T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

HİSSE SENEDİ ALIM SATIMINDA PARÇACIK SÜRÜ OPTİMİZASYONU TABANLI CNN-LSTM AĞLARININ KULLANILMASI

YÜKSEK LİSANS TEZİ

Ahmet Bedirhan SAĞIR

Bilgisayar Mühendisliği Ana Bilim Dalı
Bilgisayar Mühendisliği Programı

ŞUBAT, 2024

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

HİSSE SENEDİ ALIM SATIMINDA PARÇACIK SÜRÜ OPTİMİZASYONU TABANLI CNN-LSTM AĞLARININ KULLANILMASI

YÜKSEK LİSANS TEZİ

Ahmet Bedirhan SAĞIR

(Y2113.010026)

Bilgisayar Mühendisliği Ana Bilim Dalı

Bilgisayar Mühendisliği Programı

Tez Danışmanı: Dr. Öğr. Üyesi Sina APAK

ŞUBAT, 2024

ONAY SAYFASI

ONUR SÖZÜ

Yüksek Lisans tezi olarak sunduğum "HİSSE SENEDİ ALIM SATIMINDA PARÇACIK SÜRÜ OPTİMİZASYONU TABANLI CNN-LSTM AĞLARININ KULLANILMASI" adlı çalışmanın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Kaynakça 'da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve onurumla beyan ederim. (12/02/2024).

Ahmet Bedirhan SAĞIR

ÖNSÖZ

Bu çalışmada yapay sinir ağları ile derin öğrenme metotlarından Parçacık Sürü Optimizasyonuyla optimize edilmiş bir LSTM uygulaması olan LeNet-5 ağları kullanılarak hisse senedi tahmini ve alım-satımın yapılması amaçlanmıştır.

Bu çalışmanın hayata geçmesinde bilgi ve tecrübeleriyle bana yol gösteren Dr. Öğr. Üyesi Sina APAK'a, çalışmalarımda bana zaman izni vererek çalışmalarıma katkıda bulunan görev yaptığım Zeytinburnu Sosyal Güvenlik Merkezi müdürü sayın Ahmet KURTULUŞ başta olmak üzere, görevli tüm müdür yardımcılarıma, bana inanarak yolumu aydınlatan sevgili aileme teşekkür etmeyi bir görev bilirim.

Şubat, 2024 Ahmet Bedirhan SAĞIR

HİSSE SENEDİ ALIM SATIMINDA PARÇACIK SÜRÜ OPTİMİZASYONU TABANLI CNN-LSTM AĞLARININ KULLANILMASI

ÖZET

"Hisse senedi piyasası tahmini, şirketlerin parasal stoklarının piyasa değerinin gelecekteki eğilimini tahmin etmektir. Makine öğrenimi ve derin öğrenme, geçmiş ticaret verilerine dayalı eğitime dayalı tahminler yapan borsa tahmin teknolojilerinde yeni bir trend haline gelmiştir. Makine öğrenimi, tahminleri daha doğru ve basit hale getirmek için çeşitli modeller kullanır. Bu makalede, hisse senedi fiyatını zaman içinde analiz etmek, hisse senedinin ortalama günlük getirisini, en düşük değerini, en yüksek değerini ve son olarak gelecekteki hisse senedi davranışını tahmin etmek için makine öğrenimi tekniklerini kullanıyoruz. Bu çalışmada, hisse senedi alım satımında bir CNN uygulaması olan LeNet-5 tabanlı evrimsel sinir ağları (CNN), LSTM ve Parçacık Sürü Optimizasyonu kullanılarak otomatik bir al/sat kararı oluşturulmaya çalışılmıştır. S&P 500 borsasındaki bazı şirketlere ait hisse senetleri üzerinde yapılan çalışmalarda çeşitli doğruluk oranları elde edilmiştir.."

Anahtar Kelimeler: LeNet-5, PSO, Makine Öğrenmesi, Derin Öğrenme, borsa tahmini, LSTM.

USING PARTICLE SWARM OPTIMIZATION BASED CNN-LSTM NETWORKS IN STOCK TRADING

ABSTRACT

"Stock market prediction is the process of forecasting the future trend of the market value of companies' monetary stocks. Machine learning and deep learning have become a new trend in stock market prediction technologies that make predictions based on training on historical trading data. Machine learning uses a variety of models to make predictions more accurate and simpler. In this paper, we use machine learning techniques to analyze stock prices over time, predict the average daily return of the stock, the minimum value, the maximum value, and finally the future behavior of the stock. In this study, an automatic buy/sell decision was attempted to be created using convolutional neural networks (CNNs) based on LeNet-5, which is an application of CNN in stock trading, LSTM, and Particle Swarm Optimization. Various accuracy rates were obtained in studies conducted on stocks belonging to some companies listed on the S&P 500."

Keywords: LeNet-5, PSO, Machine learning , deep learning , stock market prediction, LSTM.

İÇİNDEKİLER

ONUR SÖZÜ ..... **ii**
ÖNSÖZ ..... **iii**
ÖZET ..... **iv**
ABSTRACT ..... **v**
İÇİNDEKİLER ..... **vi**
ÇİZELGELER LİSTESİ ..... **x**
ŞEKİLLER LİSTESİ ..... **xi**
I. GİRİŞ **12**
A. Borsa Nedir? 12
1. Listelenmiş şirketler 12
2. Yatırımcılar 12
3. Hisse Senetleri ve Hisseler 13
4. Borsanın İşlevleri 13
5. Ticareti Kolaylaştırmak 13
6. Fiyat keşfi 13
7. Likidite 13
8. Sermaye oluşumu 13
9. Piyasa katılımcıları 13
10. Komisyoncu 13
11. Yatırım bankaları 14
12. Düzenleyiciler 14
13. Küresel Etki 14
B. Borsanın Tarihçesi 14
C. Borsa Türleri 16
1. Borsa 17
2. Ticaret Borsaları 17

3. Türev Borsalar 17
4. Döviz (Forex) Piyasası 17
5. Kripto Para Borsaları 17
6. Tezgâh Üstü (OTC) Piyasası 18
7. Vadeli İşlem Borsaları 18
8. Sabit Getirili Borsalar 18

D. Hisse Senedi Nedir? 18

1. Adi Hisse Senedi 19
2. İmtiyazlı Hisse Senedi 19

E. Hisse Senedi Türleri 20

1. Adi Hisse Senedi 20
2. İmtiyazlı Hisse Senedi 20
3. Hak Kullanım Kılavuzu (Warrant) 20
4. Konvertibl Hisse Senedi 21
5. Teminatlı Hisse Senedi (Depositary Receipts) 21
6. Halka Arz Edilen Hisse Senedi 21

F. Neden Hisse Senedi Tahmini Yapıyoruz? 21

1. Yatırım Stratejilerini Belirleme 21
2. Risk Yönetimi 21
3. Kâr Elde Etme Stratejilerini Belirleme 22
4. Finansal Planlama ve Hedef Belirleme 22
5. Şirket Değerlemesi 22
6. Ekonomik ve Finansal Analiz 22
7. Bilgiye Dayalı Yatırım Kararları 22

G. Hisse Senedi Tahmini Nedir? 23

1. Temel Analiz 23
2. Teknik Analiz 23
3. Haber ve Olay Analizi 23
4. Makine Öğrenimi ve Veri Madenciliği 23
5. Duvar Sokağı Beklentileri 24

II. İLİŞKİLİ ÇALIŞMALAR 25
III. KULLANILAN YÖNTEMLER (METODOLOJİ)..... 28
A. Cnn (Evrişimli Sinir Ağları)..... 29
B. Lstm (Long Short-Term Memory/Uzun Kısa Süreli Bellek) 31
C. LeNeT-5 33
1. Evrişimsel Katmanlar..... 33
2. Alt Örnekleme Katmanları..... 34
3. Tamamen Bağlı Katmanlar 34
4. LeNet-5 Mimarisi..... 35
D. Relu 35
1. Tanım ve Özellikler..... 35
2. Matematiksel Formülasyon..... 36
3. ReLU'nun Avantajları 36
4. ReLU'nun çeşitleri..... 37
E. Softmax Layer 37
F. Optimizasyon Algoritmaları 38
1. Adam Optimizer 40
2. Pso (Parçacık Sürü Optimizasyonu)..... 42
IV. ÇALIŞMANIN SONUÇLARI 47
A. Veriseti Hakkında..... 48
B. Verisetini Düzenleme (Etiketleme/Labellıng)..... 52
1. Buy/Sell (Al/Sat) Etiketleme Nedir?..... 53
C. Yapılan İşlemler 54
1. 1 Boyutlu Verinin 2 Boyutlu Görüntü Haline Getirilmesi..... 57
D. Hiperparametre Optimizasyonu 60
E. Pso'nun Performans Üzerine Etkileri 61
V. SONUÇ VE TARTIŞMA..... 65
A. Sonuç..... 67

B. Ek Tartışmalar 67
VI. KAYNAKÇA 69
ÖZGEÇMİŞ 73

ÇİZELGELER LİSTESİ

Çizelge 1: Parametre Optimizasyon Sınırları..... 61

Çizelge 2: Performans Metrikleri..... 62

ŞEKİLLER LİSTESİ

Şekil 1: IMAGENET çalışma şeması 28
Şekil 2: CNN Çalışma Şeması 29
Şekil 3: LSTM Çalışma Şeması 31
Şekil 4: LeNet-5 Mimarisi 33
Şekil 5: Boeing'e ait veriseti 49
Şekil 6: Amazon'a ait veriseti 49
Şekil 7: Netflix'e ait veriseti 49
Şekil 8: Etiketlenmiş Veriler 53
Şekil 9: Boeing'in yıllara göre ALIM emirleri 54
Şekil 10: Amazon'un yıllara göre ALIM emirleri 55
Şekil 11: Netflix'in Yıllara Göre ALIM emirleri 55
Şekil 12: Boeing'in yıllara göre SATIŞ emirleri 56
Şekil 13: Amazon'un yıllara göre SATIŞ emirleri 56
Şekil 14: Netflix'in yıllara göre SATIŞ emirleri 57
Şekil 15: Genel Görüntü Matrisleri-1 (50x50) 58
Şekil 16: Netflix'e ait genel görüntü matrisi (50x50) 58
Şekil 17: Genel Görüntü Matrisleri-2 (32x32) 59
Şekil 18: 10 ×10'luk görüntü matrisleri 60
Şekil 19: Karışıklık Matrisleri 63

I. GİRİŞ

Hisse senedi borsalarında özellikle alım-satım işlemlerinde hız ve doğruluk oldukça büyük önem taşımaktadır. Zira, fırsatlar anlık olup, anında kaybolmaktadır. Hisse senedi borsasında fiyatlar anlık olarak yükselip düşerken, gerekli refleksi gösteremeyen yatırımcılar daima kayıplar yaşamıştır. Bu yüzden hisse senedi tahmini ve alım satımın otomatikleştirilmesi büyük önem arz etmektedir. Genel olarak hisse senedi borsasında tüm işlemler saniyenin neredeyse onda hatta yirmide biri zamanda gerçekleşmektedir. Bu durum hisse senedinin alım satımının takibini ve anlık refleksle işlem yapılmasını mecburi hale getirmiştir. İşte bu mecburiyet ise yeni icatların ihtiyaç duyulmasına yol açmıştır. Otomatik alım-satım ve tahmin robotları da icatlar, ihtiyaçlardan doğar önermesine uygun olarak geliştirilmiştir.

A. Borsa Nedir?

Borsa, bireylerin ve kurumların halka açık şirketlerin hisselerini alıp sattığı dinamik bir finansal pazardır. Hisse alım satımı yoluyla şirketlerde mülkiyet değişimini kolaylaştırarak küresel finansal sistemin önemli bir dayanağı olarak hizmet vermektedir. Borsa temel olarak şu bileşenlerden oluşur:

1. Listelenmiş şirketler

Halka açık şirketler, yatırımcılardan sermaye toplamak amacıyla hisselerini borsalarda listeler. Listeleme, şirketlere daha geniş bir yatırımcı tabanına erişim ve hisseleri için likidite sağlar.

2. Yatırımcılar

Bireysel yatırımcılardan kurumsal kuruluşlara kadar geniş bir yelpazede yatırımcılar borsaya katılmaktadır. Şirket performansı, piyasa eğilimleri ve ekonomik göstergeler gibi çeşitli faktörlere dayalı olarak hisse senedi alıp satar.

3. Hisse Senetleri ve Hisseler

Hisse senetleri bir şirketteki sahipliği temsil eder ve hisseler mülkiyet birimleridir. Yatırımcılar hisse satın aldıklarında şirketin kısmi sahibi haline gelirler ve temettü ve sermaye kazancından yararlanabilirler.

4. Borsanın İşlevleri

5. Ticareti Kolaylaştırmak

Birincil işlevi, menkul kıymet alım satımı için bir platform sağlamaktır. Alıcılar ve satıcılar, borsada işlem yapan komisyoncular aracılığıyla bağlantı kurar.

6. Fiyat keşfi

Hisse senedi fiyatları arz ve talep dinamikleri tarafından belirlenmektedir. Borsa, yatırımcıların bir şirketin hisselerinin gerçeğe uygun değerini toplu olarak belirlediği bir pazar yeri görevi görür.

7. Likidite

Menkul kıymet borsaları menkul kıymetler için hazır bir piyasa sağlayarak likiditeyi artırır. Yatırımcılar, varlıklarını hızlı bir şekilde nakde çevirerek verimli sermaye tahsisini teşvik edebilirler.

8. Sermaye oluşumu

Şirketler borsayı, ilk halka arzlar (IPO'lar) yoluyla halka yeni hisseler ihraç ederek sermaye artırmak için kullanır. Bu sermaye daha sonra işin genişletilmesi, araştırma ve geliştirme için kullanılır.

9. Piyasa katılımcıları

10. Komisyoncu

Yatırımcılar adına alım satımı kolaylaştıran aracılar. İşlemleri yürütürler, piyasa bilgileri sağlarlar ve yatırım tavsiyeleri sunarlar.

11. Yatırım bankaları

Halka arzlarda çok önemli bir rol oynar, şirketlerin halka açılmasına yardımcı olur, yeni hisse ihracını kolaylaştırır.

12. Düzenleyiciler

Menkul Kıymetler ve Borsa Komisyonu (SEC) gibi yetkililer, adil ve şeffaf ticaret uygulamalarını sağlamak için borsaları denetler ve düzenler.

13. Küresel Etki

Menkul kıymet borsaları küresel olarak birbirine bağlı olup, uluslararası ekonomik eğilimleri etkilemekte ve onlardan etkilenmektedir. Bir piyasadaki dalgalanmaların diğerleri üzerinde kademeli etkileri olabilir, bu da küresel finansal sistemin birbirine bağlılığını vurgulamaktadır.

Özünde borsa, ekonomik büyümenin hayati bir motoru olarak hizmet eder ve şirketlerin sermaye artırmasına ve yatırımcıların servet yaratmaya katılmasına olanak tanır. Şeffaflık, likidite ve fiyat keşfi ilkelerini bünyesinde barındırır ve bu da onu modern finansın temel taşı haline getirir. Borsanın dinamiklerini anlamak, finans dünyasının karmaşıklıklarında yol alan yatırımcılar, işletmeler ve politika yapıcılar için çok önemlidir.

B. Borsanın Tarihçesi

Roma İmparatorluğu döneminde bildiğimiz modern borsa mevcut olmasa da menkul kıymet alım satımı kavramıyla benzerlikler gösteren bazı finansal uygulamalar vardı. Romalılar çeşitli ekonomik faaliyetlerde bulunmuşlar ve o dönemdeki finansal araçlar, piyasalarda gelecekte yaşanacak gelişmelere zemin hazırlamıştır.

Antik Roma'da vergi ve geçiş ücretlerinin toplanmasından sorumlu büyük müteahhitlik firmaları olan ve "publicani" olarak bilinen girişimler vardı. Çoğunlukla varlıklı bireylerden oluşan yatırımcılar, kârdan pay almaları karşılığında bu publicani'lere sermaye sağlıyorlardı. Bu sistem modern hisse senedi alım satımıyla aynı olmasa da, yatırımcıların kaynaklarını ortak girişimlerde bir araya getirmesi kavramını içeriyordu.

Roma İmparatorluğu'nda ayrıca yatırımcı gruplarının ticaret gezilerini finanse etmek için bir araya geldiği "publicani societates" olarak bilinen ilkel bir "şirket" biçimi vardı. Her yatırımcı bu girişimlerden elde edilen kar ve zararlardan bir paya sahipti. Yine borsanın doğrudan öncüsü olmasa da ortak mülkiyet ve risk fikrini yansıtıyordu.

Ancak Roma İmparatorluğu'nun çöküşü ve ardından gelen ekonomik istikrarsızlık, bu ilk mali uygulamalardan önemli bir sapmaya işaret ediyordu. Avrupa'da orta çağ döneminde organize finansal faaliyetlerde bir düşüş görüldü ve borsa faaliyetlerine benzeyen bazı unsurların yeniden ortaya çıkması Orta Çağ'ın sonlarına ve Rönesans'a kadar gerçekleşmedi.

Özetle, Roma İmparatorluğu'nun ortak yatırımlar ve ortak girişimler içeren finansal uygulamaları olmasına rağmen resmi bir borsaları yoktu. Modern borsaların gelişimi tarihte çok daha sonra, özellikle 17. yüzyılda Amsterdam'da ve ardından diğer Avrupa şehirlerinde gerçekleşti. Roma mali uygulamaları, paylaşılan yatırım ve riskin ilk örnekleri olarak görülebilir, ancak bunlar daha sonraki yüzyıllarda ortaya çıkacak borsalar kadar karmaşık veya organize değildi.

Borsanın tarihi, finans dünyasını şekillendiren önemli olayların damgasını vurduğu, yüzyıllara yayılan karmaşık ve büyüleyici bir hikayedir. Hisse senedi ticaretinin kökenleri, Hollanda Doğu Hindistan Şirketi'nin halka hisse ihraç eden ilk şirket olduğu ve yatırımcıların şirketteki sahiplik hisselerini alıp satmasına olanak tanıyan 17. yüzyıla kadar uzanmaktadır. Bu yenilikçi finansal konsept, modern borsanın temelini attı.

18. yüzyılda Avrupa'nın çeşitli şehirlerinde alıcı ve satıcıların işlem yapmaları için merkezi bir konum sağlayan borsalar ortaya çıkmaya başladı. 1602 yılında kurulan Amsterdam Menkul Kıymetler Borsası genellikle dünyanın ilk resmi borsası olarak kabul edilir. Bu arada 1801 yılında kurulan Londra Menkul Kıymetler Borsası da küresel finansal sistemin gelişmesinde önemli bir rol oynadı.

19. yüzyıl Amerika Birleşik Devletleri'nde borsaların yükselişine tanık oldu ve New York Menkul Kıymetler Borsası (NYSE) önemli bir oyuncu haline geldi. Sanayi Devrimi ekonomik büyümeyi körükledi ve sermaye talebini artırarak halka açık şirketlerin çoğalmasına yol açtı. 19. yüzyılın ortasındaki demiryolu patlaması ve ardından diğer endüstrilerin genişlemesi, pazarın genişlemesine katkıda bulundu.

20. yüzyıl borsaya hem refah hem de zorluklar getirdi. Kükreyen Yirmiler, yükselen hisse senedi fiyatları ve yaygın spekülasyonların damgasını vurduğu bir ekonomik coşku dönemine tanık oldu. Ancak 1929'daki borsa çöküşüyle bu mutluluk büyük bir durma noktasına geldi ve Büyük Bunalımı tetikledi. Sonrasında, güveni yeniden tesis etmek ve piyasa suiistimallerini önlemek için 1933 Menkul Kıymetler Kanunu ve 1934 Menkul Kıymetler Borsası Kanunu gibi düzenleyici tedbirlere hız verildi.

İkinci Dünya Savaşı sonrasında borsa, yeni finansal araçların ve teknolojilerin ortaya çıkmasıyla birlikte uzun bir büyüme dönemi yaşadı. 20. yüzyılın sonlarında elektronik ticaretin ortaya çıkışı, hisse senetlerinin alınıp satılma biçiminde devrim yaratarak işlemleri daha hızlı ve daha erişilebilir hale getirdi.

21. yüzyılda borsa, 2000'li yılların başındaki dot-com balonunun patlaması ve 2008'deki küresel mali kriz de dahil olmak üzere çeşitli zorluklarla karşı karşıya kaldı. Teknolojik gelişmeler ve çevrimiçi ticaret platformlarının yükselişi, borsaya erişimi daha da demokratikleştirdi. Bireysel yatırımcıların daha aktif katılımını sağlamak.

Son yıllarda piyasa oynaklığı, yüksek frekanslı ticaret ve sosyal medyanın hisse senedi fiyatları üzerindeki etkisi hakkındaki tartışmalar finansal manşetlere hâkim oldu. Hisse senedi piyasasının tarihi, küresel finansın sürekli gelişen doğasını yansıtan, ekonomik, politik ve teknolojik güçler tarafından şekillendirilen dinamik bir anlatıdır.

C. Borsa Türleri

Borsalar, çeşitli finansal araçların alım satımı için platformlar sağlayarak küresel finansal sistemde önemli mekanizmalar olarak hizmet vermektedir. Bu borsalar piyasa fiyatlarının belirlenmesinde, likiditenin kolaylaştırılmasında ve yatırımcıların geniş bir yelpazedeki varlıklara erişmesini sağlamada çok önemli bir rol oynamaktadır. Farklı takas türlerinin kapsamlı bir açıklamasını burada bulabilirsiniz:

1. Borsa

Menkul kıymet borsaları, halka açık şirketlerin hisselerinin alınıp satıldığı hisse senedi ticaretinin kalbidir. New York Menkul Kıymetler Borsası (NYSE) ve NASDAQ gibi bu borsalar, şirketlerde hisse sahibi olmak isteyen yatırımcılar için birincil merkez görevi görüyor. Hisse senetleri bir şirketteki mülkiyet biçimini temsil eder ve fiyatları arz ve talep dinamikleri tarafından belirlenir.

2. Ticaret Borsaları

Emtia borsaları fiziksel malların veya emtiaların ticaretine odaklanır. Tarım ürünleri, enerji kaynakları ve değerli metaller takas edilen varlıklar arasında yer alıyor. Önemli emtia borsaları arasında Chicago Ticaret Borsası (CME) ve Londra Metal Borsası (LME) bulunmaktadır. Yatırımcılar emtia vadeli işlem sözleşmelerine katılarak gelecekteki fiyat hareketleri hakkında spekülasyon yapmalarına veya fiyat dalgalanmalarına karşı korunmalarına olanak tanıyabilir.

3. Türev Borsalar

Türev borsaları, değeri dayanak varlıktan türetilen finansal araçlarla ilgilidir. Chicago Board Options Exchange (CBOE) ve Eurex bunlara örnektir. Opsiyonlar ve vadeli işlem sözleşmeleri gibi türevler, yatırımcılara gerçek varlığa sahip olmadan riskten korunma veya fiyat hareketleri hakkında spekülasyon yapma fırsatları sunar.

4. Döviz (Forex) Piyasası

Forex piyasası, döviz ticareti için merkezi olmayan küresel bir pazardır. Katılımcılar döviz kurlarına göre bir para birimini alıp diğerini satarak döviz çiftleriyle meşgul olurlar. Haftanın beş günü, günün 24 saati faaliyet gösteren Forex piyasası, uluslararası ticaret ve finansın kritik bir bileşenidir.

5. Kripto Para Borsaları

Kripto para borsaları, Bitcoin ve Ethereum gibi dijital veya sanal para birimlerinin alım satımını kolaylaştırır. Coinbase, Binance ve Kraken gibi platformlar, kullanıcıların kripto para birimlerini birbirlerine veya geleneksel fiat para birimlerine

karşı takas etmelerine olanak tanıyor. Bu borsalar blockchain teknolojisi üzerinde çalışıyor ve merkezi olmayan yapıları nedeniyle popülerlik kazanıyor.

6. Tezgâh Üstü (OTC) Piyasası

OTC piyasası, ticaretin doğrudan iki taraf arasında gerçekleştiği merkezi olmayan bir ağdır. Hisse senetleri, tahviller ve türevler dahil olmak üzere çeşitli finansal araçları yönetir. Merkezi borsaların aksine, OTC işlemleri genellikle bayi ağlarını içerir ve bu da ticaret koşullarında esneklik ve özelleştirme sağlar.

7. Vadeli İşlem Borsaları

Vadeli işlem borsaları, varlıkları önceden belirlenmiş bir gelecek tarih ve fiyattan satın alma veya satma anlaşmaları olan standart vadeli işlem sözleşmelerinde uzmanlaşmıştır. Chicago Ticaret Kurulu (CBOT) ve Euronext öne çıkan örneklerdir. Vadeli işlem sözleşmeleri fiyat dalgalanmalarından korunmak ve spekülatif amaçlarla yaygın olarak kullanılmaktadır.

8. Sabit Getirili Borsalar

Sabit getirili borsalar, tahvil ve hazine bonosu gibi borçlanma senetlerinin alım satımına odaklanmaktadır. Yatırımcılar bu borsalara sabit getirili enstrümanları alıp satarak faiz geliri elde etmek için katılıyorlar. Örnekler arasında Tahvil Piyasası Birliği (BMA) ve Avrupa Toptan Menkul Kıymetler Piyasası (EWSM) yer almaktadır.

Bu çeşitli borsa türlerini anlamak, yatırımcılar ve tüccarlar için çok önemlidir çünkü bu, finansal piyasaların çeşitli ortamlarında gezinmelerini sağlar. Her borsa türü belirli varlık sınıflarına ve alım satım tercihlerine hitap ederek katılımcılara portföylerini çeşitlendirme ve riski etkili bir şekilde yönetme fırsatları sunar.

D. Hisse Senedi Nedir?

Hisse senedi, aynı zamanda öz sermaye veya pay olarak bilinen, genelde halka açık bir şirkette sahipliği temsil eden bir finansal araçtır. Bireyler veya kurumsal yatırımcılar hisse senetleri satın aldığında, etkili bir şekilde şirkette bir sahiplik payı edinirler ve bu da onları hissedar yapar. Bu sahiplik, şirket içinde belirli haklara ve ayrıcalıklara sahip olma anlamına gelir.

Hisse senetleri, şirketin varlıklarına ve kazançlarına bir talebi temsil eder. Hissedarlar, iki temel şekilde fayda sağlama potansiyeline sahiptir: sermaye artışı ve temettüler aracılığıyla. Sermaye artışı, hisse senedinin piyasa değerinin arttığı durumlarda ortaya çıkar ve hissedarların hisselerini kârla satabilmelerini sağlar. Diğer taraftan, temettüler, şirketin karından hissedarlarına periyodik ödemelerdir.

Hisse senetleri genellikle iki ana türe ayrılır: adi hisse senedi ve imtiyazlı hisse senedi.

1. Adi Hisse Senedi

Adi hisse senedi, en yaygın türdür ve insanlar "hisse senetleri" dediklerinde genellikle adi hisse senetlerini kastederler. Adi hissedarlar, hissedar toplantılarında oy kullanma yetkisine sahiptir, bu da şirketin yönetimini etkileyen kararlara katılabilmelerini sağlar.

Aynı zamanda sermaye artışı ve temettü alma potansiyeline sahiptirler, ancak bu ödemeler garanti değildir.

2. İmtiyazlı Hisse Senedi

İmtiyazlı hisse senedi, farklı bir sahiplik sınıfını temsil eder. Adi hissedarlardan farklı olarak, imtiyazlı hissedarların genellikle oy kullanma hakları yoktur. Ancak, adi hissedarlara göre şirketin varlıkları ve kazançları üzerinde daha üst bir talepleri vardır. Likidasyon durumunda, imtiyazlı hissedarlar adi hissedarlardan önce ödenir. İmtiyazlı hisse senedi genellikle sabit temettü ödemeleri yaparak daha öngörülebilir bir gelir akışı sağlar.

Hisse senetlerinin değeri çeşitli faktörlerden etkilenir ve fiyatları piyasadaki talep ve arza bağlı olarak dalgalanır. Yatırımcılar, bir şirketin finansal performansı, yönetimi, endüstri trendleri ve ekonomik koşulları analiz ederek hisse senetleri hakkında bilinçli kararlar verirler.

Hisse senetleri, alıcı ve satıcıların işlemlerini gerçekleştirdiği New York Menkul Kıymetler Borsası (NYSE) veya NASDAQ gibi borsalarda işlem görür. Yatırımcılar, menkul kıymetlerin alım satımını kolaylaştıran aracı kurumlar

aracılığıyla hisse senedi satın alabilirler. Çevrimiçi ticaret platformlarının ortaya çıkması, bireysel yatırımcılar için erişimi daha da artırmıştır.

Sonuç olarak, bir hisse senedi, halka açık bir şirkette sahipliği temsil eden bir finansal araçtır ve hissedara belirli haklar ve potansiyel finansal faydalar sunar. Adi ve imtiyazlı hisse senetlerinin özelliklerini anlamak ve hisse senetlerini etkileyen faktörleri kavramak, yatırımcıların karmaşık hisse senedi piyasasında gezinirken temel öneme sahiptir.

E. Hisse Senedi Türleri

Hisse senetleri, şirketlerde sahiplik hakkı temsil eden finansal araçlardır ve farklı türleri vardır.

1. Adi Hisse Senedi

Adi hisse senedi, genellikle "hisse senetleri" olarak adlandırılan en yaygın türdür.

Adi hissedarlar, şirketin yönetimine katılma hakkına sahip olur ve hissedar toplantılarında oy kullanabilirler. Sermaye artışından ve olası temettü ödemelerinden potansiyel olarak faydalanabilirler, ancak temettü ödemeleri garanti değildir.

2. İmtiyazlı Hisse Senedi

İmtiyazlı hisse senedi, özel bir sahiplik sınıfını temsil eder. İmtiyazlı hissedarlar genellikle oy kullanma haklarına sahip değildir, ancak adi hissedarlara göre öncelikli bir talepleri vardır. Likidasyon durumunda, imtiyazlı hissedarlar adi hissedarlardan önce ödeme alırlar. Genellikle sabit temettü ödemeleri yaparak daha öngörülebilir bir gelir akışı sağlarlar.

3. Hak Kullanım Kılavuzu (Warrant)

Hak kullanım kılavuzları, belirli bir tarih ve fiyat aralığında şirketin hisse senetlerini alma hakkını içerir. Yatırımcılara gelecekteki hisse senedi alımları için fırsat sunarlar.

4. Konvertibl Hisse Senedi

Konvertibl hisse senetleri, belirli bir dönemde hissedarın bu senetleri belirli bir oranda başka bir güvenlik veya varlıkla değiştirebileceği bir türdür. Yatırımcılara esneklik sağlar ve potansiyel olarak hisse senetlerinden başka değerli varlıklara geçiş yapma olanağı tanır.

5. Teminatlı Hisse Senedi (Depositary Receipts)

Teminatlı hisse senetleri, yabancı şirketlerin hisselerini temsil eden ve genellikle Amerikan borsalarında işlem gören bir türdür. Amerikan Depozit Makbuzu (ADR) ve Küresel Depozit Makbuzu (GDR) gibi türleri bulunur.

6. Halka Arz Edilen Hisse Senedi

Halka arz edilen hisse senetleri, şirketin halka açık bir pazara sunulmuş ve yatırımcıların satın alabileceği hisse senetlerini temsil eder. İlk halka arz (IPO) sırasında şirket tarafından çıkarılırlar. Her bir hisse senedi türü, farklı hak ve avantajlara sahiptir ve yatırımcıların stratejilerine göre çeşitli avantajlar sunar

F. Neden Hisse Senedi Tahmini Yapıyoruz?

Hisse senedi tahminleri, yatırımcılara ve finans profesyonellerine gelecekteki fiyat hareketlerini anlama ve değerlendirme konusunda rehberlik etmeyi amaçlayan analitik bir süreçtir. Bu tahminler, bir dizi nedenle yapılır

1. Yatırım Stratejilerini Belirleme

Hisse senedi tahminleri, yatırımcılara belirli bir hisse senedine yatırım yapma veya elde tutma stratejilerini belirleme konusunda yardımcı olur. Bu, yatırımcıların portföylerini çeşitlendirmelerine ve risklerini yönetmelerine olanak tanır

2. Risk Yönetimi

Hisse senedi tahminleri, yatırımcılara potansiyel riskleri değerlendirme ve yönetme konusunda rehberlik eder. Fiyat hareketlerinin önceden tahmin edilmesi, yatırımcılara riskli varlıklardan kaçınma veya onları daha bilinçli bir şekilde yönetme olanağı sağlar.

3. Kâr Elde Etme Stratejilerini Belirleme

Hisse senedi tahminleri, yatırımcılara belirli bir zaman diliminde kâr elde etme stratejilerini geliştirme konusunda yardımcı olur. Bu stratejiler, hisse senetlerini uygun fiyat seviyelerinde almak veya satmak amacıyla kullanılabilir.

4. Finansal Planlama ve Hedef Belirleme

Yatırımcılar ve finans profesyonelleri, hisse senedi tahminleri kullanarak finansal hedeflerini belirleme ve bunlara ulaşma stratejilerini planlama konusunda yardımcı olabilirler. Bu, bireylerin veya şirketlerin mali hedeflere ulaşmalarına destek sağlar.

5. Şirket Değerlemesi

Hisse senedi tahminleri, şirketlerin değerini belirleme ve değerleme modelleri geliştirme sürecinde önemli bir rol oynar. Yatırımcılar, bu tahminleri kullanarak bir şirketin gelecekteki performansını ve değerini daha iyi anlayabilirler.

6. Ekonomik ve Finansal Analiz

Hisse senedi tahminleri, genellikle ekonomik ve finansal analizle birleştirilerek, piyasa trendlerini anlama ve bu trendlere göre hareket etme konusunda yardımcı olur. Bu hem mikroekonomik hem de makroekonomik faktörleri içerebilir.

7. Bilgiye Dayalı Yatırım Kararları

Yatırımcılar, hisse senedi tahminleri kullanarak daha bilgiye dayalı yatırım kararları alabilirler. Bu, piyasa analizi, teknik analiz ve temel analizi içerebilir.

Bu nedenlerle, hisse senedi tahminleri yapılarak yatırımcılara, analistlere ve şirketlere piyasa koşulları hakkında daha fazla anlayış kazanma ve bilinçli kararlar alma fırsatı sağlanır.

G. Hisse Senedi Tahmini Nedir?

Hisse senedi tahmini, finansal piyasalarda belirli bir hisse senedinin gelecekteki fiyat hareketlerini öngörme çabasıdır. Yatırımcılar, analistler ve finans uzmanları, çeşitli yöntemler ve analitik araçlar kullanarak hisse senetlerinin değerini anlamaya ve gelecekteki piyasa koşullarını tahmin etmeye çalışırlar. Bu tahminler, bir dizi faktör ve analitik yaklaşım kullanılarak oluşturulur ve genellikle yatırım stratejileri oluşturmak, riskleri yönetmek ve kararlar almak amacıyla kullanılır.

Hisse senedi tahmini yapılırken kullanılan bazı anahtar unsurlar şunlardır:

1. Temel Analiz

Temel analiz, bir şirketin temel sağlığına odaklanarak hisse senedi değerlemesi yapma yöntemidir. Şirketin finansal durumu, gelir tablosu, bilanço ve gelecekteki büyüme potansiyeli gibi temel göstergeler incelenir. Ayrıca sektörel ve ekonomik faktörler de dikkate alınır.

2. Teknik Analiz

Teknik analiz, geçmiş fiyat hareketlerine ve ticaret hacimine odaklanarak gelecekteki fiyat hareketlerini tahmin etme yöntemidir. Grafikler, göstergeler ve matematiksel modeller kullanılarak piyasa trendleri ve momentum analizi yapılır.

3. Haber ve Olay Analizi

Haber ve olay analizi, şirketle ilgili gelişmeleri ve genel piyasa olaylarını takip ederek hisse senedi fiyatlarının üzerindeki etkileri değerlendirir. Örneğin, şirketin bir kazanç raporu açıklaması veya sektörel bir kriz gibi olaylar hisse senedi fiyatlarını etkileyebilir.

4. Makine Öğrenimi ve Veri Madenciliği

Gelişmiş teknolojiler, özellikle makine öğrenimi ve veri madenciliği, büyük veri setleri üzerinde çalışarak karmaşık modeller oluşturabilir. Bu modeller, geçmiş verilerden öğrenilen desenleri kullanarak gelecekteki fiyat hareketlerini tahmin edebilir.

5. Duvar Sokağı Beklentileri

Duvar sokağı beklentileri, yatırımcıların ve analistlerin hisse senetleri hakkındaki görüşlerini içerir. Bu beklentiler, hisse senedinin gelecekteki performansını etkileyebilir ve yatırımcılar için önemli bir rehber olabilir.

Hisse senedi tahminleri, genellikle bir kombinasyonu içerir ve tek bir yaklaşıma dayanmaz.

II. İLİŞKİLİ ÇALIŞMALAR

Bu konuda yapılan bazı çalışmalarda çeşitli avantajlar ve dezavantajlar bulunmaktadır. Örneğin, J. Eapen ve arkadaşlarının makalesinde %9 oranında daha iyi performans elde edilirken, uygulamanın bazı zorlukları olduğu ortaya konmuştur. (J. Eapen, 2019) Yine SI-RCNN ve diğer hibrit modelleri kullanan çalışmasında performansın daha iyi olmasına rağmen, büyük verilerde yanlış tahminler oluşturabilme riski bulunmaktadır. (M.Vargas, 2018)

LSTM ve RMSE modelli çalışmasında elde edilen modelin karar alma hızının yüksek, hata oranının düşük olduğu ancak büyük çaptaki verilerde fazla kaynak kullanımı ihtiyacının olduğu belirtilmiştir. (S. Banik, 2021)

RNN ağları ve AdaGrad kullanarak gerçekleştirdiği çalışmada hata oranının oldukça düşük olduğu, ancak çok fazla veriye ihtiyaç duyulduğundan kesin doğruluğa odaklanılamadığı ifade edilmiştir. (K. Sutradhar, 2021). RNN ve LSTM tabanlı bir çalışmada RNN ve LSTM tabanlı çalışmasında yüksek doğruluk oranı (%83.88) elde edilmesine karşın overtfitting durumu yaşandığı ve overfittingten arındırılmaya ihtiyaç olduğu vurgulanmıştır. (P.S. Sisodia, 2022)

Word2Vec, FastText ve GloVe tabanlı RNN LSTM modeli çalışmasında modelin doğruluğunun yüksek olmasına rağmen manipülasyonlara açık olduğu, ancak alım satımın kolaylaştırıldığı belirtilmiştir. (Duvar, 2020) MLP ile yaptığı çalışmada yüksek doğruluğa ulaşıldığı ancak modelin daha fazla veri ve öznitelikle desteklenmeye ihtiyaç duyduğu ifade edilmiştir. (Z.H Kilimci, 2021)

ARIMA, AR ve ARMA algoritmalarıyla desteklenen çalışmasında yüksek doğruluk ve tahmin oranına rağmen yer yer overfittinglere rastlandığı ve bu durumun modelin bilimsel doğruluğunu şüpheye düşürdüğü belirtilmiştir. (Rao, 2022) RNN ve CNN karşılaştırmalı çalışmasında RNN'nin tahminlemede daha iyi olduğu ancak her iki model arasında belirgin bir performans farkı olmadığı ifade edilmiştir.(A.Aaryan, 2022)

Relu, MLP, LSTM ve diğer metodolojilerden oluşan hibrit model çalışmasında ölçeklemenin iyi olmasına rağmen verilerin gelişmiş normalizasyona tabi tutulmaya ihtiyaç duyduğu belirtilmiştir.(A. Tsantekidis, 2017) XGBoost, LR, EMA, SMA ve diğer hibrit metotlardan oluşan çalışmasında ilgili modelin çeşitli düzeylerde tahmin performansının iyi olmasına rağmen çok fazla eğitim verisine ihtiyaç duyduğu ifade edilmiştir. (M. Biswas, 2021) RNN ve LSTM ile çok iyi tahmin sonuçları alındığı ancak modelin çoklu katmanlara ihtiyaç duyduğu belirtilmiştir. (M. Nabipour, 2020)

Çekişmeli üretici ağ ile desteklenen çalışmasında LSTM'nin daha doğru sonuç verdiği ancak optimum eğitim sağlanamadığı ifade edilmiştir (K. J, 2021) PSO-LSTM ile desteklenen modelinde oldukça iyi sonuçlar elde edildiği ancak modelin daha iyi bir temelde geliştirilme ihtiyacı olduğu vurgulanmıştır. (D, 2020)

Başka bir çalışmada ise bu modelle birlikte bir başka modelin kullanılarak oluşturulan modelin performans ve tahminleme açısından daha bilimsel ve geçerli hale getirildiği ifade edilmiştir. (Qi-Qiao He, 2022) Mao'nun Merton-LSTM temelli çalışmasında yüksek doğruluğa rağmen uygulama zorlukları olduğu (Weifang Mao, 2023)

Sosyal analizle kullanıcı davranışını ölçerek alım satım piyasa fiyatlamasını belirlediği çalışmasında model doğruluğunun yüksek olmasına rağmen karmaşıklığın yüksek olması, çalışmanın biraz daha geliştirilme ihtiyacını ortaya çıkardığı belirtilmiştir. (C. Vaca, 2020) EMD algoritmasının kullanıldığı çalışmasında modelin kendi kendine öğrenme, organize etme ve bilgi işlem yeteneğinin yüksek olduğu ancak ek faktörlere bağımlılık duyduğu ve bu bağımlılığın modelin en zayıf noktası olduğu belirtilmiştir. (Yong'an Zhang, 2020)

DMLP, CNN, SVM ve RF tabanlı çalışmasında RF'nin avantajlarına rağmen genellikle büyük cirolu hisse senetlerinde çalışmanın zor olduğu ifade edilmiştir. (Ho, 1995) Breiman tarafından önerilen model, parametrik ve doğrusal olmayan bir modeldir. Bu model, her zaman yakınsadığı için aşırı uyum sorununu ortadan kaldırır (Breiman, 2001). RF'nin avantajları nedeniyle, genellikle hisse senedi tahmini için kullanılır. Bu sayede performans yönüyle güçlü olan bu çalışma büyük cirolu hisse senetlerinde çalışması oldukça zordur. (Yilin Ma, 2020)

DMLP katmalı CNN RNN ve LSTM ağları temelli çalışmasında büyük veride çalışmanın kolay olduğu ancak ilişki kaybı riski taşıdığı belirtilmiştir (A M Özbayoğlu, 2020) Nakayama'nın görüntü tabanlı çalışmasında verilerin önce görüntüye çevrildiği ve ardından bu görüntülere CNN ve LR uygulandığı ifade edilmiştir. (A Nakayama, 2019)

LSTM tabanlı çalışmasında varyasyon tespiti daha iyi olmasına rağmen boyut küçültmeye ihtiyaç duymayan bir model elde edildiği ancak doğruluk oranının düşük olduğu belirtilmiştir. (D.M.O Nelson, 2017) Çok katmanlı ileri beslemeli sinir ağı temelli çalışmasında performans kalitesinin iyi olmasına rağmen sinyal kalitesinden etkilendiği ifade edilmiştir. (W. Long, 2019)

2 boyutlu verilere çevrilen 1 boyutlu veriler üzerinde CNN ağları oluşturduğu çalışmasında yüksek kesinlik ve doğruluk elde edildiği ancak kullanılan algoritmanın en düşük ve en yüksek ETF'leri bulamadığı ve optimize edilmeye ihtiyaç duyduğu belirtilmiştir. Bu çalışma aynı zamanda temel alınan iki çalışmadan biridir (M. U. Gudelek, 2017) RNN-LSTM tabanlı çalışmasında daha tutarlı sonuçlar elde edildiği ancak daha fazla kategorisel veriyle çalışmaya ihtiyaç duyulduğu belirtilmiştir. (T. Sanboon, 2019).

III. KULLANILAN YÖNTEMLER (METODOLOJİ)

Bu çalışmada bir LSTM alt uygulaması olan LeNet 5'in hiperparametresinin optimizasyonu için PSO optimizasyon algoritmasını kullandık. LeNet5 modelinin amacı IMAGENET veritabanı ile eğitilmiş imzaların doğrulanmasıdır. bu nedenle LeNet5 modelinin hiperparametrelerini alım satım emirleri almak için optimize ettik. Sunulan yöntemin şeması aşağıda sunulmuştur.

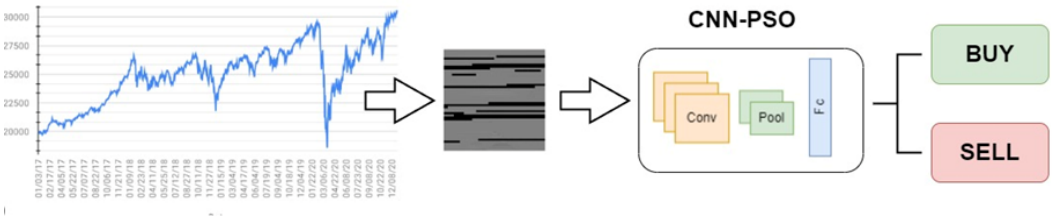

Şekil 1: IMAGENET çalışma şeması

Bu şemaya göre grafik olarak gösterilen 1- boyutlu hisse senedi verileri, 2-boyutlu görüntülere çevrilmiş ve üzerinde CNN-PSO algoritması uygulanarak oluşturulan hiperparametreler aracılığıyla al-sat emirlerine çevrilmiştir. Model, hisse senedine ait ilgili görüntü desenini gördüğünde; görüntü desenine karşılık gelen komutu (al ya da sat) yerine getirecektir. Bu sayede; hisse senedi işlemlerinde insan faktörü en aza indirilmiştir. Bu modelin oluşumunda kullanılan veriler üzerinde verilerin düzenlenmesi, etiketleme, genel görüntü matrisi oluşturma, görüntü matrisine çevirme, görüntüler üzerinde LeNet-5 tabanlı sinir ağlarının uygulanması, oluşturulan modelin Parçacık Sürü Optimizasyonu(PSO) ile optimize edilmesi sonucu model geliştirilmiştir. Geliştirilen model ise devreye alınarak, her hisse senedi için kendine özgü performans ve değerlendirme metrikleri elde edilmiştir. Bu metriklerden yola çıkarak model hakkında bir hükme varılabilir.

A. Cnn (Evrişimli Sinir Ağları)

Evrişimli Sinir Ağı (CNN), görüntü ve görsel veri işleme için tasarlanmış bir tür sinir ağı mimarisidir. Özellikle görüntü tanıma, nesne algılama ve görüntü sınıflandırma gibi görevlerde etkilidir. CNN'ler, giriş verilerinden özelliklerin mekânsal hiyerarşilerini otomatik ve uyarlanabilir bir şekilde öğrenmek için evrişimli katmanları kullanır.

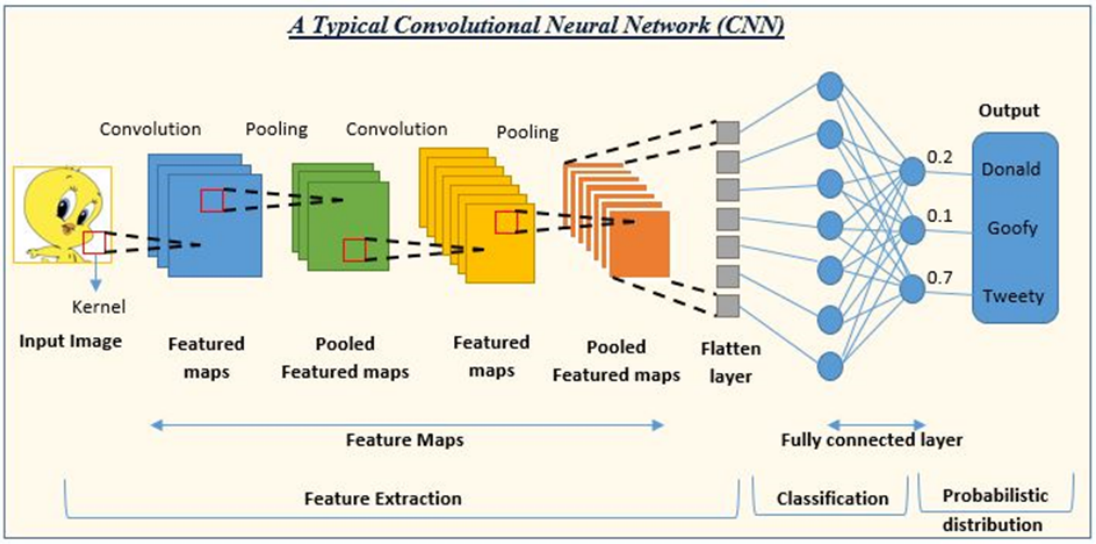

Şekil 2: CNN Çalışma Şeması

Evrişimsel Katmanlar: Bu katmanlar, özellikleri çıkarmak için filtreleri veya çekirdekleri kullanarak giriş verilerine evrişim işlemlerini uygular. Evrişim, ağın kenarlar, dokular ve daha karmaşık yapılar gibi kalıpları tanımasına yardımcı olur.

$$S(i,j) = (I \times K)(i,j) = \Sigma m \Sigma n\, I(m,n).K(i-m, j-n). \quad (1)$$

S(i,j): (i,j) konumundaki evrişim işleminin çıktısı

I(m,n): (m,n) konumundaki giriş görüntüsü pikseli

K(i-m, j-n): (i-m, j-n) konumundaki evrişim çekirdeği (filtre)

Havuzlama Katmanları: Havuzlama katmanları, giriş verilerinin uzamsal boyutlarını alt örnekleyerek hesaplama karmaşıklığını azaltır ve önemli özellikleri korur. Yaygın havuzlama işlemleri, bir bölgedeki maksimum değeri koruyan maksimum havuzlamayı ve ortalamayı hesaplayan ortalama havuzlamayı içerir.

$$O_{ij} = max_{m,n} I_{(i+m)(j+n)} \quad (2)$$

Tamamen Bağlantılı Katmanlar: Birden fazla evrişim ve havuzlama katmanından sonra, sinir ağındaki üst düzey mantık, tamamen bağlı katmanlar tarafından yakalanır. Bu katmanlar tahminlerde bulunmak için öğrenilen özellikleri kullanır.

$$P(y = j \mid X) = \frac{e^{(Wj.X+bj)}}{\sum_k e^{(Wk.X+bk)}} \quad (3)$$

Burada:

- P(y=j|X), j sınıfının olasılığını
- Wj ve bj, sınıf j için ağırlık ve bias vektörlerini
- X, özellik vektörünü temsil eder

Eğitim ve Ağırlık Güncelleme

- Ağın eğitimi, geriye yayılım algoritması kullanılarak yapılır. Ağırlıkların güncellenmesi için gradyan iniş yöntemi kullanılır:
- $W_{new} = W_{old} - \alpha \nabla J(W_{old})$

  (4)
- Burada:
- Wnew , güncellenmiş ağırlıkları
- Wold , eski ağırlıkları
- α∇J(Wold) ise maliyet fonksiyonunun gradyanını temsil eder

Özetle CNN'ler, hiyerarşik özellikleri otomatik olarak öğrenmek için evrişimli işlemlerden yararlanan, görsel verileri işlemek ve analiz etmek için güçlü sinir ağı mimarileridir. Formül, CNN'lerde özellik çıkarma için temel bir süreç olan temel evrişim işlemini göstermektedir.

B. Lstm (Long Short-Term Memory/Uzun Kısa Süreli Bellek)

Uzun Kısa Süreli Bellek (LSTM), sıralı verilerdeki uzun vadeli bağımlılıkları yakalamanın zorluklarının üstesinden gelmek için tasarlanmış bir tür tekrarlayan sinir ağıdır (RNN). LSTM'ler, bağlamsal bilgilerin uzun süreler boyunca korunmasının çok önemli olduğu zaman serisi verileri ve doğal dil işlemeyi içeren görevlerde özellikle etkilidir.

Bir LSTM ağı, her biri üç önemli kapıyla donatılmış bellek hücrelerinden oluşur: Unutma Kapısı, Giriş Kapısı ve Çıkış Kapısı. Bu kapılar, hücrenin içine ve dışına bilgi akışını kontrol ederek LSTM'lerin zaman içinde bilgiyi seçici olarak depolamasına, almasına ve güncellemesine olanak tanır.

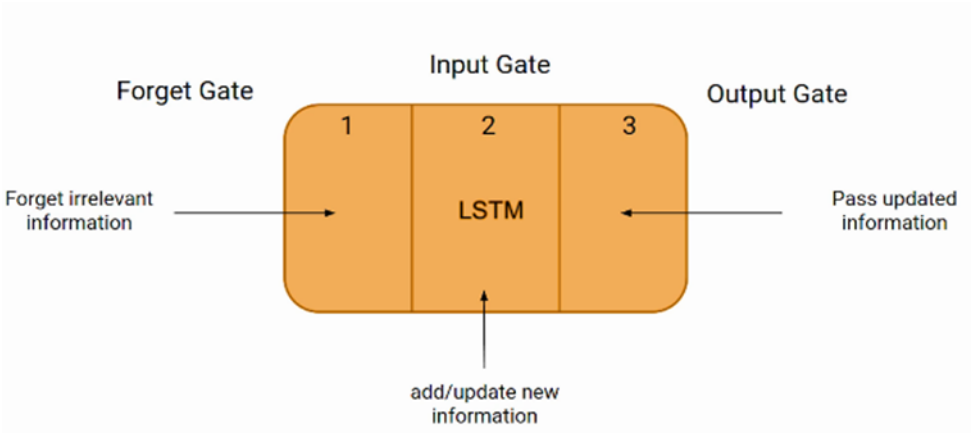

Şekil 3: LSTM Çalışma Şeması

Unutma Kapısı

- Önceki hücre durumu Ct-1'in ne kadarının saklanması veya unutulması gerektiğini belirler. Sigmoid aktivasyon fonksiyonu tarafından yönetilir.
- $f_t = \sigma(W_f.[h_{t-1},X_t] + b_f)$ (5)

Burada

- ft, unutma kapısı çıkışı
- Wf ağırlık kapısı için ağırlık matrisi
- $[h_{t-1},X_t]$, önceki gizli durum h_{t-1} ile mevcut giriş x_t
- b_f ise unutma kapısının bias vektörünü temsil eder.

Giriş Kapısı

- Giriş Kapısı, C_t hücre durumuna hangi yeni bilginin eklenmesi gerektiğini belirler. Giriş kapısı; i_t giriş kapısı çıkışı ve C_t aday hücre durumu olmak üzere iki bileşenden oluşur
- $i_t = \sigma(W_i .[h_{t-1}, X_t] + b_i)$ (6)
- $C_t = tanh(W_c .[h_{t-1}, X_t] + b_c)$ (7)
- Burada
- it, giriş kapısının çıktısı
- Wi ve Wc giriş ve aday hücrenin ağırlık matrisleri
- Tanh, hiperbolik tanjant aktivasyon fonksiyonudur.

Hücre Durumunun Güncellenmesi

- Ct hücre durumu, ft unutma kapısına, it giriş kapısına ve Ĉt aday hücre durumuna göre güncellenir.
- Ct= ft. Ct-1 + it. Ĉt (8)
- Bu denklem, hücre durumunun zamana göre nasıl gelişeceğini yönetir ve LSTM'in dinamik bir hafızayı korumasını sağlar.

Çıkış Kapısı

- Çıkış Kapısı, güncellenmiş hücre durumu Ct'ye dayalı olarak bir sonraki gizli durumu (ht) belirler. Çıkış kapısı Ot ve hücre durumunun hiperbolik tanjantından oluşur. Hücredeki bilgileri kullanarak çıktı üretir.
- ot = σ(Wo .[ht-1,Xt] + bo) (9)
- ht= ot . tanh(Ct) (10)

Burada

- ot, çıkış kapısı çıktısı
- Wo, çıkış kapısının ağırlık matrisi
- σ ise sigmoid aktivasyon fonksiyonudur.

Özetle, LSTM ağları, geleneksel RNN'lerdeki kaybolan ve patlayan gradyan sorunlarını ele almak ve uzun vadeli bağımlılıkları etkili bir şekilde yakalamalarına ve yaymalarına olanak sağlamak üzere tasarlanmıştır. Unutma, giriş ve çıkış kapılarının karmaşık etkileşimi ve hücre durumu güncellemesi, LSTM'lerin gelişmiş bellek tutma özelliğiyle sıralı verileri modellemesine olanak tanır. Mimarinin esnekliği ve geçici olarak uzaktaki bilgilerden öğrenme yeteneği, LSTM'leri çeşitli uygulamalarda güçlü bir araç haline getirir.

C. LeNeT-5

LeNet-5, Yann LeCun ve işbirlikçileri tarafından 1998 yılında tasarlanan öncü bir evrişimli sinir ağı (CNN) mimarisidir. Öncelikle el yazısı rakam tanıma görevleri için geliştirildi ve derin öğrenmenin ilerlemesinde çok önemli bir rol oynadı. LeNet-5, evrişimli katmanlar, alt örnekleme katmanları ve tamamen bağlantılı katmanlar içeren benzersiz mimarisiyle karakterize edilir.

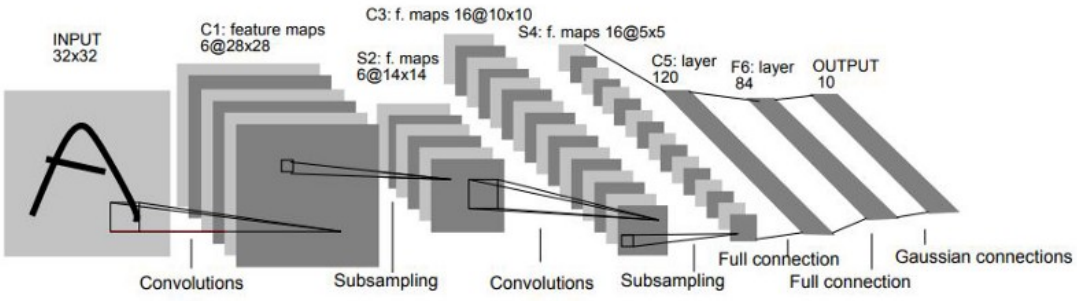

Şekil 4: LeNet-5 Mimarisi

1. Evrişimsel Katmanlar

LeNet-5'in ilk iki katmanı, giriş görüntüsünden mekânsal hiyerarşileri ve özellikleri çıkarmak için tasarlanmış evrişimli katmanlardır. Evrişim işlemi şu şekilde tanımlanır:

$$S(i,j) = (I \times K)(i,j) = \Sigma m \Sigma n\, K(m,n).I(i+m, j+n) \qquad (11)$$

Burada:

- S(i,j) evrişim sonucunu,

- I giriş resmini,
- K evrişim çekirdeği ya da filtreyi temsil eder.

LeNet-5'te bu evrişimli katmanları hiperbolik tanjant (tanh) aktivasyon fonksiyonu takip eder.

2. Alt Örnekleme Katmanları

LeNet-5'teki sonraki iki katman, genellikle havuzlama katmanları olarak adlandırılan alt örnekleme katmanlarıdır. Bu katmanlar, önemli özellikleri korurken mekânsal boyutları ve hesaplama karmaşıklığını azaltmayı amaçlamaktadır. Havuzlama işlemi, genellikle maksimum havuzlama, matematiksel olarak şu şekilde ifade edilir:

$$O_{ij}=max_{m.n}\, I_{(i+m)(j+n)} \quad (12)$$

- Burada

O_{ij} havuzlama sonucunu,

I ise giriş özellik haritasını temsil etmektedir.

3. Tamamen Bağlı Katmanlar

Evrişim ve alt örnekleme katmanlarından sonra LeNet-5, tamamen bağlantılı üç katman içerir. Bu katmanlar, önceki katmanlardan çıkarılan özelliklere dayanarak üst düzey akıl yürütme ve karar verme işleminden sorumludur. Tamamen bağlantılı katman işlemi, ağırlıklı bir toplam ve aktivasyon fonksiyonunu içerir:

$$y_k=\sigma(\sum_i W_{ki}x_i+b_k) \quad (13)$$

Burada

- y_k: k. nörona ait tamamen bağlı katman çıktısı
- W_{ki}: i'inci giriş nöronunu k'inci çıkış nöronuna bağlayan ağırlığı temsil eder,
- X_i: i. Nöron girdisi
- B_k: bias
- σ: ise aktivasyon fonksiyonunu temsil eder

4. LeNet-5 Mimarisi

LeNet-5'in genel mimarisi şu şekilde özetlenebilir:

- Giriş Katmanı: 32x32 piksel boyutunda gri tonlamalı bir görüntüyü kabul eder.
- Evrişimsel Katman C1: 5x5 çekirdek ve tanh aktivasyonuyla evrişimi uygular.
- Alt Örnekleme Katmanı S2: 2x2 pencere üzerinde maksimum havuzlama gerçekleştirir.
- Evrişimsel Katman C3: 5x5 çekirdek ve tanh aktivasyonuyla ikinci bir evrişim uygular.
- Alt Örnekleme Katmanı S4: Başka bir maksimum havuzlama katmanı.
- Tamamen Bağlı Katman C5: Tanh aktivasyonu ile S4 çıkışına bağlanır.
- Tam Bağlantılı Katman F6: Tanh aktivasyonuna sahip ikinci bir tam bağlantılı katman.
- Çıkış Katmanı: Nihai sınıflandırma sonucunu üretir.

Sonuç olarak, LeNet-5, CNN'lerin görüntü tanıma görevleri için etkinliğini belirlemede çok önemli bir rol oynadı. Evrişim, alt örnekleme ve tamamen bağlantılı katmanları içeren mimari ilkeleri, derin öğrenmedeki sonraki gelişmeleri etkilemiştir. İlgili formüllerle birlikte yapılan ayrıntılı açıklama, LeNet-5'in işlevselliğini destekleyen matematiksel işlemlere ilişkin bilgi sağlar ve sinir ağı mimarileri tarihindeki önemine katkıda bulunur.

D. Relu

Düzeltilmiş Doğrusal Birim (ReLU), basitliği ve etkinliği nedeniyle yaygın olarak kullanılan, sinir ağlarında popüler bir aktivasyon işlevidir. Kaybolan gradyan sorunu gibi sorunları çözmek için tanıtılan ReLU, çeşitli derin öğrenme mimarilerinde temel bir bileşen haline geldi. Bu açıklamada ReLU'nun özellikleri, avantajları ve matematiksel formülasyonları ayrıntılı olarak ele alınacaktır.

1. Tanım ve Özellikler

ReLU aktivasyonu şu şekilde tanımlanır:

$$f(x)=max(0,x) \tag{14}$$

Burada x, fonksiyonun girişidir. Daha basit bir ifadeyle, eğer x girişi pozitifse fonksiyon x değerini döndürür, x negatifse sıfır değerini döndürür. ReLU işlevi ağa doğrusal olmamayı getirerek verilerdeki karmaşık kalıpları ve ilişkileri öğrenmesine olanak tanır.

ReLU'nun en önemli avantajlarından biri basitliği ve hesaplama verimliliğidir. Sigmoid veya hiperbolik tanjant gibi geleneksel aktivasyon fonksiyonlarının aksine ReLU, üstel sayılar gibi karmaşık matematiksel işlemleri içermez, bu da onu hesaplama açısından daha ucuz hale getirir.

2. Matematiksel Formülasyon

ReLU işlevi matematiksel olarak şu şekilde tanımlanır:

- $f(x)=max(0,x)$ (15)

Bu aynı zamanda parçalı bir fonksiyonla da ifade edilebilir:

- x & text{eğer } x > 0
- 0 & text{aksi takdirde}
- end{durumlar}
- Burada (f(x)), bir (x) girişi için ReLU aktivasyon fonksiyonunun çıkışını temsil eder.

3. ReLU'nun Avantajları

- -Doğrusal olmama:ReLU, modele doğrusal olmamayı getirerek verilerdeki karmaşık ilişkileri öğrenmesine ve bunlara yaklaşmasına olanak tanır.
- Kaybolan Gradyan'ın Azaltılması: ReLU, geri yayılım sırasında gradyanlar çok küçük hale geldiğinde ortaya çıkan kaybolan gradyan sorununun azaltılmasına yardımcı olur. Bu, derin sinir ağlarının daha etkili eğitimini kolaylaştırır.
- Hesaplama Verimliliği:ReLU işlevinin basitliği, daha hızlı eğitim sürelerine yol açarak diğer bazı etkinleştirme işlevleriyle karşılaştırıldığında hesaplama açısından verimli olmasını sağlar.

4. ReLU'nun çeşitleri

Zamanla, sınırlamalarını gidermek için ReLU'nun çeşitli varyasyonları önerildi. İki yaygın varyant şunlardır:

- Sızdıran ReLU:Negatif giriş değerleri için küçük, pozitif bir eğime izin vererek nöronların tamamen devre dışı kalmasını önler.

$$f(x) = max(alpha\ x, x) \tag{16}$$

- Parametrik ReLU (PReLU):Negatif giriş değerlerinin eğimini belirlemek için öğrenilebilir bir parametre sunar ve eğitim sırasında uyarlanabilirliği sağlar.

$$f(x) = max(alpha\ x, x) \tag{17}$$

ReLU, basitliği, doğrusal olmaması ve yok olan gradyan sorunu gibi yaygın zorlukların azaltılmasındaki etkinliği nedeniyle derin öğrenmede bir mihenk taşı haline geldi. Matematiksel formülü çeşitli sinir ağı mimarilerinin başarısında etkili olduğu kanıtlanmış bir eşileme işlemini temsil eder. Popülaritesine rağmen, eğitim sırasında nöronların etkisiz hale gelebildiği "ölen ReLU" sorunu gibi çeşitlerinin ve potansiyel sorunlarının farkında olmak önemlidir. Sinir ağlarının herhangi bir bileşeninde olduğu gibi, ReLU ve türevleri de dahil olmak üzere aktivasyon fonksiyonunun seçimi, eldeki problemin spesifik özelliklerine dayanmalıdır.

E. Softmax Layer

Softmax katmanı, özellikle çok sınıflı sınıflandırma problemleri için tasarlanmış, sinir ağı mimarilerinde önemli bir bileşendir. Çıkış katmanı olarak hizmet veren softmax işlevi, rastgele gerçek değerlerden oluşan bir vektörü, her sınıfa olasılıklar atayarak bir olasılık dağılımına dönüştürür. Softmax katmanının temel amacı, genellikle logitler olarak adlandırılan ham model çıktılarını, toplamı bir olan normalleştirilmiş olasılıklara dönüştürmektir.

Matematiksel olarak softmax fonksiyonu şu şekilde tanımlanır:

$$P(y_i) = \frac{e^{z_i}}{\sum_{J=1}^{K} e^{z_j}} \tag{18}$$

Burada

- P(yi) i'inci sınıfın olasılığıdır,
- zi, i. sınıfın logit veya ham puanını temsil eder,
- K toplam sınıf sayısıdır.

Softmax işlevi logitleri üstelleştirerek pozitif değerler sağlar ve ardından üstelleştirilmiş her değeri tüm üstelleştirilmiş değerlerin toplamına bölerek bunları normalleştirir. Bu normalleştirme, ortaya çıkan olasılıkların toplamının bire eşit olmasını garanti eder ve bunları sınıf olasılıkları olarak yorumlanabilir hale getirir.

Softmax katmanı, görüntü sınıflandırma, doğal dil işleme ve diğer çeşitli sınıflandırma problemleri gibi görevler için sinir ağlarının son katmanında yaygın olarak kullanılır. Yalnızca sınıflar arasında bir olasılık dağılımı sağlamakla kalmaz, aynı zamanda gradyan iniş optimizasyonu sırasında geri yayılım için çok önemli olan farklılaştırılabilir doğası sayesinde verimli eğitimi kolaylaştırır. Softmax katmanı, sinir ağı tahminlerini eyleme geçirilebilir ve yorumlanabilir olasılıklara dönüştürmede önemli bir rol oynayarak çeşitli uygulamalarda karar vermeye yardımcı olur.

F. Optimizasyon Algoritmaları

Optimizasyon algoritmaları, çeşitli makine öğrenimi ve derin öğrenme süreçlerinin omurgasını oluşturur; modellerin iyileştirilmesinde, performansın artırılmasında ve karmaşık sorunlara en uygun çözümlerin bulunmasında önemli bir rol oynar. Optimizasyon algoritmaları özünde, bir amaç fonksiyonunu en aza indirmek veya en üst düzeye çıkarmak için bir modelin veya sistemin parametrelerini yinelemeli olarak ayarlamayı amaçlar. Bu kapsamlı genel bakış, optimizasyon algoritmalarının temel kavramlarını, türlerini ve uygulamalarını ele alacak ve bunların yapay zekâ alanındaki önemine ışık tutacaktır.

Temel Kavramlar

Optimizasyon algoritmalarının kalbinde, bir dizi uygulanabilir çözüm arasından mümkün olan en iyi çözümü bulmayı içeren temel optimizasyon kavramı yatmaktadır. Maliyet fonksiyonu veya kayıp fonksiyonu olarak da bilinen amaç fonksiyonu, bir çözümün kalitesini ölçer. Optimizasyon algoritmaları, minimizasyon problemlerinde bu amaç fonksiyonunu en aza indirmek veya maksimizasyon

problemlerinde maksimize etmek için bir modelin parametrelerini yinelemeli olarak güncellemeyi amaçlamaktadır.

Optimizasyon Algoritması Türleri

Gradyan İnişi: Temel optimizasyon algoritmalarından biri gradyan inişidir. Amaç fonksiyonundaki en dik düşüşe doğru yinelemeli olarak hareket ederek çalışır. Temel fikir, parametrelere göre amaç fonksiyonunun gradyanının (türevinin) hesaplanmasını ve parametrelerin gradyanın ters yönünde ayarlanmasını içerir.

Stokastik Gradyan İniş (SGD): Gradyan inişin bir çeşidi olan SGD, her yineleme için eğitim verilerinin bir alt kümesini rastgele seçerek hesaplama açısından daha verimli ve büyük veri kümeleri için uygun hale getirir.

Adam: Adam (Uyarlanabilir Moment Tahmini), momentum optimizasyonu ve RMSprop'tan gelen fikirleri birleştiren uyarlanabilir bir optimizasyon algoritmasıdır. Her parametre için öğrenme oranlarını dinamik olarak ayarlayarak daha hızlı yakınsama ve gelişmiş performans sağlar.

Genetik Algoritmalar: Biyolojik evrimden ilham alan genetik algoritmalar, en uygun çözümleri bulmak için doğal seçilim sürecini simüle eden optimizasyon teknikleridir. Mutasyon ve çapraz geçiş gibi süreçlerle nesiller boyunca gelişen aday çözüm popülasyonunu sürdürerek çalışırlar.

Uygulamalar

Makine Öğrenimi: Optimizasyon algoritmaları, derin sinir ağlarının eğitimi gibi makine öğrenimi görevlerinde yaygın olarak kullanılır. Adam ve RMSprop dahil olmak üzere gradyan iniş varyantları, eğitim kaybını en aza indirmek amacıyla model parametrelerini güncellemek için yaygın olarak kullanılır.

Yöneylem Araştırması: Yöneylem araştırmasında, kaynak tahsisi, tedarik zinciri yönetimi ve planlama gibi karmaşık karar verme sorunlarına en uygun çözümleri bulmak için optimizasyon algoritmalarından yararlanılır.

Mühendislik Tasarımı: Optimizasyon, mühendislik tasarımında önemli bir rol oynar ve mühendislerin sistemler, yapılar veya süreçler için en verimli konfigürasyonları bulmalarına yardımcı olur. Uygulamalar, uçak kanatlarının tasarlanmasından binalardaki enerji tüketiminin optimize edilmesine kadar uzanır.

Zorluklar ve Dikkat Edilmesi Gerekenler

Optimizasyon algoritmaları, etkinliklerine rağmen optimal olmayan çözümlere yakınsama, hiper parametrelere duyarlılık ve hesaplama yoğunluğu gibi zorluklarla karşı karşıyadır. Uygun optimizasyon algoritmalarının seçilmesi ve parametrelerinin ayarlanması, optimum sonuçlara ulaşmanın kritik yönleridir.

Optimizasyon algoritmaları, yapay zekâ, makine öğrenimi ve ötesindeki çok çeşitli uygulamaların başarısının ayrılmaz bir parçasıdır. Teknoloji ilerlemeye devam ettikçe, yeni algoritmaların geliştirilmesi ve mevcut algoritmaların iyileştirilmesi, karmaşık sistemlerin optimize edilmesinde, verimliliğin arttırılmasında ve bilimsel ve mühendislik çalışmalarının ilerletilmesinde ilerlemeyi daha da artıracaktır. Optimizasyon algoritmalarının ilkelerini ve uygulamalarını anlamak, bu alandaki uygulayıcılar için çok önemlidir ve onlara model geliştirme ve çözüm optimizasyonunun karmaşık ortamında gezinme olanağı sağlar.

1. Adam Optimizer

Adam (Uyarlanabilir Moment Tahmini), derin sinir ağlarının eğitiminde yaygın olarak kullanılan popüler bir optimizasyon algoritmasıdır. D. P. Kingma ve J. Ba tarafından 2014 yılında tanıtılan Adam, diğer iki optimizasyon tekniğinin faydalarını birleştiriyor: momentum optimizasyonu ve RMSprop. Momentum benzeri tekniklerle birlikte her parametre için uyarlanabilir öğrenme oranları, karmaşık, yüksek boyutlu modellerin optimize edilmesindeki verimliliğine ve etkinliğine katkıda bulunur. Bu ayrıntılı incelemede Adam optimize edicinin temel bileşenlerini, matematiksel formülasyonlarını ve avantajlarını inceleyeceğiz.

a. Anahtar bileşenler

b. Öğrenme oranı

Öğrenme oranı, optimizasyon algoritmalarında her yinelemede adım boyutunu belirleyen çok önemli bir hiper parametredir. Adam, her bir parametrenin öğrenme oranlarını geçmiş değişimlerine göre dinamik olarak ayarlayarak daha az sıklıkta güncellenen parametreler için daha agresif güncellemelere olanak tanır.

c. İtme

Momentum optimizasyonundan ilham alan Adam, salınımları azaltmak ve yakınsamayı hızlandırmak için momentum kavramını birleştiriyor. Geçmiş gradyanların üstel olarak azalan hareketli ortalamasını koruyarak algoritmanın önceki güncellemelerin yönü hakkındaki bilgileri saklamasına olanak tanır.

d. RMSprop

Adam aynı zamanda kareli gradyanların hareketli ortalamasının korunmasını içeren RMSprop'un fikirlerini de entegre ediyor. Bu hareketli ortalama, her parametre için öğrenme oranlarını ayrı ayrı ölçeklendirerek sık sık güncellenen parametrelerin daha küçük güncellemeler almasını sağlayarak optimizasyon sürecini dengeler.

Matematiksel Formülasyonlar:

- Adam optimizer parametreleri günceller
- Aşağıdaki formüllere dayanan bir modelin θ'sı:
- $Mt = \beta 1 \,.\, mt - 1 + (1 - \beta 1).\nabla Jt\,(\theta)$ (19)
- $Vt = \beta 2 \,.\, vt - 1 + (1 - \beta 2\,).\left(\nabla Jt\,(\theta)\right)^2$ (20)
- $\hat{m}t = \frac{m_t}{1-\beta_1^{\,t}}$ (21)
- $\hat{v}t = \frac{v_t}{1-\beta_2^{\,t}}$ (22)
- $\theta t + 1 = \theta_t - \alpha \,.\, \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \varepsilon}}$ (23)
- θ: Model Parametreleri
- α: Öğrenme Oranı
- J_t: t zamanındaki parametrelerin objektif fonksiyonuna göre gradyanıdır.
- β_1 ve β_2: Birinci ve ikinci anlar için üstel bozulma oranları
- m_t: ilk an (gradyanların ortalaması)
- v_t: ikinci an (kare gradyanların ortalaması)
- t: zaman
- $\hat{m}_t$: düzeltilmiş ilk an
- $\hat{v}_t$: düzeltilmiş ikinci an

- ε: sayısal kararlılık için paydanın altına eklenen küçük bir sabittir (genellikle 10^{-8})

e. Avantajları ve Hususları

f. Uyarlanabilir Öğrenme Oranları

Adam'ın başlıca avantajlarından biri uyarlanabilir öğrenme oranlarıdır. Adam, her bir parametre için bireysel öğrenme oranlarını koruyarak, sık güncellenmeyen parametreler için agresif güncellemeler ve sık güncellenen parametreler için muhafazakâr güncellemeler yapabilir ve bu da verimli yakınsama sağlayabilir.

g. Verimli Optimizasyon

Adam genellikle daha hızlı yakınsar ve stokastik gradyan iniş gibi geleneksel optimizasyon algoritmalarına kıyasla hiperparametrelerin daha az ayarlanmasını gerektirir. Uyarlanabilir öğrenme oranları ve momentum benzeri teknikleri, çeşitli sinir ağı mimarileri ve veri kümeleri genelinde sağlamlığına katkıda bulunur.

h. Hususlar

Adam güçlü ve yaygın olarak kullanılan bir optimize edici olsa da, tüm senaryolarda her zaman diğer optimize edicilerden daha iyi performans göstermeyebilir. Dikkate alınması gereken bazı noktalar arasında, özellikle eğitimin ilk aşamalarında hiperparametre seçimlerine ve potansiyel salınımlara karşı hassasiyet yer alır.

Adam, çeşitli modeller için verimli ve uyarlanabilir bir optimizasyon yaklaşımı sunarak, derin öğrenme uygulayıcılarının araç kutusunda temel bir öğe haline geldi. Momentum ve RMSprop tekniklerinin ve uyarlanabilir öğrenme oranlarının birleşimi, karmaşık sinir ağlarının eğitimindeki çok yönlülüğüne ve etkinliğine katkıda bulunur. Adam optimize edicinin matematiksel temellerini ve dikkate alınması gereken hususları anlamak, uygulayıcılara optimizasyon sürecinde bilinçli kararlar alırken onun avantajlarından yararlanma gücü verir.

2. Pso (Parçacık Sürü Optimizasyonu)

Parçacık Sürü Optimizasyonu (PSO), doğadaki sürülerin, sürülerin veya okulların kolektif davranışlarından ilham alan, doğadan ilham alan bir optimizasyon

algoritmasıdır. 1995 yılında James Kennedy ve Russell Eberhart tarafından tanıtılan PSO, basitliği, etkinliği ve karmaşık arama uzaylarında çözüm bulma yeteneği nedeniyle popülerlik kazanmıştır. Bu kapsamlı araştırma, PSO'nun temel kavramlarını, mekanizmalarını ve matematiksel formülasyonlarını derinlemesine inceleyecek ve optimizasyon problemlerinin çözümünde uygulanmasına ışık tutacaktır.

a. Temel Kavramlar

b. Parçacık Sürüsü

PSO'nun arkasındaki temel fikir, potansiyel çözümlerden oluşan bir popülasyonu parçacık sürüsü olarak modellemektir. Sürüdeki her parçacık, optimizasyon problemine potansiyel bir çözümü temsil eder ve sürünün kolektif hareketi, optimum çözüm arayışına rehberlik eder. Parçacıklar bireysel ve kolektif deneyimlerine göre iletişim kurar ve konumlarını ayarlar.

c. Konum ve Hız

Her parçacığın çözüm uzayında bir konumu ve hızı vardır. Konum potansiyel bir çözümü temsil eder ve hız, hareketin yönünü ve büyüklüğünü belirler. Konum ve hızın birleşimi, parçacıkların çözüm uzayını dinamik olarak keşfetmesine olanak tanır.

d. Fitness fonksiyonu

Optimizasyon problemi, çözümün kalitesini değerlendiren bir uygunluk fonksiyonu ile tanımlanır. PSO'nun amacı, uygunluk fonksiyonunu en aza indiren veya en üst düzeye çıkaran optimal konumlar (çözümler) kümesini bulmaktır. Parçacıklar konumlarını kendi deneyimlerine ve sürünün deneyimlerine göre ayarlarlar.

e. Mekanizmalar

f. Başlatma

PSO, çözüm uzayı içinde rastgele konumlara ve hızlara sahip bir parçacık popülasyonunun başlatılmasıyla başlar. Her parçacığın konumu, uygunluğu veya kalitesi belirlenerek uygunluk fonksiyonu kullanılarak değerlendirilir.

g. Parçacık Hareketi

Her yinelemede parçacıklar, önceki deneyimlerine ve komşu parçacıkların deneyimlerine dayanarak hızlarını ve konumlarını ayarlar. Her parçacığın hareketi, sürüdeki herhangi bir parçacığın bulduğu kişisel en iyi konumdan (pbest) ve küresel en iyi konumdan (gbest) etkilenir.

$$velocityi\ (t+1 = \ w \times velocityi(t) \ + \ c1 \times r1 \times (pbesti - positioni(t)) \ + \ c2 \times r2 \times (gbest - \ positioni(t)) \quad (24)$$

velocity$_i$ (t+1) parçacığın t+1 zamanındaki güncellenmiş hızıdır.

$$positioni(t+1) \ = \ positioni(t) \ + \ velocityi \ (t+1) \quad (25)$$

position$_i$(t+1) parçacığın t+1 zamanındaki güncellenmiş pozisyonudur.

Bu denklemler, parçacıkların geçmiş bilgilerine ve küresel en iyi konuma göre hızlarını ve konumlarını ayarladığı PSO'nun temel güncelleme mekanizmasını temsil eder.

h. Avantajları ve Hususları

- Avantajları

Basitlik: PSO'nun uygulanması nispeten basittir ve diğer bazı optimizasyon algoritmalarına kıyasla daha az parametre gerektirir.

Çok yönlülük: PSO, sürekli, ayrık ve kombinatoryal problemler dahil olmak üzere çeşitli optimizasyon problemlerine başarıyla uygulanmıştır.

Küresel Arama: Sürünün kolektif doğası, PSO'nun geniş bir çözüm alanı keşfetmesine olanak tanır ve bu da onu karmaşık ortamlara sahip problemler için uygun hale getirir.

i. Hususlar

Erken Yakınsama: PSO, özellikle yüksek boyutlu alanlarda veya yetersiz parametre ayarıyla optimal olmayan çözümlere zamanından önce yakınlaşabilir.

Parametrelere Duyarlılık: PSO'nun performansı atalet ağırlığı, ivme sabitleri ve sürü boyutu gibi parametrelerin seçiminden etkilenir.

j. Uygulamalar

Mühendislik Tasarımı: PSO, yapısal optimizasyon, anten tasarımı ve kontrol sistemlerinde parametre ayarlama gibi mühendislik tasarım problemlerine uygulanmıştır.

Fonksiyon Optimizasyonu: PSO, karmaşık, doğrusal olmayan yapılar da dahil olmak üzere matematiksel fonksiyonları optimize etmek için yaygın olarak kullanılır.

Görüntü İşleme: PSO, görüntü bölümleme, özellik seçimi ve filtre tasarımı gibi görüntü işleme görevlerinde uygulamalar bulmuştur.

Parçacık Sürü Optimizasyonu, çeşitli optimizasyon problemlerinin çözümünde basitlik, çok yönlülük ve etkinlik sunan güçlü ve doğadan ilham alan bir optimizasyon algoritmasıdır. Kolektif zekadan yararlanma ve çözüm alanlarını keşfetme yeteneği, onu mühendislikten hesaplamalı zekaya kadar çeşitli alanlarda değerli bir araç haline getiriyor. Bununla birlikte, dikkatli parametre ayarı ve erken yakınsamaya ilişkin hususlar, tam potansiyelinden yararlanmak için gereklidir. PSO'nun mekanizmalarını

ve matematiksel temellerini anlamak, uygulayıcılara bu algoritmayı çeşitli optimizasyon zorluklarına etkili bir şekilde uygulama gücü verir.

IV. ÇALIŞMANIN SONUÇLARI

Bu bölümde, alım-satım emirleri için KERAS platformunu kullanarak oluşturduğumuz modelin performansını değerlendirdik. Model, çeşitli hisse senetlerinde, hisse senedi verilerine bağlı olarak değişen doğruluk ve kesinlikte sonuçlar elde ettik.

Modeli oluşturmak için öncelikle kullandığımız hisse senetlerini elde ettik. Daha sonra, hisse senetlerinin doğru anlaşılması ve işlem yapılabilmesi için verileri etiketledik. Verilerin etiketlenmesi, modelin performansını önemli ölçüde artırmaya yardımcı oldu.

Modeli eğitmek için Keras platformunu kullandık. Keras, makine öğrenimi ve derin öğrenme modelleri geliştirmek için kullanılan yüksek seviyeli bir Python kütüphanesidir. Keras, model oluşturma, eğitim, değerlendirme ve kullanım için kullanıcı dostu bir arayüz sağlar.

Keras'ın temel özellikleri ve avantajları:

Modüler ve Uyumluluk: Keras, bir dizi farklı backend (arka uç) ile uyumludur. TensorFlow, Theano ve Microsoft Cognitive Toolkit (CNTK) gibi popüler makine öğrenimi backend'leri ile entegre edilebilir.

Kullanım Kolaylığı: Keras, basit ve açık bir API sağlar. Bu, kullanıcıların karmaşık derin öğrenme modelleri oluşturmasını daha kolay hale getirir. Ayrıca, hızlı prototip oluşturma ve deneme yapma süreçlerini hızlandırır.

Modüler Katman Yapısı: Keras, farklı tipteki katmanları (örneğin, yoğun katmanlar, konvolüsyonel katmanlar, tekrarlayan katmanlar) birleştirmek ve uygun bir modeli oluşturmak için modüler bir yapı sunar.

Derin Öğrenme Modelleri İçin Destek: Keras, birçok farklı derin öğrenme modelini destekler, örneğin, çoklu girişli, çoklu çıkışlı, paylaşılan katmanlar ve modeli paylaşma gibi özellikleri içerir.

Hızlı Eğitim: Keras, GPU'ları kullanarak paralel hesaplamalar yapabilir, bu da derin öğrenme modellerini daha hızlı eğitmeyi mümkün kılar.

Topluluk Desteği: Keras, büyük bir açık kaynak topluluğuna sahiptir. Bu topluluk, kullanıcıların sorularına cevap verir, hataları düzeltir ve sürekli olarak kütüphaneyi günceller.

Keras, 2017'de TensorFlow projesine entegre edildi ve artık TensorFlow'un bir yüksek seviyeli API'si olarak kullanılmaktadır. Bu entegrasyon, TensorFlow'un güçlü altyapısıyla Keras'ın kullanım kolaylığını bir araya getirir, böylece kullanıcılar hem hızlı prototip oluşturabilir hem de ölçeklenebilir ve dağıtılabilir modeller geliştirebilirler.

Keras sayesinde iyi performanslı bir model oluşturulmuştur.

A. Veriseti Hakkında

Bu çalışmada, S&P 500 hisselerinden Netflix, Boeing ve Amazon hisse senetlerinin verileri kullanılmıştır. Bu veriler, tarih, düşük değer, açılış değeri, işlem hacmi, günlük en yüksek değer, kapanış değeri ve düzeltilmiş kapanış değeri olmak üzere yedi parametreden oluşmaktadır. Bu parametreler, hisse senetleri hakkında bilgi edinmek için kullanılabilir.

Verilerin tarih aralıkları aşağıdaki gibidir:

- Amazon: 15.05.1997 - 12.12.2022
- Netflix: 23.05.2002 - 12.12.2022
- Boeing: 02.01.1970 - 12.12.2022

BA

Date	Low	Open	Volume	High	Close	Adjusted Close
02-01-1970	0.9259260296821594	0.9259260296821594	634838	0.979423999786377	0.979423999786377	0.29056739807128906
05-01-1970	1.0082299709320068	1.0082299709320068	741150	1.0246909856796265	1.0164610147476196	0.30155524611473083
06-01-1970	1.0246909856796265	1.0246909856796265	1354725	1.0493830442428589	1.0288070440292358	0.30521801114082336
07-01-1970	1.020576000213623	1.0288070440292358	646988	1.0452669858932495	1.0329220294952393	0.3064388036727905
08-01-1970	1.0082299709320068	1.0329220294952393	807975	1.0370370149612427	1.020576000213623	0.3027762174606323
09-01-1970	0.9958850145339966	1.020576000213623	634838	1.0329220294952393	0.9958850145339966	0.2954510748386383
12-01-1970	0.979423999786377	0.9958850145339966	568013	1.0	0.9876539707183838	0.2930091619491577
13-01-1970	0.9341560006141663	0.9835389852523804	883913	0.9835389852523804	0.9382719993591309	0.2783587872982025
14-01-1970	0.9135800004005432	0.9341560006141663	1105650	0.9341560006141663	0.9300410151481628	0.27591708302497864
15-01-1970	0.9053500294685364	0.9259260296821594	1436738	0.9259260296821594	0.9094650149345398	0.26981258392333984
16-01-1970	0.8724279999732971	0.9094650149345398	1166400	0.9094650149345398	0.880657970905304	0.26126644015312195

Şekil 5: Boeing'e ait veriseti

AMZN

Date	Low	Open	Volume	High	Close	Adjusted Close
15-05-1997	0.09635400027036667	0.12187500298023224	1443120000	125	0.09791699796915054	0.09791699796915054
16-05-1997	0.0854170024394989	0.09843800216913223	294000000	0.09895800054073334	0.0864579975605011	0.0864579975605011
19-05-1997	0.08124999701976776	0.08802100270986557	122136000	0.08854199945926666	0.0854170024394989	0.0854170024394989
20-05-1997	0.08177100121974945	0.0864579975605011	109344000	0.08749999850988388	0.08177100121974945	0.08177100121974945
21-05-1997	0.08675000149011612	0.08177100121974945	377064000	0.08229199796915054	0.07135400176048279	0.07135400176048279
22-05-1997	0.06562499701976776	0.07187499850988388	235536000	0.07239600270986557	0.0697920024394989	0.0697920024394989
23-05-1997	0.06666699796915054	0.0703129991889	318744000	0.07604199647903442	0.07500000298023224	0.07500000298023224
27-05-1997	0.07291699945926666	0.07552099972963333	173952000	0.08229199796915054	0.07916700094938278	0.07916700094938278
28-05-1997	0.07656300067901611	0.08124999701976776	91488000	0.08177100121974945	0.07656300067901611	0.07656300067901611

Şekil 6: Amazon'a ait veriseti

NFLX

Date	Low	Open	Volume	High	Close	Adjusted Close
23-05-2002	1.1457140445709229	1.1564290523529053	104790000	1.2428569793701172	1.1964290142059326	1.1964290142059326
24-05-2002	1.1971429586410522	1.214285969734192	11104800	1.225000023841858	1.2100000381469727	1.2100000381469727
28-05-2002	1.157142996788025	1.2135709524154663	6609400	1.2321430444717407	1.157142996788025	1.157142996788025
29-05-2002	1.0857139825820923	1.1642860174179077	6757800	1.1642860174179077	1.1035710573196411	1.1035710573196411
30-05-2002	1.0714290142059326	1.1078569889068604	10154200	1.1078569889068604	1.0714290142059326	1.0714290142059326
31-05-2002	1.0714290142059326	1.0785709619522095	8464400	1.0785709619522095	1.076429009437561	1.076429009437561
03-06-2002	1.076429009437561	1.0800000429153442	3151400	1.1492860317230225	1.1285710334777832	1.1285710334777832

Şekil 7: Netflix'e ait veriseti

Verisetindeki sütunlar ve anlamları

1. İşlem Tarihi: Borsada işlem tarihi, bir finansal enstrümanın (hisse senedi, tahvil, opsiyon, vb.) alım veya satım işleminin gerçekleştiği tarihi ifade eder. Bu tarih, yatırımcının belirli bir finansal varlığı elinde tuttuğu veya elinden çıkardığı tarihi belirtir. İşlem tarihi, finansal piyasalarda yapılan ticaretin ne zaman gerçekleştiğini belirlemek için kullanılır ve genellikle bir ticaretin tarih damgasını ifade eder. İşlem tarihi, alıcı ve satıcı arasında yapılan anlaşmanın

tamamlandığı ve varlığın el değiştirdiği belirli bir tarihi ifade eder. Bu tarih, ticaretin gerçekleştiği günü gösterir ve genellikle gün, ay ve yıl olarak belirtilir. İşlem tarihi, finansal hesaplamalarda ve varlık takibinde önemli bir bilgi olarak kullanılır.

İşlem tarihi, bir yatırımcının portföyündeki varlıkları ne zaman aldığını veya sattığını belirlemek için kullanışlıdır. Bu bilgi, vergi beyannameleri gibi finansal raporlama ve hesaplamalarda önemli olabilir. Ayrıca, bir varlığın performansının izlenmesi ve analiz edilmesi için de işlem tarihleri dikkate alınır.

2. Düşük değer: Borsada "düşük değer" terimi genellikle bir finansal varlığın düşük fiyat seviyesini ifade eder. Bu değer, belirli bir zaman diliminde bir varlığın en düşük fiyatına karşılık gelir. Genellikle hisse senetleri için "düşük değer" ifadesi, belirli bir hisse senedinin belli bir süre içinde ulaştığı en düşük fiyat seviyesini ifade eder.
3. Açılış Değeri: Borsada açılış değeri, bir finansal enstrümanın (hisse senedi, endeks, vb.) belirli bir ticaret gününde işlemlere başlamadan önce ilk kez alıcı ve satıcıların karşılaştığı fiyat seviyesidir. Bu değer, borsanın açılış anında oluşan ilk işlem fiyatını temsil eder. Açılış değeri, önceki günün kapanış fiyatından etkilenebilir ve genellikle günlük piyasa dinamikleri, haberler ve genel ekonomik faktörlere bağlı olarak değişebilir. Açılış değeri, yatırımcılar ve analistler için günlük ticaret stratejilerini oluştururken ve piyasa hareketlerini değerlendirirken önemli bir referans noktasıdır.
4. İşlem Hacmi: Borsada işlem hacmi, belirli bir zaman diliminde gerçekleşen toplam alım ve satım işlemlerinin sayısını veya değerini ifade eden bir ölçümdür. İşlem hacmi, piyasadaki likiditeyi ve bir finansal varlığın ilgi düzeyini yansıtarak yatırımcıların ilgisini çeker. Yüksek işlem hacmi, genellikle bir varlık üzerindeki alım satım aktivitesinin arttığını gösterir ve bu da piyasadaki güçlü katılımı işaret edebilir. Düşük işlem hacmi ise genellikle daha sakin bir piyasa veya düşük ilgi düzeyini gösterir. İşlem hacmi, teknik analizde kullanılarak fiyat hareketlerinin gücünü değerlendirmek, eğilimleri tanımlamak ve piyasa katılımcılarının duyarlılığını anlamak için önemli bir gösterge olarak kabul edilir.

5. Günlük En Yüksek Değer: Borsada günlük en yüksek değer, bir finansal enstrümanın (hisse senedi, endeks, vb.) belirli bir ticaret gününde ulaştığı en yüksek fiyat seviyesini temsil eder. Bu değer, gün içindeki alıcı ve satıcıların etkileşimleri sonucu oluşan en yüksek işlem fiyatını ifade eder. Günlük en yüksek değer, yatırımcılar ve analistler için önemli bir referans noktasıdır, çünkü bu değer, varlığın gün içindeki fiyat hareketliliğini, talep ve arz dengesini yansıtarak piyasadaki güçlü veya zayıf noktaları belirlemede kullanılır. Aynı zamanda, günlük en yüksek değer, teknik analizde direnç seviyelerini belirleme ve trendleri izleme amacıyla da dikkate alınır.
6. Kapanış Değeri: Borsada kapanış değeri, belirli bir ticaret gününün sonunda bir finansal enstrümanın (hisse senedi, endeks, vb.) gerçekleşen son işlem fiyatını ifade eder. Bu değer, piyasa kapandıktan sonra gerçekleşen son işlem fiyatını temsil eder ve genellikle bir gün boyunca varlığın fiyatındaki değişiklikleri özetler. Kapanış değeri, yatırımcılar ve analistler tarafından, bir varlığın gün içindeki performansını değerlendirmek, eğilimleri belirlemek ve gelecekteki fiyat hareketlerini tahmin etmek amacıyla dikkate alınan önemli bir gösterge olarak kabul edilir. Kapanış değeri, teknik analizde destek ve direnç seviyelerini belirleme, grafik analiz ve diğer stratejik kararlar için kullanılır.
7. Düzeltilmiş Kapanış Değeri: Borsada düzeltilmiş kapanış değeri, finansal varlıkların kapanış fiyatlarının, belli bir olayın etkilerinden arındırılarak düzeltilmiş halidir. Bu olaylar genellikle şirket birleşmeleri, temettü ödemeleri, hisse bölünmeleri veya sermaye artırımları gibi şirketin temel yapısını etkileyen durumları içerebilir. Düzeltilmiş kapanış değerleri, yatırımcılara varlık fiyatlarının aslında bu tür olaylardan etkilenmeden önceki durumu hakkında daha net bir bakış açısı sağlar. Bu değerler, hisse senetleri ve diğer varlıkların performansını karşılaştırmak ve analiz etmek için kullanılırken, fiyat değişikliklerinin temel faktörlerle mi yoksa olaylardan kaynaklanan geçici etkilerle mi ilgili olduğunu belirlemeye yardımcı olabilir.

B. Verisetini Düzenleme (Etiketleme/Labellıng)

Veri setlerinde, verilerin anlaşılması ve işlenmesini kolaylaştırmak için öncelikle verilerin etiketlenmesi gerekir. Bu çalışmada, 1/0 Buy/Sell etiketleme yöntemi kullanılmıştır. Bu yöntemde, veriler "al" (1) veya "sat" (0) olarak etiketlenir.

Etiketleme, verilerin anlaşılmasını ve işlenmesini kolaylaştırır çünkü verileri kategorilere ayırır. Bu, verilerin daha kolay analiz edilmesini sağlar. Örneğin, bir veri seti hisse senedi verilerinden oluşuyorsa, veriler "al" veya "sat" olarak etiketlenerek, hisse senetlerinin mevcut durumu hakkında daha kolay bilgi edinilebilir.

Etiketleme, teknik analizde de önemli bir rol oynar. Teknik analiz, gelecekteki fiyat hareketlerini tahmin etmek için geçmiş fiyat verileri, teknik göstergeler ve diğer faktörleri inceleyen bir analiz yöntemidir. Alış ve satış sinyalleri, teknik analizde kullanılan önemli araçlardır. Bu sinyaller, bir pozisyona girmek veya pozisyondan çıkmak için iyi bir zaman olabileceğini gösterir.

Etiketleme, teknik analizde kullanılacak olan sinyallerin oluşturulmasında önemli bir rol oynar. Örneğin, bir sinyal, belirli bir teknik göstergenin belirli bir değere ulaştığında oluşturulabilir. Bu durumda, sinyal oluşturulabilmesi için önce teknik göstergenin belirli bir değere ulaştığının belirlenmesi gerekir. Bu, verileri etiketleyerek yapılabilir.

Sonuç olarak, veri setlerinde verilerin anlaşılmasını ve işlenmesini kolaylaştırmak için etiketleme önemlidir.

1 to 10 of 5176 entries Filter

Date	Low	Open	Volume	High	Close	Adjusted Close	Label
2002-05-23	1.1457140445709229	1.1564290523529053	104790000	1.2428569793701172	1.1964290142059326	1.1964290142059326	0.0
2002-05-24	1.1971429586410522	1.214285969734192	11104800	1.225000023841858	1.2100000381469729	1.2100000381469729	0.0
2002-05-28	1.157142996788025	1.2135709524154663	6609400	1.2321430444717407	1.157142996788025	1.157142996788025	0.0
2002-05-29	1.0857139825820925	1.1642860174179075	6757800	1.1642860174179075	1.1035710573196411	1.1035710573196411	0.0
2002-05-30	1.0714290142059326	1.1078569889068604	10154200	1.1078569889068604	1.0714290142059326	1.0714290142059326	0.0
2002-05-31	1.0714290142059326	1.0785709619522097	8464400	1.0785709619522097	1.076429009437561	1.076429009437561	0.0
2002-03-06	1.076429009437561	1.0800000429153442	3151400	1.1492860317230225	1.1285710334777832	1.1285710334777832	0.0
2002-04-06	1.1107139587402344	1.135714054107666	3105200	1.1399999856948853	1.1178569793701172	1.1178569793701172	0.0
2002-05-06	1.1071430444717407	1.1107139587402344	1531600	1.1592860221862793	1.147143006324768	1.147143006324768	0.0
2002-06-06	1.1485710144042969	1.149999976158142	2305800	1.2321430444717407	1.182142972946167	1.182142972946167	0.0

a. Netflix'e ait etiketlenmiş veri

Şekil 8: Etiketlenmiş Veriler

labeled_stock_data_amzn.csv ×

1 to 10 of 6438 entries Filter

Date	Low	Open	Volume	High	Close	Adjusted Close	Label
1997-05-15	0.0963540002703666	0.1218750029802322	1443120000	0.125	0.0979169979691505	0.0979169979691505	0.0
1997-05-16	0.0854170024394989	0.0984380021691322	294000000	0.0989580005407333	0.0864579975605011	0.0864579975605011	0.0
1997-05-19	0.0812499970197677	0.0880210027098655	122136000	0.0885419994592666	0.0854170024394989	0.0854170024394989	0.0
1997-05-20	0.0817710012197494	0.0864579975605011	109344000	0.0874999985098838	0.0817710012197494	0.0817710012197494	0.0
1997-05-21	0.0687500014901161	0.0817710012197494	377064000	0.0822919979691505	0.0713540017604827	0.0713540017604827	0.0
1997-05-22	0.0656249970197677	0.0718749985098838	235536000	0.0723960027098655	0.0697920024394989	0.0697920024394989	0.0
1997-05-23	0.0666669979691505	0.0703129991889	318744000	0.0760419964790344	0.0750000029802322	0.0750000029802322	0.0
1997-05-27	0.0729169994592666	0.0755209997296333	173952000	0.0822919979691505	0.0791670009493827	0.0791670009493827	0.0
1997-05-28	0.0765630006790161	0.0812499970197677	91488000	0.0817710012197494	0.0765630006790161	0.0765630006790161	0.0
1997-05-29	0.0739580020308494	0.0770829990506172	69456000	0.0770829990506172	0.0752599984407424	0.0752599984407424	0.0

b. Amazon'a ait etiketlenmiş veri

Şekil 8: Etiketlenmiş Veriler

1 to 10 of 13356 entries Filter

Date	Low	Open	Volume	High	Close	Adjusted Close	Label
1970-02-01	0.9259260296821594	0.9259260296821594	634838	0.979423999786377	0.979423999786377	0.290567398071289	0.0
1970-05-01	1.0082299709320068	1.0082299709320068	741150	1.0246909856796265	1.0164610147476196	0.3015552461147308	0.0
1970-06-01	1.0246909856796265	1.0246909856796265	1354725	1.0493830442428589	1.0288070440292358	0.3052180111408233	0.0
1970-07-01	1.020576000213623	1.0288070440292358	646988	1.0452669858932495	1.0329220294952393	0.3064388036727905	0.0
1970-08-01	1.0082299709320068	1.0329220294952393	807975	1.037037014961243	1.020576000213623	0.3027762174606323	0.0
1970-09-01	0.9958850145339966	1.020576000213623	634838	1.0329220294952393	0.9958850145339966	0.2954510748386383	0.0
1970-12-01	0.979423999786377	0.9958850145339966	568013	1.0	0.9876539707183838	0.2930091619491577	0.0
1970-01-13	0.9341560006141664	0.9835389852523804	883913	0.9835389852523804	0.9382719993591307	0.2783587872982025	0.0
1970-01-14	0.9135800004005432	0.9341560006141664	1105650	0.9341560006141664	0.9300410151481628	0.2759170830249786	0.0
1970-01-15	0.9053500294685364	0.9259260296821594	1436738	0.9259260296821594	0.9094650149345398	0.2698125839233398	0.0

c. Boeing'e ait etiketlenmiş veri

Şekil 8: Etiketlenmiş Veriler

1. Buy/Sell (Al/Sat) Etiketleme Nedir?

Buy/Sell Labelling" (Al/Sat Etiketleme), finansal piyasalarda yapılan ticaret stratejilerini ve sinyallerini belirlemek amacıyla kullanılan bir kavramdır. Bu etiketleme, bir varlığın alım veya satım önerisi verilmesini ifade eder. Finansal analistler, yatırımcılar veya ticaret stratejisi oluşturan yazılım sistemleri genellikle piyasa koşulları ve teknik analiz temelinde belirlenen kriterlere dayanarak bir varlığın alım veya satım yapılması gerektiğine dair sinyaller üretirler.

"Buy" (Al) etiketi, belirli bir varlığın alımını önerirken, "Sell" (Sat) etiketi, varlığın satılması gerektiğini belirtir. Bu etiketlemeler, genellikle grafik analizi, teknik göstergeler veya matematiksel modeller kullanılarak türetilen ticaret stratejilerinin bir sonucu olarak ortaya çıkar. Bu tür etiketlemeler, yatırımcılara ve trader'lara belirli bir varlık üzerindeki ticaret kararlarını destekleme ve rehberlik etme amacıyla hizmet

eder. Ancak, bu tür sinyallerin başarı oranı ve güvenilirliği, kullanılan strateji ve piyasa koşulları gibi faktörlere bağlı olarak değişebilir.

C. Yapılan İşlemler

Çalışma kapsamında ilk olarak veriseti elde edilmiştir. Daha sonra verisetinin anlaşılması ve üzerinde birtakım işlemlerin yapılması amacıyla verisetindeki kapanış değerlerine karşılaştırmalı etiketleme metodu da olan 1/0 buy/sell binary labelling (etiketleme) metoduyla veriler etiketlenmiştir. Etiketlenen verilerin analşılması amacıyla hisse senetlerinin yıllara göre alım ve satım emirlerinin grafikleri çıkarılarak, hisse senetleri üzerinde çıkarımlarda bulunulmuştur. Daha sonrasında bu 1 boyutlu veriler, üzerinde çalışma yapılması amacıyla matrissel görüntülere çevrilmiş ve bu matrissel görüntüler üzerinde modellemeler yapılarak çalışmamız oluşturulmuştur.

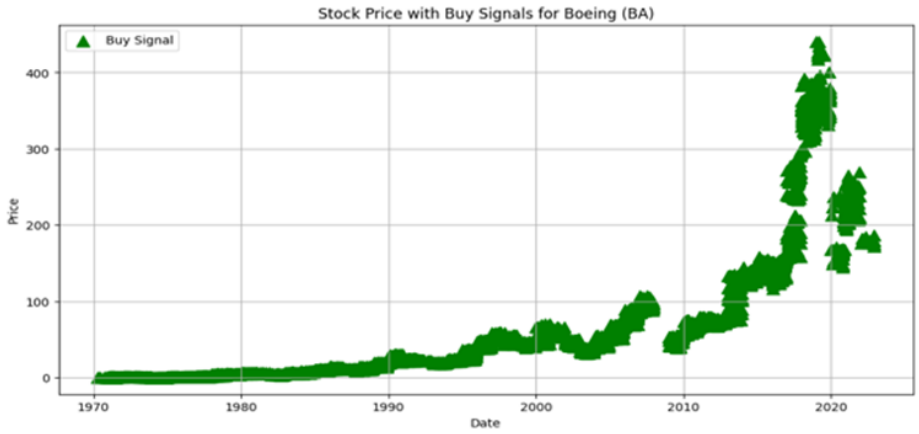

Şekil 9: Boeing'in yıllara göre ALIM emirleri

Şekil 10: Amazon'un yıllara göre ALIM emirleri

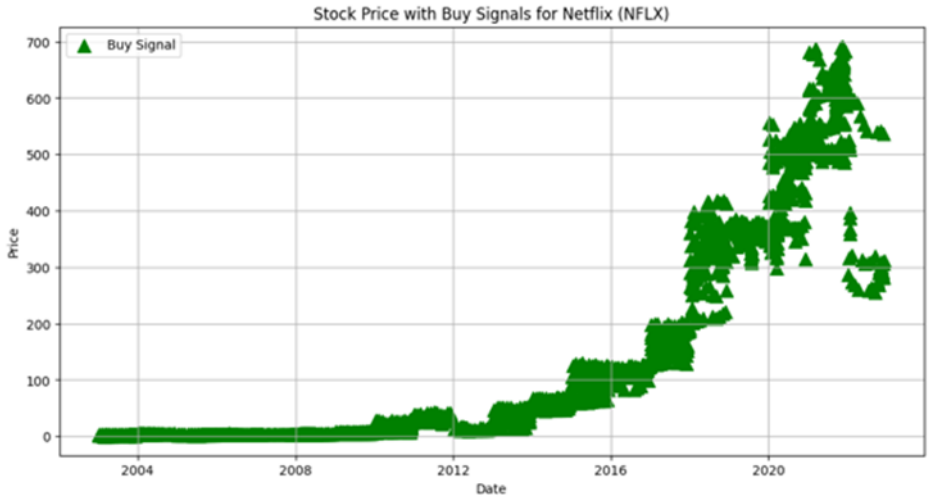

Şekil 11: Netflix'in Yıllara Göre ALIM emirleri

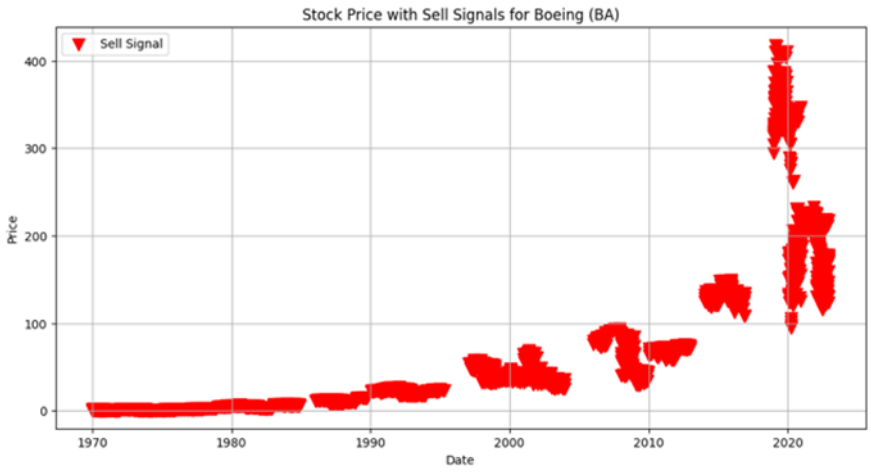

Şekil 12: Boeing'in yıllara göre SATIŞ emirleri

Şekil 13: Amazon'un yıllara göre SATIŞ emirleri

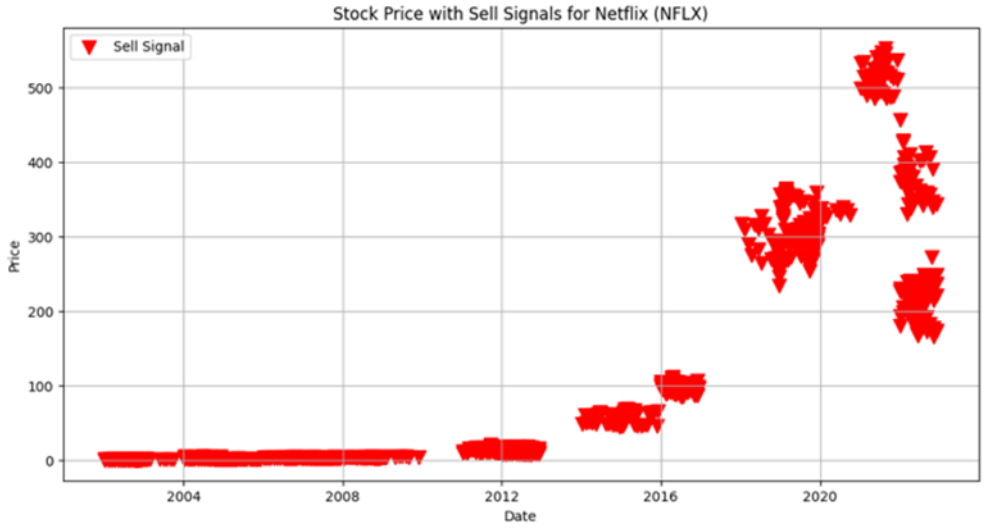

Şekil 14: Netflix'in yıllara göre SATIŞ emirleri

Bu alım ve satış emirleri grafiklerine göre şu çıkarımlar yapılabilir;

1. Boeing 1990ların 2. Yarısına kadar genellikle yatay bir seyir izlemiş, 1990ların 2. yarısından itibaren havacılık sektörünün tüm dünyada hızlı bir biçimde gelişmesi ve artan uçak talepleri sonrasında inişli çıkışlı da olsa genel olarak artış göstermiştir. Bu bakımdan Boeing, dünyadaki havacılık trendleriyle paralel olarak değerlenmiştir.
2. Amazon 2012 yılına kadar yatay seyir izlemiş, 2012 yılından itibaren dünya genelinde popülerliğinin artmasıyla beraber hisse değerinde sürekli olarak artış göstermiştir.
3. Netflix te 2014'e kadar sabit seyir izlemiş, 2014 ten itibaren dijital platformların trend hale gelmesiyle beraber değeri sürekli olarak artmıştır. Bu artışın temel sebebi dijital platformların konvansiyonel yayıncılığa oranla daha hızlı aksiyon göstermesidir.

1. 1 Boyutlu Verinin 2 Boyutlu Görüntü Haline Getirilmesi

Makine öğrenimi modelleri, verilerden öğrenerek çalışır. Bu nedenle, verilerin doğru bir şekilde hazırlanması, modellerin performansı için kritik öneme sahiptir.

Bu çalışmada, verileri makine öğrenimi için hazırlamak için aşağıdaki adımları takip ettik:

1. Verileri 1 boyutlu verilerden 10x10'luk kare matrislere dönüştürdük.

2. Tüm verileri görmek için 50x50'lik matrisler oluşturduk.
3. Verileri daha küçük ve daha yönetilebilir boyutlara indirmek için 32x32'lik matrisler oluşturduk.

Bu adımlar, verilerin daha kolay okunmasını ve analiz edilmesini sağladı. Ayrıca, verilerin makine öğrenimi modelleri tarafından daha iyi öğrenilmesini sağladı.

Verilerin makine öğrenimi için hazırlanması, modellerin performansını önemli ölçüde artırabilir. Bu nedenle, verileri hazırlamak için doğru adımları takip etmek önemlidir.

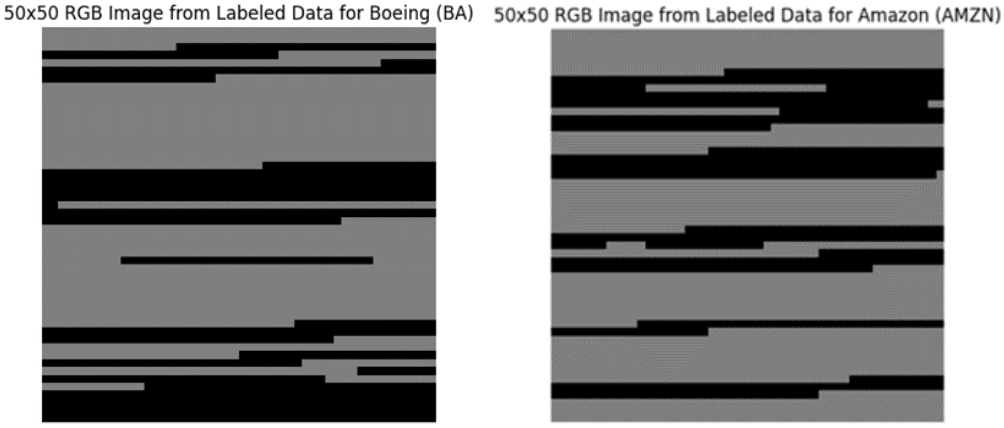

Şekil 15: Genel Görüntü Matrisleri-1 (50x50)

Şekil 16: Netflix'e ait genel görüntü matrisi (50x50)

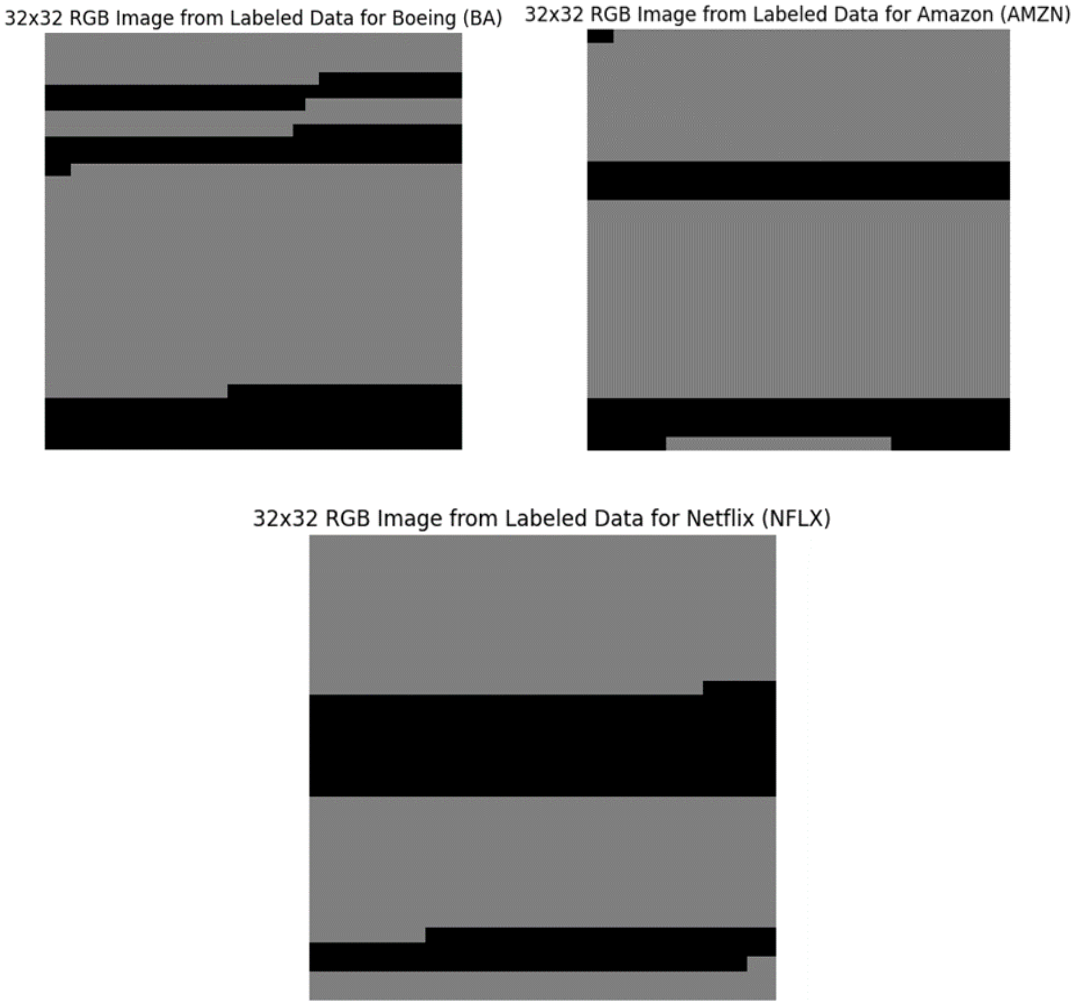

Şekil 17: Genel Görüntü Matrisleri-2 (32x32)

Sonrasında, genel görüntü matrisi, detaylı ve makine öğrenimi için uygun bir şekilde 10x10'luk görüntülere dönüştürüldü. Bu işlem, her bir günün bir piksel olarak temsil edilmesini mümkün kıldı. Bu 2 boyutlu görüntüler üzerinde çalışmalar yaparak, çalışmada kullanılan model oluşturuldu ve performans metrikleri elde edildi. Böylece, makine öğrenmesi çalışmalarının gerçekleştirilebileceği 2 boyutlu görüntüsel veriler elde edilmiş oldu.

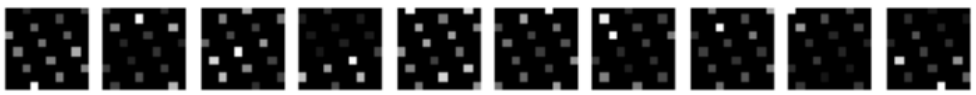

a. Netflix'e ait görüntü matrisi

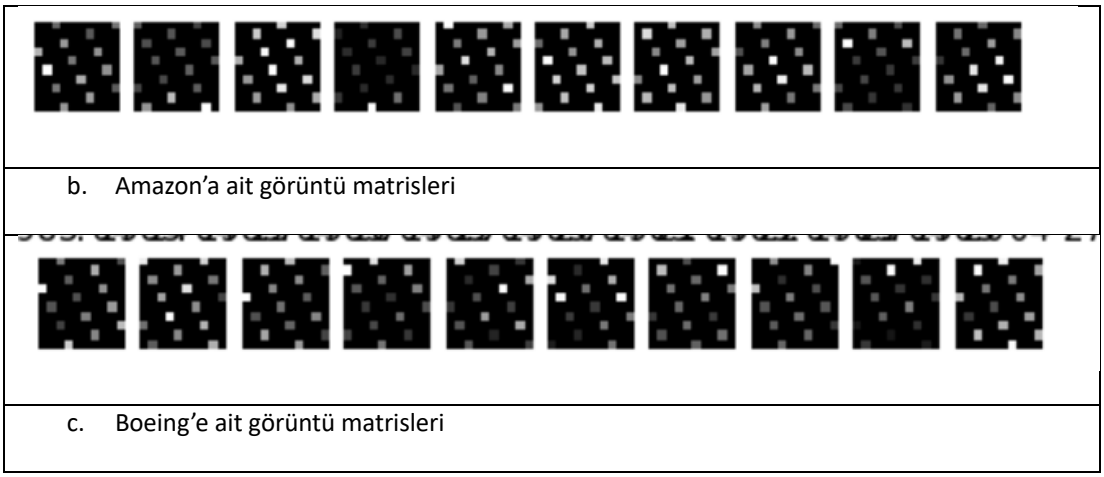

b. Amazon'a ait görüntü matrisleri

c. Boeing'e ait görüntü matrisleri

Şekil 18: 10 ×10'luk görüntü matrisleri

D. Hiperparametre Optimizasyonu

Hiperparametre optimizasyonu, bir makine öğrenimi modelinin performansını en üst düzeye çıkarmak amacıyla kullanılan bir süreçtir. Makine öğrenimi modelleri, eğitilirken kullanılan hiperparametreler tarafından kontrol edilir. Hiperparametreler, modelin yapılandırılması, öğrenme süreci ve genel performansı üzerinde etkili olan değerlerdir. Örnek olarak, öğrenme oranı, ağ derinliği, ağdaki nöron sayısı gibi hiperparametreler bulunabilir.

Hiperparametre optimizasyonu, farklı hiperparametre değerleri denemek ve modelin performansını ölçmek suretiyle en iyi hiperparametre kombinasyonunu bulmayı amaçlar. Bu genellikle bir arama stratejisi ve ölçüm metriklerine dayanır. Ölçüm metrikleri, modelin performansını değerlendirmek için kullanılan ölçülerdir, örneğin doğruluk (accuracy), hassasiyet (precision), geri çağrı (recall) gibi.

Yaygın olarak kullanılan hiperparametre optimizasyon yöntemleri arasında Grid Search, Random Search, ve Bayesian Optimization bulunur. Bu teknikler, modelin performansını artırmak ve aşırı uydurmaya (overfitting) karşı koymak için etkili hiperparametre değerlerini bulmak için kullanılır. Hiperparametre optimizasyonu, makine öğrenimi modellerinin daha genel ve daha iyi genelleme yapabilen yapılar oluşturmasına yardımcı olabilir.

Bu projede, PSO algoritmasını kullanarak veri kümesini optimize ettik. Optimizasyon sonucunda, Netflix'in yoğunluğunun diğer hisse senetlerine göre daha düşük olduğu görüldü. Buna karşılık, Amazon'un verileri en yoğun katmanları oluşturdu. Bu durum, Netflix'in piyasaya görece yeni olması ve hareketliliğinin az olmasından kaynaklanıyor olabilir. Boeing ve Amazon'un ise piyasada uzun yıllardır var olması, katman derinliklerinin yüksek olmasını sağlamış olabilir.

Optimizasyon, veri kümelerinin daha iyi anlaşılmasını ve daha doğru sonuçlar elde edilmesini sağlar. Bu çalışmada, PSO algoritması kullanılarak veri kümesi optimize edildi ve Netflix'in yoğunluğunun diğer hisse senetlerine göre daha düşük olduğu görüldü. Bu bilgi, Netflix'in hisse senedi fiyatlarının eğilimini tahmin etmek için kullanılabilir.

Çizelge 1: Parametre Optimizasyon Sınırları

Parametreler11	**Değer sınırları**	**PSO tarafından seçilen hedef parametreler**		
		Netflix	Amazon	Boeing
Dense katman	[8- 128]	109	128	120
Dense katman	[6- 64]	4	32	24
Adam optimizasyon başlangıç değeri	[0.0001- 0.1]	0.001	0.001	0.001

E. Pso'nun Performans Üzerine Etkileri

Varsayılan parametrelerle LeNet 5 ve LeNet-PSO yöntemlerini kullanarak, farklı hisse senedi verilerinde modellerin performansını karşılaştırdık. Burada modellin tümü 30 dönem ve 16 toplu iş boyutuna göre eğitilmiştir.

LeNet-PSO yöntemiyle oluşturulan modellerin doğruluk ve kesinlikleri, varsayılan parametrelerle oluşturulan LeNet modellerine göre daha yüksektir. Bu durum, PSO optimizasyonunun model performansını iyileştirdiğini göstermektedir.

Ancak, bu yüksekliğin görece az olmasının temel nedeni, karşılaştırmada kullanılan hisse senedi verilerinden kaynaklanmaktadır. Başka hisse senetleri kullanılması durumunda, bu oranlar daha farklı olabilir.

Duyarlılık oranı, Boeing hariç diğer senetlerde artmaktadır. Bu durum, LeNet-PSO yönteminin bu senetlerde daha iyi performans gösterdiğini göstermektedir. Ancak, Boeing verisinde ise LeNet-PSO yöntemiyle oluşturulan modelin duyarlılığı, varsayılan parametrelerle oluşturulan LeNet modelinden daha düşüktür. Bu durum, Boeing verilerinin oynaklığından kaynaklanıyor olabilir.

Sonuç olarak, LeNet-PSO yöntemi, hisse senedi fiyatlarının tahmininde kullanılabilecek etkili bir yöntemdir. Ancak, yöntemin performansı, kullanılan hisse senedi verilerine göre değişebilir.

Çizelge 2: Performans Metrikleri

Data / **Sonuç**	**Netflix**		**Amazon**		**Boeing**	
	LeNet 5	LeNet 5-PSO	LeNet 5	LeNet5-PSO	LeNet 5	LeNet 5-PSO
Accuracy	0.58	0.64	0.55	0.62	0.59	0.60
precision	0.39	0.42	0.41	0.54	0.55	0.63
recall	0.61	0.65	0.57	0.59	0.57	0.52
f1-score	0.49	0.51	0.51	0.66	0.61	0.44

Aşağıda sunulan karışıklık matrisi, Netflix borsasında alış olarak tespit edilen satış sayısının hem optimize edilmiş hem de varsayılan ağda (LeNet 5) 60 olduğunu göstermektedir. Ancak, derin öğrenme ile optimize edilmiş ağda tespit edilen satın alma sayısı, 20'ye kıyasla varsayılan ağdakinden daha iyi bir performans sergileyerek 80'e yükselmektedir.

Öte yandan, Amazon'da derin öğrenme ile optimize edilmiş modelde satın almanın, 25'e kıyasla 33,7 gibi nispeten iyi bir değerle varsayılandan daha başarılı olduğu söylenebilir. Ancak, tespit edilen satışlarda herhangi bir değişiklik olmamıştır.

Boeing'de ise varsayılan modelin satın alma sayısı 61,5 iken, optimize edilmiş modelde 55,6'ya düşmüştür. Bu durumun sebebi, Boeing hisselerindeki iniş çıkışların diğer iki hisse senedine göre daha fazla olması, yani oynaklık olarak bilinmesidir. Buna karşın, satış sayısı optimize edilen modelde artış göstermiştir.

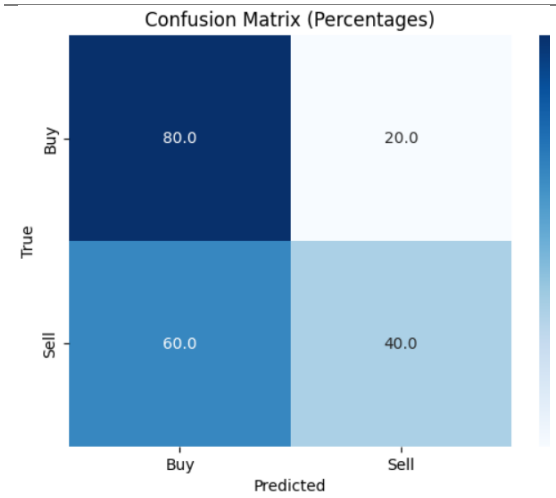

I. LeNet5-PSO (Netflix)

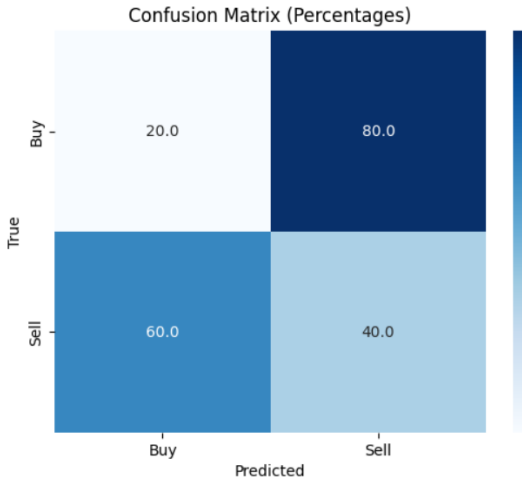

II. LeNet5 (Netflix)

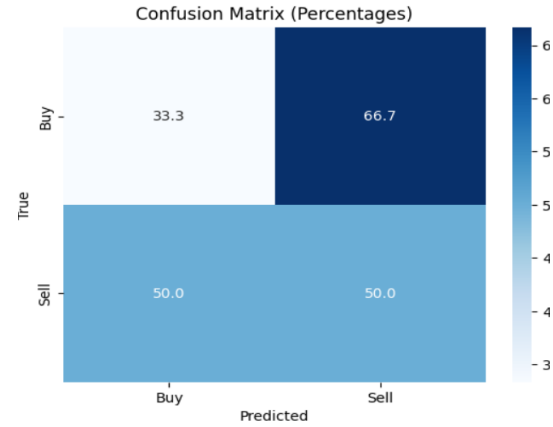

III. LeNet5-PSO (Amazon)

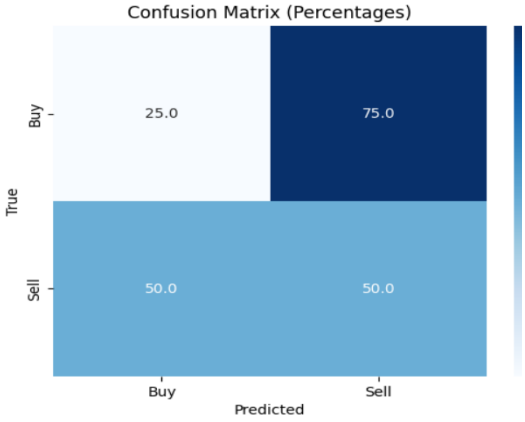

IV. LeNet5 (Amazon)

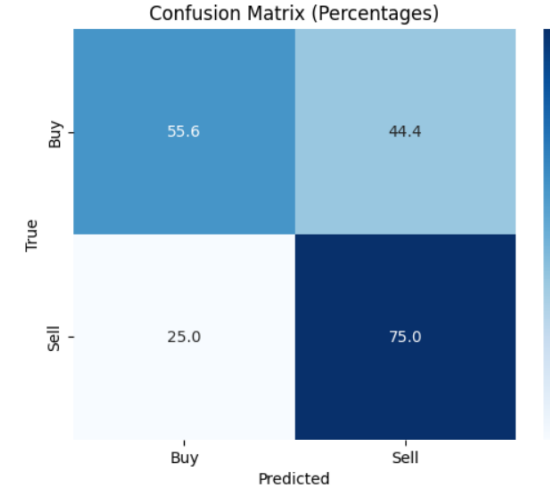

V. LeNet 5-PSO (Boeing)

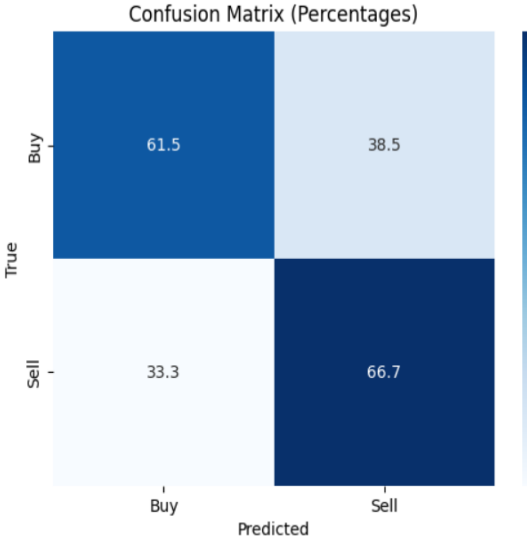

VI. LeNet5 (Boeing)

Şekil 19: Karışıklık Matrisleri

Sonuç olarak; modelin performansı eldeki verilerin stabilliğine, verilerin yoğunluğuna bağlı olarak değişkenlik gösterse de genel olarak performans açısından standart modele kıyasla daha iyi olduğu söylenebilmektedir.

V. SONUÇ VE TARTIŞMA

Yapılan bu kapsamlı çalışmada, LeNet5-PSO tabanlı oluşturulan al-sat modellerinin diğer modellere göre daha yüksek doğruluk sağladığı belirlenmiştir. Bu önemli bulgu, finansal piyasalardaki hisse senedi performansının tahminlenmesinde yeni bir perspektif sunmaktadır. Özellikle LeNet5-PSO modelinin, farklı şirket hisseleri üzerinde gerçekleştirilen testlerde elde ettiği doğruluk oranlarının, sadece LeNet5 kullanılarak oluşturulan modellere göre belirgin bir şekilde üstün olduğu gözlemlenmiştir.

Örneğin, yalnızca LeNet5 kullanılarak oluşturulan model, Netflix hisselerinde %58 doğruluk oranına sahipken, PSO ile optimize edilen modelde bu oran %64'e yükselmiştir. Benzer şekilde, Amazon hisselerinde LeNet5 uygulanan modelin %55 doğruluğuna karşılık, PSO ile optimize edilen model %62 doğruluk elde etmiştir. Boeing hisselerinde de LeNet5 uygulanan model %59 doğruluk gösterirken, PSO ile optimize edilen model %60 doğruluk elde etmiştir. Bu sonuçlar, LeNet5-PSO modelinin farklı şirket hisseleri üzerinde tutarlı bir şekilde daha iyi performans sergilediğini göstermektedir.

Ancak, bu başarıların yanında LeNet5-PSO modelinin belirsiz (unstable) olduğu bir gerçektir. Her bir hisse senedinde farklı sonuçlar elde edilmesi ve karışıklık matrisinin bazı durumlarda olumlu, bazı durumlarda ise olumsuz sonuçlar vermesi, modelin güvenilirliğini zayıflatan bir etkendir. Bu durum, LeNet5-PSO modelinin ciddi bir dezavantajını oluşturmaktadır.

LeNet5-PSO Modelinin Belirsizliğine Neden Olan Faktörler

LeNet5-PSO modelinin belirsizliğine neden olan faktörleri şu şekilde özetleyebiliriz:

Eğitim verileri: Modelin eğitim verileri, modelin performansını önemli ölçüde etkileyen bir faktördür. Veriler yeterli miktarda ve çeşitlilik içermiyorsa, modelin

doğruluğu düşebilir. LeNet5-PSO modelinin belirsizliği, eğitim verilerinin kalitesinden kaynaklanıyor olabilir.

Özellik seçimi: Modelin performansını artırmak için, modele yalnızca ilgili özellikler verilmelidir. Gereksiz özellikler, modelin karmaşıklığını ve belirsizliğini artırabilir. LeNet5-PSO modelinin belirsizliği, özellik seçiminden kaynaklanıyor olabilir.

Parametre ayarları: Modelin parametreleri, modelin performansını etkileyen bir diğer önemli faktördür. Parametreler doğru ayarlanmazsa, modelin doğruluğu düşebilir. LeNet5-PSO modelinin belirsizliği, parametre ayarlarından kaynaklanıyor olabilir.

Optimizasyon stratejisi: Modelin performansını artırmak için, modelin optimizasyon stratejisi de önemlidir. Yetersiz bir optimizasyon stratejisi, modelin doğruluğunu düşürebilir. LeNet5-PSO modelinin belirsizliği, optimizasyon stratejisinden kaynaklanıyor olabilir.

LeNet5-PSO Modelinin Belirsizliğini Azaltmak için Öneriler

LeNet5-PSO modelinin belirsizliğini azaltmak için aşağıdaki öneriler yapılabilir:

Eğitim verilerinin kalitesini ve çeşitliliğini artırmak: Modelin eğitimi için daha fazla ve daha çeşitli veri kullanılmalıdır. Bu, modelin öğrenme kapasitesini artıracak ve belirsizliğini azaltacaktır.

Özellik seçimini iyileştirmek: Modele yalnızca ilgili özellikler verilmelidir. Gereksiz özellikler, modelin karmaşıklığını ve belirsizliğini artırabilir. Bu nedenle, özellik seçimi için daha gelişmiş teknikler kullanılabilir.

Parametre ayarlarını optimize etmek: Modelin parametreleri, deneme-yanılma yöntemi ile değil, daha sistematik bir şekilde optimize edilmelidir. Bu, modelin doğruluğunu ve kararlılığını artıracaktır.

Yeni optimizasyon stratejileri ve derin öğrenme teknikleri kullanmak: Yeni optimizasyon stratejileri ve derin öğrenme teknikleri, modelin performansını ve kararlılığını artırmaya yardımcı olabilir.

A. Sonuç

LeNet5-PSO modeli, finansal piyasalardaki hisse senedi performansının tahminlenmesinde önemli bir potansiyele sahiptir. Ancak, modelin belirsizliği, bu potansiyelin tam olarak değerlendirilmesini engellemektedir. Gelecekteki çalışmalarda, modelin belirsizliğini azaltmak için yukarıda belirtilen önerilerin uygulanması, LeNet5-PSO modelini daha güvenilir bir finansal analiz aracı haline getirmeye yardımcı olacaktır.

B. Ek Tartışmalar

LeNet5-PSO modelinin belirsizliğini azaltmak için yapılan çalışmalar, finansal piyasalarda derin öğrenmenin kullanımının önemli bir araştırma alanı olduğunu göstermektedir. Bu çalışmalar, derin öğrenmenin finansal piyasalarda daha geniş bir şekilde kullanılmasına olanak sağlayacaktır.

LeNet5-PSO modelinin belirsizliğini azaltmak için yapılan çalışmalarda, aşağıdaki konulara odaklanılabilir:

Eğitim verilerinin kalitesini ve çeşitliliğini artırmak için yeni teknikler geliştirmek: Bu, modelin öğrenme kapasitesini artıracak ve belirsizliğini azaltacaktır.

Özellik seçimini iyileştirmek için yeni teknikler geliştirmek: Bu, modelin karmaşıklığını ve belirsizliğini azaltacaktır.

Parametre ayarlarını optimize etmek için yeni teknikler geliştirmek: Bu, modelin doğruluğunu ve kararlılığını artıracaktır.

Yeni optimizasyon stratejileri ve derin öğrenme teknikleri geliştirmek: Bu, modelin performansını ve kararlılığını artırmaya yardımcı olacaktır.

Bu çalışmalar, LeNet5-PSO modelinin belirsizliğini azaltmak ve finansal piyasalarda derin öğrenmenin kullanımını yaygınlaştırmak için önemli bir katkı sağlayacaktır.

Gelecekteki çalışmalarımızda, LeNet5-PSO modelini daha stabil bir hale getirmek amacıyla çeşitli değişiklikler yapılması önerilmektedir. Bu değişiklikler arasında, modelin eğitim verileri, özellik seçimi ve parametre ayarları gibi faktörlerin

gözden geçirilmesi yer alabilir. Ayrıca, modelin genel performansını artırmak için yeni optimizasyon stratejileri ve derin öğrenme teknikleri de incelenebilir. Bu şekilde, LeNet5-PSO modelinin belirsizlik sorunları aşılarak daha güvenilir bir finansal analiz aracı haline getirilmesi hedeflenmektedir.

VII. KAYNAKÇA

MAKALELER

A M ÖZBAYOĞLU, O. B. (2020). **Deep learning for financial applications : A survey. Applied Soft Computing,** Volume 93, 2020,.

A NAKAYAMA, K. I. (2019). **Short-term Stock Price Prediction by Analysis of Order Pattern Images. 2019 IEEE Conference on Computational Intelligence for Financial Engineering & Economics** (CIFEr), Shenzhen, China, 2019, pp. 1-5, doi: 10.1109/CIFEr.2019.8759057., 1-5.

A. TSANTEKİDİS, N. P. (2017). **Using deep learning to detect price change indications in financial markets.** 2017 25th European Signal Processing Conference (EUSIPCO), Kos, Greece, 2511-2515.

A.AARYAN, B. K. (2022**). Forecasting stock market price using LSTM-RNN. 2022 2nd International Conference on Advance Computing and Innovative Technologies in Engineering** (ICACITE), 1557-1560.

C. VACA, D. R. (2020). **Buy & Sell Trends Analysis Using Decision Trees . DOI:10.1109/ColCACI50549.**2020.9247907 Conference: 2020 IEEE Colombian Conference on Applications of Computational Intelligence (ColCACI).

D, A. M. (2020). **Indian Stock Market Prediction using Deep Learning . 2020 IEEE REGION 10 CONFERENCE (TENCON**), Osaka, Japan, 2020, pp. 1215-1220, doi: 10.1109/TENCON50793.2020.9293712., 1215-1220.

D.M.O NELSON, A. P. (2017). **Stock market's price movement prediction with LSTM neural networks. 2017 International Joint Conference on Neural Networks (IJCNN),** Anchorage, AK, USA, 2017, pp. 1419-1426, doi: 10.1109/IJCNN.2017.7966019., 1419-1426.

DUVAR, Z. H. (2020). **An Efficient Word Embedding and Deep Learning Based Model to Forecast the Direction of Stock Exchange Market Using Twitter and Financial News Sites: A Case of Istanbul Stock Exchange (BIST 100**). IEEE Access 8:188186 - 188198.

J. EAPEN, D. A. (2019). **Novel Deep Learning Model with CNN and Bi-Directional LSTM for Improved Stock Market Index Prediction. Conference**: 2019 IEEE 9th Annual Computing and Communication Workshop and Conference (CCWC) .

K. J, H. E. (2021). **Stock Price Prediction Based on LSTM Deep Learning Model. 2021 International Conference on System, Computation**, Automation and Networking (ICSCAN), Puducherry, India, 2021, pp. 1-4, doi: 10.1109/ICSCAN53069.2021.9526491., 1-4.

K. SUTRADHAR, S. S. (2021). **Stock Market Prediction using Recurrent Neural Network's LSTM Architecture** . Conference: 2021 IEEE 12th Annual Ubiquitous Computing, Electronics & Mobile Communication Conference (UEMCON).

M. BİSWAS, A. S. (2021). **Predicting Stock Market Price: A Logical Strategy using Deep Learning**. 2021 IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE), Penang, Malaysia, 218-223.

M. NABİPOUR, P. N. (2020). **Predicting Stock Market Trends Using Machine Learning and Deep Learning Algorithms Via Continuous and Binary Data; a Comparative Analysis.** IEEE Access, vol. 8, pp. 150199-150212, 2020, doi: 10.1109/ACCESS.2020.3015966. , 150199-150212.

M. U. GUDELEK, S. A. (2017). **A deep learning based stock trading model with 2-D CNN trend detection. 2017 IEEE Symposium Series on Computational Intelligenc**e (SSCI), Honolulu, HI, USA, 2017, pp. 1-8, doi: 10.1109/SSCI.2017.8285188., 1-8.

M.VARGAS, C. D. (2018). **Deep Learning for Stock Market Prediction** Using Technical Indicators and Financial News Articles.

P.S. SİSODİA, A. G. (2022). **Stock Market Analysis and Prediction for Nifty50 using LSTM Deep Learning Approach**. Conference: 2022 2nd International Conference on Innovative Practices in Technology and Management (ICIPTM) .

Qİ-QİAO HE, C. W.-W. (2022). **LSTM with particle Swam optimization for sales forecasting.** Electronic Commerce Research and Applications, Volume 51,.

RAO, B. S. (2022). **Analysis of a Stock Exchange and Future Prediction Using LSTM. "2021 4th International Conference on Recent Trends in Computer Science and Technology (ICRTCST),** Jamshedpur, India, 2022, doi: 10.1109/ICRTCST54752.2022., 48-54.

S. BANİK, N. S. (2021). **LSTM based decision support system for swing trading in stock market .** Knowledge-Based Systems 239(2):107994.

T. SANBOON, K. K. (2019). **A Deep Learning Model for Predicting Buy and Sell Recommendations in Stock Exchange of Thailand using Long Short-Term Memory. 2019 IEEE 4th International Conference on Computer and Communication Systems** (ICCCS), Singapore, 2019, 757-760.

W. LONG, Z. L. (2019). **Deep learning-based feature engineering for stock price movement prediction.** Knowledge-Based Systems, Volume 164, 2019,.

WEİFANG MAO, H. Z. (2023). **Forecasting and trading credit default swap indices using a deep learning model integrating Merton and LSTMs**. Expert Systems with Applications, Volume 213, Part B, https://doi.org/10.1016/j.eswa.2022.119012. .

YİLİN MA, R. H. (2020). **Portfolio optimization with return prediction using deep learning and machine learning** . Expert Systems with Applications 10.1016/j.eswa.2020.113973.

YONG'AN ZHANG, B. Y. (2020). **A novel deep learning framework: Prediction and analysis of financial time series using CEEMD and LSTM .** Expert Systems with Applications, Volume 159, https://doi.org/10.1016/j.eswa.2020.113609. .

Z.H KİLİMCİ, H. K. (2021). **Deep Learning-based Decision Integration Strategy for the Price Prediction of Istanbul Stock Exchange (BIST100). 2021 13th** International Conference on Electrical and Electronics Engineering (ELECO).

ÖZGEÇMİŞ

İsim Soyisim: Ahmet Bedirhan SAĞIR

A. Eğitim Durumu

Yüksek Lisans: İstanbul Aydın Üniversitesi-Bilgisayar Mühendisliği A.B.D. (2022-2024)

Lisans: İstanbul Sabahattin Zaim Üniversitesi- Mühendislik ve Doğa Bilimleri Fakültesi-Bilgisayar Mühendisliği (2015-2020)

Lisans: Anadolu Üniversitesi-İşletme Fakültesi-İşletme (2014-2020)

Önlisans: Anadolu Üniversitesi-Açıköğretim Fakültesi-Adalet (2020-2024)

B. Çalışma Durumu

Eylül 2021-15 Mart 2022: MEB İsmet Aktar MTAL- Bilişim Teknolojileri Öğretmeni (ücretli)

16 Mart 2022- halen: Sosyal Güvenlik Kurumu Zeytinburnu S.G.M.- Memur

C. Yayınları

i. MANDAL, T., SAĞIR, A. B., ÖZTÜRK, M. N. A., UYSAL, M. Y., vd. (2022). Metaverse: Sanal Dünyadan Gerçek Gizlilik ve Güvenlik Problemlerine. İstanbul Sabahattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 4(2), 100-106. https://doi.org/10.47769/izufbed.1130284

ii. SAGIR A.B., APAK Sina, (2024). A Diffrent Look At Stock Trading With LeNet5 And Particle Swarm Optimizaton (PSO). International Journal Of Engineering Research and Applications (IJERA), 14(1) January 2024, 90-102 https://www.ijera.com/papers/vol14no1/140190102.pdf