning Algorithms	25
Şekil 3.11: Artificial Neural Network Algorithms	26
Şekil 3.12: Dimensionality Reduction Algorithms	27
Şekil 3.13: Ensemble Algorithms	28
Şekil 3.14: Deep Learning Algorithms	29
Şekil 3.15: Tekrarlayan Sinir ağları göngüleri	30
Şekil 3.16: Xt Giriş ve ht çıkış Sinir Ağı	30
Şekil 3.17: RNN Çalışma şekli	31
Şekil 3.18: Standart bir RNN'deki tekrar eden modül, tek bir katman içerir	32
Şekil 3.19: LSTM Kapıları	33
Şekil 5.1: Twitter verilerinin tablodaki ham hali	42
Şekil 5.2: Web uygulama Twitter listesi	44
Şekil 5.3: Kümelenmiş sütün grafiği	51
Şekil 5.4: Twitter Sayı Grafikleri	52
Şekil 5.5: Epochs Grafikleri	53
Şekil 5.6: Sezonsal değişim grafikleri	54
Şekil 5.7: LSTM Tahmin grafikleri	55
Şekil 5.8: ARIMA Tahmin grafikleri	56
Şekil 5.9: İstanbul Aydın Üniversitesi eğitim, test ve tahmin grafiği	62
Şekil 5.10: İstanbul Üniversitesi eğitim, test ve tahmin grafiği	63
Şekil 5.11: İstanbul Teknik Üniversitesi eğitim, test ve tahmin grafiği	64
Şekil 5.12: Yıldız Teknik Üniversitesi eğitim, test ve tahmin grafiği	65
Şekil 5.13: Marmara Üniversitesi eğitim, test ve tahmin grafiği	66

ÜNİVERSİTELERİN TWİTTER KULLANIM ANALİZİ VE TAHMİNİ

ÖZET

Sosyal medya uygulamaları günlük hayatımızda önemli bir yere sahiptir. Sosyal Medya blog sayfaları, ticari alanlar, sosyal ağlar, haberleşme kanalları birçok alanda hizmet vermektedir. Bu alanda sosyal medya çeşitli kurumsal sayfalar ve kullanıcı paylaşımları olmak üzere önemli bir şekilde veri kaynağı oluşturulmaktadır. Bu kaynak bize sosyal medya alanı üzerinde ticari anlamda birçok alanda analizler ve tahminler yapma imkânı sunmaktadır. Bu veri kaynakları, sosyal medya üzerinden paylaşılan bilgilerden zamana bağlı çıkarımlar yapılması konusunda veri analizi önemli bir çalışma alanıdır. Bu çalışmada, Twitter üzerinde belirlemiş olduğumuz beş üniversiteye ait Twitter verilerine göre tahmin analizi yapılacaktır. Bu verileri analiz ederken tahmin problemini çözmek ve iyi bir sonuç alabilmemiz için model olarak LSTM (Uzun Kısa Süreli Bellek) ağı ve Tekrarlayan Sinir Ağı (RNN) modeli, tahmin problemini çözmek için ise RMSE (Kök Ortalama Kare Hatası) kullanılacaktır. Yapılan çalışma sonucunda belirlemiş olduğu üniversitelerin geriye dönük zaman bazında verilerine göre %67 eğitim %33 oranında test verileri üzerinde tahmin yapılmıştır. Tahmin sonuçları; İstanbul Aydın Üniversitesi, İstanbul Üniversitesi, İstanbul Teknik Üniversitesi, Yıldız Teknik Üniversitesi, Marmara Üniversitesi sırayla RMSE değerleri 0.06, 0.04, 0.09, 0.07, 0.05 ve R2 değerleri sırayla 0.92, 0.96, 0.90, 0.93, 0.95 sonuçları elde edilmiştir. LSTM modeli tahmin değerleri ARIMA tahmin değerlerine göre daha iyi sonuçlar vermiştir. Derin öğrenme metotlarından LSTM modeli ile yapılan çalışmada, tahmin uygulamalarında başarılı ve etkili sonuçlar elde edileceği gösterilmiştir.

Anahtar Kelimeler: *Uzun-Kısa Süreli Bellek, sosyal medya tahmin analizi, tekrarlayan sinir ağı, zaman serileri.*

UNIVERSITIES TWITTER USE ANALYSIS AND FORECASTING

ABSTRACT

Social media applications have an important place in our daily life. Social Media blog pages, commercial areas, social networks, communication channels serve in many areas. In this area, an important source of data is created, including social media, various corporate pages and user shares. This resource offers us the opportunity to make commercial analyzes and forecasts on the social media field. These data sources are an important field of study for making inferences based on time from the information shared on social media. In this study, predictive analysis will be made according to the Twitter data of five universities that we have determined on Twitter. While analyzing these data, LSTM (Long Short Term Memory) network and Recurrent Neural Network (RNN) model will be used as models to solve the prediction problem and get a good result, and RMSE (Root Mean Square Error) will be used to solve the prediction problem. According to the retrospective time-based data of the universities determined as a result of the study, 67% education was estimated on 33% test data. Forecast results; Istanbul Aydın University, Istanbul University, Istanbul Technical University, Yıldız Technical University, Marmara University, respectively, RMSE values 0.06, 0.04, 0.09, 0.07, 0.05 and R2 values 0.92, 0.96, 0.90, 0.93, 0.95, respectively. LSTM model predictive values gave better results than ARIMA predicted values. In the study conducted with LSTM model, one of the deep learning methods, it has been shown that successful and effective results can be obtained in prediction applications.

Keywords: *Long-Short Term Memory, Social media prediction analysis, recurrent neural network, time series*

1. GİRİŞ

Derin öğrenme, yapay sinir ağları insan beynin yapısı ve işlevinden esinlenen analiz etme, öğrenme ve karar verme gibi yetenekler ve algoritmalarla ilgili makine öğreniminin bir alt adıdır. Derin öğrenmenin literatüre kazandırılması 1940'lı yıllara dayanmaktadır. İnsan düşünce sürecini taklit etmek için, sinir ağı modeli geliştirilmiştir (1). Derin öğrenme yaklaşık 75 yıllık geçmişe sahiptir. Derin öğrenme Google, Twitter, Facebook, gibi sosyal medya ve arama motorları gibi en çok kazan firmalar tarafından kullanılmaktadır (2).

Derin öğrenme algoritmaları, karmaşık veri temsillerinin (özelliklerin) yüksek soyutlama düzeylerinde otomatik olarak çıkarılması için umut verici bir araştırma yoludur. Bu algoritmalar, daha yüksek düzeyli (daha abstre) özelliklerin daha düşük düzeyli (daha az abstre) özellikler olarak tanımlandığı, katmanlı, hiyerarşik bir öğrenme ve veri mimarisi geliştirir. Derin Öğrenme algoritmalarının hiyerarşik öğrenme mimarisi, insan beynindeki neokorteksin birincil duyuşal alanlarının derin, katmanlı öğrenme sürecini taklit eden yapay zeka tarafından motive edilir, bu da temel verilerden özellikleri ve soyutlamaları otomatik olarak çıkarır (3). Derin Öğrenme algoritmaları büyük miktarlarda denetimsiz verilerden öğrenme ile oldukça faydalıdır ve tipik olarak veri temsillerini açgözlü bir şekilde bilge bir şekilde öğrenir (4). Karar verme, tahmin ve diğer çıkarımlar için büyük girdi verilerinden anlamlı kalıpların çıkarılması ve çıkarılması Big Data Analytics'in merkezinde yer almaktadır. Büyük Veri hacimlerini analiz etmenin yanı sıra, Büyük Veri Analitiği ham verilerin format değişimi, hızlı hareket eden veri akışı, veri analizinin güvenilirliği, yüksek oranda dağıtılmış girdi kaynakları, gürültü ve düşük kaliteli veriler, yüksek boyutluluk, algoritmaların ölçeklenebilirliği, dengesiz giriş verileri, denetimsiz ve kategorize edilmemiş veriler, sınırlı denetimli / etiketli veriler, vb. Yeterli veri depolama, veri indeksleme / etiketleme ve hızlı bilgi alımı Büyük veri deki diğer önemli problemlerdir analitik. Sonuç olarak,

Büyük veri ile çalışırken yenilikçi veri analizi ve veri yönetimi çözümleri garanti edilmektedir (5)

Bu çalışmada, Twitter sosyal medya uygulaması üzerinde belirlemiş olduğumuz beş üniversiteye ait Twitter verilerine göre tahmin analizi yapılacaktır. Bu verileri analiz ederken tahmin problemini çözmek ve iyi bir sonuç alabilmemiz için model olarak LSTM (Uzun Kısa Süreli Bellek) ağı ve Tekrarlayan Sinir Ağı (RNN) modeli, tahmin problemini çözmek için ise RMSE (Kök Ortalama Kare Hatası) kullanılacaktır. Yapılan çalışma sonucunda belirlemiş olduğu üniversitelerin geriye dönük zaman bazında verilerine göre %67 eğitim %33 oranında test verileri üzerinde tahmin yapılmıştır. Tahmin sonuçları; İstanbul Aydın Üniversitesi, İstanbul Üniversitesi, İstanbul Teknik Üniversitesi, Yıldız Teknik Üniversitesi, Marmara Üniversitesi sırayla RMSE değerleri 0.06, 0.04, 0.09, 0.07, 0.05 ve R2 değerleri sırayla 0.92, 0.96, 0.90, 0.93, 0.95 sonuçları elde edilmiştir sonuçları elde edilmiştir. Derin öğrenme metotlarından LSTM modeli ile yapılan çalışmada, tahmin uygulamalarında başarılı ve etkili sonuçlar elde edileceği gösterilmiştir

1.1 Kaynak Araştırması

Sosyal medya kullanımının yaygınlaşmasıyla birlikte sosyal medya analizi alanında kullanım analizi ve yapılan çalışmalar zaman içerisinde artmıştır. Bu alanda konuyla ilgili bazı literatür çalışmalarına yer verilmiştir.

Shivam Sinha yapmış olduğu çalışmada Uluslararası havayolu yolcuları verileri üzerinde analiz yapıp Derin öğrenme algoritmalarından LSTM (Long Short Term Memories)'de eğitim için 11 yıllık, değerlendirme için 2 yıllık ve test haftalık, ortalama yolcu verileri üzerinde zaman serilerinde tekrarlayan ağlarda tahmin yapmıştır. LSTM yöntemi ile başarılı sonuçlar elde etmiştir. Aldığı sonuçlar eğitim sonucu 22.92 RMSE test sonucu 47.53 RMSE oranlarıdır. Shivam Sinha çalışmasında sonuç olarak geleceği tahmin etme konusunda LSTM ile analizin en iyi sonuçlara vardığı ortaya koyulmuştur (6).

Ahmet Ali S. ve diğer yapmış oldukları çalışmada derin öğrenme yöntemleri ile sıcaklık tahmini yapmıştır. Belirlemiş olduğu il için merkezi için Meteoroloji Genel Müdürlüğünden alınan basınç, rüzgâr hızı, nem ve sıcaklık verileri

kullanılarak, derin öğrenme algoritmaları ile sıcaklık tahmini yapmıştır. Derin öğrenme algoritmalarından LSTM kullanmıştır. Verilerde eğitim için 14 yıllık, değerlendirme için 2 yıllık ve test için 2 yıllık basınç, rüzgâr hızı, nem, yağış ve sıcaklığın günlük ortalama verileri kullanarak çalışma yapmıştır. Kullanmış olduğu model 4 giriş 1 çıkış verisi elde etmiştir. Geliştirilen sistem eğitildikten sonra Isparta iline ait sonraki 4 yıl için günlük ortalama sıcaklıkları tahmin ettirilmiştir. Sonuç olarak; derin öğrenme algoritmaları ile geleceği tahmin etmede başarıyla kullanılabileceği ortaya koymuştur. (7)

Emre DOĞAN yapmış olduğu çalışmada birçok sosyal ağdan elde edilen veriler ile iki kategorili duygu analiz çalışılıp, Twitter üzerinde bir konu hakkında duygu sınıfı bulunup sınıf üzerinde metin özetlenmesi yapmıştır. Duygu analizi bir sınıflandırma problemi olarak düşünülüp başarı oranını artması için kelimeler arasındaki semantik bağlam kelime gömme metotlarını kullanarak kelimelere ağırlık verilmiştir. Klasik metin sınıflandırma yöntemleri yerine bir derin öğrenme yöntemi olan LSTM kullanmıştır. Kelimeler arası semantik anlamı kaybetmemek için birden fazla kelimelerin sayısal gösterimi (Word Embedings) yöntemi kullanılarak başarı oranlarının değişimi gözlemlemiştir. Metin özetlemesi için yine LSA kullanmıştır. Hem duygu analizi hem de metin özetlemenin gerçekleştirildiği bu çalışmada asıl hedef bir konu hakkındaki duygu ve düşüncüyü analiz edip kullanıcıya özet bilgi sunmaktır. Ana model birçok sosyal ağdan toplanan veriler ile oluşturmuştur. Analiz ve metin özetleme ise Twitter üzerinde bir hashtag den alınan veriler ile yapılmıştır. Duygu analizinde kullanılan yöntemler ile en yüksek %93 oranında başarı elde edilmiştir. Metin özetleme ile başarılı bir şekilde özet bilgi sunmuştur (8).

İbrahim TOPAL yapmış olduğu çalışmasında tüketici satın alma karar süreci ilgili çalışma yapmıştır. Bu çalışmada yeniden satın alma, arama motoru verilerinin ve tüketici bütünleşmesi ile yapay zekâ yöntemi ile satış miktarı tahmin edilmesini amaçlamıştır. Yapmış olduğu çalışmasında Soysal medya uygulamalarından Facebook kurumsal sayfalarında otomobil sektöründe yapılmıştır Çalışma iki aşamada yapılmıştır. Birinci aşamada arama motoru verileri Google Trends uygulamasından satış verilerini almıştır. İkinci aşamada derin öğrenme algoritmalarından Feedforward Neural Networks ve Bayesian Regülasyon yöntemleriyle analizler yapmıştır. Sonuç aşamasında, gözlemler

neticesinde sektöre ve çalışmanın akademik alana olan katkıları yorumlamıştır. Çalışmasında sonuç olarak bulunan korelasyon %74 ile kabul edilebilir değer üzerinde sonuç almıştır. Ek olarak %1'lik RSME ile sistemi modellemiştir. Oluşturduğu model ile başarı ile satış tahmini yapıldığı gözlemlenmiştir. (9)

Özlem Alpay yapmış olduğu çalışmada finansal zaman verileri üzerinde finansal varlıkların fiyatını tahmin etmek ve bu tahmin sonucunda yatırım karar verme riskin azaltma yönünde bir çalışma yapmıştır. Çalışmasını 17 yıllık veriler üzerinde USD/TRY paritesi veri setini kullanarak gerçekleştirmiştir. Yapmış olduğu çalışma sonucunda LSTM yaklaşımının başarılı ve reel değerlere daha yakın bir tahmin yaptığını sonucuna varmıştır. Çalışmaların sonucunda 2000'li yıllarda USD/TRY paritesi ortalama 0,6 oranından 2016 yılında ise ortalama 3,5 oranına yükselmiştir. Tahmin edilen 2017 yılında ise ortalama 3,8 oranlarını elde etmiştir (10).

Ahmet Ali Süzen yapmış olduğu çalışmada LSTM ile Üniversitelere giriş sınavındaki matematik testlerindeki soru sayılarının tahmin edilmesi için bir model kullanmıştır. Veriler 1981-2018 yıllarına ait üniversite sınavlarına matematik testlerinin 16 farklı konuya göre gruplandırmış ve toplamda 931 adet soru sayısı verisinde analiz yapmıştır. Veri kümesi kullanımında %80'ni modelin eğitilmesi, %20'ni modelin testi için ayırmıştır. Yapmış olduğu çalışma sonucunda eğitimde ortalama %98,42, testte ortalama %96,82 doğruluk değeri elde etmiştir. Kullanılan Dijital İmza algoritmasının başarısının ölçülmesi için veri kümesi makine öğrenme algoritmalarında test edilerek ile kıyaslanmıştır. Çalışmasının sonucunda LSTM ile DSA algoritmaların da en yüksek başarı oranı elde etmiştir. (11).

Mehmet Ç. ve diğer yapmış oldukları çalışmada spor yapma alışkanlığı ile ilgili duygu analizi yapmıştır. Bu çalışmada analizi 11-14 yaşları arasındaki ortaokul öğrencilerinin spor yapma bağımlılığının duygu kontrol seviyeleri üzerine anlamlı bir neticesinin olup olmadığını, varsa bu neticenin bazı nesnelere (sınıf, cinsiyet, yaş, anne-baba eğitim durumları, okul takımında görev alıp/almama) göre değişip değişmediğinin belirlenmesi, sonuç olarak ulaşılan bilgilere dayalı olarak da alana fayda sağlayabilecek önermelerde bulunulması istihdaf etmiştir (12).

Nalan Ö. ve diğeri yapılmış oldukları çalışmada ihtiyaç duyulan elektrik miktarının doğru tahmin edilerek ve tüketim bu tahminleri yakalayarak dengesizlik maliyeti minimuma indirmek ve elektrik fiyatını en uygun değerlere belirlemektedir. Çalışmasında elektrik ihtiyacını doğru tahmin edebilmek için Uzun-Kısa Dönemli Bellek derin öğrenme yöntemi Enerji Piyasaları İşletme A.Ş. ait resmî web sayfasında yayınladığı saatlik üretim verilerine uygulamıştır. Çalışma sonucunda 24,48 ve 72 saatlik geçmiş zaman verisi test için kullanmıştır, hata ölçütü olarak MAPE değerinin sırasıyla 0,81, 0,73 ve 0,77 yüzdelik oranlarda elde etmiştir (13).

Uğurcan Şencan yapılmış olduğu çalışmada derin öğrenme yöntemlerinden biri olan Uzun Kısa Süreli Bellek (LSTM) kullanılarak kısa vadeli elektrik fiyatı tahmini yapmıştır. Çalışmasından girdi olarak yalnızca tarihe göre zamana bağlı elektrik fiyat değerlerini kullanmıştır. Veri olarak 2015, 2016 ve 2017 için Türkiye saatlik elektrik fiyatı değerleri girdi verisi olarak kullanılmıştır. Çalışmada kullanılan veriler, yaz ve kış sezonları için eğitim ve test verileri olarak ikiye ayrılmıştır. Kısa vadeli elektrik fiyat tahmini için tekniğin performansı, tekrarlayan sinir ağı ve üstel yumuşatma tekniklerinin performansları ile karşılaştırmıştır. Önerilen çözüm tekniği kullanılarak elde ettiği MAPE değeri kış için yüzde 5,91, yaz için yüzde 5,77'dir. İhtiyaç duyulan elektrik miktarının doğru tahmin ederek ve tüketim tahminlerini yakalayarak dengesizlik maliyeti minimuma indirmek ve elektrik fiyatını en uygun değerlere belirlemek çalışma yapmıştır. Çalışmasında elektrik ihtiyacını doğru tahmin edebilmek için Uzun-Kısa Dönemli Bellek derin öğrenme yöntemi Enerji Piyasaları İşletme A.Ş. ait resmî web sayfasında yayınladığı saatlik üretim verilerini kullanarak çalışmasından girdi olarak kullanmıştır. Çalışma sonucunda 24,48 ve 72 saatlik geçmiş zaman verisi test için kullanmıştır, hata ölçütü olarak MAPE değerinin sırasıyla 0,81, 0,73 ve 0,77 yüzdelik oranlarda elde etmiştir. (14)

Deniz Can Y. Yapılmış olduğu çalışmasında derin öğrenme yöntemlerinden biri olan Uzun Kısa Süreli Bellek (LSTM) kullanılarak teknik ve makro ekonomik göstergelerle kullanan bir model Forex verilerinin yönlü hareketini tahmin etmek için kullanmıştır. Çalışma EUR / USD para birimi üzerinden yapılmıştır.

1 gün, 3 gün ve 5 gün önceden tahmin etmek için çift ve umut verici sonuçlar elde etmiştir. (15)

Merve A. ve Bülent B. Yapmış oldukları çalışmada uçak motoru sağlığı için öngörücü bakım tahmini yapmıştır. Otomotiv, uçak vb. gibi özellikle maliyeti yüksek motor bakımı gerektiren işlemlerde motor bakımının önemli bir yer aldığını belirtmiştir. İş güvenliği ve en yüksek verim bakımından motorların periyotlarını önceden tahmin etmek ve bu tahmin verilerine göre iş yönetim stratejisi geliştirmek önemini anlatmıştır. Çalışmasında Uzun-Kısa Süreli Bellek (LSTM) algoritma modeli kullanmıştır. Bu model ile uçak motorlarının kalan yaşam ömürlerinin tahmin edilmesini amaçlamıştır. Data seti olarak NASA tarafından sunulan olan bir veri kümesi üzerinde LSTM yapısı test etmiştir ve elde edilen sonuçlar farklı yöntemlerle kıyaslamıştır. Yapılan uygulamaların sonucunda en yüksek sınıflandırma başarısını %98,876; en düşük ortalama mutlak hata ise 1,343 olarak LSTM ile elde etmiştir (16).

Kemal B. Yapmış olduğu çalışmada para piyasaları üzerinde tahmin çalışmaları yapmıştır. Neural network mimarisi olan Recurrent Neural Network sisteminin zaman serileri ile çalışmaya en uygunlardan algoritmalarından birisi olan, LSTM aracılığı deneyler yapmıştır. Bu çalışmada, Efficient Market varsayımından veya teknik analizlerde yapılan değerlendirmelerden yola çıkmıştır, geçmiş veriler sonucunda yönelim hakkında fikir edinebileceği savunmuştur. Bu çalışma sürecinde ekonomik, coğrafik veya dış etkenlerin müdahalesi ve etkisi açısından, hareketleri diğer para piyasalarına göre çok daha fazla değişebilen ve tüm bu faktörlere bakıldığında öngörülemez olarak düşünülen Türk Lirası üzerinde analiz yapılmıştır. Model oluşturma ve tahmin süreçlerinde kullanılan veri sadece USD/TRY para piyasası verileri kullanılarak sade veri kuralı gözetmiştir. MSE ve MAE tahminlerin hata oranlarını belirlemek için hata ölçümleri kullanılmıştır. Sonuç olarak 2 günlük verilerden oluşan veri setinin daha başarılı sonuçlar verdiği belirlemiştir. LSTM modeli 2, 5, 10 ve 20 gün geriye dönük kapanış değerleri geriye dönük iki günlük veriler, daha fazla değer içerdiğinden daha iyi sonuçlar vermiştir (17).

Sreelekshmy S. ve diğer yapmış oldukları çalışmada Stok fiyatlarını tahmin etmiştir. Derin öğrenme yöntemlerinden biri olan Uzun Kısa Süreli Bellek (LSTM) ve RNN kullanmıştır. Bu çalışmada üç farklı derin öğrenme mimarisi

kullanmıştır. NSE'de listelenen şirketlerin fiyat tahminleri ve karşılaştırmaları veri olarak kullanmıştır. Sürgülü pencere yaklaşımı uygulamıştır. Kısa vadede gelecekteki değerleri tahmin etmiştir. Performans Modellerin % 'si hata yüzdesi kullanılarak ölçmüştür. Endeks Terimleri- Zaman serisi, Borsa, RNN, LSTM, CNN. Sonuç olarak CNN mimarisi trendlerdeki değişiklikleri belirleyebilir. Önerilen için metodoloji CNN en iyi model olarak tanımlanmıştır (18).

Tae-Young K. ve diğerleri yapmış oldukları çalışmada çevrimiçi web sitelerini ziyaret eden kişilerin web trafiği anormallik tespiti yapmıştır. Web trafiği, çevrimiçi web sitelerini ziyaret eden kişiler tarafından gönderilen ve alınan veri miktarını ifade eder. Web trafiği anormallikleri, zaman serisi trafiğindeki anormal değişiklikleri temsil eder ve karmaşık bilgisayar ağı sistemlerinin verimli çalışması için hızlı ve doğru bir şekilde algılamanın gerçekleştirilmesi önemlidir. Bu çalışmada, tek boyutlu bir zaman serisi sinyali olan trafik verilerinde yer alan mesafe ve zamana bağlı bilgileri etkili bir şekilde modellemek için bir C-LSTM sinir ağını önermiştir. Ham verilerden uzamsal-zamansal bilgilerin sağlam özelliklerini otomatik olarak çıkarmak için bir yöntem sunmuştur. Deneyler, C-LSTM yönteminin bir konvansiyonel sinir ağı (CNN), uzun kısa süreli bellek (LSTM) ve derin sinir ağını (DNN) birleştirerek daha karmaşık özellikler çıkarabileceğini göstermiştir. CNN katmanı, mesafe bilgilerdeki frekans değişimini düşürmek için kullanılır; Zaman bilgisini modellemek için LSTM network katmanı uygundur. Verileri daha belirgin hale getirmek ve bir alana eşlemek için DNN katmanı kullanmıştır. C-LSTM algoritma yönteminin, web trafiği verileri için neredeyse mükemmel anormallik algılama performansı belirtmiştir. Sonuç olarak C-LSTM yöntemi, Yahoo'nun tanınmış Webscope S5 veri kümesinde diğer son teknoloji makine öğrenimi tekniklerinden daha iyi performans gösterdiğini göstermiştir ve test veri kümesinde %98,6 genel doğruluk ve %89,7 geri çağırma elde etmiştir (19).

Sima s. ve diğerleri yağmış olduğu çalışmada LSTM gibi derin öğrenme tabanlı algoritmaların ARIMA modeli gibi geleneksel tabanlı algoritmalarından daha iyi performans karşılaştırmıştır. Daha spesifik olarak, hatadaki ortalama azalma LSTM tarafından elde edilen oranlar, ARIMA ile karşılaştırıldığında LSTM'nin üstünlüğünü gösteren yüzde 84-87 arasındadır. ARIMA'ya. Ayrıca, derin öğrenmede "epoch" olarak bilinen eğitim sürelerinin sayısının eğitimi tahmin

modelinin performansı üzerinde hiçbir etkisi yoktur ve gerçekten rastgele bir davranış sergilemiştir. Bu makale, ARIMA ve LSTM'İN doğruluğunu temsili teknikler olarak karşılaştırır zaman serisi verilerini tahmin etme. Bu iki teknik, bir dizi finansal veri üzerinde uygulamıştır. Sonuç olarak , LSTM'İN ARIMA'DAN daha üstün olduğunu göstermiştir. Daha spesifik olarak, LSTM tabanlı algoritma ARIMA ile karşılaştırıldığında ortalama %85 oranında tahmin. Bu makalede açıklanan çalışma, derin öğrenme tabanlı algoritmaların ve tekniklerin uygulanmasının faydalarını savunmaktadır (20).

Burcu C. yapmış olduğu çalışmada LSTM ağları ağlarını ve diğer modeli ile Türkçe kök bulma çalışması yapmıştır. Yapmış olduğu çalışmada sözcüklerin köklerini bulmak için otomatik bulunması için çalışma yapmıştır. Bu çalışmada sözcüklerin yapım ve çekim eklerini temizleme işlemi yaparak köklerinin otomatik olarak bulunabilmesi için bir yöntem önermiştir. Kullanmış olduğu bu yöntem derin öğrenme algoritmalarından tekrarlayan sinir ağlarını kullanarak oluşturulan kodlayıcı ve kod çözücü üzerinde kazanç sağlamaktır. Parametre olarak kullanılan her bir sözcük, oluşturduğu yapay zekâ algoritmalarından sinir ağı yapısı ile kodlamıştır, ardından kodu çözülerek köküne ulaşmıştır. Bu yöntem ile sadece etiketleme veya makine tercümesi gibi problemlerde kullanmıştır. Yapmış olduğu çalışmasında diğer Türkçe kök bulma çalışma modelleriyle karşılaştırıldığında LSTM ile sonuçların diğer modellere göre daha iyi sonuçlar verdiği gözlemlenmiştir. Sonuç olarak önerilen modellerden birincisi kodlayıcı ve kod çözücü ilkesine dayanmakta ve her iki bileşen için de LSTM kullanmıştır. Temel modelde 2 katmanlı LSTM'in makine öğrenmesinin modeli daha iyi öğrendiği sonucuna varmıştır. 32'lik girdi vektörü ilgi mekanizmasında yeterli gelmemiştir. Bu sonuç mimarinin parametrelerin üzerinde önemli bir etkisi olduğunu göstermiştir (21).

Zacharcy c. ve diğerleri yapmış oldukları çalışmada LSTM ve RNN kullanarak hastaları teşhis etmek için zamana bağlı tahmin çalışması yapmışlardır. Çalışmasında veri data seti olarak hasta ziyareti, sensor verileri, laboratuvar test sonuçlarını kullanmıştır. Teşhislerin çok etiketli sınıflandırmasını, eğitimi 13 sık fakat düzensiz örneklemiş 128 tanıyı sınıflandırmak için bir model klinik ölçümlenmiştir. Öncelikle basit bir LSTM'nin etkinliğini belirleriz klinik verileri modellemiş ve ardından, basit bir şekilde ve her sıra adımında hedefleri

kopyalayıp etkili eğitim stratejisi geliřtirmiřtir. Sadece ham zaman serisi verileri ile eđitilen modeller birkaç g¼c¼l¼ temelden daha iyi sonular verdiđini g¼rm¼řt¼r. alıřmalarında ilk ařamayı tamamlayıp LSTM ile ok iyi sonular aldıkları g¼zlemlenmiřtir (22).

Ayře Soy T. yapmıř olduđu alıřmada bir iřletmenin gemiř d¼nemlere ait satıř verilerini data seti olarak kullanarak aylık satıř miktarı b¼tesi oluřturmaktadır. Bir iřletmenin toplamda 7 yıllık verilerin aylık verilerine g¼re aylık tahakkuk edilen satıř temelli toplam adetlerini dikkate alarak toplamda 96 aylık data setini kullanmıřtır. alıřmada satıřların tahmin edebilmek iin zaman bađlı tahmin yapabilmek iin dođrusal model y¼ntemi olan ARIMA, dođrusal olmayan model olarak LSTM ve tek modele kıyasla tahmin dođruluđunu artırabilmek iin oluřturulmuř bir Hibrit model kullanılarak elde edilen uygulama sonuları g¼stermiřtir. Modellerin tahmin edilmesi iin veri setinin %67'si modellerin eđitim iin, %37 oranında test verisi olarak kullanılmıřtır. (23).

Serdar Turan yapmıř olduđu alıřmada Borsa İstanbul 100 endeks deđer, tahmini üzerine bir alıřma yapmıřtır. Bu alıřmada derin ¼đrenme y¼ntemleri ile finansal varlıklar iin fiyat tahminini yapmıřtır. alıřmada Borsa İstanbul 100 endeksine ait 2001-2018 yıllarına toplamda 7 yıl verilerde g¼nl¼k kapanıř deđerleri kullanılmıřtır. Bu verileri kullanarak ıkan endeksin gelecekteki y¼n¼ ve deđerini tahmin etmeye alıřmıřtır. alıřmasında LSTM ve geitli yinelenen birim y¼ntemleri kullanmıřtır. Bu iki y¼ntemi birbiriyle karřılařtırmıřtır sonu olarak geitli yinelenen birim y¼nteminin daha bařarılı sonu verdiđini g¼zlemlemiřtir (24).

Fischer ve diđerleri yapmıř oldukları alıřmalarda LSTM modelini kullanarak 1992-2015 tarihleri arasında S&P 500 hisselerinin verileri üzerinden bir model oluřturmuřlardır. Bu model sonucunda UKSH modelinin, Random Forest, Deep Neural Net ve Lojistik Regresyon modellerine g¼re daha bařarılı olduđu sonucuna ulařmıřlardır (25).

1.2 Amaç

Çalışmanın temel amacı, Twitter geçmiş dönem verilerini kullanarak gelecek dönemlere dair doğru tahminler üretilebilmesinin sağlanmasıdır. Bu çalışmada belirlemiş olduğum üniversitelere ait sosyal medya aracı olan Twitter uygulamasındaki kurumsal hesaplarında oluşturulan tweet verilerine göre tahmin analizi yapmaktır. Bu alanda sosyal medya çeşitli kurumsal sayfalar ve kullanıcı paylaşımları olmak üzere önemli bir şekilde veri kaynağı oluşturulmaktadır. Bu kaynak bize sosyal medya alanı üzerinde ticari anlamda birçok alanda analizler, tahminler yapma imkânı sunmaktadır. Bu veri kaynakları, sosyal medya üzerinden paylaşılan bilgilerden zamana bağlı çıkarımlar yapılması konusunda zaman bağlı veri analizi önemli bir çalışma alanıdır. Bu çalışma sonucunda oluşan verilerin analizinde tahmin edebilmek için tahmin problemini en uygun ve en iyi sonuca ulaşabilecek bir model oluşturmak için Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) ağı ve Tekrarlayan Sinir Ağı (RNN) modeli kullanılacaktır.

2. BİLGİ TEKNOLOJİLERİNİN HAYATIMIZDAKİ ETKİLERİ

Bilgi sistemi, verilerin toplanması, depolanması ve işlenmesi ve sağlanması için bütünleşmiş bir bileşen seti bilgi, bilgi ve dijital ürünler. İşletme firmaları ve diğer kuruluşlar, işlemlerini yürütmek ve yönetmek, müşterileri ve tedarikçileriyle etkileşim kurmak ve pazarda rekabet etmek için bilgi sistemlerine güvenirlir. Bilgi sistemleri, organizasyonlar arası tedarik zincirlerini ve elektronik pazarları çalıştırmak için kullanılır. Örneğin şirketler, finansal hesapları tutmak, insan kaynaklarını yönetmek ve potansiyel müşterilerine çevrimiçi promosyonlarla ulaşmak için bilgi sistemlerini kullanır. Pek çok büyük şirket tamamen bilgi sistemleri etrafında inşa edilmiştir. Bilgi sistemleri birçok şirkete kolaylık ve karlılık sağlamaktadır. Bunlardan bazıları; Amazon büyüyen bir elektronik alışveriş merkezi ve bulut bilişim hizmetleri sağlayıcısı, elektronik alışveriş merkezi Ebay, Hepsiburada, n11, Gittigidiyor gibi firmalar. Google, Yandex, Yanii gibi firmalar gelirinin çoğunu İnternet aramalarında anahtar kelime reklamcılığında sağlayan arama motoru şirketleridir. Devletler, hizmetleri vatandaşlara en hızlı ve düşük maliyetle sağlamak için bilgi sistemlerini kullanırlar. Ülkemizde bazıları e-devlet, e-nabız, GİB gibi kamu kuruluşlarına örnek uygulamalardır. E-kitaplar, video ürünleri ve yazılımlar gibi dijital ürünler ve oyun ve sosyal ağ gibi çevrimiçi hizmetler bilgi sistemleriyle birlikte kullanılır. İnsanlar, sosyalleşme, ders çalışma, alışveriş yapma, bankacılık ve eğlence gibi kişisel yaşamlarının çoğunu yürütmek için genellikle İnternet tabanlı bilgi sistemlerini kullanırlar.

Eğitim üzerindeki etkiler; Bilgi teknolojisi, eğitim sürecini daha etkili ve verimli hale getirmiştir. Öğrencilerin refahını arttırmıştır. Geliştirilen eğitim yöntemleri, kitapların yerine tablet ve dizüstü bilgisayarlar gibi araçlar bu süreci kolaylaştırmıştır. Dahası, öğrencilerin evlerinden öğrenmelerini sağlayan e-öğrenme platformlarının ortaya çıkması. Bu platformlar, okul dışında olan veya sınıfta öğretmenlerine ayak uydurmakta güçlük çeken kişiler için etkili bir alternatif olabilir. Bu platformlar, öğrencilere dersleri her an daha basit ve daha

somut açıklamalarla gözden geçirme şansı verir ve bu da eğitim sürecini güçlendirir ve çoğu öğrenci için okulda daha iyi sonuçlar alınmasını sağlar. Bu platformlar özellikle pandemi sürecinde eğitim üzerinde çok etkisi olmuştur ve çok yaygın kullanılmaya başlamıştır.

Sağlık sistemi üzerindeki etkiler; Tıp alanında tıbbi cihazlar birçoğu bilgi teknolojileri kullanmıştır, bu cihazlar bir çok alanda dikkat çekici bir gelişme kaydetmiştir. Bu sayede daha verimli hale gelmiştir. BT, bu cihazlara girdi ve onları programlama ve işlemlerini kolaylaştıran dijital cihazlara dönüştürmüştür. Yapay zeka (AI) gibi bilişim sektörleri sayesinde dünya, robotlar sayesinde mesafe ameliyatlarına, yapay üyelerin yapay bacaklar, eller ve hatta yapay kardiyo-aort kapakçıkları olarak uygulanmasına tanık olmuştur. Bilgi teknolojisi, sağlık hizmetlerinin sunulması için özel bir öneme sahiptir. Bilgisayarlı hasta kayıtlarındaki gelişmeler, sağlık hizmetlerinin verimliliğini, etkililiğini ve dağıtımını artıracaktır. Yönetilen bakım programları geliştikçe, toplum temelli bilginin sağlık hizmeti sunucuları ve halk sağlığı topluluğu için önemi artacaktır. Bu bilgileri tele tıp da dahil olmak üzere telekomünikasyon bağlantıları yoluyla iletme kapasitesi hem kırsal hem de kentsel nüfus dahil olmak üzere sağlık hizmetlerinin yetersiz hizmet alan alanlara erişilebilirliğinde devrim yaratacaktır. Bu gelişmeler, gizlilik ve mahremiyet konusunda önemli endişeler uyandıracaktır çünkü sağlıkla ilgili bilgiler istihdam ve sigortalanabilirlik açısından çok önemli olabilir. Verimli, etkili, güvenilir bilgi sistemleri aslında, Rutin veri toplama yerine klinik karar verme ve hasta tercihlerine odaklanarak hasta / doktor etkileşimlerinin insan kalitesini artırmak. Bu bağlamda, bilgi teknolojisi aslında bu etkileşimin kalitesini artırabilir. Bu gelişim teknoloji alanında ülkemizde e-nabız uygulamasını örnek gösterebiliriz.

Ekonomik Etkisi; Teknolojik ilerleme ve örgütsel olgunluk, artan üretime, sermaye birikimine ve üreticiler arasında yoğun rekabetin oluşmasına katkıda bulunmuştur. Bu rekabetin bir yansıması olarak, Ar-Ge kavramı, bilimsel fikirlerin uyumu ve bunların sürdürülmesinde teknik, yasal ve idari becerilere sahip Ar-Ge rolünü büyük bölümlere yapan mühendisler ve bilim insanları tarafından pratik uygulamaları yoluyla bir izolasyon stratejisi olarak ortaya çıkmıştır. Endüstriyel konum ve kalite, verimlilik ve maliyete referans. Bu gelişmeler, ivmesini, araştırma ve geliştirmenin doğal bir sonucu olarak

olgunlaşan ve derinleşen bilim ve teknolojinin ilerlemelerinden alan bir endüstri kültürü ile sonuçlanmıştır “Bilgi Teknolojisi (BT), birçok mevcut ürün ve hizmetin tasarımının yanı sıra neredeyse hepsinin üretim ve pazarlama biçimini etkileyen, her şeyi kapsayan bir değişikliktir. İmalat veya hizmet sektöründeki sektör çalışmalarının yanı sıra Ar-Ge, patentlenme ve inovasyondaki genel eğilimlerden her geçen gün daha güçlü bir şekilde ortaya çıkmaktadır. Fabrikalarda farklı üretim teknolojilerinin kullanılması, işletmelerdeki yeniliklerin etkisinin değerlendirilmesinde önemli bir unsurdur. Günümüzde rekabet yoğunlaştı ve ulusaldan küresel arenaya kaydı ve ürün yaşam döngüleri küçülmüştür; yine de müşterilerin özel ve bireysel ihtiyaçlarını karşılamak için artan bir gereksinim vardır. Dünya ekonomisi hızlı bir dönüşümün ortasındadır. İnternet, Mobil teknoloji, Sosyal Medya ve Büyük Veri trendleri, binlerce yeni girişim ve iş pozisyonu yaratan ve geleneksel endüstrileri yeniden icat eden bir izolasyon dalgasını ortaya çıkardı. Günümüzde, iş dünyasını ve ekonomiyi olduğu kadar toplumu da dönüştüren büyük teknoloji trendlerine tanık olmaktayız. Artık her endüstri, küresel ekonominin manzarasını yeniden çizen Bulut, Sosyal Medya, Büyük Veri gibi bilgi teknolojisi trendlerinin ortaya çıkışından tamamen olmasa da büyük ölçüde etkileniyor. Bu ortaya çıkmanın en büyük sonucu, küresel pazarda en çok talep edilen işlerin haritasını değiştiren ve aynı zamanda yeni iş pozisyon profillerini mümkün kılan ve yaratan bazı işlerin yer değiştirmesidir.

2.1 Bilgi Sistemlerinin Bileşenleri

Bilgi sistemlerinin ana bileşenleri bilgisayar donanımı ve yazılımı, telekomünikasyon, veri tabanları ve veri ambarları, insan kaynakları ve prosedürlerdir. Donanım, yazılım ve telekomünikasyon, artık organizasyonların operasyonlarında ve yönetiminde yerleşik olan bilgi teknolojisini (BT) oluşturur

2.2 Riskler

Bilgi teknolojisi (BT) birçok işletmede kritik bir rol oynar. BT'yi kullanan bir işletmeye sahipseniz veya yönetiyorsanız, BT sistemlerinize ve verilerinize yönelik riskleri belirlemek, bu riskleri azaltmak veya yönetmek ve BT krizi durumunda bir müdahale planı geliştirmek önemlidir. İşletme sahiplerinin, BT

risk yönetimi stratejilerini etkileyen gizlilik, elektronik işlemler ve personel eğitimi ile ilgili yasal yükümlülükleri vardır. BT riskleri arasında donanım ve yazılım arızası, insan hatası, istenmeyen e-posta, virüsler ve kötü niyetli saldırılar ile yangınlar, siklonlar veya seller gibi doğal afetler bulunur. Bir iş riski değerlendirmesini tamamlayarak BT risklerini yönetebilirsiniz. Bir iş sürekliliği planına sahip olmak, işletmenizin bir BT olayından kurtulmasına yardımcı olabilir. Bu kılavuz, BT risklerini anlamanıza yardımcı olur ve BT olaylarına hazırlanma ve müdahale etme yolları hakkında bilgi sağlar.

3. TANIMLAR

3.1 Yapay Zeka

Yapay zekâ ilk bakışta insanlar gibi çalışan ve akıllı makinelerin oluşturmasını sağlayan sistemleri akla getirmektedir. Bu makineleri zeki canlılara benzeterek onlar gibi davranmaya çalışan ve sistemleri yöneten bir bilim dalıdır. Günümüz teknolojisinde hayatımızda önemli bir yer almaktadır. Bu sistemler içerisinde öğrenme, muhakeme, bilgi, algı, planlama gibi kavramlar yer almaktadır. Yapay zekâ insan gibi düşünüp, davranan bir yapıyı algoritma olarak bilgisayar sistemlerinde uygulayarak gerçekleştirilmektedir. Yapay zekânın günümüzde olumlu yönleri olduğu kadar olumsuz yönleri de vardır. Birçoğumuz insanlığa karşı çıkan benzeri bir robot ordusunu hayal ederken, birçoğumuz ise hayatımızda çok önemli yeri olacağını düşünmektedir. Makine öğrenmesiyle desteklenmiş yapay zekâ sistemleri, şirketlerin herhangi bir kimsenin dikkatini bozması olanaksız olacak öngörülerini ve sistemleri açığa çıkarmak, daha verimli, hatasız ve güvenli, kişileştirilmiş iletişim kurmalarını, kritik onarım olaylarını tahmin etmelerini sağlamaya olanaklı kılmak için mevcut büyük miktardaki verilerden yararlanmasını sağlamaktadır.

3.1.1 Tarihçe

Yapay zekâ tarihi yaklaşık yüz yıl önce başlamıştır.1920 'de Çekli yazar Karel Papek rosum'un evrensel robotları adında bir bilim kurgu oyunu yayınlanmaktadır. Rossumun evrensel robotları, robot olarak isimlendirilerek yapay insanları yaratan bir fabrika ile ilgilenmektedir [15]. 1912 'de Alan Turing, 23 Haziran 1912'de Londra'da doğmuştur. Yaygın olarak tanınmaktadır, çünkü Nazi Almanya'sında haberleşmek için kullanılan gizem kodunu şifrelemektedir. Alan Turing'in çalışması aynı zamanda, problemlerin ne kadar verimli şekilde çözümlenebileceğine dair yaptığı hesaplama teorisine yol açmaktadır. Turing makinenin fikrini de sunmaktadır ve hala şuan yaygın

kullanılmaktadır. Bu makine modelinin sadeliğine rağmen, herhangi bir algoritma mantığını oluşturabilen bir soyut makinedir.

Yapay zekâ sözünün doğuşu 1956 Dartmouth Konferansı'na dayanmaktadır. Bu konferans yaklaşık sekiz haftada sürmüştür, konferansta Auto mata teorisi, sibernetik, yapay sinir ağları, sinyal işleme, bilişsel bilim ve mantık teorisi gibi farklı alanlardan dönemin önemli 10-20 araştırmacıları katılmıştır. Bu isimlerin her biri kendi alanında birer uzmandır. Ancak, MIT yapay zekâ laboratuvarlarının kurucusu Marvin Minsky yapay zekâ alanında genel olarak öne çıkan isimdir [16]. Yapay zekânın ile ilgili konuşulan konu başlıklarından bazıları yapay sinir ağları, genetik algoritmalar, bileşenler, uzman sistemler, bulanık mantıktır.

Yirmi birinci yüzyılda yapay zekâ daha yavaş şekilde büyümektedir. Yapay zekâ pazarı 2017'de sekiz milyar dolara ulaşmaktadır, araştırma firması International Data Corporation pazarın 2020 yılına kadar 47 milyar dolar olacağını öngörmektedir. [17] Bu veriler daha performanslı bilgisayarlar ve son yıllardaki machine learning uygulamalarındaki gelişmelere sayesinde mümkündür. Yapay zekâ önümüzdeki yıllarda daha yaygın hale gelecektir.

3.1.2 Yapay Zekâ Tanım

Yapay Zekâ, akıllı davranışı simüle edebilen bilgisayar ve makineler kurmaya odaklanan bir bilgisayar bilim dalıdır. Bilgisayar ve makineler insan gibi düşünmek ve karar vermek için programlanmaktadır. Bu makineler insanın davranış şeklini alır. Yapay zekâ en önemli özelliği, öğrenme ve problem çözme gibi bir insan beyniyle ilgili özellik gösteren ve herhangi bir makineye uygulanabilir olmasına rağmen, belirli bir hedefe ulaşma şansına sahip olanları karar verme ve harekete geçirme yeteneğidir. En basit bir insan davranışı dışında hepsi yönetilirken, en karmaşık bir hayvan davranışı bile asla bir zekânın göstergesi değildir. Psikologlar genellikle insan zekâsını sadece bir özellik ile değil, birçok farklı yeteneğin bir araya getirmesiyle karakterize etmektedir.

3.1.3 Yapay Zekâ kullanım alanları

3.1.3.1 Öğrenme

Yapay zekâ ile uygulanan birçok öğrenme türleri vardır. Bunlardan en basitini örnek göstermek gerekirse deneme ve yanılma ile sonuca ulaşarak öğrenmektir. Bir satranç problemini çözmek için basit bir bilgisayar programı sonuca ulaşana kadar rastgele bütün hareketleri deneyebilir. Program sonra çözüm pozisyonunu hafızasında tutabilir, böylece bilgisayar aynı pozisyonda karşı karşıya geldiğinde çözümü hatırlayacaktır.

3.1.3.2 Muhakeme

Akıl yürütme, yapay zekâ teknolojilerin çok sayıda yapılandırılmış ve yapılandırılmamış veri havuzundan kritik bilgi çıkarmasına, kümeleme, analiz yapmasına ve insan bilişine yaklaştırmaya başlayacak şekilde istatistiksel çıkarım kullanmasına izin verir.

3.1.3.3 Etkileşim

Etkileşim yapay zekâ teknolojilerinin bilgisayar vizyonunu, iletişim için konuşma yapay zekasını ve okumak hesaplama algoritmalarını kullanmalarını ve insan seviyesindeki bilişine yaklaşmasını sağlar

3.1.3.4 Problem çözme

Yapay zekâ da problem çözme, önceden belirlenmiş bir amaç yâda çözüme ulaşmak için çeşitli ihtimal eylemler aracılığıyla sistemli bir arama olarak tanımlanmaktadır. Problem çözme aşamaları iki amaca ayrılır. Bunlar özel ve yaygın amaçlardır. Özel bir prosedür, belirli bir sıkıntı için özel olarak hazırlanmıştır. Yapay zekâ da kullanılan genel amaçlı bir teknik adım adım ve artarak sonuç analiz etmektedir. Yapay zekâ programları ile birçok farklı problem çözülmüştür. Bunlardan bazıları, masa oyununda kazanma hareketini tespit edip bulma, matematiksel gerçek sonuçlar üretip geliştirmek ve bilgisayar tarafından sanal nesnelere kullanılmaktadır.

3.1.3.5 Algı

Algı çevredeki tüm her şeyi duyu organları ile algılanır, mekân bazlı yerlerde ayrı objelere ayırır. Analiz ederken bir objenin görüntülediği açığa, boyuta


ve yönüne, yoğunluğuna bulunduğu alana göre farklılık göstermektedir Bu yüzden çok karışıktır bir yapıdır

3.2 Makine Öğrenmesi nedir?

Makine öğrenimi sistemlere herhangi bir programlama yapmadan yapılan işlemlerden deneyimden otomatik olarak bellek ve iyileştirme kabiliyeti sağlayan bir yapay zekâ uygulamasıdır. Bu süreç verideki kalıpları aramak ve sunduğumuz örneklerle dayanarak gelecekte daha iyi kararlar almak için örnekler, doğrudan deneyim veya talimat gibi gözlemler veya verilerle başlar. Temel amaç bilgisayarların insan müdahalesi ve desteği olmadan insan gibi düşünerek otomatik olarak öğrenmesine ve aksiyonları buna göre ayarlamasına izin vermektedir (26).

3.2.1 Denetimli Öğrenim (Supervised Learning)

Denetimli öğrenme algoritmaları input verilerine eğitim verileri denir. Tahmin işlemleri gerekli olduğu bir çalışmada eğitim süreci ile bir model hazırlanır, bu tahminler yanlış sonuç verdiğinde düzeltilir. Eğitim ve test süreçleri, model eğitim verileri üzerinde istenen doğruluk seviyesine ulaşana kadar sürekli tekrarlanmasıdır. Örnek sorunlar sınıflandırma ve regresyondur. Örnek algoritmalarından bazıları Logistic Regression ve Back Propagation Neural Network.




Supervised Learning
Algorithms

Şekil 3.1: Denetimli öğrenme Algoritmaları

3.2.2 Denetimsiz Öğrenme (Unsupervised Learning)

İnput verilerinde bulunan yapılar çıkarılarak bir model hazırlanır.

Giriş verileri etiketlenmemiş ve bilinen bir sonucu yok. Genel kuralları ayıklamak için Girdi verilerinde bulunan yapılar çıkarılarak bir model hazırlanır. Sistemik olarak fazlalığı azaltmak için matematiksel bir süreç olabilir veya verileri benzerliğe göre organize etmek olabilir. Örnek problemler kümeleme, ölçüsellik azaltılması ve bağlantı kurallarının öğrenilmesidir. Örnek algoritmalar Apriori algorithm ve K-Means.




Unsupervised Learning
Algorithms

Şekil 3.2: Denetimsiz Öğrenme

3.2.3 Yarı Denetimli Öğrenim (Semi-Supervised Learning)

Input verileri, etiketli ve etiketlenmemiş örneklerin bir karışımıdır. Bir model verileri düzenlemek ve tahmin yapmak için yapıları öğrenmesi gerekiyor. Classification ve regression örnek olarak kullanılan problemleridir. Örnek bazı algoritmalar, etiketlenmemiş verilerin nasıl modelleneceğine dair tahminler yapan diğer esnek yöntemlerin dallarıdır (27).



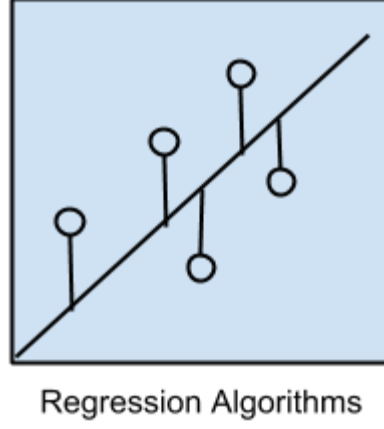
Semi-supervised
Learning Algorithms

Şekil 3.3: Semi-Supervised Learning

3.2.4 Regresyon Algoritmaları (Regression Algorithms)

Regresyon, model tarafından yapılan tahminlerde bir hata oranı kullanılarak tekrarlı olarak artırılmış olarak elde edilen nesnelere arasındaki ilişkiyi modellemektir. Regresyon işlemleri sayısal bir çalışma adıdır ve istatistiksel makine öğrenimine kapsamıştır. Problem sınıfına ve algoritma sınıfına uygulamak için regresyonu kullanabiliriz. Regresyon gerçek bir süreçtir. Yaygın regresyon algoritmalarından bazıları;

- Ordinary Least Squares Regression(OLSR) :Olağan En Küçük Kareler Regresyonu
- Multivariate Adaptive Regression Splines (MARS):Çok Değişkenli Uyarlanabilir Regresyon Spline'lar
- Locally Estimated Scatterplot Smoothing (LOESS):Yerel Olarak Tahmini Dağılım Grafiği Düzeltme
- Linear Regression :Doğrusal Regresyon
- Logistic Regression :Lojistik regresyon
- Stepwise Regression :Aşamalı Regresyon

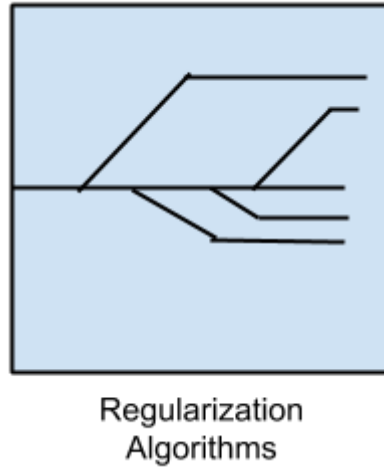


Şekil 3.4: Instance-based Algorithms

3.2.5 Örnek tabanlı algoritmalar (Instance-based Algorithms)

En popüler örnek tabanlı uygulamalar

- k-Nearest Neighbor (kNN): k-En Yakın Komşu
- Learning Vector Quantization (LVQ) : Vektör Nicemlemeyi
- Self-Organizing Map(SOM) :Kendi Kendini Düzenleyen Harita
- Locally Weighted Learning (LWL) :Yerel Ağırlıklı Öğrenme
- Support Vector Machines(SVM): Destek Vektör Makineleri




Şekil 3.5: Instance-based Algorithms

3.2.6 Düzenleme Algoritmaları (Regularization Algorithms)

Düzenleme algoritmalarının arkasındaki genel fikir, aşırı takmayı en aza indirmeye ve hatta önlemeye çalışmalarıdır. Önyargı ve varyans dengeleme

kavramı, aşırı uyum olgusunu anlamada yardımcı olur. En popüler düzenleme algoritmaları şunlardır:

- Ridge Regresyon
- Least Absolute Shrinkage and Selection Operator (LASSO) :En Az Mutlak Büzülme ve Seçim Operatörü
- Elastic Net: Elastik Ağ
- Least-Angle Regression (LARS):En Küçük Açılı Regresyon



Regularization Algorithms


Şekil 3.6: Regularization Algorithms

3.2.7 Karar Ağacı Algoritmaları (Decision Tree Algorithms)

Karar ağacı algoritması datalardaki özelliklerinin gerçeklerine dayalı olarak alınan kararların bir modelini oluşturur. Bu kararlar belirli bir kayıt için bir tahmin kararı verilene kadar ağaç yapılarında parçalanır. Karar ağaçları, sınıflandırma ve regresyon problemlerine yönelik veriler üzerinde eğitilir. Karar ağaçları genelde hızlı ve doğru sonuçlar üretir. Makine öğreniminde en çok kullanılan bir algoritmadır.

- Classification and Regression Tree (CART): Sınıflandırma ve Regresyon Ağacı
- Iterative Dichotomiser 3 (ID3) : Yinelemeli Dikotomiser 3
- C4.5 and C5.0 (different versions of a powerful approach): C4.5 ve C5.0 (güçlü bir yaklaşımın farklı versiyonları)

- Chi-squared Automatic Interaction Detection (CHAID) : Ki-kare Otomatik Etkileşim Algılama (CHAID)
- Decision Stump: Karar Gdk
- M5
- Conditional Decision Trees




Decision Tree Algorithms

Şekil 3.7: Decision Tree Algorithms

3.2.8 Bayes Algoritmaları (Bayesian Algorithms)

Sınıflandırma ve regresyon gibi sorunlar için Bayes kuramını açıkça uygulayan yöntemlerdir.

- En popüler Bayesian algoritmaları;
- Naive Bayes: Naif bayanlar
- Gaussian Naive Bayes
- Multinomial Naive Bayes: Çok terimli Naif Bayes
- Averaged One-Dependence Estimators (AOE): Ortalamalı Tek Bağımlılık Tahmincileri
- Bayesian Belief Network (BBN): Bayes İnanç Ağı
- Bayesian Network (BN): Bayes Ağı




Şekil 3.8: Bayesian Algorithms

3.2.9 Küme algoritmaları(Clustering Algorithms)

Kümeleme algoritmaları, regresyon algoritmaları gibi , problem ve yöntem sınıfını tanımlar. Kümeleme yöntemleri karakteristik olarak merkez tabanlı ve hiyerarşik gibi modelleme yaklaşımları tarafından düzenlenir. Tüm yöntemler, verileri maksimal ortak gruplara göre en iyi şekilde organize etmek için verilerdeki saf yapıları kullanmakla ilgilidir.

- k-Means
- k-Medians
- Hierarchical Clustering: Hiyerarşik kümeleme
- Expectation Maximisation (EM): Beklenti Maksimizasyonu




Şekil 3.9: Clustering Algorithms

3.2.10 Birliktelik Kural Çıkarımı (Association Rule Learning Algorithms)

Verilerdeki değişkenler arasında gözlemlenen ilişkileri en iyi açıklayan kuralları gösterir. Bu kurallar, bir kuruluş tarafından yararlanılabilecek çok büyük ölçekli veri kümelerinde önemli ve ticari olarak yararlı ilişkileri keşfedebilir.

En yaygın birliktelik kuralı öğrenme algoritmaları bazıları

- Apriori algorithm
- Eclat algorithm



Association Rule
Learning Algorithms

Şekil 3.10: Association Rule Learning Algorithms


3.2.11 Yapay sinir ağı algoritmaları (Artificial Neural Network Algorithms)

Yapay Sinir Ağları algoritmaları , biyolojik sinir ağlarının yapısındaki çalışma biçiminden esinlenen modellerdir. Bu modeller, regresyon ve sınıflandırma problemleri için popüler olarak yaygın kullanılan, ancak her türlü problem türü için yüzlerce algoritma ve değişikliklikten oluşan bir model eşleştirme sınıfıdır. Yapay sinir ağları çok büyüme ve popülerlik nedeniyle derin sinir ağlarından ayırmıştır.

En popüler yapay sinir ağı algoritmalarından bazıları;

- Radial Basis Function Network (RBFN)
- Stochastic Gradient Descent
- Hopfield Network
- Perceptron

- Multilayer Perceptrons (MLP)
- Back-Propagation




Artificial Neural Network
Algorithms

Şekil 3.11: Artificial Neural Network Algorithms

3.2.12 Boyut İndirgeme Algoritmaları (Dimensionality Reduction Algorithms)

Kümeleme algoritma yöntemleri gibi, boyut küçültme de verilerdeki saf yapıyı arar ve kullanır, ancak bu durumda denetimsiz bir şekilde veya sırayla daha az bilgi kullanarak verileri özetlemek veya açıklamak. Bu, boyutsal verileri görselleştirmek veya daha sonra denetimli bir öğrenme yönteminde kullanılacak verileri basitleştirmek için yararlı olabilir.

- Linear Discriminant Analysis (LDA)
- Principal Component Analysis (PCA)
- Principal Component Regression (PCR)
- Mixture Discriminant Analysis (MDA)
- Quadratic Discriminant Analysis (QDA)
- Flexible Discriminant Analysis (FDA)
- Partial Least Squares Regression (PLSR)
- Sammon Mapping
- Multidimensional Scaling (MDS)
- Projection Pursuit




Dimensional Reduction
Algorithms

Şekil 3.12: Dimensionality Reduction Algorithms

3.2.13 Topluluk Algoritmaları (Ensemble Algorithms)

Topluluk algoritmaları, bağımsız olarak eğitilmiş ve tahminleri bir şekilde genel tahmini yapmak için birleştirilen çok sayıda zayıf modelden oluşan modellerdir. Hangi tür zayıf öğrencilerin bir araya getirileceği ve bunları nasıl bir araya getireceği konusunda çok çaba harcanır. Bu algoritma modeli çok kuvvetli ve teknikler sınıfıdır ve bu nedenle çok yaygındır.

- Bootstrapped Aggregation (Bagging)
- Boosting
- Random Forest
- Weighted Average (Blending)
- AdaBoost
- Stacked Generalization (Stacking)
- Gradient Boosting Machines (GBM)
- Gradient Boosted Regression Trees (GBRT)



Ensemble Algorithms

Şekil 3.13: Ensemble Algorithms

3.2.14 Diğer Makine Öğrenme Algoritmaları

- Algorithm accuracy evaluation
- Optimization algorithms
- Performance measures
- Feature selection algorithms
- Algorithm accuracy evaluation
- Performance measures
- Optimization algorithms
- Computer Vision (CV)
- Reinforcement Learning
- Graphical Models
- Computational intelligence (evolutionary algorithms, etc.)
- Natural Language Processing (NLP)
- Recommender Systems


3.2.15 Derin Öğrenme Algoritmaları (Deep Learning Algorithms)

Derin Öğrenme yöntemleri, çok miktarda uygun hesaplamadan yararlanan Yapay Sinir Ağlarına yönelik modern bir algoritmadır. Daha çok büyük ve daha komplike sinir ağları oluşturmakla ilgilenirler. Görüntü, metin gibi çok büyük

etiketli analog veri veri kümeleriyle ilgili yöntemlerdir. Ses ve video işlemlerinde de yaygın olarak kullanılmaktadır.

En popüler derin öğrenme algoritmaları şunlardır;

- Long Short-Term Memory Networks (LSTMs): Uzun Kısa Süreli Bellek Ağları
- Recurrent Neural Networks (RNNs): Tekrarlayan Sinir Ağları
- Convolutional Neural Network (CNN): Evrişimli Sinir Ağı
- Stacked Auto-Encoders : Yığınlanmış Otomatik Kodlayıcılar
- Deep Boltzmann Machine (DBM): Derin Boltzmann Makinesi
- Deep Belief Networks (DBN): Derin İnanç Ağları




Deep Learning Algorithms

Şekil 3.14: Deep Learning Algorithms

3.3 RNN Tekrarlayan Sinir ağı Nedir?


Tekrarlayan sinir ağı (RNN), çoğunlukla sıralı verilerin analizi için kullanılan bir tür derin öğrenme modelidir (zaman seri analizi). RNN kullanılan uygulama alanlarımdan bazıları müzik, üretimi, dil modeli, sinirsel makine (neural machine) çeviri, finansal tahmin, zaman serisi tahmini, zamanla değişen hisse senedi fiyatları, sensor okumaları, tıbbi kayıtlar vb. alanlarda kullanılır.

Tekrarlayan sinir ağları bu sorunu çözer. Bilginin kalıcı olmasını sağlayan, içlerinde döngüler bulunan ağlardır.



Şekil 3.15: Tekrarlayan Sinir ağı göngüleri

Yukarıdaki şekilde, bir sinir ağı kümesi olan A , bazı x_t girişlerine bakar ve bir h_t değeri verir. Döngü, bilgilerin ağı bir basamağından diğerine aktarılmasına izin verir. Bu döngüler, tekrarlayan sinir ağlarını biraz gizemli gösteriyor. Bununla birlikte, biraz daha fazla düşünersek, bu ağlar normal bir sinir ağından çok da değişik olmadığı ortaya çıkar. Yinelenen bir sinir ağı, her biri bir halefine bir ileti ileten aynı ağı birden fazla kopyası olarak düşünülebilir.

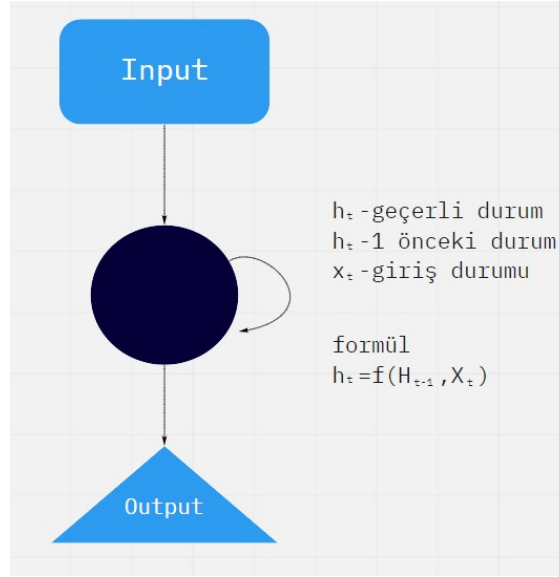


Şekil 3.16: X_t Giriş ve h_t çıkış Sinir Ağı

Şekil 2 de gösterildiği gibi girdi X_t ve çıktı h_t kullanan bir sinir ağıdır. Bilgi aktarılırken bir ardımdan arka arkaya aktarılır.

Tekrarlayan sinir ağları çalışma şekli aşağıdaki şekilde gösterilmiştir. Tekrarlayan sinir ağları ilk olarak bağımsız aktivasyonların bağımlı aktivasyonlara dönüştürülmesini gerçekleştirir. Aynı zamanda tüm katmanlara aynı ağırlık ve sapma atar, bu sapma RNN parametrelerinin karmaşıklığını daha

da azaltır ve bir sonraki katmana girdi olarak önceki çıktıyı sağlar ve önceki çıktıların bellekte tutulması için standart bir platform sağlar



Şekil 3.17: RNN Çalışma şekli

3.3.1 Tekrarlayan Sinir Ağının Avantajları?

- RNN, veri dizisini modelleyebilir, böylece her örneğin öncekilere bağlı olduğu varsayılabilir.
- Yinelenen sinir ağı, etkili piksel komşuluğunu genişletmek için evrimsel katmanlarla bile kullanılır.

3.3.2 Tekrarlayan Sinir Ağının Dezavantajları?

- Gradyan kaybolma ve patlama problemleri.
- Bir RNN eğitimi çok zor bir iştir.
- Etkinleştirme işlevi olarak tanh veya relu kullanılıyorsa çok uzun dizileri işleyemez.

3.3.3 Neden RNN?

Geleneksel sinir ağları, geçmişteki girdilere dayanarak gelecekteki girdileri ele alma yeteneğinden yoksundur. Örneğin, geleneksel bir sinir ağı önceki dizilere dayanan dizideki bir sonraki sözcüğü tahmin edemez fakat. RNN kesinlikle yapabilir. Tekrarlayan sinir ağları (RNN) yinele bildiği için bilgilerin devam

etmesine izin veren döngüler halinde işlemi yürütmektedir. RNN'ler bir dizi veya bir vektör zinciri üzerinden modelleme yapmamıza izin verir.

3.4 Zaman Seri Analizi Nedir?


Zaman serisi, zaman içindeki farklı noktalarda bir değişkenin değerini veya durumunu temsil eden seri olarak sıralanmış bir değerler kümesidir. Örneğin saatler, aylar veya yıllar gibi belirli bir zamanda kaydedilmiş sıralı gözlemlerin makalemizde Twitter üzerinde belirlediğimiz üniversitelere ait aylık tüm tweetleri içeren veri setlerini analiz edilecektir.

Zaman serileri kullanıldığı alanların bazıları; Sosyal Medya Tahmin Analizi, Bütçe Analizi, Finansal Piyasa Analizi, Sayım Analizi, Envanter yönetimi, Ekonomik Tahmin, Pazarlama ve Satış Tahmini, Getiri Projeksiyonları Sismolojik Tahminler, İş Yükü Projeksiyonları, Askeri Planlama

3.5 LSTM Nedir?

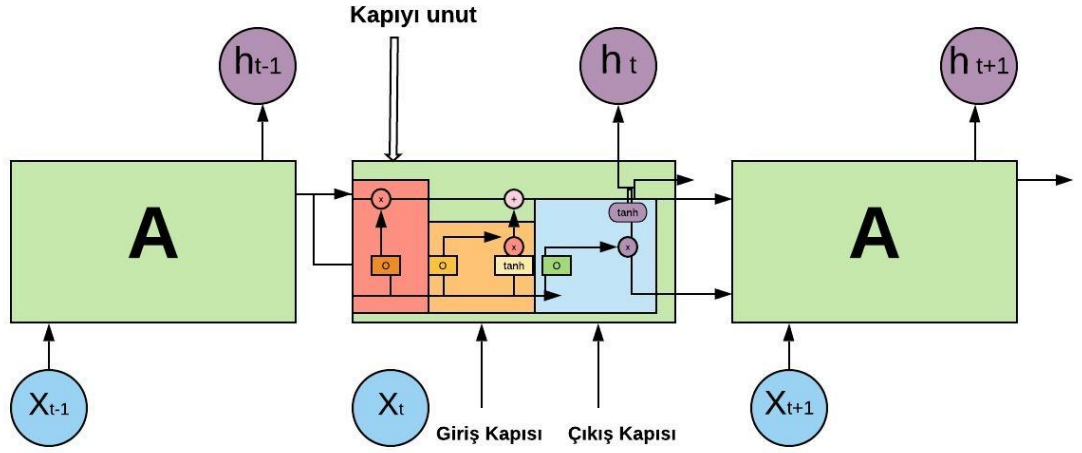
LSTM uzun kısa süreli bellek anlamına gelir. Tekrarlayan sinir ağlarının hafızasını genişleten bir model veya mimaridir. Karakteristik olarak, tekrarlayan sinir ağları, mevcut sinir ağına kullanılmak üzere kalıcı önceki bilgileri kullandıkları için kısa süreli belleğe sahiptir.

Tüm yinelenen sinir ağları, sinir ağının yinelenen modüllerinden oluşan bir zincir biçimine sahiptir. Standart RNN'lerde, bu tekrar eden modül, tek bir tanh katmanı gibi çok basit bir yapıya sahip olacaktır.



Şekil 3.18: Standart bir RNN'deki tekrar eden modül, tek bir katman içerir

LSTM, süresi bilinmeyen zaman aralıklarında verilen zaman serilerini sınıflandırmak, işlemek ve tahmin etmek için çok uygundur. Geri yayılım kullanarak modeli eğitir. Bir LSTM ağında üç kapı bulunur:



Şekil 3.19: LSTM Kapıları

$$i_t = o(W_i \cdot [h_{t-1}, x_t] + b_i)$$

Giriş ve güncelleme geçidinin aktivasyon vektörü

$$c_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Hücre giriş aktivasyon vektörü

Kapı: Girdi kapısı

Şekil 2’de görüldüğü gibi girdi kapısı belleği değiştirmek için girişten hangi değerlerin kullanılması gerektirdiğini keşfeder. Sigmoid: 0,1 ile hangi değerleri girebileceğine karar verir.

Kapıyı unut kapısı:

Bloktan hangi detayların çıkarılacağını keşfeder. Sigmoid fonksiyonu tarafından karar verilir ve önceki duruma bakar HT-1 ve içerik girdi (X_t) arasında bir sayı üretir

$$f_t = o(W_f \cdot [h_{t-1}, x_t] + b_f)$$

- Aktivasyon vektörünü unut
- Formül 1Unut Kapısı

Çıkış Kapısı: Bloğun girdi ve hafızayı çıktığı karar vermek için kullanılır. Sigmoid işlevi 0,1 ile hangi değerlerin girileceğine karar verir

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o)$$

LSTM birimine giriş vektörü

- Formül 2 Çıkış Kapısı

$$h_t = \tanh(C_t)$$

LSTM ünitesinin gizli durum vektörü

$$R^2_{\text{wrong}} = \text{mean}_i \left(\frac{(y_i - \hat{y}_i)^2}{(y_i - \mu)^2} - 1 \right)$$

- Formül 3-R Kare Hesaplama formülü

3.5.1 LSTM'lerin Arkasındaki Temel Fikir?

LSTM'lerin anahtarı, diyagramın üstünden geçen yatay çizgi olan hücre durumudur. Hücre durumu bir tür taşıma bandı gibidir. Sadece bazı küçük doğrusal etkileşimlerle tüm zincir boyunca düz bir şekilde ilerler. Bilginin değişmeden akması çok kolaydır. LSTM, kapılar adı verilen yapılar tarafından özenle düzenlenen hücre durumuna bilgileri kaldırma veya ekleme kabiliyetine sahiptir. Kapılar, isteğe bağlı olarak bilgi aktarmanın bir yoludur. Bir sigmoid sinir ağı katmanından ve noktasal çarpma işleminden oluşurlar. Sigmoid katman, her bir bileşenin ne kadarının geçişine izin verilmesi gerektiğini açıklayan sıfır ile bir arasındaki sayıları verir. Sıfır değeri "hiçbir şeyin iletilmesin izin vermeyin" anlamına gelirken, bir değeri "her şeyin geçmesine izin verin!" Bir LSTM, hücre durumunu denetlemek ve korumak için bu kapılardan üçüne sahiptir. [18]

3.5.2 LSTM Uygulamaları

- Language modeling (Dil Modelleme)
- Image captioning (Resim yazısı)
- Handwriting recognition (Elyazısı tanıma)
- Machine translation (Makine çevirisi)
- Question answering (Soru cevaplama)

- Video-to-text conversion (Videodan metne dönüştürme)
- Polymorphic music modeling (Polimorfik müzik modelleme)
- Speech synthesis (Konuşma sentezi)
- Image generation using attention models (Dikkat modelleri kullanarak görüntü oluşturma)
- LSTM sinir ağları, RNN'ler gibi önceki öğrenme algoritmaları tarafından çözülmeyen çok sayıda görevi çözme yeteneğine sahiptir. Uzun vadeli zamansal bağımlılıklar, çok sayıda optimizasyon engeline maruz kalmadan LSTM tarafından etkili bir şekilde yakalanabilir.

3.6 Lstm ile Rnn arasındaki farklar nedir?

Long short term memory algoritmaları, özel bir tekrarlayan sinir ağları (Recurrent neural networkler türüdür. RNN sinir ağları geri bildirim döngüleri olan geniş bir sinir ağları kategorisidir. Önceki inputlarla ilgili bilgileri "hatırlama" ve kullanma yeteneğine sahiptir.

LSTM'lerin neden RNN'ler alanına hâkim olduğunu anlamak için önce sinir ağlarının nasıl eğitildiğine kısaca bakmamız gerekiyor. Çoğu ağ, yinelemeli bir süreç olan bazı gradyan iniş varyantları ile eğitilir.

Sinir ağlarının her adımda aşağıdakileri yapmaktadır.

1. Veri kümesinden bir örnek girdi girin.
2. Ağ bu örneği alacak ve rastgele başlatılmış değişkenler (ağırlık ve önyargı olarak adlandırılır) kullanarak ona bazı karmaşık hesaplamalar uygulayacaktır.
3. Tahmin edilen bir sonuç üretilecektir.
4. Bu sonucu beklenen değerle karşılaştırmak bize bir hata verecektir.
5. Hatayı aynı yoldan geri yaymak değişkenleri ayarlayacaktır.
6. Değişkenlerimizin iyi tanımlandığından emin olana kadar 1-5 arasındaki adımlar tekrarlanır.

7. Hesaplamak için hata kullanarak gradyanı modelimizdeki hata miktarını azaltmak için sinir ağıımızdaki parametreleri nasıl değiştireceğimizi söyler. Gradyan, temelde analizdeki zincir kuralı olan geri yayılma yoluyla hesaplanır.
8. 1-4 arası adımları diğer girişlerle tekrarlayın
9. Bu değişkenler yeni bir görünmeyen girdiye uygulanarak bir tahmin yapılır. (28)

(Kullandığınız gradyan iniş varyantına bağlı olarak, bu adımlar biraz değişebilir)

Rnn sinir ağlarındaki değişim kararsızdır. Daha önceki gradyanlar sonraki gradyanların ürünü olduğundan, üstünlük olarak çoğalma veya eksilme eğilimindedirler. Bu, kaybolan / patlayan gradyan problemi olarak bilinir.

Kararsız gradyanlar RNN'lerde daha çok kötüdür bu da bir olarak bilinmektedir. Bunun nedeni RNN'leri eğittiğimizde, sadece tüm farklı katmanlardaki gradyanı değil, aynı zamanda zaman içinde de hesaplıyoruz. Bunu görselleştirmenin bir yolu, RNN'yi "açmamızdır", bu sayede aynı RNN'nin birçok farklı kopyası birbirinin üzerine toplanır ve hepsini aynı anda eğitiriz. Bu, çok daha fazla katmana yol açar ve böylece kaybolan gradyan problemi çok daha kötü hale getirir. Bu nedenle, "vanilla " RNN'lerin teorik olarak uzak geçmişten gelen bilgileri kullanabilmeleri gerekmesine rağmen, pratikte bunu yapamamışlardır. Örnek vermek gerekirse bir önceki cümlede bir kelimeyi hatırlamak.

Uzun Kısa Süreli Bellek ağları hücre durumu, neredeyse bir bilgisayarın hafızasında depolanan veriler gibi düşünülebilir. LSTM'ler, "kapılar" adı verilen özel nöronları kullanarak hücre durumundaki bilgileri "hatırlayabilir" veya "unutabilir". Bu şekilde, LSTM'ler uzun vadeli bağımlılıkları koruyabilir ve geçmişten günümüze bilgi bağlayabilir. LSTM'lerde üç kapı vardır.

1. Kapıyı unutun: Önceki girdilerden hangi bilgilerin unutulacağına karar verir
2. Girdi kapısı: hangi yeni bilgilerin hatırlanacağına karar verir
3. Çıktı kapısı: hücre durumunun hangi kısmının çıkacağına karar verir (LSTM sonucunda çıkan şey budur)

LSTM'lerde geri yayılma matematiđi (gradyanı ölçmek) çok daha karmaşıktır, ancak hücre durumumuzdaki bilgilerin kaybolan gradyan probleminden etkilenmemesi için uygun şekilde çalışır. Böylece, LSTM'ler kaybolan gradyanlara çok daha dayanıklıdır (29).

4. KAPSAM

Bu çalışma kapsamında sosyal medya uygulaması Twitter üzerinde üniversitelere ait tweetleri göre analiz yaparak tahmin edilmesi sonucu pazarlama faaliyetlerinde kullanılmak üzere amaçlanmıştır.

5. YÖNTEM

Yapılan çalışmada geliştirilen veri kümesi Twitter sosyal medya üzerindeki veriler üzerinde oluşturulan veri kümesi Python dilinde Jupiter ara yüz ile veriler girdi olarak kullanılmıştır. Makine öğrenmesi yöntemi olan LSTM Uzun Kısa Süreli Bellek (Long Short-Term Memory- LSTM) ağı ve Tekrarlayan Sinir Ağı (RNN) modeli kullanılmıştır. Veriler Twitter API üzerinden veriler C# dili ile belirli zaman diliminde veriler API aracılığı veri tabanına kaydedilmektedir. Bu veriler veri tabanından çıktı alınarak Python dili ile yapılan çalışmada girdi olarak kullanılmaktadır. Makine öğrenme algoritmalarından açık kaynak kodlu olan Tensorflow, LSTM, RNN kullanılmıştır. Matplotlib, pandas, keras kütüphaneleri analiz çalışmasında kullanılmıştır. Zaman serilerinin

İ kullanırken, değerlerin sırası önemlidir. Kullanabileceğimiz basit bir yöntem, elde edilen veri setini eğitim ve test veri setlerine bölmektedir. Elde edilen veriler ile ilgili çalışmamızda verilerin eğitilmesi için %67, değerlendirilmesi için %33 oranında veriler kullanılmıştır.

5.1 Algoritma seçimi ve projeye uyarlama aşamaları

LSTM ağları, bir zaman serisindeki önemli olayları bilinmeyen süre gecikmeleri olabileceğinden, zaman serisi verilerine dayalı olarak sınıflandırma, işleme ve tahminler yapmak için çok uygundur. LSTM'ler, geleneksel RNN'leri eğitirken karşılaşılabilen kaybolan gradyan problemini çözmek için geliştirilmiştir. Boşluk uzunluğuna göreceli duyarsızlık, birçok uygulamada LSTM'nin RNN'lere, gizli Markov modellerine ve diğer dizi öğrenme yöntemlerine göre bir avantajıdır. LSTM modeli ile alınan sonuçlar ARIMA Modeli ile karşılaştırılmıştır. Literatür araştırmalarımda bu çalışmada da LSTM ile tahmin problemlerinde en iyi ve en yakın sonuçlar aldığı görülmüştür.

5.1.1 Verilerin API üzerinden alınması c# kod bloğu

-Twitter Api search parametreleri; arama türü, dil, max tweet sayısı, tür filtresi ile sorgu filtresi oluşturulmaktadır.

-

```
var searchParameter = new SearchTweetsParameters("tweetinvi")
{
    SearchQuery = item.News,
    Lang = LanguageFilter.Turkish,
    MaximumNumberOfResults = 100,
    Filters = TweetSearchFilters.News,
};
```

Kod Bloğu 1: Twitter arama parametreleri

-

```
var tweets = Search.SearchTweets(searchParameter);
```

- **Kod Bloğu 2:** Twitter sorgulama isteği.

-

```
if (tweets.Count() > 0)
{
    foreach (var it in tweets)
    {
        if (!allTweets.Any(x=>x.StrId==it.IdStr.ToString()))
```

```
    {
        _tweetService.Insert(new Domain.Tweet()
        {
            StrId = it.IdStr,
            TweetId = it.CreatedBy.Id.ToString(),
            Name = it.CreatedBy.Name,
            FullText = it.FullText,
            CreateDate = it.CreatedAt.Date,
            Source = it.Source.ToString(),
            Suffix = it.Suffix.ToString(),
            Text = it.Text.ToString()
            ,UniversityId=item.Id,
            Type = "Comments"

        });
    }
}
```

Kod Bloğu 3: *Api sonucu ile gelen verilerin veri tabanına kaydedilmesi.*

5.1.2 Analiz verilerinin analize uygun formata çevrilmesi

Ham veriler veri tabanında satır bazlı tutulmaktadır. İstenilen formata çevrilmesi için SQL server tarafında sorgu yazılarak üniversite bazlı aylık toplam Twitter raporu hazırlanmıştır.

StrId	Name	FullText	TweetId
1217847966981029891	Melike Kazancı	RT @dmdaydin: EWORA Başkanı Prof. Dr. Gülsün Sağ...	1184494931181817857
1217847958777016329	Melike Kazancı	RT @dmdaydin: Bu değerli etkinliği üniversitemizde ger...	1184494931181817857
1217846136599449600	Muhammet Enes Altıntaş	RT @dmdaydin: Düzce Üni.Rektörü Sn. Prof.Dr.Nigar ...	1184811331007987713
1217846123651616776	Muhammet Enes Altıntaş	RT @dmdaydin: Bu değerli etkinliği üniversitemizde ger...	1184811331007987713
1217846099656003584	Muhammet Enes Altıntaş	RT @dmdaydin: EWORA Başkanı Prof. Dr. Gülsün Sağ...	1184811331007987713
1217845668989034496	yakuptek	RT @dmdaydin: Düzce Üni.Rektörü Sn. Prof.Dr.Nigar ...	933802973611864064
1217845554971062276	yakuptek	RT @dmdaydin: Bu değerli etkinliği üniversitemizde ger...	933802973611864064
1217845513707573250	yakuptek	RT @dmdaydin: EWORA Başkanı Prof. Dr. Gülsün Sağ...	933802973611864064

Şekil 5.1: Twitter verilerinin tablodaki ham hali

Çizelge 5.1: Analiz verilerinin girdiye uyarlanması

Month	IAU	IU	ITU	YTU	MU
2019-01	79	77	24	94	124
2019-02	419	330	681	205	85
2019-03	559	533	669	125	180
2019-04	700	732	686	281	485
2019-05	305	300	271	205	230
2019-06	265	422	638	268	172
2019-07	412	608	491	446	372
2019-08	523	625	443	320	248
2019-09	331	328	501	616	438
2019-10	540	843	457	592	520
2019-11	294	286	454	248	235
2019-12	214	220	202	212	240
2020-01	82	90	26	96	133
2020-02	441	371	732	223	84
2020-03	665	620	704	128	176
2020-04	761	755	762	287	470
2020-05	311	306	279	228	239
2020-06	312	431	717	295	169
2020-07	443	668	528	474	367
2020-08	539	651	457	364	254
2020-09	376	360	551	648	441
2020-10	628	937	544	610	543
2020-11	303	329	468	279	251
2020-12	233	227	238	221	254

5.1.3 Python dili ile verilerin analiz ve ön işleme kod bloğu

```
import numpy as nup

import pandas as pd

from statsmodels.tsa.statespace.sarimax import SARIMAX

from statsmodels.graphics.tsaplots import plot_acf,plot_pacf

from statsmodels.tsa.seasonal import seasonal_decompose

from statsmodels.tools.eval_measures import rmse

from pmdarima import auto_arima

from sklearn.metrics import r2_score

import math
```

Kod Bloğu 4: *Kullanılan Paketlerin import edilmesi*

```
df = pd.read_csv('tezaylik.csv',usecols=[0, 1])

universite="İstanbul Aydın Üniversitesi"

columnName='IAU'

df.head()
```

Kod Bloğu 5: *Csv analiz verilerinin okunması*

5.1.4 Twitter API ile geliştiren web uygulaması

.Net core uygulaması ile web uygulaması geliştirdi. Bu uygulama ile belirli zaman diliminde Twitter API üzerinden veriler çekilerek MS SQL veri tabanına kaydedilmektedir. Web uygulamasında örnek Twitter listeleme örnek sayfası aşağıdadır.

University	Name	FullText	TweetId	CreateDate	Text	TextHtml	UniversityId
Istanbul Aydın Üniversitesi	Atakan Kahya	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf @IAUKampus #iaukampus https://t.co/8...	3041211310	12.10.2020 00:00:00	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf @IAUKampus #iaukampus https://t.co/8...		3
Istanbul Aydın Üniversitesi	ayşegül tiryaki	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf @IAUKampus #iaukampus https://t.co/8...	70651740	12.10.2020 00:00:00	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf @IAUKampus #iaukampus https://t.co/8...		3
Istanbul Aydın Üniversitesi	Serhat Yılmaz	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf	60034800	12.10.2020 00:00:00	RT @iauíf: Kampüse giriş için getirilen HES Kodu gösterme zorunluluğu hakkında açıklama. @iauíf @iauíf		3

Şekil 5.2: Web uygulama Twitter listesi

5.1.5 Modelin Eğitilmesi ve Tahmin

Üniversitelere ait verileri modelledikten ve eğitim veri setindeki modelimizin kalitesini değerlendirdikten sonra, ağın görmediği veri kümesi için tahminin ne kadar doğru olduğunu bilmemiz gerekir. Her zamanki sınıflandırma veya regresyon görevi için bunu çapraz doğrulamayı kullanarak yapacağız. Zaman serilerini kullanırken, değerlerin sırası önemlidir. Kullanabileceğimiz basit bir yöntem, elde edilen veri setini eğitim ve test veri setlerine bölmektir. Elde edilen veriler ile ilgili çalışmamızda verilerin eğitilmesi için %67, değerlendirilmesi için %33 oranında test verileri ayrılmıştır. Verilerde normalizasyon ve transform işlemlerinden sonra Lstm modeline verilip tahmin değerleri üretilmiştir. LSTM algoritmasında yapay sinir ağının eğitilmesi için gerekli parametrik değerler Tablo 1’de gösterilmiştir.

Çizelge 5.2: Modelde kullanılan parametreler

Param	Değer
Epochs	20
Batch Size	1
Verbose	1
Layers	2
Outputs	5

Epochs: Döngü sayısı, eğitim işlemi sırasında tüm verilerin sinir ağı yoluyla yalnızca bir kez ile geri aktarılmasıdır

Batch Size: Bir grupta toplanan eğitim örneklerinin toplam sayısı.

Verbose : Eğitim sırasında her bir epochdan sonra elde edilen sonuçların gösterilmesini sağlamaktadır.

5.1.6 Verilerin normalizasyon ve transform işlemleri.

```
from sklearn.preprocessing import MinMaxScaler  
  
scaler = MinMaxScaler(feature_range=(0, 1))  
  
#scaler.fit(train_data)  
  
scaler.fit(df)  
  
scaled_train_data = scaler.transform(train_data)  
  
scaled_test_data = scaler.transform(test_data)
```

- **Kod Bloğu 7:** Normalizasyon işlemi, Min-Max değerlerinin alınması

```
train_data = df[:len(df)-48]  
test_data = df[len(df)-48:]  
  
losses_lstm = lstm_model.history.history['loss']  
  
plt.figure(figsize=(12,4))  
  
plt.xlabel("Epochs")  
  
plt.ylabel("Loss")  
  
plt.xticks(nup.arange(0,21,1))  
  
plt.plot(range(len(losses_lstm)),losses_lstm);
```

- **Kod Bloğu 8:** Verilerin test ve train için ayrılması ve epos değerleri

```
#Lstm ile modelin algoritmada kullanımı  
  
from keras.preprocessing.sequence import TimeseriesGenerator
```

```

n_input = 12
n_features= 1
generator = TimeseriesGenerator(scaled_train_data, scaled_train_data,
length=n_input, batch_size=1)
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import LSTM

lstm_model = Sequential()
lstm_model.add(LSTM(200, activation='relu', input_shape=(n_input,
n_features)))
lstm_model.add(Dense(1))
lstm_model.compile(optimizer='adam', loss='mse')
lstm_model.summary()

```

- **Kod Bloğu 9:** Lstm Modeli işlemi

5.1.7 Epoc değerlerinin oluşturulması, İstanbul aydın Üniversitesine ait epoc değerleri

```

poch 1/20
108/108 [=====] - 1s 10ms/step - loss:
0.0271
Epoch 2/20
108/108 [=====] - 1s 8ms/step - loss: 0.0242
Epoch 3/20
108/108 [=====] - 1s 9ms/step - loss: 0.0227
Epoch 4/20

```

```
108/108 [=====] - 1s 11ms/step - loss:
0.0161
Epoch 5/20
108/108 [=====] - 1s 12ms/step - loss:
0.0098
Epoch 6/20
108/108 [=====] - 1s 10ms/step - loss:
0.0049
Epoch 7/20
108/108 [=====] - 1s 9ms/step - loss: 0.0028
Epoch 8/20
108/108 [=====] - 1s 12ms/step - loss:
0.0074
Epoch 9/20
108/108 [=====] - 1s 13ms/step - loss:
0.0025: 0s - loss: 0.00
Epoch 10/20
108/108 [=====] - 1s 12ms/step - loss:
0.0026
Epoch 11/20
108/108 [=====] - 2s 19ms/step - loss:
0.0010
Epoch 12/20
108/108 [=====] - 1s 12ms/step - loss:
0.0011
Epoch 13/20
108/108 [=====] - 1s 14ms/step - loss:
9.2829e-04: 0s - loss: 9.3677e-0
```

Epoch 14/20
108/108 [=====] - 1s 14ms/step - loss:
9.4551e-04

Epoch 15/20
108/108 [=====] - 1s 11ms/step - loss:
8.4720e-04

Epoch 16/20
108/108 [=====] - 2s 14ms/step - loss:
8.7305e-04

Epoch 17/20
108/108 [=====] - 1s 10ms/step - loss:
0.0010

Epoch 18/20
108/108 [=====] - 1s 9ms/step - loss:
9.2762e-04

Epoch 19/20
108/108 [=====] - 1s 9ms/step - loss:
6.6755e-04

Epoch 20/20
108/108 [=====] - 1s 9ms/step - loss:
7.3559e-04

5.1.8 RMSE,R2 ve MSE değerlerinin hesaplanması kod bloğu

```
arima_rmse_error = rmse(test_data[columnName], arima_pred)

arima_mse_error = arima_rmse_error**2

mean_value = scaled_test_data.mean()

#mean_value = scaled_test_data.mean()

#testScore = math.sqrt(mean_squared_error(test_data['IAU'],
test_data["LSTM_TAHMIN"]))

#print('Train Score: %.2f RMSE' % (testScore))

arima_testScore = r2_score(test_data[columnName], arima_pred)

print('R2 Score: %.2f' % (arima_testScore))

print(f'MSE Error: {arima_mse_error}\nRMSE Error:
{arima_rmse_error}\nMean: {mean_value}')
```

5.1.9 ARIMA Örneği kod bloğu

```
arima_model = SARIMAX(train_data[columnName], order = (3,1,0),
seasonal_order = (3,1,1,12))

arima_result = arima_model.fit()

arima_result.summary()
```

5.1.10 ARIMA p, d, q, P, D, Q değerlerini elde etmek için auto_arima () işlevi kod bloğu

```
auto_arima(df[columnName], seasonal=True, m=12,max_p=7,  
max_d=5,max_q=7, max_P=4, max_D=4,max_Q=4).summary()
```

5.1.11 SARIMAX Verileri eğitime ve test setine ayırma işlemi

```
arima_model = SARIMAX(train_data[columnName], order = (3,1,0),  
seasonal_order = (3,1,1,12))  
arima_result = arima_model.fit()  
arima_result.summary()
```

5.1.12 ARIM Tahmin Kod bloğu


```
arima_pred = arima_result.predict(start = len(train_data), end = len(df)-1,  
typ="levels").rename("ARIMA TAHMIN")
```

5.1.13 Üniversitelerin Twitter kullanım istatistikleri ve kümelenmiş sütun grafiği

Çizelge 5.3: Tüm üniversitelere ait sütun grafiği

Üniversite	Toplam Tweet Sayısı
İstanbul Aydın Üniversitesi	45174
İstanbul Üniversitesi	52665
İstanbul Teknik Üniversitesi	54735
Yıldız Teknik Üniversitesi	35207
Marmara Üniversitesi	29269

Bu veri seti kullanılarak 10 yıllık veriler üzerinden analiz yapılmıştır. Beş üniversiteye veriler ile girdi oluşturularak analiz yapılmıştır. Aşağıdaki grafikte bütün verinin aylık kümelenmiş grafiği gösterilmiştir.



Şekil 5.3: Kümelenmiş sütun grafiği

5.1.14 RMSE ve R2 değerleri

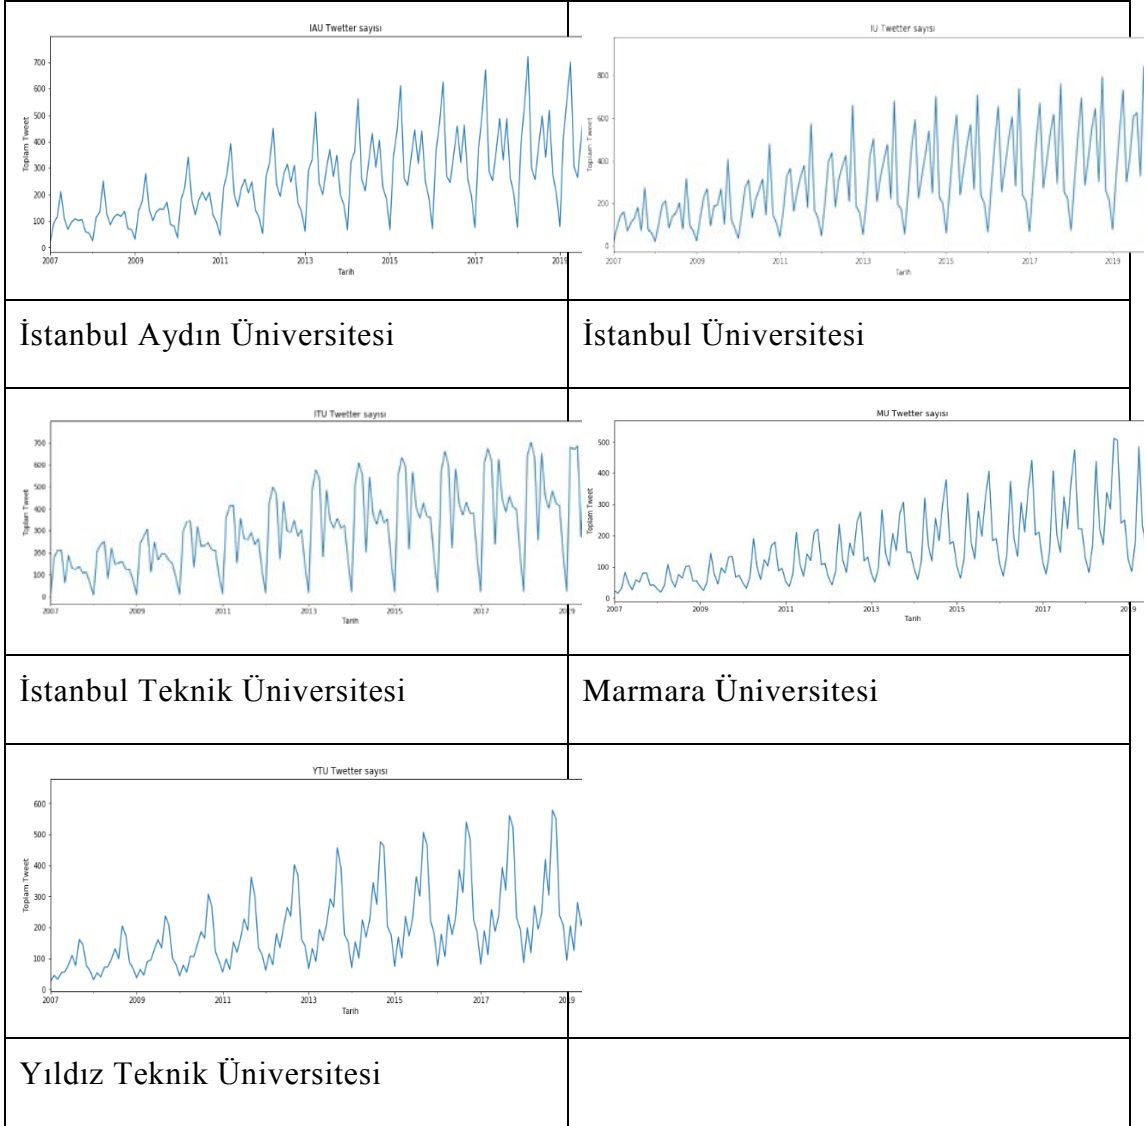
Çizelge 5.4: Üniversitelere ait tahmin sonuçlarının karşılaştırılması

Üniversite	RMSE Değeri	R2 Değeri
İstanbul Aydın Üniversitesi	0,06 RMSE	0,92
İstanbul Üniversitesi	0,04 RMSE	0,96
İstanbul Teknik Üniversitesi	0,09 RMSE	0,90
Yıldız Teknik Üniversitesi	0,07 RMSE	0,93
Marmara Üniversitesi	0,05 RMSE	0,95

Çizelge 5.7: Üniversitelere ait Mean değerleri

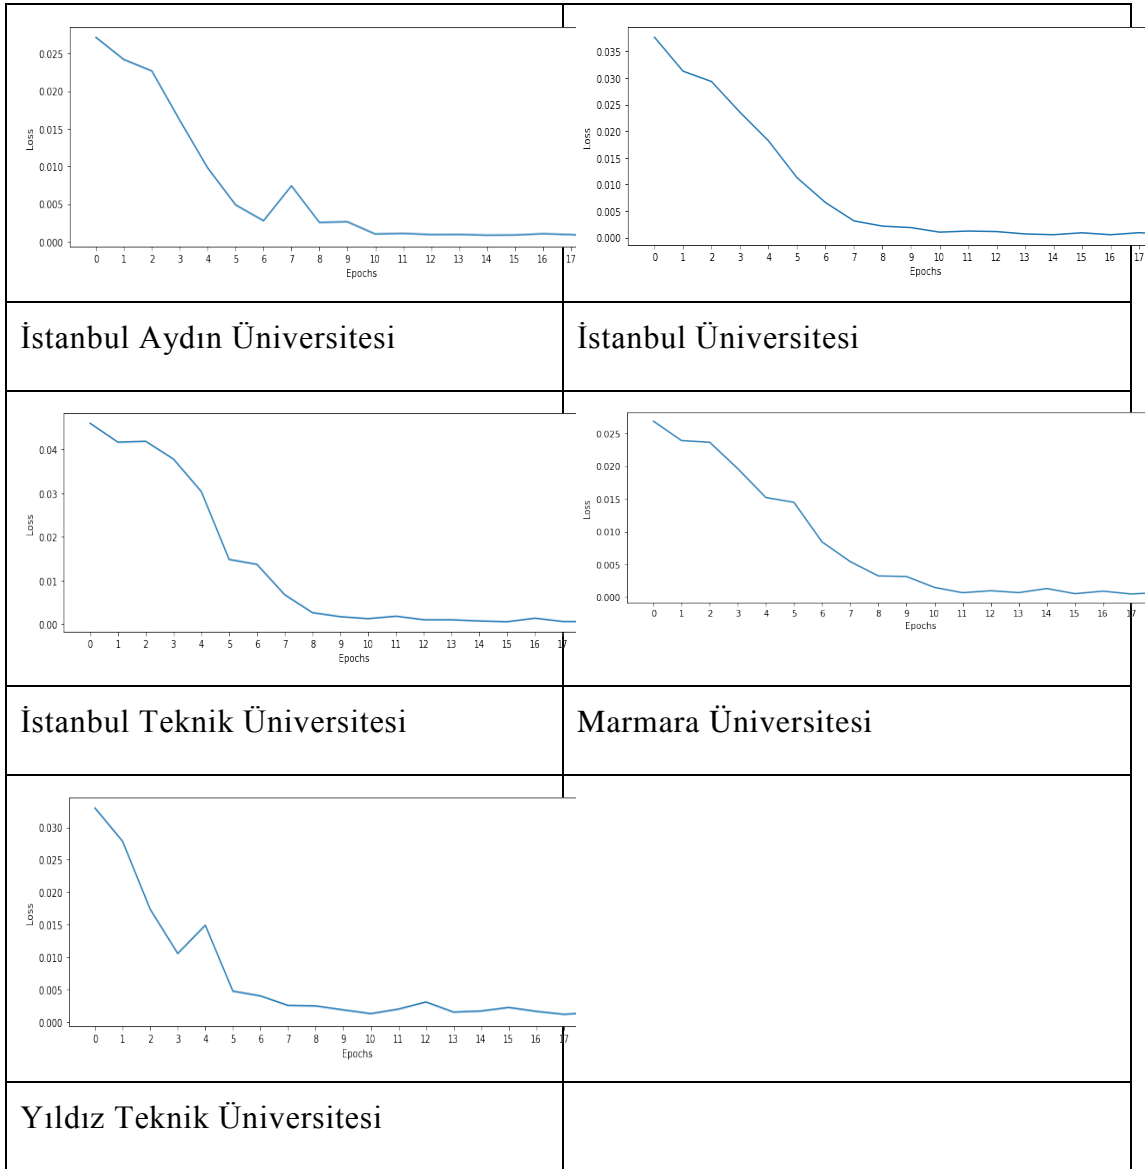
Üniversite	MEAN Değeri
İstanbul Aydın Üniversitesi	0,49
İstanbul Üniversitesi	0,46
İstanbul Teknik Üniversitesi	0,59
Yıldız Teknik Üniversitesi	0,48
Marmara Üniversitesi	0,43

5.1.15 Twitter Sayı Grafikleri



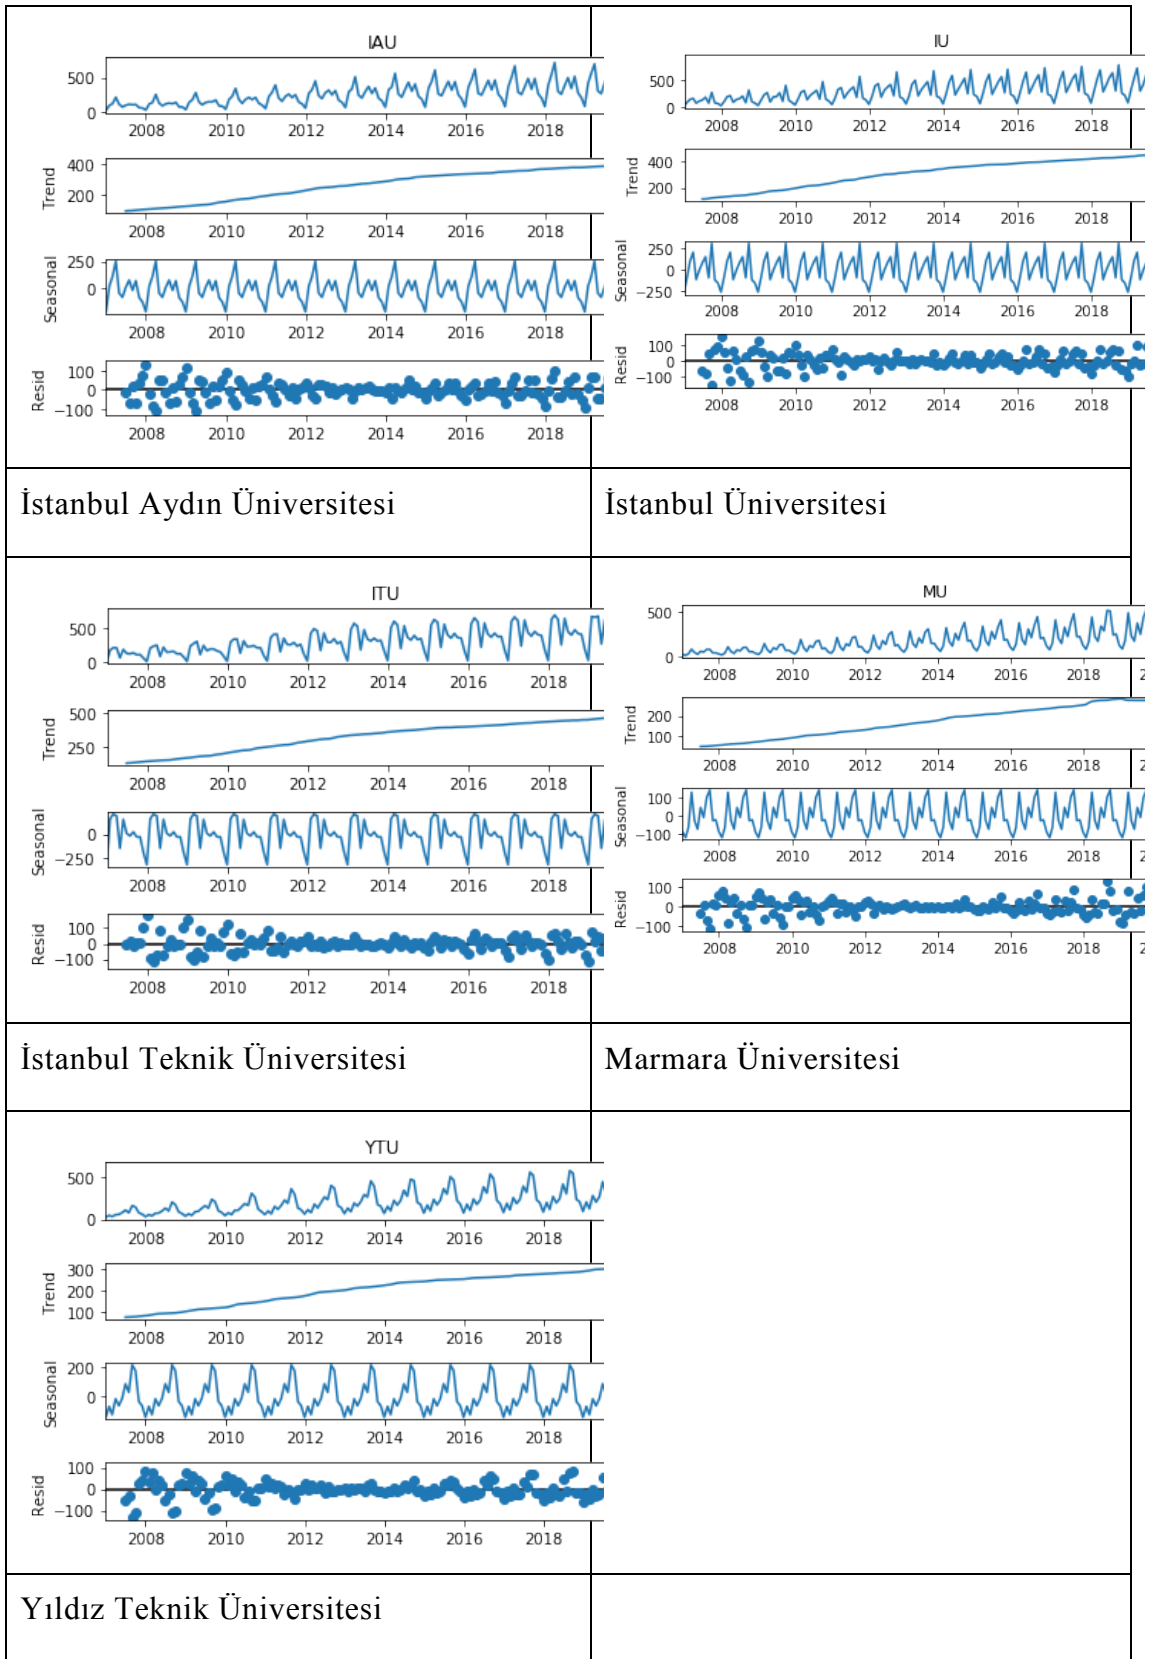
Şekil 5.4: Twitter Sayı Grafikleri

5.1.16 Epochs Grafikleri



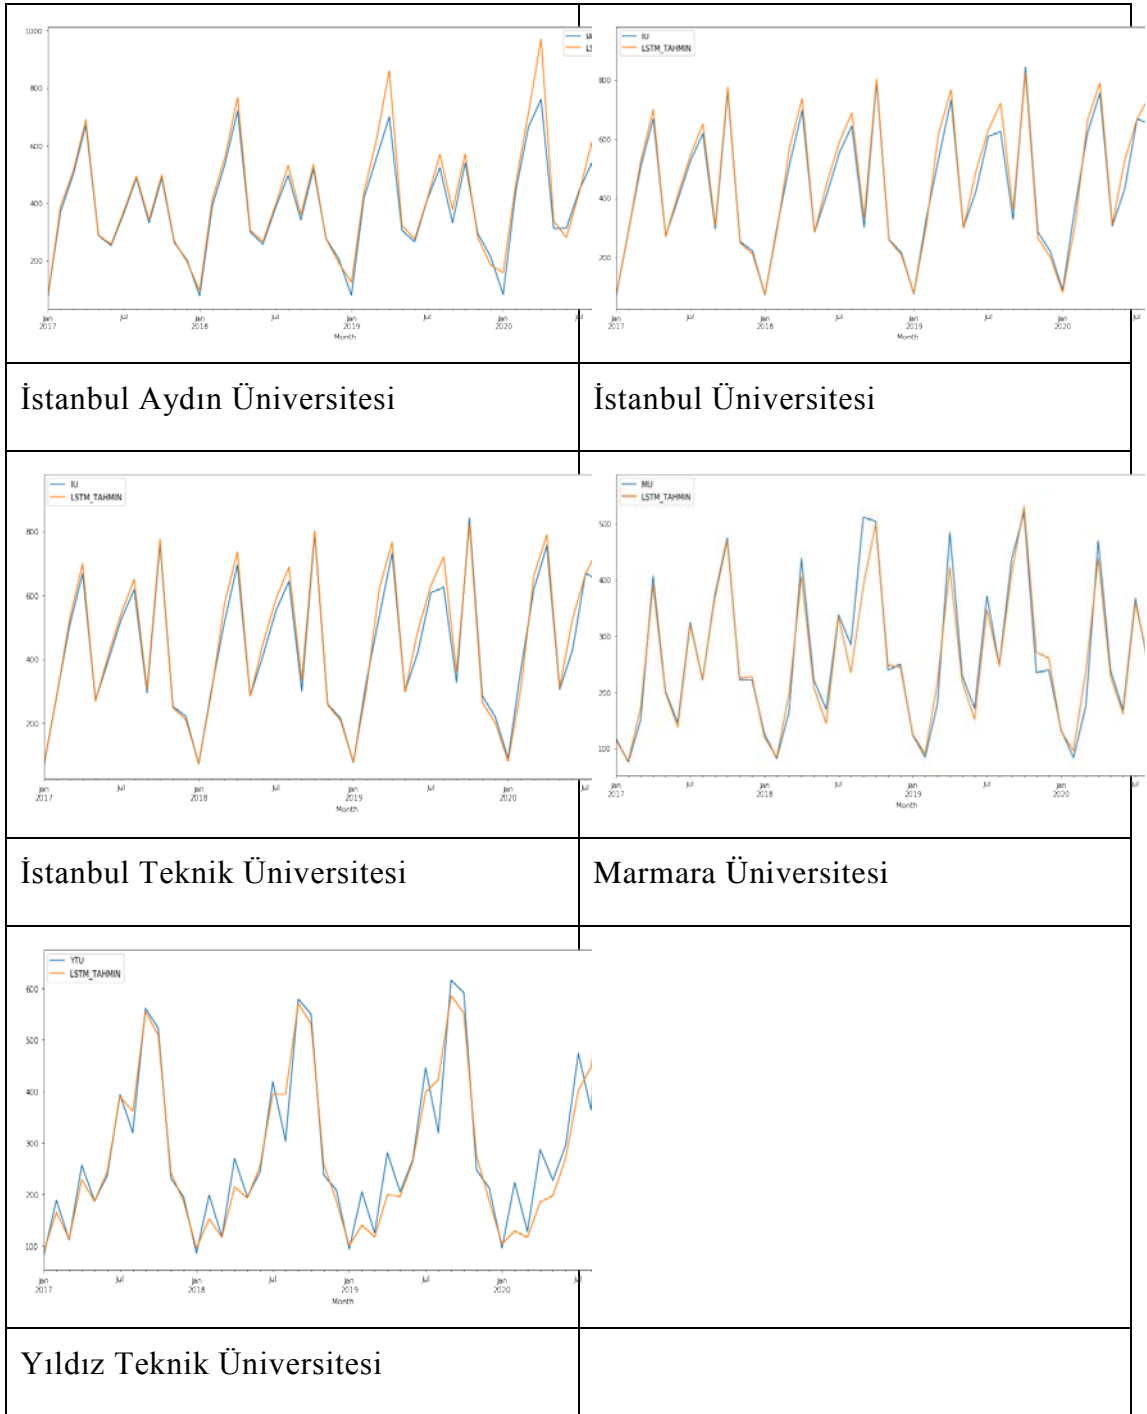
Şekil 5.5: Epochs Grafikleri

5.1.17 Sezonal deęişim grafikleri



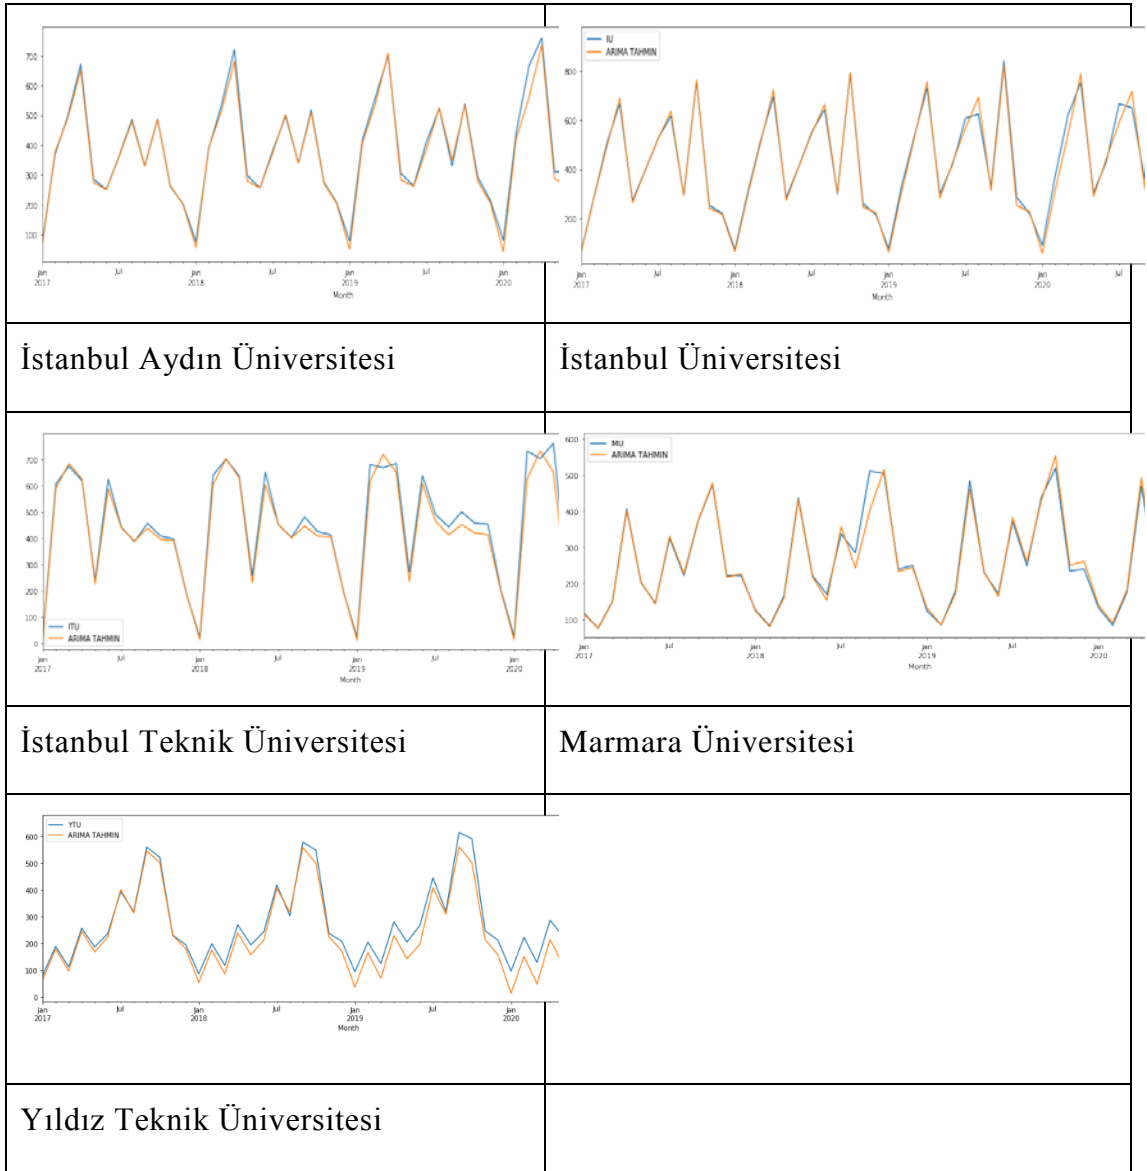
Şekil 5.6: Sezonal deęişim grafikleri

5.1.18 LSTM Tahmin grafikleri



Şekil 5.7: LSTM Tahmin grafikleri

5.1.19 ARIMA Tahmin grafikleri



Şekil 5.8: ARIMA Tahmin grafikleri

5.1.20 Tahmin sonuçları

Çizelge 5.5: İstanbul Aydın Üniversitesi

Month	IAU	LSTM_TAHMIN	ARIMA_TAHMIN
2019-01-01	79	124.199847	50.915292
2019-02-01	419	439.050598	407.588308
2019-03-01	559	623.629681	537.487845
2019-04-01	700	860.318392	708.732516
2019-05-01	305	322.351207	284.372751
2019-06-01	265	274.212482	263.038146
2019-07-01	412	414.901423	388.124972
2019-08-01	523	569.692592	525.450409
2019-09-01	331	376.237527	349.860503
2019-10-01	540	571.103104	534.374622
2019-11-01	294	279.411029	280.082332
2019-12-01	214	185.724296	205.342064
2020-01-01	82	158.074700	43.417488
2020-02-01	441	468.074262	421.704200
2020-03-01	665	714.159313	559.591755
2020-04-01	761	970.040406	736.771303
2020-05-01	311	337.373274	287.877660
2020-06-01	312	279.974105	268.008587
2020-07-01	443	434.331146	400.442436
2020-08-01	539	610.401110	547.158021
2020-09-01	376	392.016368	358.829359
2020-10-01	628	610.261158	557.249721
2020-11-01	303	280.507628	286.843363
2020-12-01	233	177.841151	207.072235

- **Tahmin Deęerleri**

Çizelge 5.6: İstanbul Üniversitesi Tahmin Deęerleri

Month	IU	LSTM_TAHMIN	ARIMA_TAHMIN
2019-01-01	77	78.630282	61.083589
2019-02-01	330	304.570547	305.574171
2019-03-01	533	618.825631	525.431701
2019-04-01	732	766.455078	757.148103
2019-05-01	300	298.938121	282.436732
2019-06-01	422	489.315185	428.747873
2019-07-01	608	629.808075	569.638645
2019-08-01	625	720.586783	692.175430
2019-09-01	328	360.616755	313.578437
2019-10-01	843	822.504549	820.823629
2019-11-01	286	265.514206	252.551839
2019-12-01	220	200.127626	228.254235
2020-01-01	90	81.647805	57.954955
2020-02-01	371	310.356541	313.441414
2020-03-01	620	662.783868	542.372282
2020-04-01	755	789.603552	789.148520
2020-05-01	306	311.958940	289.739417
2020-06-01	431	527.360866	443.348964
2020-07-01	668	667.269585	590.982909
2020-08-01	651	746.792271	718.016271
2020-09-01	360	387.403233	322.378203
2020-10-01	937	835.906260	848.565309
2020-11-01	329	270.910452	257.715615
2020-12-01	227	187.063446	232.412633

Çizelge 5.7: İstanbul Teknik Üniversitesi Tahmin Değerleri

Month	ITU	LSTM_TAHMIN	ARIMA_TAHMIN
2019-01-01	24	51.310056	12.127649
2019-02-01	681	626.147525	617.342036
2019-03-01	669	665.593679	719.689810
2019-04-01	686	609.689067	650.348653
2019-05-01	271	257.810944	236.214692
2019-06-01	638	595.032730	607.651780
2019-07-01	491	451.226872	465.096595
2019-08-01	443	386.585761	413.002037
2019-09-01	501	442.461676	451.675754
2019-10-01	457	378.625519	419.903683
2019-11-01	454	374.879980	413.489314
2019-12-01	202	101.147824	197.241044
2020-01-01	26	87.071774	13.009005
2020-02-01	732	639.615788	626.437966
2020-03-01	704	666.929929	732.429035
2020-04-01	762	612.308956	652.696132
2020-05-01	279	273.892395	240.919807
2020-06-01	717	597.765376	622.183663
2020-07-01	528	460.175393	474.651892
2020-08-01	457	391.588294	422.097295
2020-09-01	551	446.012631	459.769270
2020-10-01	544	378.180922	428.406831
2020-11-01	468	371.308518	425.876274
2020-12-01	238	67.190752	202.374580


Çizelge 5.8: Marmara Üniversitesi Tahmin Değerleri

Month	MU	LSTM_TAHMIN	ARIMA_TAHMIN
2019-01-01	124	125.443758	132.365814
2019-02-01	85	90.862949	85.275888
2019-03-01	180	218.429830	171.295382
2019-04-01	485	422.311586	462.460582
2019-05-01	230	218.934015	232.867603
2019-06-01	172	152.683630	164.042505
2019-07-01	372	347.496992	382.568581
2019-08-01	248	247.350589	259.109419
2019-09-01	438	411.594555	429.621311
2019-10-01	520	530.922687	553.446971
2019-11-01	235	271.085751	250.112504
2019-12-01	240	261.441905	261.332197
2020-01-01	133	130.916443	140.824618
2020-02-01	84	96.459356	90.604614
2020-03-01	176	237.609355	182.307907
2020-04-01	470	438.380304	492.800600
2020-05-01	239	227.945367	247.502698
2020-06-01	169	162.257452	174.680553
2020-07-01	367	359.757091	408.489870
2020-08-01	254	260.843117	275.421362
2020-09-01	441	436.948677	457.159199
2020-10-01	543	564.991859	591.111306
2020-11-01	251	293.662142	266.615778
2020-12-01	254	277.665367	278.712795

Çizelge 5.9: Yıldız Teknik Üniversitesi Tahmin Değerleri


Month	YTU	LSTM_TAHMIN	ARIMA_TAHMIN
2019-01-01	94	100.568636	36.056175
2019-02-01	205	140.148920	165.950483
2019-03-01	125	117.604776	70.013940
2019-04-01	281	199.468742	229.327944
2019-05-01	205	196.116238	142.530743
2019-06-01	268	264.357514	197.216181
2019-07-01	446	398.581892	408.357866
2019-08-01	320	422.741444	309.256899
2019-09-01	616	585.714467	562.496375
2019-10-01	592	551.855074	502.203906
2019-11-01	248	275.283751	215.001948
2019-12-01	212	187.577624	157.562020
2020-01-01	96	103.899853	12.956944
2020-02-01	223	128.896751	151.183760
2020-03-01	128	116.720818	47.777784
2020-04-01	287	185.294644	214.675589
2020-05-01	228	197.382089	121.168584
2020-06-01	295	270.749931	176.235059
2020-07-01	474	401.978139	403.096921
2020-08-01	364	447.322612	297.365843
2020-09-01	648	600.620340	557.849744
2020-10-01	610	571.638347	494.673085
2020-11-01	279	292.327429	201.652551
2020-12-01	221	188.469222	138.280980

5.1.21 Grafiksel Sonular ve yorumlar



Őekil 5.9: İstanbul Aydın Üniversitesi eğitim, test ve tahmin grafiđi

Yukarıdaki grafikte İstanbul Aydın Üniversitesine ait verilerle kullanılan yöntemlerle elde edilen Twitter tahminlerinin değerlerini göstermektedir. Dikeyde Twitter datası yatayda yıl içerisindeki ay sayılarını göstermektedir. Mavi renk veriyi, yeşil renkteki çizgiler LSTM tahmin değerlerini ve turuncu ARIMA tahmin değerlerini göstermektedir. Grafikteki kıvrımlara baktığımızda en yüksek 2020 01-6 ayları arasında görülmüştür. Tahmin grafiđi ile gerçek veri grafikleri birbirine yakın seviyelerde olduđu görülmüştür. Őekilden de görülebileceđi gibi, modelin tahmini gerçek veri grafiđiyle yakından eŐleşmektedir. Bu durum, tahmin alışmasının oldukça başarılı olduđunun bir iŐaretidir. Yalnızca bazı aylarda gerçek veri grafiđinde artış/azalış ve tahmine uzak değerler oluşmuş iken tahmin grafiklerinde azalış/artış gibi ters bir sonuç elde edilmiştir. Bu durum, üniversitelerin kayıt, dönem başlangıları ve tercih tanıtım gibi önemli dönemlerde deđişiklikler göstermektedir. LSTM modeli ile epochs değeri 20 üzerinden deneme yapılmıştır. Sonuç olarak RMSE değeri 0.06 R2 değeri ise 0.92 sonucunu elde edilmiştir.




Şekil 5.10: İstanbul Üniversitesi eğitim, test ve tahmin grafiği

Yukarıdaki grafikte İstanbul Üniversitesine ait verilerle kullanılan yöntemlerle elde edilen Twitter tahminlerinin değerlerini göstermektedir. Dikeyde Twitter datası yatayda yıl içerisindeki ay sayılarını göstermektedir. Mavi renk veriyi, yeşil renkteki çizgiler LSTM tahmin değerlerini ve turuncu ARIMA tahmin değerlerini göstermektedir. Grafikteki kıvrımlara baktığımızda en yüksek 2020 8-12 ayları arasında görülmüştür. Tahmin grafiği ile gerçek veri grafikleri birbirine yakın seviyelerde olduğu görülmüştür. Şekilden de görülebileceği gibi, modelin tahmini gerçek veri grafiğiyle yakından eşleşmektedir. Bu durum, tahmin çalışmasının oldukça başarılı olduğunun bir işaretidir. Yalnızca bazı aylarda gerçek veri grafiğinde artış/azalış ve tahmine uzak değerler oluşmuş iken tahmin grafiklerinde azalış/artış gibi ters bir sonuç elde edilmiştir. Bu durum, üniversitelerin kayıt, dönem başlangıçları ve tercih tanıtım gibi önemli dönemlerde değişiklikler göstermektedir. LSTM modeli ile epochs değeri 20 üzerinden deneme yapılmıştır. Sonuç olarak RMSE değeri 0.04 R2 değeri ise 0.96 sonucunu elde edilmiştir.




Şekil 5.11: İstanbul Teknik Üniversitesi eğitim, test ve tahmin grafiği

Yukarıdaki grafikte İstanbul Teknik Üniversitesine ait verilerle kullanılan yöntemlerle elde edilen Twitter tahminlerinin değerlerini göstermektedir. Dikeyde Twitter datası yatayda yıl içerisindeki ay sayılarını göstermektedir. Mavi renk veriyi, yeşil renkteki çizgiler LSTM tahmin değerlerini ve turuncu ARIMA tahmin değerlerini göstermektedir. Grafikteki kıvrımlara baktığımızda en yüksek 2020 1-3 ayları arasında görülmüştür. Tahmin grafiği ile gerçek veri grafikleri birbirine yakın seviyelerde olduğu görülmüştür. Şekilden de görülebileceği gibi, modelin tahmini gerçek veri grafiğiyle yakından eşleşmektedir. Bu durum, tahmin çalışmasının oldukça başarılı olduğunun bir işaretidir. Yalnızca bazı aylarda gerçek veri grafiğinde artış/azalış ve tahmine uzak değerler oluşmuş iken tahmin grafiklerinde azalış/artış gibi ters bir sonuç elde edilmiştir. Bu durum, üniversitelerin kayıt, dönem başlangıçları ve tercih tanıtım gibi önemli dönemlerde değişiklikler göstermektedir. LSTM modeli ile epochs değeri 20 üzerinden deneme yapılmıştır. Sonuç olarak RMSE değeri 0.09 R2 değeri ise 0.90 sonucunu elde edilmiştir.



Şekil 5.12: Yıldız Teknik Üniversitesi eğitim, test ve tahmin grafiği

Yukarıdaki grafikte Yıldız Teknik Üniversitesine ait verilerle kullanılan yöntemlerle elde edilen Twitter tahminlerinin değerlerini göstermektedir. Dikeyde Twitter datası yatayda yıl içerisindeki ay sayılarını göstermektedir. Mavi renk veriyi, yeşil renkteki çizgiler LSTM tahmin değerlerini ve turuncu ARIMA tahmin değerlerini göstermektedir. Grafikteki kıvrımlara baktığımızda en yüksek 2020 7-9 ayları arasında görülmüştür. Tahmin grafiği ile gerçek veri grafikleri birbirine yakın seviyelerde olduğu görülmüştür. Şekilden de görülebileceği gibi, modelin tahmini gerçek veri grafiğiyle yakından eşleşmektedir. Bu durum, tahmin çalışmasının oldukça başarılı olduğunun bir işaretidir. Yalnızca bazı aylarda gerçek veri grafiğinde artış/azalış ve tahmine uzak değerler oluşmuş iken tahmin grafiklerinde azalış/artış gibi ters bir sonuç elde edilmiştir. Bu durum, üniversitelerin kayıt, dönem başlangıçları ve tercih tanıtım gibi önemli dönemlerde değişiklikler göstermektedir. LSTM modeli ile epochs değeri 20 üzerinden deneme yapılmıştır. Sonuç olarak RMSE değeri 0.07 R2 değeri ise 0.93 sonucunu elde edilmiştir.



Şekil 5.13: Marmara Üniversitesi eğitim, test ve tahmin grafiği

Yukarıdaki grafikte Marmara Üniversitesine ait verilerle kullanılan yöntemlerle elde edilen Twitter tahminlerinin değerlerini göstermektedir. Dikeyde Twitter datası yatayda yıl içerisindeki ay sayılarını göstermektedir. Mavi renk veriyi, yeşil renkteki çizgiler LSTM tahmin değerlerini ve turuncu ARIMA tahmin değerlerini göstermektedir. Grafikteki kıvrımlara baktığımızda en yüksek 2020 10-12 ayları arasında görülmüştür. Tahmin grafiği ile gerçek veri grafikleri birbirine yakın seviyelerde olduğu görülmüştür. Şekilden de görülebileceği gibi, modelin tahmini gerçek veri grafiğiyle yakından eşleşmektedir. Bu durum, tahmin çalışmasının oldukça başarılı olduğunun bir işaretidir. Yalnızca bazı aylarda gerçek veri grafiğinde artış/azalış ve tahmine uzak değerler oluşmuş iken tahmin grafiklerinde azalış/artış gibi ters bir sonuç elde edilmiştir. Bu durum, üniversitelerin kayıt, dönem başlangıçları ve tercih tanıtım gibi önemli dönemlerde değişiklikler göstermektedir. Sonuç olarak RMSE değeri 0.05 R2 değeri ise 0.95 sonucunu elde edilmiştir.

6. SONUÇ

Yapılan çalışma sonucunda üniversitelere ait geriye dönük yıllara ait aylık veriler İstanbul Aydın Üniversitesi, İstanbul Üniversitesi, İstanbul Teknik Üniversitesi, Yıldız Teknik Üniversitesi, Marmara Üniversitesi sırayla 45174, 52665, 54735, 35207, 29269 toplamda 217050 adet analiz verisi edilmiştir. Verileri tahmin işlemi yapılmadan önce normalizasyon ve transform işlemleri yapılarak elde edilen veriler tahmin formülüne göre tahmin değerleri üretilmiştir. Deneysel sonuçlara göre epoch değerlerinin sürekli artması ile modelin başarılı sonuç oranı da artmaktadır. Derin öğrenme modelinin eğitilmesi, test edilmesi ve ileriye dönük tahmin işlemleri için Anakonda platformunda çalışan Jupyter notebook ara yüzü kullanılmıştır. LSTM algoritma modeli ile RMSE ve R2 sonuçları elde edilmiştir. Bu çalışmada asıl amaç geçmiş Twitter verilerin zamana bağlı değişimlerini ders alarak ve bu model üzerinde tahmin ederek ileriye dönük Twitter tahminlerini modelleyen en iyi değerleri bulmaya çalışmaktadır. Sonuç olarak, belirli epoch ve batch size değerlerinde oluşturulan modelin başarılı bir şekilde sayı tahmini yaptığı gözlenmiştir. Yapılan çalışma sonucunda üniversitelere ait geriye dönük son 13 yıla ait aylık verilere ait sonraki aylara göre tahmin değerleri; İstanbul Aydın Üniversitesi, İstanbul Üniversitesi, İstanbul Teknik Üniversitesi, Yıldız Teknik Üniversitesi, Marmara Üniversitesi sırayla RMSE değerleri 0.06, 0.04, 0.09, 0.07, 0.05 ve R2 değerleri sırayla 0.92, 0.96, 0.90, 0.93, 0.95 sonuçları elde edilmiştir. Yukarıdaki grafiklerinde derin öğrenme metotlarından LSTM modeli ile yapılan çalışmada, tahmin uygulamalarında başarılı ve etkili sonuçlar elde edileceği gösterilmiştir. LSTM modelinin ARIMA modeline göre daha iyi sonuçlar ortaya çıkardığı gösterilmiştir

KAYNAKÇA

- Pitts,WARren s.** (1990). "A Logical Calculus of the Idea Immanent in Nervous Activity. Bulletin of Mathematical Biophysics", Bulletin of Mothemnticnl Biology Vol. 52, No. 1/2. pp. 1990, s. 99-115
- Mikolov, T., Karafiát, M., Burget, L., Černocký J. Khudanpur, S.** (2010). Recurrent neural network based language model. In Eleventh Annual Conference of the International Speech Communication Association
- Bottou L, Chapelle O, DeCoste D, Weston J. MIT Press,. Bengio Y, LeCun** (2007)," Scaling learning algorithms towards"," AI.In Large Scale Kernel Machines Edited by"
- Hinton GE, Osindero S, Teh Y-W** (2006) "A fast learning algorithm for deep belief nets". 1527–1554, basım yeri bilinmiyor : Neural Comput 2006, 2006, Cilt 1527–1554. 10.1162/.
- Khoshgoftaar** (2013), "Overcoming big data challenges", Proceedings of the 25th International Conference on Software Engineering and Knowledge Engineering, MA. ICSE. Invited Keynote Speaker
- Sinha, Shivam** (2018), LSTM RNN Time Series Prediciion Of International Airline Passengers, Gitup
- Ahmet Ali SÜZEN, Kıyas KAYAALP** (2018), Derin öğrenme yöntemleri ile sıcaklık tahmini : Isparta ili örneği
- Doğan E.** (2019). Derin öğrenme yöntemiyle çevrimiçi sosyal ağlarda duygu analizi ve metin özetleme,
- İbrahim T.** (2019). Çevrimiçi tüketici bütünleşmesi ve arama motoru verileri kullanılarak yapay sinir ağları ile otomobil satış tahmini, E-ISSN: 2149-3871
- Özlem A.** (2019) LSTM Mimarisi Kullanarak USD/TRY Fiyat Tahmini, Dergi Park, ISSN:2148-2683
- Ahmet Ali S.** (2019) LSTM derin sinir ağları ile üniversite giriş sınavındaki matematik Soru sayılarının konulara göre tahmini, ISSN: 1308-7231
- Çebi, M, Yamak, B, Öztürk.** (2019). 11-14 Yaş Çağındaki Çocukların Spor Yapma Alışkanlığının Duygu Kontrolü Üzerine Etkilerinin İncelenmesi, 468-482. , basım yeri bilinmiyor : Amasya Üniversitesi Eğitim Fakültesi Dergisi, 2016, Cilt 5.
- Nalan Ö. , Hacer Ş. , Cüneyt G.** (2019). Uzun kısa dönemli bellek derin öğrenme modeli ile türkiye elektrik üretiminin saat temelinde tahmini
- Uğur Ş.** (2018). Short term electricity price forecasting using long short-term memory.
- Deniz Can Y.** (2019) Forecasting directional movement of forex data using lstm with technical and macroeconomic indicators,
- Merve A. , Bülent B.** (2018) Uçak Motoru Sağlığı için Uzun-Kısa Süreli Bellek Yöntemi ile Öngörücü Bakım, DOI: 10.17671/gazibtd.495730, 2018.
- Kemal B.** (2017). Financial time series prediction with lstm recurrent neural networks.

- Sreelekshmy S, Vinayakumar R, Gopalakrishnan E.A, Vijay Krishna M., Soman K.P.** (2017), Stock price prediction using lstm,rnn and cnn-sliding window model, ISSN:2148-2683
- Tae-Young Kim, Sung-Bae Cho** (2018) Web traffic anomaly detection using C-LSTM neural networks.
- Sima N. , Akbar N.** (2018) Forecasting economic and financial time series Arima vs.Lstm.2019
- Burcu C.** (2019) LSTM Ağları ile Türkçe Kök Bulma, : gazibtd.486042, 2019, Cilt 10.17671.
- Zachary C. Lipton, David C. Kale,Charles Elkan,Randall Wetzel** (2016) Learning to diagnose with lstm recurrent neural networks, Published as a conference paper at ICLR 2016, 2016.
- Ayşe Soy T.** (2019). İşletmelerin satış bütçelerinin oluşturulmasında arima, lstm ve hibrit modellerin karşılaştırılması: üretim işletmesi örneği.
- Serdar T.** (2019) Uzun Kisa Süreli Hafıza Ve Geçitli Yinelenen Birim İle Borsa İstanbul 100 Endeks Değeri Tahmini Üzerine Bir Uygulama, ISSN:2148-2683
- Thomas F. , Christopher K.** (2017) Deep learning with long short-term memory.
- Özlem A.** (2019) LSTM Mimarisi Kullanarak USD/TRY Fiyat Tahmini, Dergi Park, ISSN:2148-2683
- İnternet Kaynakları**
- Expert.ai Team** , 2020 What is Machine Learning A definition. *Expert System*”, (21.10. 2020)
< <https://expertsystem.com/machine-learning-definition> >
- Machinelearningmastery** (2020). “A Tour of Machine Learning Algorithms”, (12.10.2020)
< <https://machinelearningmastery.com/a-tour-of-machine-learning-algorithms/>>
- Simeon Kostadinov** (2017). “How Recurrent Neural Networks work”, (12.01.2021)
<<https://towardsdatascience.com/learn-how-recurrent-neural-networks-work-84e975feaf7>>
- Joy Jiao** (2017). “How is LSTM different from RNN? In a layman explanation.”, quora.com, (24.10.2020)
< <https://www.quora.com/How-is-LSTM-different-from-RNN-In-a-layman-explanation>>

ÖZGEÇMİŞ

Yasin KIZILBAKIR

Yazılım Mühendisi

İletişim Bilgiler

Adres : M.Akif Mah. İnönü Cad. A.Sevim Sok No: 11 Kat:2 Daire: 2
İkitelli/Küçükçekmece İstanbul

Gsm : +90 (538) 269 47 71

E-posta Adres : yasin-kizilbakir@hotmail.com.tr

Kişisel Adres : www.yasinkizilbakir.com.tr

Blog Adres : www.blog.yasinkizilbakir.com.tr



Kişisel Bilgiler

Uyruğum : T.C.

Doğum Yerim :
İstanbul

Doğum Tarihim :
02.08.1990

Medeni Durumum : Evli

Ehliyet:B sınıf

Askerlik: Yapıldı

Sigara: Kullanmıyor

Aldığım Eğitimler

Yazılım ve Veritabanı Uzmanlığı (300 saat) Bilge Adam

Web Grafik ve Tasarım (300 Saat) Bilge Adam

Aldığım Sertifikalar

Bilge Adam Yazılım ve Veritabanı Uzmanlığı (Başarı Sertifikası - BTA)

Web Grafik ve Tasarım (Üstün başarı sertifikası)

Microsoft Certified Professional Developer (18 / 06 / 2010 - Microsoft)
ASP.NET Developer 3.5

Microsoft Certified Technology Specialist (11 / 05 / 2010 - Microsoft) .NET
Framework 3.5, ASP.NET Applications

Microsoft Certified Professional (30 / 04 / 2010 - Microsoft)

İngilizce

Konuşma	Okuma	Yazma	Anlama	Eğitim Aldığım Kurumlar
İyi	Çok iyi	İyi	İyi	Bilge Adam-Aydın Üniversitesi Hazırlık- Just English

Yazılım Geliştirme Süreçleri

- Agile Development
- Scrum Geliştirme Ortamları
- DevOps
- Visual Studio.NET 2019 ve alt sürümleri
- Managment SQL Server 2019 ve alt sürümler

Geliştirme Araçları

- Visual Studio
- Visual Studio Code
- SQL Server Managment Studio

- Android Studio

İş Deneyimleri

Toplam Süre: 11 Yıl

Şirket	İşe Başlangıç Tarihi	Bitiş Tarihi
Flo Mağazacılık	01.04.2020	?
Nuevo Software House	08.09.2019	01.04.2020
Fatih Sultan Mehmet Vakıf Üniversitesi	15.01.2018	07.09.2019
Uniball Türkiye (Uni Yazı Gereçleri Kırtasiye ve San. Tic. A.Ş.)	26.10.2011	12.01.2018
Usishi Bilişim Teknolojileri Ltd. Şti.	01.02.2011	02.08.2011
Boytek Ltd.(netstore.com.tr)	14.04.2010	30.01.2011

Flo Mağazacılık -Kıdemli Yazılım Uzmanı

Kvkk İzin yönetimi ve Sorgulama: Şirkete ait kvkk kapsamında yaklaşık 10 farklı platformdaki telefon, email, sms vb. izin gerektiren tüm bilgilerin merkezi izin yönetim sistemi. Tüm sistemlerden api aracılığı ile veri alışverişi ve izin sorgulama işlemleri yapar. Ek olarak sms, mail gönderim ve iys sistemi ile entegre bir web api uygulaması ve background worker uygulamasıdır.

Oms (order management system): E-Ticari taraftan verilen siparişlerin e-ticaret stoklarından bulunmayan siparişlerin en yakın mağazaya sipariş düşürülmesi ve mağaza tarafında tüm süreçlerin yapılması ve müşteriye iletilmesi ile ilgili tüm süreçlerin olduğu uygulama.Api tarafı .net mvc servis tarafı .net core Windows background worker ön yüz Angular.

Nuevo Software House -Analist Yazılım Geliştirici

Almanya merkezli ve Türkiye 'de bir çok firmanın sayımlarını yapan Trenkwalder firması için stok sayım sistemi geliştirilmesi. Uygulama Web, Windows Ce ve Mobil uygulama olarak geliştirilmektedir. Uygulama online ve offline sistemde çalıştırılacaktır, bu yüzden büyük verilerin çok hızlı sure ve mevcut cihazların maksimum kapasitesine göre performanslı aktarma ve süreci yeni teknolojilere uygun geliştirilmesi.

Fatih Sultan Mehmet Vakıf Üniversitesi- Yazılım Uzmanı

Banka hareketleri Uygulaması: Üniversiteye ait tüm bankalardaki hesapların hareketlerinin web servisler aracılığıyla toplamda 6 banka ve yaklaşık 70 adet hesap hareketlerinin, servislerden anlık olarak verilerin logo muhasebe uygulanasına aktarma işlemleri. Geliştirilen web uygulama ile bütün hesapların anlık görüntüleme, yönetsel özel raporların geliştirilmesi, tek sayfada tüm bankaların mevcut bakiye raporlarının hazırlama gibi işlemlerin raporlama ve verilerin anlık transfer işlemleri yapılmaktadır.

Ödeme sistemi: Üniversite çevrimiçi ödeme sistemindeki yapılan tüm ödemelerin logo sistemine anlık aktarma, öğrenci borç sorgulama, logo taksit bilgilerinin çekilmesi, indirim döneminde ise indirim oranlarının dönmesi gibi işlemlerin web servis aracılığı yapılması. İşlemler sırasında hataların önüne geçilmesi için ara tablolarda verilerin tutulması ve belirli periyotlar da aktarılması. İndirim uygulamaları ve diğer koşullarla ilgili kontrollere göre aktarımların tamamlanması vb. işlemler yapılmaktadır.

Kuta Sistemi(Online ödeme sistemi): Üniversite Banka Şube, Mobil Şube, Atm, Online internet ve diğer ödeme kanalları ile öğrenci borç sorgulama, tahsilat, tahsilat iptal ve mutabakat sorgulama işlemleri yapılmaktadır. Bu işlemler web, servisler aracılığı ile yapılmaktadır. İşlemler logo tarafına anlık aktarılmaktadır. Ödeme işlemlerinde öğrencilerin ödemelerine ve kredi kartı taksit işlemlerine göre peşin indirimi kontrolleri ve indirimlerin logo tarafına otomatik olarak yansıtılması. Yapılan işlemlerin tüm bankalara göre uyarlanması(C#, Web servis)

Ots (Okul taksit sistemi):Anlaşmalı bankalar üzerinden öğrenciye borç sorgulama ve yapılan işlem tarihine göre kalan taksitlerin oluşturulması, taksitlerin tahsil edilmesi, yapılan ots'lerin iptal edilmesi gibi işlemlerin web

servis aracılığı ile yapılmaktadır. Bu işlemler logo tarafına anlık yansıtılmaktadır

Proliz Öğrenci Otomasyonu Ödeme Entegrasyonu: Öğrenci otomasyon sisteminin muhasebeyle haberleşmesi ve öğrencilerin anlık olarak bakiyelerini görüntüleyebilmeleri için ara servislerin yapılandırılması. Öğrenciler ders seçimlerinde anlık olarak derslerin onayatabilmeleri ve kontenjandan yerini alabilmesi için ödeme işlemlerinin hızlı şekilde tamamlamaları gerekiyor. Bu yüzden Proliz uygulaması ile muhasebe sistemi arasındaki bağlantıyı sağlamaktadır. Bu servisler ile tüm işlemleri anlık olarak logo 'ya ve ödeme sistemlerine yansıtılmaktadır

Yüksek Lisans ve Doktora başvuru sistemi: Üniversite yüksek lisans ve doktora yapmak isteyen öğrenciler öncelikle ön başvuru sistemi ile öğrencilerde bilgiler ve evrakları toplayarak işlem yapmaktadır. Bu projede YÖK ve ÖSYM servislerinden mezun bilgilerini ve öğrenci bilgileri tüm bilgiler kullanılmaktadır. Öğrenci başvuru takip ve başvuru yönetim paneli mevcuttur.

Bütçe Talep Sistemi: Üniversitenin yıllık bütçelerini daire başkanlık ve birimlerden bütçe talepleri toplamaktadır. Panel tarafında özel raporlamalar, onay mekanizması, ürün, kategori, proje bazlı raporlama işlemleri yapmaktadır. Yapılan tüm işlemleri ilgili birimlere yetkilendirme bilgilendirme işlemlerini yapmaktadır

Kalite Yönetim Strateji Plan Sistemi: Üniversitenin kalite yönetimi departmanında kullanılmak üzere üniversitenin genel olarak kalite yönetimi ile ilgili tüm hedef ve amaçların takip ve raporlama sistemi.

Uniball Türkiye - Uni yazı gereçleri kırtasiye A.Ş Yazılım Mühendisi ve Ekip Liderliği

Tiger Ce Uygulama: Satış temsilcilerinin kullandıkları el terminali cihazları ile sipariş takip, ziyaret, stok ve sipariş aşamaları ve tüm işlemler yapılmaktadır. Bu işlemler online ve offline olarak çalışmaktadır. Uygulama Windows Ce işletim sistemi üzerinde çalışmaktadır.

B2B-B2C:İřortakları,ara toptancıları perakendeciler ve personellerin sipariř ile ilgili tüm ařamaların tamamlama ve onaylama iřlemleri, raporlama vb. iřlemler yapılmaktadır.

Uniball Depo Takip Sistemi: Kesilen fatura ve irsaliyelerin hazırlanma ařamaları ve kargo takip sistemi ve performans raporlama iřlemleri yapılmaktadır.

Intranet: Sadece řirket bünyesinde kullanılan sipariř analiz, raporlama, personel raporlama ve takip iřlemleri, cari hesaplar ile ilgili güncellemeler ve yönetimsel raporlar yapılmaktadır

Export Intranet: řirketin yurt dıřı personel ve müşteri takip iřlemleri yapılmaktadır. Mevcut intranete benzer yapıda yapılandırılmıřtır.

IT:řirket içiresinde ve řirket dıřında ticket sistemi IT tarafında daha hızlı çalıřmaların ilerlemesi ve takibi açısında yapılan sistem

UniRobot :Server tarafında çalıřan servis uygulamasıdır. Bu uygulama sayesinde tüm sipariřlerin yeni, onay, iptal ve fatura iřlemleri yönetim ve müşteri bazlı mail sistemi, yönetim giriř çıkıř, ziyaret vb. gibi raporlar belirli saatlerde mail ile yönlendirilmesi yapılmaktadır.

Sipariř Aktarma: Metro ve tüm zincir marketlerden gelen sipariřlerin transferi ve dięeri iřlemleri.

řirket bünyesinde ihtiyaç halinde server bakım, firewall, IIS,DNS, Microsoft Exchange vb. sistem ve uygulamalar yönetilmektedir.

řirket bünyesinde çalıřan personellerin takip, ürün sorgulama, sipariř iřlemleri, ziyaret konum iřlemleri, özel raporlamalar gibi iřlemler yapılmaktadır. Uygulama ile veri tabanı arasındaki iletiřim Wcf servisi ile yapılmaktadır. Mikro muhasebe programı ile entegre çalıřmaktadır

Uni Kurumsal Web

Kurumsal web sayfası geliřtirme süreci

Usishi Biliřim Teknolojileri Ltd. řti. - ASP.Net Yazılım Uzmanı

Bilgi Teknolojileri alanında ar-ge řirketi bünyesinde yazılım uygulamalar geliřtirdim. Türk Telekom, OYAK bank, ark řirketler grubu vb. řirketler için geliřtirilen web projelerinde görev aldım.

Boytek Ltd- ASP.Net Yazılım Uzmanı-

Şirket bünyesinde kullanılmak üzere e-ticaret sistemi geliştirilmesi ve paket programı haline getirilmesi.