



GİRESUN
ÜNİVERSİTESİ



FEN BİLİMLERİ ENSTİTÜSÜ

**YENİ BİR EVRİŞİMSEL SİNİR AĞI MODELİ İLE
ZAMAN SERİSİ ÖNGÖRÜSÜ**

**İSTATİSTİK
ANABİLİM DALI**

Yüksek Lisans Tezi

**Melih KIRIŞCI
182116008**

2021

GİRESUN

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YENİ BİR EVRİŞİMSEL SİNİR AĞI MODELİ İLE
ZAMAN SERİSİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Öğrencinin Adı SOYADI : Melih KİRİŞCİ

Tezin Enstitüye Verildiği Tarih : 13/08/2021

Enstitü Anabilim Dalı : İstatistik

Tez Danışmanı : Doç. Dr. Özge CAĞCAĞ YOLCU

**Temmuz 2021
GİRESUN**

**T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**

**YENİ BİR EVRİŞİMSEL SİNİR AĞI MODELİ İLE
ZAMAN SERİSİ ÖNGÖRÜSÜ**

YÜKSEK LİSANS TEZİ

Melih KİRİŞCİ

Enstitü Anabilim Dalı : İstatistik

Bu tez 27/07/2021 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile kabul edilmiştir.

**Doç. Dr.
Cem KOÇAK
Jüri Başkanı**

**Doç. Dr.
Özge CAĞCAĞ YOLCU
Üye**

**Dr. Öğretim Üyesi
Ali Zafer DALAR
Üye**

**Doç. Dr.
Bahadır KOZ
Enstitü Müdürü**

BEYAN

Tez içindeki tüm verilerin akademik kurallar çerçevesinde tarafımdan elde edildiğini, görsel ve yazılı tüm bilgi ve sonuçların akademik ve etik kurallara uygun şekilde sunulduğunu, kullanılan verilerde herhangi bir tahrifat yapılmadığını, başkalarının eserlerinden yararlanılması durumunda bilimsel normlara uygun olarak atıfta bulunulduğunu, tezde yer alan verilerin bu üniversite veya başka bir üniversitede herhangi bir tez çalışmasında kullanılmadığını beyan ederim.

Melih KİRİŞCİ

08/07/2021

TEŞEKKÜR

Tez çalışması süresince değerli bilgi ve tecrübeleri ile bana yol gösterici ve destek olan danışman hocam Doç. Dr. Özge CAĞCAĞ YOLCU' ya teşekkürü bir borç bilirim.

Çalışmalarım boyunca beni hiçbir zaman yalnız bırakmayan manevi desteğini eksik etmeyen eşim Songül KİRİŞCİ' ye sonsuz teşekkür ederim.



İÇİNDEKİLER

TEŞEKKÜR.....	I
SİMGELER VE KISALTMALAR LİSTESİ	IV
ŞEKİLLER LİSTESİ	V
TABLOLAR LİSTESİ.....	VI
ÖZET.....	VII
SUMMARY	VIII
BÖLÜM 1. GİRİŞ.....	1
BÖLÜM 2. KAYNAK ARAŞTIRMASI.....	3
BÖLÜM 3. MATERYAL VE YÖNTEM	7
3.1. YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME	7
3.2. EVRİŞİMSEL SİNİR AĞLARI.....	9
3.2.1. EVRİŞİM KATMANI (EVRİŞİM İŞLEMİ)	13
3.2.2. HAVUZLAMA KATMANI (HAVUZLAMA İŞLEMİ)	16
3.2.3. TAM BAĞLANTILI KATMAN	17
3.2.4. AKTİVASYON FONKSİYONLARI	18
3.2.5. SEYRELTME KATMANI	18
3.2.6. OPTİMİZASYON YÖNTEMLERİ.....	19
3.3. EVRİŞİMSEL SİNİR AĞ MİMARİLERİ.....	19
3.3.1. LENET-5.....	19
3.3.2. ALEXNET	20
3.3.3. VGG-16.....	21
3.3.4. GOOGLNET (INCEPTION).....	22
3.3.5. MICROSOFT RESNET	23

BÖLÜM 4. ARAŞTIRMA BULGULARI.....	24
4.1. ÖNERİLEN YENİ ESA (CNN) TAHMİN MODELİ	24
 BÖLÜM 5. TARTIŞMA VE SONUÇ	29
5.1. VERİLERİN ORGANİZASYONU	29
5.2. PERFORMANS ÖLÇÜTLERİ.....	30
5.3. ALTERNATİF KARŞILAŞTIRMA MODELLERİ.....	30
5.4. METOT PERFORMANSLARININ DEĞERLENDİRİLMESİ.....	32
5.4.1. TAIEX VERİSİ SONUÇLARI VE TARTIŞMASI.....	32
5.4.2. FTSE VERİSİ SONUÇLARI VE TARTIŞMASI	37
 KAYNAKLAR	41
ÖZGEÇMİŞ	46

SİMGELER VE KISALTMALAR LİSTESİ

ADAGRAD	: Adaptive Gradient (Adaptif Eğitim)
Adam	: Adaptive Moment Estimation (Adaptif Moment Tahmin)
ARMA	: Otoregresif hareketli ortalama
ARIMA	: Otoregresif tümleşik hareketli ortalama
CNN	: Convolutional Neural Network
CPU	: Merkezi İşlem Birimi
DVM	: Destek Vektör Makineleri
ESA	: Evrimsel Sinir Ağları
FTSE	: Financial Times Stock Exchange
GPU	: Grafik İşlem Birimi
İMKB	: İstanbul Menkul Kıymetler Borsası
RGB	: Red, Green, Blue (Kırmızı, Yeşil, Mavi Renk Uzayı)
TAIEX	: Taiwan Stock Exchange
YSA	: Yapay Sinir Ağları
UKDH	: Uzun Kısa Dönem Hafıza

ŞEKİLLER LİSTESİ

Şekil 3.1. Bir sinir hücresinin biyolojik gösterimi ve matematiksel modeli.....	7
Şekil 3.2. Makine öğrenmesi ve derin öğrenme yöntemlerinin işlem adımları	8
Şekil 3.3. LENET-5 evrişimsel sinir ağı modeli	10
Şekil 3.4. Dijital bir görüntünün bilgisayar ortamında piksel görüntüsü	10
Şekil 3.5. Giriş verilerinin etiketlendirilmesi	11
Şekil 3.6. Bir nesnenin farklı açılardan görüntüsü	11
Şekil 3.7. Geleneksel bir evrişimsel sinir ağı mimarisi.....	12
Şekil 3.8. Evrişimsel sinir ağı için örnek bir filtre	13
Şekil 3.9. 5x5 boyutundaki veriye 3x3 filtre uygulanması	14
Şekil 3.10. Maksimum ve ortalama havuzlama sonrası çıkış verileri.....	16
Şekil 3.11. Evrişimsel sinir ağı modeli tam bağlantılı katman	17
Şekil 3.12. Seyreltme katmanı öncesi ve seyreltme katmanı sonrası ağ yapısı	19
Şekil 3.13. LeNet-5 ağı mimarisi	20
Şekil 3.14. AlexNet ağı mimarisi.....	21
Şekil 3.15. VGG-16 ağı mimarisi	22
Şekil 3.16. Inception bloğu mimarisi	22
Şekil 3.17. ResNet ağı artık bağlantı mimarisi	23
Şekil 4.1. Önerilen evrişimsel sinir ağı mimarisi.....	26
Şekil 5.1. TAIEX2000 verisi için dağılım grafiği.....	35
Şekil 5.2. TAIEX2001 verisi için dağılım grafiği.....	35
Şekil 5.3. TAIEX2002 verisi için dağılım grafiği.....	36
Şekil 5.4. TAIEX2003 verisi için dağılım grafiği.....	36
Şekil 5.5. TAIEX2004 verisi için dağılım grafiği.....	36
Şekil 5.6. Bulanık temelli yöntemlere göre iyileşme yüzdeleri	38
Şekil 5.7. YSA temelli yöntemlere göre iyileşme yüzdeleri	39

TABLÖLAR LİSTESİ

Tablo 3.1. Aktivasyon fonksiyonları.....	18
Tablo 5.1. TAIEX ve FTSE veri organizasyonu.....	29
Tablo 5.2. TAIEX için modellerin tahmin performansları	33
Tablo 5.3. Lineer regresyon modeli karakteristikleri.....	34
Tablo 5.4. FTSE veri seti için modellerin tahmin performansları	38

YENİ BİR EVRİŞİMSEL SİNİR AĞI MODELİ İLE ZAMAN SERİSİ ÖNGÖRÜSÜ

ÖZET

Zaman serisi tahmini, birçok bilimsel alanda, her zaman çekici bir konu olmuştur. Özellikle finansal zaman serileri tahmini, geniş uygulama alanları ve onlar üzerine olan önemli etkisi nedeniyle oldukça çekici bir konu haline gelmiştir. Bu doğrultuda, finansal zaman serisi tahmini için evrişimsel sinir ağları (ESA (CNN)) gibi çeşitli hesaplamalı zekâ teknikleri kullanılmaktadır. Ancak şimdiye kadar bildirilen bu çalışmalarda, finansal zaman serilerinin tahmininde ESA (CNN) nadiren tercih edilmiştir. Ve hemen hemen tüm çalışmalarda, zaman serilerinin zaman dizisi etkisi, görüntü dönüşümü nedeniyle tahminler üzerinde korunmamaktadır. Bu noktadan hareketle bu tez kapsamında yeni bir ESA (CNN) tahmin modeli tanıtılarak, görüntü dönüştürme sürecinde oluşabilecek bilgi kayıplarının önüne geçilmesi ve zaman serilerinin tahmin üzerine olan özelliklerinin başarılı bir şekilde ortaya çıkarılması amaçlanmaktadır. Önerilen ESA (CNN) tahmin modeli, üç evrişim katmanı ve beş tam bağlantılı katmandan oluşmaktadır, ayrıca girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri belirlemek için Relu ve Elu aktivasyon fonksiyonları tercih edilmiştir. Önerilen sistemin performansını değerlendirmek için model, finansal zaman serileri literatüründe sıklıkla kullanılan Tayvan Menkul Kıymetler Borsası Kapitalizasyon Ağırlıklı Hisse Senedi Endeksi (TAIEX) ve Londra borsa verilerine uygulanmıştır. Sonuçlar, hata kriteri, regresyon analizi ve ayrıca görsel gösterim olmak üzere farklı açılardan değerlendirilmiştir. Önerilen modelinin üstün tahmin performansı, elde edilen sonuçların farklı yapay sinir ağları, uzun kısa dönem hafıza, bulanık tabanlı yaklaşımlar ve bazı geleneksel yöntemler gibi son teknoloji tahmin araçlarıyla karşılaştırılmasıyla gözlemlenmiştir.

Anahtar kelimeler: Evrişimsel sinir ağları, finansal zaman serileri, tahminleme, derin öğrenme

TIME SERIES PREDICTION WITH A NEW CONVOLUTIONAL NEURAL NETWORK MODEL

SUMMARY

Time series forecasting has always been an attractive issue in the most scientific area. In particular financial time series forecasting has become quite attractive topics owing to its broad implementation areas and substantial impact. Therefore, various types of computational intelligence techniques such as convolutional neural networks (CNNs) have been used for financial time series forecasting. However, in these studies reported so far, CNNs have been rarely preferred for the forecasting of financial time series. And almost all-studies time sequence effect of time series is not preserved on forecasts because of image transformation. From this point of view, within the scope of this thesis, by introducing a new CNN prediction model, it is aimed to prevent information loss that may occur in the image transformation process and to successfully reveal the properties of time series. The proposed CNN forecasting model consists of three convolutional layers and five fully connected layers, also Relu and Elu activation functions have been preferred to determine the nonlinear relations between inputs and outputs. In order to evaluate the performance of the proposed system, the model has been applied to Taiwan Stock Exchange Capitalization Weighted Stock Index (TAIEX) and London stock market data, which are frequently used in financial time series literature. The results have been evaluated on different aspects as an error criterion, a regression analyses and also a visual demonstration. Outstanding forecasting performance of the proposed CNN model has been observed by comparing the obtained results with some state-of-the-art forecasting tools such as different kinds of Artificial Neural Networks (ANN), Long Short-Term Memory (LSTM), fuzzy-based approaches, and some traditional methods.

Keywords: Convolutional neural network, financial time series, forecasting, deep learning

BÖLÜM 1. GİRİŞ

Yapay zekâ bir bilgisayarın ya da bir robotun, canlılara benzer şekilde düşünme, karar verme, algılama ve sorun çözme gibi bilişsel fonksiyonları ve otonom davranışları yerine getirme kabiliyetini sağlayan sistemdir. Yapay zekâ alanında yapılan ilk çalışmalar Turing makinelerine kadar giden bir sistemdir. Turing makineleri geliştirilirken insanın düşünme yöntemlerinden yararlanılmıştır. İnsandaki düşünme yöntemlerinden yararlanılırken insandaki yapay sinir ağları taklit edilerek matematiksel modellemesi yapılmıştır. Tanımlanan bu yapay sinir ağ modellerinin aynı insanda olduğu gibi uygun şekilde tanımlanmaları halinde öğrenme yeteneğinin kazandırılabilceği görüşü ortaya çıkmıştır.

Son dönemlerde derin öğrenme modelleri ise yapay sinir ağlarının bir alt tekniği olarak uygulanmaya başlanmıştır. Derin öğrenme teknolojisi, herhangi bir bilgisayarın ya da robotun görüntü ve ses tanınmasında, kendi kendine karar verebilen otonom araçların kullanılmasında, pazarlama alanında kullanılmak üzere büyük verilerin analizinde popüler olarak kullanılmaya başlanmıştır.

Derin öğrenme modellerinden biri olan evrişimsel sinir ağları, klasik yapay sinir ağlarına göre kendine has katmanları sayesinde özellikle nesnelerin sınıflandırılmasında, yüz tanıma işlemlerinde, görüntü işlemede ve analizinde oldukça başarılıdır. Son yıllarda yapılan çalışmalarda bilgisayarlı görü işlemlerinde en iyi çözümlere evrişimsel sinir ağları ile ulaşılmıştır. Yapay sinir ağları insandaki sinir hücreleri taklit edilerek oluşturulmuşken evrişimsel sinir ağları insanlarda bulunan görsel korteks bölgesinden esinlenerek oluşturulmuştur. Her sene sanal ortamda artan veri miktarı ve gelişen donanım birimleri sayesinde derin ve karmaşık yapıdaki evrişimsel sinir ağ modelleri geliştirilmiş ve başarılı sonuçlar elde edilmiştir.

Bu tez kapsamında genellikle görüntü sınıflamada kullanılan evrişimsel sinir ağları ile zaman serisi gözlemleri bir görüntü verisi gibi kullanılarak tahminleme yapılmıştır.

Geliştirilen ESA modeli ile ilgili literatürde yaygın olarak kullanılan TAIEX ve FTSE veri setleri detaylı olarak analiz edilmiştir. Elde edilen sonuçlar zaman serisi analiz yöntemlerinde önemli yer tutan model ve yöntemlerle karşılaştırmalı olarak değerlendirilmiştir.

Tezin devamı şu şekilde kurgulanmıştır: İkinci bölümde zaman serisi analizlerinde kullanılan yöntemler ve evrimsel sinir ağ modellerinin literatürde yapılmış olan çalışmalar incelenmiştir. Üçüncü bölümde ESA (CNN) modellerine ilişkin bir teorik altyapı detaylı olarak incelenmiş ve dördüncü bölümde araştırmanın metodolojisi sunulmuştur. Uygulamaların detayları ve sonuçları beşinci bölümde karşılaştırmalı olarak yorum ve değerlendirmelerle verilmiştir. Son olarak da elde edilen bulgular ve sonuçlar son bölümde tartışılmıştır.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Zaman serisi tahmin yöntemleri, sahip oldukları avantajlar göz önüne alındığında, finansal piyasa tahmini, borsa, hava durumu ve çevresel durum tahmini, enerji tüketimi vb. birçok alanda yaygın olarak kullanılmaktadır. Zaman serisi tahmin yöntemlerine ait literatür incelendiğinde, finansal zaman serisi tahminlerinin geniş bir kullanım alanına sahip olduğu ve piyasaların gelecek planları ve davranışları üzerinde önemli bir etkiye sahip olduğu görülmektedir. Bu alanlarda farklı tahmin araçlarını kullanan çok sayıda çalışma olmasına rağmen, bu yöntemlerden zaman serilerinin doğru ve yansız tahminini elde etmek her zaman mümkün olamamaktadır. Bu gibi durumlarda gelişmiş tahmin modellerine olan gereklilik kaçınılmazdır.

Literatürde, zaman serisi analizi ve tahmini için uyarlanmış farklı metodolojiler vardır. Otoregresif hareketli ortalama (ARMA), otoregresif tümleşik hareketli ortalama (ARIMA), eğri uydurma, regresyon analizi, Bayesian analiz ve Kalman Filtresi yöntemleri zaman serisi analizleri sürecinde en çok bilinen ve kullanılan yöntemlerdir. Bu geleneksel yaklaşımların yanı sıra özellikle son yıllarda makine öğrenme tekniklerinin, daha doğru tahminler yapmak için tercih edilen yöntemlerden olduğu görülmektedir. Bu alanda farklı tahmin araçlarını kullanan çok sayıda çalışma mevcuttur. Krollner ve ark. (2010) farklı makine öğrenimi tabanlı modellerden borsa tahmin veri setlerini değerlendirmiştir. Cavalcante ve ark. (2016) yapay sinir ağları (YSA), destek vektör makineleri (DVM), hibrit mekanizmalar, optimizasyon ve topluluk yöntemleri gibi pek çok tahmin modeli yaklaşımını araştırmıştır. Hisse senedi piyasası endeksinin tahmini Wang ve ark. (2010) tarafından 2009 ve 2010 yılında ortaya koydukları çalışmalarda incelenmiştir. Kara ve ark. (2011) çalışmasında, İstanbul Menkul Kıymetler Borsası (İMKB) Ulusal 100 Endeksi'nin yönlü tahmin hareketini YSA ve DVM aracılığıyla tahmin etmişlerdir. Chen ve ark. (2003) daha iyi

tahmin sonuçları elde edebilmek için, TAİEX zaman serilerini, yeni bir YSA modelinden yararlanarak değerlendirmişlerdir. Ayrıca NASDAQ Hisse Endeksi verileri için çok katmanlı algılayıcı (ÇKA) ve dinamik YSA'nın tahmin performansı arasındaki fark da Güreşen ve ark. (2011) tarafından araştırılmıştır. Kim ve Han (2000), Qiu ve Song (2016), Qiu, Song ve Akagi (2016) başlangıç değerini bulmak için Genetik algoritma (GA)'yı kullanmayı tercih etmişlerdir ve YSA'nın ağırlıklarından oluşturulan hibrit yöntem, Nikkei 225 endeks getiri tahmini için standart YSA tabanlı yöntemlerden daha iyi performans göstermiştir. Vanstone ve ark. (2012) birçok katmanlı algılayıcı (ÇKA) modeli önererek, Avustralya pazarının alım satım noktaları hakkında fikir verebilecek bir sistem oluşturmayı başarmışlardır. Bu çalışmaların yanı sıra, makine öğrenme modelleriyle rekabet eden bulanık tabanlı yöntemler olarak adlandırılan finansal zaman serileri tahmini için kullanılan başka tür tahmin araçları da literatürde oldukça geniş yer tutmaktadır (Baş ve ark., 2015; S. M. Chen, 1996; S. M. Chen, 2015; Eğrioğlu ve ark., 2010, 2015; Huarng, 2001; Huarng ve Yu, 2006; Jang, 1993; Sarıca ve ark., 2018; Song ve Chissom, 1993; Türksen, 2008).

Ayrıca genetik algoritma ile eğitilmiş derin bir ÇKA modeli Sezer ve ark. (2017) tarafından, Dow Jones hisse senedi endeksini tahmin edebilmek için ortaya konmuştur. GA'nın yanı sıra parçacık sürüsü optimizasyonu (PSO), finansal zaman serisi tahmini için sunulan tahmin araçlarının performansı üzerinde de önemli bir etkiye sahiptir. Pulido ve ark. (2014) Meksika Menkul Kıymetler Borsası tahmini için PSO tarafından eğitilmiş yeni bir ÇKA önermişlerdir. Bu çalışmaların yanı sıra, piyasadaki hisse senetlerinin hareketlerini tahmin etmek için Ballings ve ark. (2015) topluluk çözümlerinin (Ratgele Orman (Random Forest), AdaBoost ve Kernel Factory) ve sınıflandırıcı modellerin (YSA, Lojistik Regresyon, VDM ve KNN) performansları arasındaki farkı incelemişlerdir. Özellikle son zamanlarda büyük verilerin analizinin gerekliliği ile ilgili olarak araştırmacılar, ESA (CNN), UKDH (LSTM) ve diğer yaklaşımlar gibi derin sinir ağlarını (DNN'ler) kullanmaya yönelmişlerdir. ESA (CNN) modellerinin çoğu görüntü/video işleme, sınıflandırma, test algılama ve tanıma ve benzeri alanlarda sıklıkla tercih edilirken, önemli tarihsel özellikleri çıkarmak için dahili belleğe sahip Tekrarlayan Sinir Ağı (TSA (RNN)) zaman serileri tahmini için

oldukça cazip yöntemlerdir. Literatürde Krizhevsky ve ark. ImageNet'in sınıflandırılması için ESA (CNN)'dan yararlanmış olmakla beraber, (Krizhevsky ve ark., 2017), Karpathy ve ark. (2014) bunu büyük ölçekli video cümle sınıflandırması ve cümle modelleme için kullanmışlardır. Krauss ve ark. (2017) ortaya koydukları çalışmada, derin sinir ağlarını, gradyan destekli ağaçları, rastgele orman (RF) yöntemlerini karşılaştırmayı amaçlamışlardır. Ayrıca Ding ve ark. (2015) internetten ve gazetelerden haber metinleri, bilgiler çıkarabilmek için olay odaklı borsa tahmini için derin öğrenme yöntemini tanıtmışlardır. Tino ve ark. (2001) Alman DAX ve İngiliz FTSE endeksleri için finansal değişiklik ticaretinde Markov modeli ve TSA (RNN)'nın kullanıldığı karşılaştırmalı bir çalışma ortaya koymuşlardır. Deng ve ark. (2017) tarafından Çin vadeli işlem piyasası ve emtia vadeli işlem piyasası hakkında bazı çıkarımlar yapmak için derin doğrudan pekiştirme yöntemi ve tekrarlayan DAN ile bulanık derin doğrudan pekiştirme yöntemi kullanılmıştır. Finansal analiz için derin öğrenme modellerinin kullanıldığı literatür incelendiğinde, hisse senedi fiyat dalgalanmalarının tahminine ilişkin birkaç rapor dışında oldukça sınırlı çalışma göze çarpmaktadır (Aggarwal ve Aggarwal, 2017; Bao ve ark., 2017; Chong ve ark., 2017; Di Persio ve Honchar, 2016; Yoshihara ve ark., 2014). Öte yandan, Yeh ve ark. (2015) hisse senedi fiyat dalgalanmalarını tahmin etmek için derin öğrenme yöntemine dayalı bir yöntem önermişlerdir. Literatür incelendiğinde ESA (CNN)'nın borsa tahmini için kullanıldığı sadece sayılı birkaç çalışma görülmektedir. Di Persio ve Honchar (2016), S&P 500 endeksinin kapanış fiyatlarına ait verilere ESA (CNN), UKDH (LSTM) ve ÇKA (MLP)'yı kullandıkları çalışmayı önermişlerdir. Arevalo ve ark. (2016) Apple Inc.'in hisse senedi fiyatının tahmini için beş gizli katmandan oluşan derin bir YSA modeli önermişlerdir. Gündüz ve ark. (2017) ise İstanbul borsasının tahmin sonuçlarını elde edebilmek için ESA (CNN) kullanmayı tercih etmişlerdir. Bununla beraber Nelson ve ark. (2017) Brezilya hisse senedi fiyatlarının yönünü tahmin etmede UKDH (LSTM)'dan yararlanmışlardır.

Literatürdeki çalışmalar detaylıca incelendiğinde, ESA (CNN)'ların finansal analizler için olan uygulamalarının sadece az sayıda çalışmada rapor edildiği görülmektedir. Bu durumun nedeni ESA (CNN)'ların yapısı ile açıklanabilir. Çünkü literatürde kullanılan ESA (CNN)'lar çoğunlukla görüntü tespiti için daha uygunken, mali tablolar dahil


olmak üzere genel sayısal veriler için daha az uygulama alanına sahiptir. Bunun yanı sıra, literatürde finansal tahminler için kullanılan sınırlı sayıdaki ESA (CNN) çalışmalarında, zaman serisi gözlemleri görüntüye dönüştürülerek işlemler gerçekleştirilmektedir. Ancak bu noktada uygulanan ekstra görüntü dönüşümünün bilgi kaybına ve zaman serisinin zaman dizisi özelliğinin kesintiye uğramasına ve dolayısıyla tahmin performansının bozulmasına neden olacağı unutulmamalıdır. Farklı yapılara sahip uygun bir ESA (CNN) modeli oluşturmak, ESA (CNN) yöntemlerini zaman serilerinin tahmininde daha uygulanabilir hale getirebilir ve finansal zaman serilerinin tahmin performansını daha iyiye taşıyabilmektedir. Bu anlamda bu tür bilgi kayıplarına, kesintilere ve bozulmalara neden olmayan bir ESA (CNN) modeli oluşturmak ve bu amaca uygun bir çalışma prensibi ortaya koymak bu tezin temel motivasyonudur. Bu noktadan hareketle, bu tez kapsamında, finansal zaman serileri için tatmin edici tahmin sonuçları elde edebilmek adına, bu tür sorunları ve kusurları olmayan, zaman serisi analizine uygun yeni bir ESA (CNN) modeli önerilmiştir.

Ayrıca, tez kapsamında, finansal zaman serisi analiz problemi için önerilen ESA (CNN) yapısının üstün tahmin performansını kanıtlamak için, ilgili literatürde yaygın olarak kullanılan TAIEX veri setlerinin detaylı incelenmesi yapılarak tahmin sonuçları elde edilmiştir. Ayrıca önerilen modelin sonuçlarını destekleyebilmek, performansını kanıtlayabilmek adına farklı bir zaman serisi olan FTSE veri setleri de detaylı olarak analiz edilmiştir. Elde edilen sonuçlar, geleneksel yöntemler başta olmak üzere, bulanık tabanlı modeller, derin sinir ağı modelleri vb. gibi literatürde önemli yer tutan model ve yöntemlerle karşılaştırmalı olarak değerlendirilmiştir. Bunların yanı sıra tez kapsamında, önerilen modelin performansını farklı açılardan da gösterebilmek için ayrıntılı regresyon analizleri ve çıktıları da elde edilmiş ve yorumlanmıştır. Ayrıca tüm bulguları görsel açıdan da desteklemek için önerilen yöntem sonuçlarına ait dağılım grafikleri de sunulmuştur.

BÖLÜM 3. MATERYAL VE YÖNTEM

3.1. Yapay Sinir Ağları ve Derin Öğrenme

Derin öğrenme yapay zekâ yöntemlerinden biri olan makine öğrenmesinin popüler alt bir yaklaşımıdır. Derin öğrenmede kullanılan yöntemler yapay sinir ağlarının daha karmaşık bir halidir. Yapay sinir ağları beyindeki sinir hücrelerinin çalışma mantığı taklit edilmeye çalışılarak oluşturulmuştur. Derin öğrenme mimarileri yapay sinir ağlarına göre katman sayısı oldukça fazladır ve daha fazla verinin çözülmesinde kullanılabilir.




Şekil 3.1. Bir sinir hücresinin biyolojik gösterimi ve matematiksel modeli

Canlıların davranışlarını inceledikten sonra matematiksel olarak modelleyip daha sonra benzer yapay modellerin üretilmesine sibernetik denir. Eğitilebilir ve kendi kendine öğrenebilen ve değerlendirme kabiliyetine sahip olan yapay sinir ağları ile insan beyninin işleyiş yapısı modellenmeye çalışılmaktadır. İnsanlarda olduğu gibi makinelerin öğrenmesi ve karar vermesi amaçlanmaktadır.

Şekil 3.1’de canlılardaki sinir hücresinin biyolojik gösterimi yer alırken sağda ise matematiksel hale dönüştürülmüş modeli yer almaktadır. Sinir hücresinde bulunan dendrit uçlarından giriş verileri ve bu giriş verilerinin ağırlıkları birlikte gelmektedir.

Sinir hücresine gelen bu giriş verileri ve ağırlıklar çarpılmakta ardından bir yan değer ile toplanmaktadır. Oluşturulan bu değer akson boyunca iletilerek bir başka sinir hücresine aktararak istenen bilgi aktarılmaktadır. Bir yapay sinir ağının en basit halini Şekil 3.1’de sağ taraftaki gibi modellediğimizde; giriş değerleri ve bu giriş değerlerinin kendilerine has ağırlık değerleri ile çarpıldıktan sonra bir yan değer ile toplanıp aktivasyon fonksiyonundan geçirildikten sonra çıkışa iletilmektedir.

Derin öğrenme yöntemlerini makine öğrenmesi yöntemlerinden ayıran en önemli fark nesnelerin öz niteliklerini kendi kendine çıkartması ve sınıflandırmasına karar vermesidir. Makine öğrenmesi yöntemlerinde öz nitelik çıkarmak işlemi ciddi bir iş olmakla birlikte öz nitelik çıkarma mühendisliği gibi bir meslek de bulunmaktadır. Makine öğrenmesinde çıkartılan öz niteliklerin hangisi yararlı ya da kullanabilir bunun ayrımını yapmak kullanıcının yapacağı testlerle belirlenmekteydi fakat derin öğrenme yöntemlerinde bu eksiklik ortadan kalkmıştır. Derin öğrenme yöntemleri eğitim verilerinin fazlalığı sayesinde öz nitelikleri kendisi belirler ve sürekli güncelleyebilir. Şekil 3.2 ‘de makine öğrenmesi ve derin öğrenme yöntemlerinin öz nitelik çıkarma ve sınıflandırma işlemlerinde izledikleri yollar gösterilmiştir.



Şekil 3.2. Makine öğrenmesi ve derin öğrenme yöntemlerinin işlem adımları


Derin öğrenme yöntemlerinin günümüzde popüler olma nedenlerinden bir diğeri ise büyük verilerde analiz yapma yetenekleridir. Makine öğrenmesi yöntemleri büyük verilerde çalışırken performans sıkıntısı oluşturmaktadır. Günümüzde milyarlarca cihaz ile birçok veri dijital ortamda paylaşılmaktadır, bu verilerin özellikle de

pazarlama açısından analiz edilmesinde yapay zekâ yöntemlerinden biri olan derin öğrenme modelleri kullanılmaktadır. Yapay zekâ modellerinin kullanılmasında donanımda önemli bir konu haline gelmiştir. Merkezi işlem birimi (CPU) ve GPU kullanılarak çalıştırılan evrişimsel sinir ağı modelleri karşılaştırıldığında GPU performansı daha iyi performans göstermiştir. GPU donanımları sayesinde işlem gücü farklı işlem birimlerine dağıtılarak yüksek paralel işlem gücüne ulaşılırken bellek problemleri giderilmiştir.

3.2. Evrişimsel Sinir Ağları


Evrişimsel sinir ağları (ESA) uygulama ve araştırma alanlarında son 10 yılda önemli gelişme göstermiştir. Günümüzde büyük verilerle yapılan araştırma çalışmalarının artması ve uygulama alanlarında geliştirilen özellikle son yıllarda kullanımı artan otonom araçlar ve robotların hayatımızda yer bulması yapay sinir ağı türlerinden biri olan ESA'nın kullanımını artırmıştır. ESA'nın yüksek doğruluk ile çalışması ve biyolojik temellere dayandırılması ile birçok gelişmiş mimariye sahip ESA modeli oluşturulmuştur. ESA modelleri genellikle görüntü sınıflandırma, nesne tespiti, nesne takip etme, doğal dil işleme, yüz tanıma, otonom araçların hareket kabiliyeti gibi problemlerin çözümünde kullanılmaktadır.

1989 yılında yayınlanan ve ilk başarılı sonucu veren evrişimsel sinir ağı modeli Lenet-5 modelidir (Lecun ve ark., 1989). Şekil 3.3'te LeNet-5 modelinin yapısı gösterilmektedir. LeNet-5 modeli Yann Lecun ve ekibi tarafından posta numaraları ve banka çekleri üzerindeki sayıların okunması için geliştirilmiştir. Farklı yazı karakterleriyle yazılmış farklı büyüklüklerdeki rakamları tanıyan bir evrişimsel sinir ağı modelidir.



Şekil 3.3. LENET-5 evrimsel sinir ağı modeli (Lecun ve ark., 1989)

Evrimsel sinir ağı modelleri genellikle görüntü verileri ile çalıştığı için giriş verilerimizin formatını bilmemiz gerekir.




Şekil 3.4. Dijital bir görüntünün bilgisayar ortamında piksel görüntüsü

Nesnelere baktığınızda bakmak ile görmek arasında fark olduğunu biliyoruz. Bakmak işlemi sadece gözde sınırlı kalırken baktığınız nesneyi görmek veya sınıflandırma işlemi beyinde yapılmaktadır. Yapay sinir ağları beyindeki sinir hücrelerinin çalışma mantığı taklit edilmeye çalışılarak oluşturulmuştur. Evrimsel sinir ağları ise beyindeki görme işleminin gerçekleştiği görsel korteks bölgesinden biyolojik bir ilham alır. Bilgisayarda bir görüntü incelendiğinde resimler sayısal olarak görünür. Renklere karşılık gelen bir sayıdan oluşan buradaki en küçük hücreye piksel adı verilir. Şekil 3.4'te görüldüğü üzere bilgisayar görüntüleri piksellerden oluşan bir matris şeklinde görünür. Fakat buradaki durum şu ki bu sayı dizisi bilgisayar için bir anlam ifade etmemektedir. Bu yüzden evrimsel sinir ağ modelimizi eğitmek için giriş verilerimizi Şekil 3.5'teki gibi etiketlendiriyoruz.


GİRİŞ VERİSİ

ETİKETLENDİRME




Şekil 3.5. Giriş verilerinin etiketlenilmesi

Veri çeşitliliğine bağlı olarak etiketlendirmiş görüntülerle evrimsel sinir ağı modeli eğitilir. Evrimsel sinir ağı modelini eğitirken Şekil 3.6'daki gibi bir nesne için farklı açılardan görüntü kullandığında veya o nesnenin farklı ışıklı ortamlarda verisine sahip olduğunda o nesne için daha iyi eğitilmiş duruma gelmektedir.



Şekil 3.6. Bir nesnenin farklı açılardan görüntüsü

Geleneksel ESA mimarisi genelde girdi katmanı, evrişim katmanı, havuzlama katmanı, tam bağlantımlı katman (fully-connected layer) ve çıktı katmanı olmak üzere Şekil 3.7’de görüldüğü üzere beş ana katman içerir. Günümüze kadar bu katmanların farklı kombinasyonları ve dizilimleri kullanılarak Alexnet, Googlenet, Resnet, VGG-16 gibi birçok farklı ESA mimarileri oluşturulmuştur.



Şekil 3.7. Geleneksel bir evrişimsel sinir ağı mimarisi (Amidi, 2019)


Evrişimsel sinir ağı modelini oluşturan temel katmanlara baktığımızda giriş görüntüsü bulunmakta ve bu giriş görüntüsünün öz niteliklerinin çıkarıldığı ilk katman evrişim katmanıdır. Evrişim katmanındaki filtreler sayesinde görüntünün temel öz nitelikleri bu katmanda çıkarılmaktadır. İkinci temel katman ise ortaklama veya havuzlama katmanı olarak isimlendirilmektedir. Havuzlama katmanı evrişimsel sinir ağı modellerinde evrişim katmanından çıkan öz niteliklerin boyutunu yarıya indirmek için kullanılır. Görüntülerle çalışıldığı için havuzlama katmanında öz niteliklerin boyutu yarıya indirilerek sinir ağı modelinin daha hızlı çalışmasını ve daha temel öz niteliklere sahip olunması sağlanmaktadır. Havuzlama katmanından elde edilen öz nitelikler düz bir vektör haline getirilerek birbirleriyle tam bağlantılı olan tam bağlantı katmanına aktarılır ve son olarak eğitilen modelden tahminler elde edilerek modelin performansı ölçülmektedir. Bu bölümde ESA modellerinde kullanılan katmanlar ve işlemler daha ayrıntılı olarak incelenecektir.

3.2.1. Evrişim Katmanı (Evrişim İşlemi)

Evrişimsel sinir ağlarının en temel katmanı evrişim katmanıdır. Evrişim katmanı yaygın olarak konvolüsyon katmanı olarak da bilinmektedir. Evrişim katmanının amacı girdi katmanındaki verilerin özniteliklerini çıkarmaktır. Evrişim katmanında yapılan işlemde girdi görüntüsü ilk parametre olurken ikinci parametre filtre (kernel) olarak bilinmektedir. Girdi verileri üzerinde belirleyeceğimiz boyutlarda filtre matrisleri yatay ve dikey olarak dolaştırılır. Her kaymada girdi verisi ile filtre matrisinin kesişen verileri çarpılıp sonuçlar toplanır. Toplanan değerler sonucu elde edilen matrislere öznitelik haritası denilmektedir. Oluşturulan öznitelik haritalarında girdi verisinin düşük ve yüksek boyuttaki öznitelikleri elde edilmiş olur. Bu durum da girdi verilerinden anlamlı parametrelerin depolanması anlamına gelir ve verimliliği artırır.

Filtreler girdi verilerinin büyüklüğü ve kullanılan donanım mimarisi de göz önünde bulundurularak seçilir. Filtre matrisleri genelde 2x2, 3x3, 5x5, 7x7 ve 9x9 büyüklüğünde seçilir. Filtre matrislerinin boyutuna bağlı olarak çıkarılan özniteliklerin büyüklüğü ve sayısı değişmektedir. Daha küçük boyutta filtre matrisleri kullanıldığı takdirde öznitelikler daha detaylı olacaktır fakat büyük veriler ile çalışıldığında işlem yükü artacağından analiz performansı düşecektir.


Evrişim katmanında kullanılan 3x3'lük filtre örneği Şekil 3.8'de yer almaktadır.



2	0	2
2	2	1
2	0	1

Şekil 3.8. Evrişimsel sinir ağı için örnek bir filtre

Filtre, girdi üzerinde kayarak ilerletilir. 3x3 boyutunda bir filtrenin 5x5 boyutlarındaki bir veriye adım sayısı 1 olacak şekilde uygulanması Şekil 3.9'da gösterilmiştir.



Şekil 3.9. 5x5 boyutundaki veriye 3x3 filtre uygulanması

Şekil 3.9’ da belirtilen tek katmanlı evrişim işlemine bir örnektir. Bu işlem N katmanlı veriler için de geliştirilerek uygulanabilir. Örnek olarak 4 katmanlı bir veri kullanılacaksa, filtre de 4 katmanlı olmalıdır. Filtrenin her katmanı ona karşılık gelen girdinin ilgili katmanında kayarak ilerleyecektir.

Girdi olarak resim gibi iki boyutlu bir girdi kullanıldığında evrişim işlemi, denklem (3.1) ile ifade edilir.

$$S(i, j) = (I * K)(i, j) \sum_m \sum_n I(i, j) K(i - m, j - n) \quad (3.1)$$

Denklem 3.1’de ii ve jj terimleri, evrişim işlemi sonucunda elde edilecek yeni matrisin konumlarını ifade etmektedir.

Evrişimsel sinir ağı modellerinde katmanlardaki işlem yükünü ve ne kadar boyutta bir öznitelik matrisi oluşturulduğunu saptayabilmek için evrişim işlemi sonucunda çıkan matrisin boyutunun bilinmesi gerekmektedir.

Evrişim işlemi uygulanacak matris 7x7 boyutunda olup uygulanacak filtre ise 3x3 boyutundadır. Evrişim işlemi sonucunda çıkış matrisinin boyutunun hesaplanması için kullanılan hesaplama denklem 3.2’de verilmiştir.

$$\frac{n + 2p - f}{s} + 1 \quad (3.2)$$

Denklem 3.2’de yer alan n ; girdi verisi olan matris boyutlarını,
 p ; eğer varsa dolgulama boyutunu,
 f ; evrişim filtresi boyutunu,
 s ; eğer varsa adım kaydırma değerini ifade etmektedir. Eğer dolgulama ve adım kaydırma özellikle belirtilmemişse bu değerler sırasıyla 0 ve 1 olarak alınmaktadır. Denklem 3.3’te 7x7 boyutunda olan bir veriye 3x3 boyutunda filtre ile evrişim işlemi uygulanarak çıktı matrisinin boyutu hesaplanmıştır.

$$\frac{n + 2p - f}{s} + 1 = \frac{7 + 2 * 0 - 3}{1} + 1 = 5 \quad (3.3)$$


Denklem 3.3’te görüldüğü üzere evrişim işlemi sonucunda oluşturulan öznitelik matrisinin boyutu 5x5 olarak elde edilmiştir.

Tek katmanlı veriler için evrişim işlemi sonucunda oluşacak çıkış matrisinin boyutu yukarıdaki gibi hesaplanmaktadır ancak giriş verisi üç katmanlı bir yapıda olduğunda evrişim işleminde kullanılacak filtre katman sayısı da üçe çıkarılmalıdır. Örnek verilecek olursa RGB formatında yani üç katmanlı bir görüntü verisi için denklem 3.2’deki hesaplama üç ayrı katman içinde ayrı ayrı yapılır. Çıkış matrisi de yine üç katmanlı olacaktır.

3.2.2. Havuzlama Katmanı (Havuzlama İşlemi)

Evrişim katmanından sonra elde ettiğimiz öznitelik matrislerinin boyutunu düşürmek için havuzlama katmanı kullanılır. Havuzlama katmanında uygulanan işlemler sonucu evrişim matrislerinin genişlik ve yükseklikleri azaltılarak bilgi kaybı oluşuyor gibi gözükse de ilerleyen aşamalarda daha az veri yükü sisteme sağlanmış olur. Havuzlama katmanı sayesinde evrişim matrislerindeki öznitelikler daha küçük boyutta neredeyse aynı bilgiyi içermektedir. Ayrıca havuzlama katmanlarının evrişimsel sınır ağlarında aşırı öğrenmenin önüne geçtiği görülmektedir (İnik ve Ülker, 2017).

Havuzlama katmanları günümüzde ortaklama katmanı olarak da isimlendirilir. Havuzlama katmanının türüne göre belirlenen filtreler evrişim katmanında elde edilen öznitelik matrisleri üzerinde önceden belirlenmiş bir adım sayısına göre gezdirilir. Gezdirme işlemi sırasında girdideki verilerin maksimum değerleri alınarak (maksimum havuzlama) ya da girdideki verilerin ortalaması alınarak (ortalama havuzlama) işlem yapılır. Tüm gezdirme işleminden sonra çıkış matrisi oluşturulur ve bu sayede öznitelik matrislerinin daha küçük boyutu elde edilmiş olur. Şekil 3.10'da 4x4 boyutundaki bir giriş verisine 2x2 boyutunda havuzlama filtresi maksimum havuzlama ve ortalama havuzlama yöntemleriyle adım sayısı 2 olacak şekilde uygulanmıştır ve çıkış matrisleri elde edilmiştir.




Şekil 3.10. Maksimum ve ortalama havuzlama sonrası çıkış verileri

Havuzlama katmanının çıktı boyutunun (o); girdi boyutu (i), işlemin gerçekleştirileceği pencere (parça) boyutu (k) ve adım sayısı (s) ile ilişkisi denklem 3.4'te gösterilmektedir.

$$o = \left\lfloor \frac{i - k}{s} \right\rfloor + 1 \quad (3.4)$$

3.2.3. Tam Bağlantılı Katman

Evrişim katmanlarında elde edilen öznitelik matrisleri aktivasyon fonksiyonlarından geçirildikten sonra genellikle havuzlama katmanı işlemi uygulanır. Havuzlama katmanı işleminden sonra birçok öznitelik matrisi elde edilmektedir. Bu öznitelik matrisleri, düzleştirme işlemi ile tek bir vektör haline getirildikten sonra klasik yapay sinir ağlarında olduğu gibi çok sayıda sinir hücresine sahip gizli katman sayısını istediğimiz miktarda belirleyeceğimiz yapıdır. Bu katmandaki nöronlar önceki katmandaki nöronlara tamamen bağlantılıdır. Şekil 3.11'de tek vektör haline getirilmiş bir öznitelik matrisinin her bir biriminin tüm nöronlara bağlantılı olduğu görülmektedir. Genellikle tam bağlantılı katmanlar evrişimsel sinir ağı mimarisinin sonunda kullanılır.



Şekil 3.11. Evrişimsel sinir ağı modeli tam bağlantılı katman (Amidi, 2019)

Tam bağlantılı katmandaki son nöron sayısı belirlenerek istenilen sayıda sınıflama yapılır ya da skaler bir sayı üretilerek tahmin işlemi yapılır.

3.2.4. Aktivasyon Fonksiyonları

Aktivasyon fonksiyonları genellikle evrişim katmanında elde edilen öznitelik matrisleri üzerinde kullanılır. Aktivasyon fonksiyonları sinir ağlarında lineer ifadelerin lineer olmayan ifadelere dönüştürülmesinde kullanılır. Bu işlem için genellikle sigmoid, ReLU, tanh, elu ve softmax fonksiyonları yaygın olarak kullanılır. ReLU'nun evrişimsel sinir ağlarında daha etkili olduğu tespit edilmiştir ve en yaygın kullanılan aktivasyon fonksiyonu türüdür. (Krizhevsky ve ark., 2012). Günümüzde kullanılan birçok aktivasyon fonksiyonu geliştirilmiştir ve bunlardan en çok tercih edilenleri Tablo 3.1'de gösterilmiştir.


Tablo 3.1. Aktivasyon fonksiyonları

İsim	Fonksiyon
Softmax	$f(x) = \frac{e^{z_j}}{\sum_k e^{z_k}}$
Tanh	$\tanh(x) = 2\sigma(2x) - 1$
ReLU	$f(x) = \max(0, x)$
ELU	$f(x) = \begin{cases} x, & \text{if } x > 0 \\ a(e^x - 1), & \text{if } x \leq 0 \end{cases}$
Sigmoid	$\sigma(x) = \frac{1}{1 + e^{-x}}$

3.2.5. Seyreltme Katmanı

Tam bağlantılı katmanlarda nöronların hepsi birbiri ile tam bağlantılı olarak çalışmaktadır. Yapay sinir ağlarının genel bir problemi olan aşırı öğrenmenin önüne geçmek için seyreltme işlemi uygulanmaktadır. Rastgele bir şekilde belirlenen oranda bazı nöronların birbiri ile bağlantısı kesilerek hem hesaplama yükü indirgenir hem de aşırı öğrenmenin önüne geçilir. Seyreltme işlemi evrişimsel sinir ağı modelinin

eğitiminde kullanılır. Test sırasında seyreltme katmanları görev almazlar (Hinton ve ark., 2012).



Şekil 3.12. Seyreltme katmanı öncesi ve seyreltme katmanı sonrası ağ yapısı (Srivastava, 2014)

3.2.6. Optimizasyon Yöntemleri

Derin öğrenme modellerinde eğitim sürecinde hesaplanan hatayı minimize etmek amacıyla geri yayılımda optimizasyon yöntemleri kullanılmaktadır. Eğitim sırasında hesaplanan hata değeri ne kadar minimize edilirse model de o kadar iyi eğitilmiş bir duruma gelir. İyi eğitilen bir ESA modeli test sırasında daha yüksek doğruluk oranı verecektir. Eğitim sırasında kullanılan optimizasyon yöntemlerinden en yaygın olanları stokastik gradyan inişi, adadelata, adam, adamax, adagrad ve rmsprop'dur. ESA'nın eğitimi sırasında kullanılan optimizasyon yöntemleri arasında başarı oranları bakımından farklılıklar bulunmaktadır. Bu nedenle optimizasyon yöntemini seçerken kurduğumuz modelin başarı oranına göre seçim yapmamız gerekmektedir.


3.3. Evrişimsel Sinir Ağ Mimarileri

Bu başlık altında LeNet-5, AlexNet, VGG-16, GoogleNet ve Microsoft ResNet mimarilerinden bahsedilecektir.

3.3.1. LeNet-5

LeNet evrişimsel sinir ağı mimarisi LeCun ve ark. (1998) tarafından geliştirilmiştir. Bulunduğu dönem için ilk kez derin bir ağ denilebilecek bir ağ mimarisine sahiptir. LeNet evrişimsel sinir ağ mimarilerinin temeli olarak kabul edilebilir. Günümüzde en

çok bilinen veri setlerinden olan el yazısı rakamlardan oluşan MNIST veri seti üzerinde eğitilmiştir. Mimarisinde iki tane evrişim katmanı, iki tane havuzlama katmanı ve üç tane tam bağlantılı katmandan oluşur. LeNet-5 ağı mimarisi Şekil 3.13'teki gibi gösterilmiştir.




Şekil 3.13. LeNet-5 ağı mimarisi (LeCun, 1998)

LeNet-5 evrişimsel sinir ağı mimarisinde en son tahmin katmanında on sınıflı bir softmax aktivasyon fonksiyonu yer almaktadır.

3.3.2. AlexNet

Bazı sinir ağı hızlandırıcıları 1990'larda da mevcut olmasına rağmen, çok sayıda parametreyle çok katmanlı ESA yapmak için yeterince güçlü değillerdi. Dahası, yeterli donanım gücü ve eğitim için yeterli veri kümeleri bulunmamaktaydı. Krizhevsky ve ark. (2012) yeni bir ESA modeli önererek AlexNet ve 2012 ImageNet yarışmasında mükemmel performans elde etmiştir. AlexNet günümüzde kullanılan sığdan derin ağlara doğru önemli bir adım olmuştur. AlexNet, tıpkı LeNet gibi evrişim katmanlarına ve ortaklama katmanlarına sahiptir. Fakat AlexNet, maksimum ortaklama ve ReLU aktivasyon fonksiyonu kullanmaktadır. LeNet mimarisinden daha fazla sayıda katmanda ve daha fazla veri üzerinde çalışmaktadır. Aynı zamanda seyreltme ve düzeltme tekniklerinden yararlanılmıştır. AlexNet ağı mimarisi Şekil 3.14'te gösterilmiştir.



Şekil 3.14. AlexNet ağı mimarisi (Krizhevsky ve ark, 2012)

AlexNet öncesi derin öğrenme sınıflandırma doğruluk oranı %74,3 civarlarındaydı. AlexNet ILSVRC yarışmasında sınıflandırma doğruluk oranını %83,6'ya çıkararak LeNet sonrasında yaşanan durgun dönemi bitirmiş ve derin ağlar üzerine olan merakı yeniden canlandırmıştır.

3.3.3. VGG-16

VGG (Visual Geometry Group) mimarisi, Oxford Üniversitesi'nde Görsel Geometri Grubu tarafından geliştirilmiştir. AlexNet ağ yapısı kullanılarak VGG yeniden kullanılabilir evrişimli bloklar kullanarak bir ağ oluşturur. AlexNet ağından farklı olarak art arda evrişim işlemlerini içermektedir. VGG ağının çeşitli derinliklerde varyasyonları bulunmaktadır. 16 katmanlı olan VGG mimarisi VGG-16 olarak adlandırılırken aynı ağın 19 ve 21 derinlikte olan çeşitleri de bulunmaktadır. VGG-16 ağının çıktı katmanında her biri 4096 nöron içeren iki adet tüm nöronları bağlantılı katman bulunmaktadır. Bu katmanlardan sonra ise 1000 sınıf için hazırlanmış bir softmax tahmin katmanı bulunmaktadır. VGG-16 ağındaki çok sayıdaki nöron toplam parametre sayısını çok büyük miktarda artırmıştır. VGG-16 ağı mimarisi Şekil 3.15'te verilmiştir.




Şekil 3.15. VGG-16 ağı mimarisi (Simonyan ve Zisserman, 2014)

VGG-16 ağı girdi katmanını verisi 224x224 boyutta ve RGB yani renkli resim formatındadır. Son olarak tahmin katmanını 1000 sınıf için ayarlanmış bir softmax katmanıdır.

3.3.4. GoogleNet (Inception)

GoogleNet aynı zamanda Inception olarak da adlandırılmaktadır. GoogleNet ağı 2014 yılında düzenlenen ILSVRC yarışmasında birincilik ödülü almıştır. Ağın en büyük avantajı hesaplama maliyeti olan toplam parametre sayısını artırmadan ya da diğer ağlara göre daha az artırarak daha derin ağların oluşmasını sağlamasıdır. GoogleNet ağı bloklardan meydana gelmektedir. Her bloğa Inception bloğu denilmektedir. Yani Inception hem blokların hem de ağın adıdır. Inception bloklarında farklı evrişim katmanları bulunmaktadır. Şekil 3.16’da Inception bloğu mimarisi gösterilmiştir.




Şekil 3.16. Inception bloğu mimarisi (Szegedy, 2015)

3.3.5. Microsoft ResNet

Microsoft'a ait ResNet evrişimsel sinir ağında atlamalı blok yapısı vardır. ResNet ağı diğer evrişimsel sinir ağ mimarilerinden farklı olarak bazı evrişim katmanlarının atlanarak diğer evrişim katmanlarına geçilmesi ve farklı boyutlarda öznetelik çıkarımına olanak sağlamasıyla bilinmektedir.

Günümüzde farklı ağ mimarileri birleştirilerek elde edilen kazanımlar ve başarı oranları artırılmaya çalışılmış ve evrişimsel sinir ağı modelleri gün geçtikçe başarısını artırmaya devam etmiştir. GoogleNet ağının ağ içerisindeki Inception bloklarında atlamalı bağlantılardan yararlanılarak ResNet ana fikri aslında uygulanmıştır. ResNet Microsoft araştırma ekibi tarafından 2015 yılında duyurulmuştur. Şekil 3.17'de ResNet ağı artık bağlantı blok diyagramı verilmiştir.



Şekil 3.17. ResNet ağı artık bağlantı mimarisi (He, 2016)

BÖLÜM 4. ARAŞTIRMA BULGULARI

4.1. Önerilen Yeni ESA (CNN) Tahmin Modeli

Tahmin yöntemleri, özellikle finansal zaman serileri için uygulanan tahmin yöntemleri, her geçen gün daha da çekici hale gelmektedir. Bir işletmenin gelecekteki performansını doğru bir şekilde tahmin etmek, yatırımcıların menkul kıymet alım satımından kar elde etmesi gibi birçok farklı noktada doğru tahminler elde etmek oldukça önem arz etmektedir. Bu noktada zaman serisi analiz yöntemleri incelendiğinde literatürde kullanılan birçok tahmin aracı bulunmaktadır. Bu araçlardan bazıları ARIMA, Zaman Serisi Regresyon ve VAR Modelleri gibi geleneksel tahmin modellerine dayalıyken, bulanık ve hesaplama tabanlı tahmin araçları da daha iyi tahmin performansları nedeniyle yaygın olarak tercih edilmektedir. Özellikle son yıllarda zaman serisi tahminleri için UKDH (LSTM) gibi derin sinir ağları yaygın olarak kullanılmasına rağmen, zaman serisi analizlerinde oldukça iyi sonuçlar verdiği görülen TSA (RNN) tabanlı bu modellerin hala üzerinde çalışılması gereken, zaman alıcı yinelemeler, karmaşık kapı mekanizmaları ve dinamik değişikliklere yavaş yanıt verme gibi bazı problemlerinin olduğu belirtilmelidir. Ayrıca, UKDH (LSTM) bazı sorunları çözmeye yardımcı olurken, yalnızca uzun dönem seri bilgisini kaydeder ve küresel modelleme konusunda iyi olmadığı da görülmektedir.

UKDH (LSTM) gibi TSA (RNN)'ların aksine, ESA (CNN)'lar hızlı eğitim gücüne sahiptir (Zhang ve ark., 2015; C. Chen ve ark., 2018; C. Chen ve ark., 2016). Basit yapıları ve önceki adımlara bağımlılık kısıtlaması olmaması gibi bazı avantajlara sahip olmakla beraber, zaman serisinin bazı temel özelliklerine küresel bir bakış açısıyla odaklanma yeteneğine sahiptir.

Bu avantajlar sayesinde, zaman serisi tahmin problemlerinde kullanılsalar da ESA (CNN)'ların bazı dönüşüm işlemleri kullanarak zaman serisi gözlemlerini görüntüye dönüştürerek işlem yapması gerekir. Fakat bu ekstra görüntü dönüşümünün bilgi kaybına neden olmasına, zaman serisinin zaman dizisi özelliğinin kesintiye uğramasına ve dolayısıyla tahmin performansının bozulmasına neden olacağı açıktır. Dolayısıyla, bu tez kapsamında temel amaç, çeşitli finansal zaman serileri için, kendi öğrenme sürecinden yararlanarak, önemli öznitelikleri çıkarabilen, aynı zamanda olağanüstü tahmin sonuçları sağlayan, ESA (CNN) tabanlı yeni bir tahmin aracı önermektir.


Bazı güncel tahmin yöntemleriyle karşılaştırıldığında, önerilen ESA (CNN) yapısının temel katkıları aşağıdaki gibi özetlenebilir;

1. Klasik YSA modellerinde olduğu gibi aşırı uyum sorununa sahip değildir.
2. Öngörü işleminde ekstra görüntü dönüşümü gerekmediğinden bilgi kaybı önlenerek daha üstün öngörüler elde edilmektedir.
3. Havuzlama işlemi kullanılmadığı için yine bilgi kaybı önlenmek ve ayrıca zaman serilerinin tahminler üzerindeki zaman dizisi etkisi korunmaktadır.

Önerilen ESA (CNN) tahmin modeli, üç evrişimli katman ve beş tam bağlantılı katman içerir ve ayrıca evrişimli katmanlarda, doğrusal olmayan ilişkilerin elde edilmesinde Relu ve Elu aktivasyon fonksiyonları tercih edilmiştir.

Oluşturulan ESA (CNN)'nın girdi katmanı bir boyutludur ve girdi katmanının boyutu zaman serilerinin gecikmeli değişkenlerine bağlıdır. Tez kapsamında önerilen tahmin modeli Şekil 4.1' de gösterilmektedir.

Şekil 4.1' de verilen ESA (CNN)'nın girdileri, zaman serisinin gecikmeli değişkenlerinden elde edilmiş vektörlerden oluşan bir matristir. Önerilen ESA (CNN) yapısı, zaman serilerinin gözlemlerine ekstra görüntü dönüşümü uygulamadan bu gözlemleri doğrudan görüntü olarak işlemektedir. Bu doğrultuda, gecikmeli değişken sayısının (model derecesi) p olması ve öğrenme örneğinin boyutunun n_{trn} olması durumunda, matrisin boyutu $(n_{trn} - p) \times p$ olacaktır.



Şekil 4.1. Önerilen evrimsel sinir ağı mimarisi

Önerilen ESA (CNN) tahmin modelinin analizlerinde girdi katmanı $(n_trn - p) \times p$ boyutlu olmakla beraber, üç evrişim katmanına (8, 16, 32 ile 2×2 kernel) sahiptir. Ayrıca, aşırı öğrenmeyi önlemek için seyreltme katmanı uygulanmıştır. Yapıda bir seyreltme katmanı uygulanmış (0,20) olup, 4 farklı tam bağlantılı katman (32, 16, 8, 4) ile tek bir çıktıdan oluşmaktadır.

Modelde filtre olarak en küçük ve en çok kullanılan kernel boyutu olan 2×2 filtre boyutu tercih edilmiştir. Literatürde 2×2 , 3×3 , 5×5 ve 7×7 gibi farklı boyutlarda ESA (CNN) filtreleri olmasına rağmen, küçük boyutlu filtrelerin kullanılması, zaman serisinin sahip olduğu ilişkilerin daha fazla detayını yakalama olanağı sunması avantajından yararlanarak genellikle daha iyi sonuçlar vermektedir. Analiz sürecinde, tahmin edilen zaman serisi gözlemine karşılık gelen bilgileri kaybetmemek adına havuzlama katmanı modelde kullanılmamıştır.

Bu çalışmada, yeni ESA (CNN) tahmin yapısının analiz sürecinde Keras ve Tensorflow altyapısı kullanılmış ve her bir test 1000 kez çalıştırılarak sonuçlar elde edilmiştir.

Aşağıdaki algoritma ile önerilen ESA (CNN) tahmin yapısının temel çalışma prensipleri sunulmuştur.

Genelleştirilmiş Önerilen Algoritma

Prosedür: Tüm aşamalar ()

Verini eğitim/test Aşaması:

$veri\ seti = oku(d)$

$x_{eğitim} = d[0: (boyut(d) - p)]$

$x_{test} = d[(boyut(d) - p + 1): boyut(d)]$

ESA (CNN) için Girdi Seti Oluşturma Aşaması:

Eğitim işlemi öncesinde tek değişkenli bir zaman serisi modeli hazırlanmalıdır. Bu doğrultuda, gözlem dizisi modelin öğrenebileceği birden fazla örneğe dönüştürülmelidir.

Tek değişkenli bir zaman serisi dikkate alındığında

$$x_{eğitim} = [5, 15, 25, 35, 45, 55, 65, 75, 85]$$

Zaman serisi, her örneğin belirli sayıda zaman serisi gecikmeli değişkenlerine sahip olduğu ve çıktının tek bir zaman adımı olduğu birden çok örneğe bölünür.

Zaman serisi gecikmesi için $(p)=4$

$$X = \begin{bmatrix} 5 & 15 & 25 & 35 \\ 15 & 25 & 35 & 45 \\ 25 & 35 & 45 & 55 \\ 35 & 45 & 55 & 65 \\ 45 & 55 & 65 & 75 \end{bmatrix} \quad y = \begin{bmatrix} 45 \\ 55 \\ 65 \\ 75 \\ 85 \end{bmatrix}$$

Tek değişkenli zaman serisi, her örneğin gecikmesinin 4 olduğu dört ve tek bir hedef değere sahip olduğu beş örneğe bölünür.

ESA (CNN) Aşaması:

Önerilen ESA (CNN) yapısı ile zaman serisi eğitim süreci döngüsü başlatılır. ESA (CNN)'da kullanılan filtreler başlangıçta (w_t) rastgele oluşturulur ve klasik YSA'nın ağırlıklarına karşılık gelir. Eğitim sürecinde iterasyon sayısı 1000 epoch olarak alınmıştır.

```
for(i = 0; i < epoch; epoch ++)
```

```
    model = ESA(CNN)(i)
```

```
    model.eğitim()
```

```
    model.test()
```

Değerlendirme Aşaması:

Eğitimi tamamlanan ESA (CNN) modelinde, her farklı başlangıç zamanı için test verileri ve gerçek değerler istatistiksel hata ölçütü hata kareler ortalamasının karekökü (HKOK) hesaplanarak en iyi model elde edilmektedir.

d: zaman serisinin vektör formatı

ts: test edilecek veri boyutu

wt: Evrimsel filtrelerin başlangıç ağırlıkları

BÖLÜM 5. TARTIŞMA VE SONUÇ

5.1. Verilerin Organizasyonu

Önerilen ESA (CNN) yapısının tahmin performansı, TAIEX ve FTSE olmak üzere iki farklı finansal zaman serisinin yine farklı yıllara ait verilerin analizi ile değerlendirilmiştir. Bu doğrultuda elde edilen, tahmin sonuçlarına dayalı bulgular, önerilen modelin üstün performansının kanıtı olarak sunulmuştur. Literatür incelendiğinde tahmin problemlerinde önerilen birçok çalışmada, örnek içi verileri örnek dışı verilerden ayırmak için belli oranlar kullanılmaktadır. Bu oranlar genellikle %70: %30 ile %90: %10 arasında değişmektedir. Bu noktadan hareketle, 2000, 2001, 2002, 2003 ve 2004 yıllarında gözlemlenen TAIEX verileri için son iki aylık döneme ait gözlemler örneklem dışı olarak alınmıştır. Ayrıca uygulamada 2010, 2011, 2012, 2013 ve 2014 yıllarında gözlemlenen FTSE verileri için de son iki haftanın gözlemleri örneklem dışı olarak alınmıştır.

Her iki zaman serisi için verilerin organizasyonunu içeren bilgiler Tablo 5.1’de özetlenmiştir.

Tablo 5.1. TAIEX ve FTSE veri organizasyonu

Seri No	Zaman Serisi	Yıl	Eğitim	Test
1	TAIEX	2000	224	47
2		2001	201	43
3		2002	205	43
4		2003	206	43
5		2004	205	45
6	FTSE	2010	252	10
7		2011	251	10
8		2012	252	10
9		2013	253	10
10		2014	253	10

5.2. Performans Ölçütleri

Literatürde, modellerin performansını karşılaştırmak için çeşitli değerlendirme ölçütleri kullanılmaktadır. Bu tez kapsamında, önerilen tahmin modelinin performansını farklı açılardan değerlendirebilmek amacıyla, farklı değerlendirme ölçütleri kullanılmış ve elde edilen sonuçlar tüm bu kriterlere göre yorumlanmıştır.

Bu çalışmada denklem 5.1'de verilen hata kareler ortalamasının karekökü (HKOK (RMSE)), değerlendirme ölçütü olarak modellerin sonuçlarını değerlendirmede kullanılan ilk ölçüttür.

$$HKOK = \sqrt{\frac{1}{n_{trn}} \sum_{t=1}^{n_{trn}} (Hedef_t - Çıktı_t)^2} \quad (5.1)$$

İkinci olarak ise tahminler ve hedef değerler için oluşturulacak regresyon modelinin analizi yapılmıştır. Bu model denklem 5.2'deki gibi temsil edilebilir. Görüldüğü gibi bu model sabit terimler içermeyen bir modeldir. Üstün bir tahmin aracı için bu modelin regresyon ve spesifikasyon katsayılarının 1'e eşit ya da oldukça yakın olması beklenir.

$$Y_t = \beta \hat{Y}_t + \varepsilon_t \quad (5.2)$$

Ayrıca, model performansını başka bir açıdan değerlendirmek için tahminler ile gerçek değerler arasındaki uyumu gösteren dağılım diyagramları da kullanılmıştır.

5.3. Alternatif Karşılaştırma Modelleri

Çalışmada, önerilen ESA (CNN) yapısının tahmin kabiliyetini karşılaştırabilmek ve yorumlayabilmek için üstün tahmin performansı bilinen çeşitli yöntemler seçilmiştir. TAIEX için karşılaştırmada kullanılan tahmin araçları aşağıda verilmiştir;

SC93	: Song and Chissom'un Modeli- Bulanık Temelli (Song & Chissom, 1993)
C96	: Chen'in Modeli- Bulanık Temelli (S. M. Chen, 1996)
H01	: Huarng'ın Modeli- Bulanık Temelli (Huarng, 2001)
HY06	: Huarng and Yu'nun Modeli- Bulanık Temelli (Huarng & Yu, 2006)
E10	: Eğrioglu ve diğ.'nin Modeli- Bulanık Temelli (Eğrioglu ve ark., 2010)
CC15	: Chen and Chen'nin Modeli- Bulanık Temelli (S. M. Chen ve Chen, 2015)
B15	: Baş ve diğ.'nin Modeli- Bulanık Temelli (Baş ve ark., 2015)
S18	: Sarıca ve ark.'nin Modeli- Bulanık Temelli (Sarıca ve ark., 2018)
L-NL	: Lineer ve Lineer Olmayan YSAA - YSA Temelli (Yolcu ve ark., 2013)
MLP	: Çok Katmanlı Algılayıcı - YSA Temelli (Rumelhart ve ark., 1986)
SP	: Sigma-Pi Nöron Model - YSA Temelli (Shin ve Ghosh, 1991)
SMN	: Tek Çarpımsal Nöron Model - YSA Temelli (Shin ve Ghosh, 1991)
ANFIS-G	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi – Izgara Bölümleme - Bulanık Temelli (Jang, 1993)
LSTM	: Uzun-Kısa Süreli Bellek - Derin YSA Temelli (Hochreiter ve Schmidhuber, 1997)

Ayrıca FTSE için karşılaştırmada kullanılan tahmin araçları aşağıda verilmiştir;

ANFIS-G	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi – Izgara Bölümleme Bulanık Temelli (Jang, 1993)
ANFIS-S	: Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi - Çıkarıcı Kümeleme - Bulanık Temelli (Jang, 1993)
MANFIS	: Modifiye Edilmiş Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi - Bulanık Temelli (Eğrioglu ve ark., 2015)
T1FRF	: T1 Bulanık Regresyon Fonksiyonu - Bulanık Temelli (Türkşen, 2008)
MLP	: Çok Katmanlı Algılayıcı YSA - YSA Temelli YSA Temelli (Türkşen, 2008)

RBF	: Radyal Temel Fonksiyonlu Sinir Ağı - YSA Temelli (Broomhead, 1988)
SP	: Sigma-Pi Nöron Model - YSA Temelli (Shin ve Ghosh, 1991)
SMNM	: Tek Çarpımsal Nöron YSA Modeli - YSA Temelli (Yadav ve ark., 2007)
L-NL	: Lineer ve Lineer Olmayan YSAA - YSA Temelli (Yolcu ve ark., 2013)

5.4. Metot Performanslarının Değerlendirilmesi

5.4.1. TAIEX Verisi Sonuçları ve Tartışması

Tez kapsamında ilk olarak, önerilen ESA (CNN) tahmin modeli ile beş farklı yıla ait günlük TAIEX verileri analiz edilmiş ve elde edilen sonuçlar çeşitli güncel tahmin modellerinin sonuçları ile birlikte değerlendirilmiştir. Analiz sürecinde eğitim seti olarak veri setinin ilk on aydaki zaman serilerinin gözlemleri alınırken, her yıl için son iki ay test seti olarak alınmıştır. Önerilen ESA (CNN) tahmin modelinin girdileri zaman serisinin gecikmeli değişkenlerinden oluşan matristir. Ayrıca çalışmada model derecesi (p) 3 ile 7 arasında değiştirilerek model sonuçları elde edilmiş ve HKOK kriterine göre aralarından en iyisi tercih edilerek nihai sonuçlar elde edilmiştir. Bu bilgiler ışığında eğitim setinin gözlem sayısı n_{trn} olduğu durumda önerilen ESA (CNN) modelinin girdi matrisinin boyutu $(n_{trn} - 3) \times 3$ 'ten $(n_{trn} - 7) \times 7$ 'ye değişecektir. Ve dolayısıyla çıktı vektörünün eleman sayısı $n_{trn} - p$ olacaktır. Karşılaştırma işleminde ise tüm mimariler arasında en iyi tahmin performansını üreten mimari kullanılmıştır.

TAIEX veri setlerinin analizi sonucunda, önerilen ESA (CNN) tahmin modelinin en iyi tahmin sonuçları iyi bilinen bazı modellerin sonuçları ile HKOK kriteri açısından Tablo 5.2'de sunulmaktadır.

Tablo 5.2. TAIEX için modellerin tahmin performansları

Tahmin Modelleri	RMSE					Ortalama
	TAIEX					
	2000	2001	2002	2003	2004	
SC93	293	116	76	77	82	129
C96	225	116	76	77	82	115
H01	152	130	84	56	116	108
HY06	133	124	82	62	85	97
E10	255	130	84	56	116	128
CC15	125	115	65	53	53	82
B16	140	120	77	60	59	91
S18	123	111	66	52	54	81
L-NL	342	113	66	51	53	125
MLP	304	130	80	68	64	129
SP	318	119	80	85	63	133
SMN	588	128	82	61	65	185
ANFIS-G	137	115	66	57	61	87
LSTM	136	<u>101</u>	89	92	70	108
Önerilen ESA (CNN)	<u>105</u>	110	<u>60</u>	<u>51</u>	<u>50</u>	<u>75</u>

Tablo 5.2 incelendiğinde, test verisi için elde edilen HKOK değerlerine göre, 2001 yılı hariç tüm yıllar için önerilen ESA (CNN) tahmin modelinin tahmin performansının diğer modellerden daha iyi olduğu görülmektedir. 2001 yılı için bile sonuçlar yorumlandığında, önerilen ESA (CNN) tahmin yöntemi ikinci en iyi tahmin performansına sahiptir ve en iyi modelin sonuçlarına da oldukça yakındır. Bu iki model arasındaki fark %10'dan azdır. Bu durum da önerilen ESA (CNN) tahmin modelinin beklendiği gibi rekabetçi tahmin yeteneğine sahip olduğu anlamına gelmektedir. Bu sonuçların yanısıra, ortalama HKOK değerleri incelendiğinde, bu değerler de önerilen ESA (CNN) tahmin modelinin üstün performans ürettiğinin bir başka kanıtı olarak görülebilir.

Farklı YSA, bulanık tabanlı modeller ve bulanık zaman serisi modellerinin yanı sıra, özellikle derin öğrenme tabanlı çok önemli bir model olan UKDH (LSTM) için de elde edilen sonuçlar incelendiğinde, önerilen ESA (CNN) tahmin modelinin ortalama %30 daha iyi sonuçlar ürettiği görülmektedir.

Tablo 5.3. Lineer regresyon modeli karakteristikleri ($Y_t = \beta \hat{Y}_t + \varepsilon_t$)


Yıl	Model Tahmini	p_F	St. Hata $\hat{\beta}$	p_β	%95 Güven Aralığı β		R^2
					Alt Sınır	Üst Sınır	
2000	$Y_t = 0,999627\hat{Y}_t$	2,74E-66	3,22E-03	8,93E-68	0,993109	1,006145	0,999797
2001	$Y_t = 1,000029\hat{Y}_t$	3,08E-64	3,65E-03	1,14E-65	0,992646	1,007413	0,999481
2002	$Y_t = 0,999927\hat{Y}_t$	5,35E-66	2,19E-03	1,12E-67	0,995486	1,004369	0,999916
2003	$Y_t = 0,999039\hat{Y}_t$	3,32E-78	1,40E-03	4,63E-80	0,996210	1,001869	0,999926
2004	$Y_t = 1,000370\hat{Y}_t$	1,42E-80	1,36E-03	1,95E-82	0,997626	1,003115	0,999928

Diğer bir değerlendirme yaklaşımı ise tahminler ve hedef değerler için oluşturulacak regresyon modelinin analizidir. Önerilen ESA (CNN) tahmin modelinin tahmin performansını gösterebilmek için, $Y_t = \beta \hat{Y}_t + \varepsilon_t$ olarak kurulan bir doğrusal regresyon modelinin bazı özelliklerinden yararlanılabilir. Bu açıdan öncelikle modelin regresyon katsayısı $\hat{\beta}$ ve belirleme katsayısı R^2 değerlendirilir. Eğer tahmin modeli tatmin edici sonuçlar veriyorsa, hem $\hat{\beta}$ hem de R^2 değerlerinin 1'e eşit olması veya mümkün olduğunca 1'e yakın olması beklenir. Tablo 5.3, bağımlı değişken olarak zaman serisinin gözlem değerlerini ve bağımsız değişken olarak da tahmin edilen değerleri dikkate alan regresyon modelinden $Y_t = \beta \hat{Y}_t + \varepsilon_t$ elde edilen tüm bulguları özetlemektedir. Tablo 5.3'te verilen bulgular incelendiğinde tüm durumlar için hem $\hat{\beta}$ hem de R^2 değerlerinin 1'e oldukça yakın olduğu açıkça görülmektedir.


Ayrıca hem sıfıra çok yakın olan regresyon katsayılarının standart hataları hem de oldukça dar ve 1'i kapsayan %95 güven aralıkları dikkate alındığında, önerilen ESA (CNN) tahmin modelinin güçlü ve tercih edilebilir bir tahmin aracı olarak kullanılabileceği görülmektedir.

Bunların yanı sıra, önerilen ESA (CNN) tahmin modelini farklı açılardan değerlendirebilmek için, test verisi için gözlenen ve tahmin edilen değerleri gösteren Kartezyen koordinatları kullanan matematiksel diyagramlar olan dağılım diyagramlarından yararlanılmıştır. Önerilen ESA (CNN) yapısının tatmin edici performansı, Şekil 5.1, Şekil 5.2, Şekil 5.3, Şekil 5.4 ve Şekil 5.5'teki verilen dağılım


grafiklerinde görülmektedir. Başarılı bir tahmin aracından bahsedebilmek için dağılım grafiklerindeki noktaların çoğunun doğru parçasına yakın olması beklenir. Şekil 5.1, Şekil 5.2, Şekil 5.3, Şekil 5.4 ve Şekil 5.5' teki veriler incelendiğinde, noktaların saçılmasının oldukça iyi bir tahmin performansına sahip bir çıkarım aracı için beklentileri karşıladığı açıktır. Bu dağılım grafikleri ayrıca tüm yıllara ait veriler için gerçek gözlem değerleri ile tahmin değerleri arasında güçlü bir pozitif ilişki olduğunu göstermektedir. Bu durum da tahmin edilen değerlerin gerçek test değerlerine çok yakın olduğu anlamına gelir.




Şekil 5.1. TAIEX2000 verisi için dağılım grafiği




Şekil 5.2. TAIEX2001 verisi için dağılım grafiği



Şekil 5.3. TAIEX2002 verisi için dağılım grafiği



Şekil 5.4. TAIEX2003 verisi için dağılım grafiği



Şekil 5.5. TAIEX2004 verisi için dağılım grafiği

5.4.2. FTSE Verisi Sonuçları ve Tartışması


İkinci olarak, önerilen ESA (CNN) tahmin modeli ile 2010, 2011, 2012, 2013 ve 2014 yıllarına ait beş farklı günlük FTSE verisi analiz edilmiş ve elde edilen sonuçlar literatürde ortaya konmuş çeşitli güncel modellerin sonuçlarıyla birlikte değerlendirilmiştir. Analiz sürecinde her yıl için test verisi olarak son on günün gözlemleri alınmıştır. Böylece iki haftalık tahminin elde edilmesi amaçlanmaktadır. TAIEX uygulamasında olduğu gibi FTSE veri setinin uygulamasında da kullanılan yeni ESA (CNN) tahmin modelinin girdileri zaman serisinin gecikmeli değişkenlerinden oluşan matrislerdir. Yine model derecesi (p) 3'ten 7'ye değiştirilerek sonuçlar her bir durum için değerlendirilmiştir. Önerilen yöntemden elde edilen optimal sonuçlara ait tahmin hatası hem bulanık tabanlı hem de YSA tabanlı modeller dahil olmak üzere diğer alternatif yöntemlerin tahmin hatalarıyla birlikte Tablo 5.4'te sunulmuştur.

Tablo 5.4'in ışığında, önerilen ESA (CNN) tahmin modeli diğer tahmin modelleriyle kıyaslandığında, minimum HKOK değerlerine sahip olduğu açıkça görülmektedir. Dolayısıyla önerilen ESA (CNN) tahmin modelinin 2012 yılı hariç tüm veri setleri için en iyi tahmin performansına sahip olduğu söylenebilir. Ayrıca, tüm yöntemlerle ilgili HKOK'ye ait ortalama ve medyan istatistikleri de dikkate alındığında, önerilen ESA (CNN) tahmin modelinin üstün tahmin performansı ürettiği açıkça görülmektedir.

Öte yandan Şekil 5.6 ile sadece her yıl için değil, aynı zamanda ortalama ve medyan istatistikleri için de bulanık tabanlı modellere göre tahmin doğruluğu üzerinde elde edilen iyileşme oranları özetlenmiştir. Özellikle Şekil 5.6 incelendiğinde, 2013 yılı için önerilen model, en iyi bulanık tabanlı modele göre %33,82 ile dikkat çekici bir iyileşme oranına sahiptir. Ayrıca tüm yıllar için ortalama ve medyan istatistiklerine bakıldığında önerilen model ile sırasıyla %17,03 ve %18,41'lik iyileşme oranlarına ulaşılmıştır.

Tablo 5.4. FTSE veri seti için modellerin tahmin performansları


Modeller	RMSE						Ortalama	Medyan
	FTSE							
	2010	2011	2012	2013	2014			
ANFIS-G (Bulanik Temelli)	38,49	50,09	21,91	49,34	82,75	48,52	49,34	
ANFIS-S (Bulanik Temelli)	40,81	40,63	19,24	47,45	68,66	43,36	40,81	
MANFIS (Bulanik Temelli)	31,36	37,77	18,50	45,60	63,36	39,32	37,77	
T1FF (Bulanik Temelli)	31,35	42,64	18,90	49,88	62,46	41,05	42,64	
MLP (YSA Temelli)	32,43	46,46	18,69	48,68	76,59	44,57	46,46	
RBF (YSA Temelli)	31,67	38,99	18,51	47,16	62,68	39,80	38,99	
SP (YSA Temelli)	32,11	44,89	18,12	46,94	76,32	43,68	44,89	
SMN (YSA Temelli)	32,60	44,78	17,88	49,29	76,61	44,23	44,78	
L-NL (YSA Temelli)	31,88	44,33	19,11	48,70	75,95	43,99	44,33	
Önerilen ESA (CNN)	30,88	30,82	18,69	30,18	52,55	32,62	30,82	



Şekil 5.6. Bulanık temelli yöntemlere göre iyileşme yüzdeleri

Benzer şekilde Şekil 5.7 incelendiğinde en iyi YSA tabanlı modele göre iyileştirme oranlarının %2,48 ile %35,70 arasında değiştiği görülmektedir. Ayrıca ortalama ve medyan istatistikleri için önerilen ESA (CNN) tahmin modelinin sırasıyla %18 ve %21 ile önemli bir iyileşme oranı sağladığı söylenebilir.

Bu bilgiler ışığında, önerilen ESA (CNN) tahmin modelinin dikkate değer bir tahmin performansı gösterdiği ve finansal zaman serilerine ait daha doğru tahmin sonuçları elde edilebilmesi için etkin ve rekabetçi bir tahmin aracı olarak kullanılabileceği gösterilmiştir.



Şekil 5.7. YSA temelli yöntemlere göre iyileşme yüzdeleri

Finansal zaman serisi tahmini, uzun yıllardır makine öğrenmesi çalışan araştırmacılar arasında oldukça popüler olmuştur. Ancak özellikle son yıllarda derin sinir ağıları zaman serileri tahmini için etkin bir şekilde kullanılmaktadır. Bunlar arasından, UKDH (LSTM) zaman serisi analizleri için yaygın olarak tercih edilmesine rağmen, farklı yapılar sahip farklı ESA (CNN) modelleri de tahmin performansını iyileştirmek için bir tahmin aracı olarak kullanılmaya başlanmıştır. Literatürdeki çalışmalar incelendiğinde, temel ve can alıcı sorun, ekstra görüntü dönüştürme ve havuzlama işlemlerinden kaynaklanan bilgi kaybı ve zaman dizisinin kesintiye uğramasıdır.

Bu çalışmada, finansal zaman serileri analizi için özel bir yapı kullanılarak üstün bir tahmin yeteneğine sahip olan ESA (CNN)'nın performansının artırılması hedeflenmiştir. Önerilen ESA (CNN)'nın tahmin yapısı, ilgili bilgileri veri setinden etkin bir şekilde çıkararak finansal zaman serileri için üstün tahmin sonuçları elde edebilmek için tasarlanmıştır. Oluşturulan ESA (CNN) tahmin modeli, girdiler için

ekstra görüntü dönüşümüne ihtiyaç duymamakla birlikte, havuzlama katmanını da kullanmamaktadır. TAIEX ve FTSE veri setlerinin tahmin sürecini içeren on farklı uygulamanın sonunda elde edilen sonuçlar, önerilen ESA (CNN) tahmin modelinin bazı bulanık, YSA ve derin YSA tabanlı modellere kıyasla etkili ve rekabetçi bir tahmin aracı olarak kullanılabileceğini göstermektedir. Ayrıca tez kapsamında önerilen modelin, diğer modellere kıyasla sistemin tahmin performansını HKOK değeri açısından ortalama %18 oranında iyileştirebildiği de gösterilmiştir. Öte yandan önerilen modelin finansal zaman serisi literatürüne önemli katkılarından biri de yine literatürde önemli yer tutan ve verdiği iyi tahmin sonuçlarıyla bilinen UKDH (LSTM)'dan bile ortalama %30 daha iyi doğruluk elde etmesidir. Ayrıca hem dağılım grafikleri hem de regresyon analizi çıktıları, önerilen modelin üstün tahmin performansının bir göstergesi olarak, elde edilen tahminlerin ve gözlemlerin oldukça uyumlu olduğunu görsel ve analitik olarak göstermektedir. Sonuç olarak, tez kapsamında önerilen ESA (CNN) tahmin modelinin, olağanüstü bir tahmin performansı ortaya koyduğu ve bununla beraber, finansal zaman serileri için güvenilir ve rekabetçi bir tahmin aracı olarak kullanılabileceği gösterilmiştir.

Gelecekteki çalışmalar için, tahmin performansını araştırmak ve bunu diğer sinir ağı çerçeveleriyle birleştirerek çok değişkenli bir ESA (CNN) tahmin modeli oluşturmayı planlanmaktadır. Ayrıca, zaman serileri için daha doğru tahmin modeli ortaya koyabilmek için ESA (CNN) modellerinde bulanık zaman serisi yöntemlerinin avantajından yararlanılarak bulanık tabanlı bir kurulum uygulanarak başka bazı potansiyel çalışmaların izlenebileceği düşünülmektedir.

KAYNAKLAR

- Aggarwal, S., & Aggarwal, S. 2017. Deep Investment in Financial Markets using Deep Learning Models. *International Journal of Computer Applications*, 162(2).
- Amidi, S. 2018. Cheatsheet: Convolutional Neural Networks, 1.
- Arévalo, A., Niño, J., Hernández, G., & Sandoval, J. 2016. High-frequency trading strategy based on deep neural networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 9773.
- Ballings, M., Van Den Poel, D., Hespeels, N., & Gryp, R. 2015. Evaluating multiple classifiers for stock price direction prediction. *Expert Systems with Applications*, 42(20).
- Bao, W., Yue, J., & Rao, Y. 2017. A deep learning framework for financial time series using stacked autoencoders and long-short term memory. *PLoS ONE*, 12(7).
- Baş, E., Eğrioglu, E., Aladağ, C. H., & Yolcu, U. 2015. Fuzzy-time-series network used to forecast linear and nonlinear time series. *Applied Intelligence*, 43(2).
- Broomhead, D. 1988. Multivariable functional interpolation and adaptive networks. *Complex Systems*, 2.
- Cavalcante, R. C., Brasileiro, R. C., Souza, V. L. F., Nobrega, J. P., & Oliveira, A. L. I. 2016. Computational Intelligence and Financial Markets: A Survey and Future Directions. *Expert Systems with Applications*, 55.
- Chen, A. S., Leung, M. T., & Daouk, H. 2003. Application of neural networks to an emerging financial market: Forecasting and trading the Taiwan Stock Index. *Computers and Operations Research*, 30(6).
- Chen, C., Li, K., Ouyang, A., Tang, Z., & Li, K. 2016. GFlink: An In-Memory Computing Architecture on Heterogeneous CPU-GPU Clusters for Big Data. *Proceedings of the International Conference on Parallel Processing*.
- Chen, C., Li, K., Teo, S. G., Chen, G., Zou, X., Yang, X., Vijay, R. C., Feng, J., & Zeng, Z. 2018. Exploiting Spatio-Temporal Correlations with Multiple 3D Convolutional Neural Networks for Citywide Vehicle Flow Prediction. *Proceedings - IEEE International Conference on Data Mining, ICDM*.

- Chen, S. M. 1996. Forecasting enrollments based on fuzzy time series. *Fuzzy Sets and Systems*, 81(3).
- Chen, S. M., & Chen, S. W. 2015. Fuzzy forecasting based on two-factors second-order fuzzy-trend logical relationship groups and the probabilities of trends of fuzzy logical relationships. *IEEE Transactions on Cybernetics*, 45(3).
- Chong, E., Han, C., & Park, F. C. 2017. Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies. *Expert Systems with Applications*, 83.
- Deng, Y., Bao, F., Kong, Y., Ren, Z., & Dai, Q. 2017. Deep Direct Reinforcement Learning for Financial Signal Representation and Trading. *IEEE Transactions on Neural Networks and Learning Systems*, 28(3).
- Di Persio, L., & Honchar, O. 2016. Artificial neural networks architectures for stock price prediction: Comparisons and applications. *International Journal of Circuits, Systems and Signal Processing*, 10.
- Ding, X., Zhang, Y., Liu, T., & Duan, J. 2015. Deep learning for event-driven stock prediction. *IJCAI International Joint Conference on Artificial Intelligence*, 2015-January.
- Eğrioğlu, E., Aladağ, C. H., Yolcu, U., & Baş, E. 2015. A New Adaptive Network Based Fuzzy Inference System for Time Series Forecasting. *Aloy Journal of Soft Computing and Applications*, 2(1).
- Eğrioğlu, E., Aladağ, C. H., Yolcu, U., Uslu, V. R., & Başaran, M. A. 2010. Finding an optimal interval length in high order fuzzy time series. *Expert Systems with Applications*, 37(7).
- Gündüz, H., Yaslan, Y., & Çataltepe, Z. 2017. Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations. *Knowledge-Based Systems*, 137.
- Güreşen, E., Kayakutlu, G., & Daim, T. U. 2011. Using artificial neural network models in stock market index prediction. *Expert Systems with Applications*, 38(8).
- He, K., Zhang, X., Ren, S. & Sun, J. 2016. Deep Residual Learning for Image Recognition. in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 770-778.
- Hochreiter, S., & Schmidhuber, J. 1997. Long short-term memory. *Neural Computation*, 9(8): 1735–1780.
- Huarng, K. (2001). Effective lengths of intervals to improve forecasting in fuzzy time series. *Fuzzy Sets and Systems*, 123(3).
- Huarng, K., & Yu, T. H. K. 2006. Ratio-based lengths of intervals to improve fuzzy time series forecasting. *IEEE Transactions on Systems, Man, and Cybernetics*,

Part B: Cybernetics, 36(2).

- İnik, Ö , Ülker, E . 2017. Derin Öğrenme ve Görüntü Analizinde Kullanılan Derin Öğrenme Modelleri . Gaziosmanpaşa Bilimsel Araştırma Dergisi , 6 (3): 85-104
- Jang, J. S. R. 1993. ANFIS: Adaptive-Network-Based Fuzzy Inference System. IEEE Transactions on Systems, Man and Cybernetics, 23(3).
- Kalchbrenner, N., Grefenstette, E., & Blunsom, P. 2014. A convolutional neural network for modelling sentences. 52nd Annual Meeting of the Association for Computational Linguistics, ACL 2014 - Proceedings of the Conference, 1.
- Kara, Y., Acar Boyacıoğlu, M., & Baykan, Ö. K. 2011. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. Expert Systems with Applications, 38(5).
- Karpathy, A., Toderici, G., Shetty, S., Leung, T., Sukthankar, R., & Li, F. F. 2014. Large-scale video classification with convolutional neural networks. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition.
- Kim, K. J., & Han, I. 2000. Genetic algorithms approach to feature discretization in artificial neural networks for the prediction of stock price index. Expert Systems with Applications, 19(2).
- Kim, Y. 2014. Convolutional neural networks for sentence classification. EMNLP 2014 - 2014 Conference on Empirical Methods in Natural Language Processing, Proceedings of the Conference.
- Krauss, C., Do, X. A., & Huck, N. 2017. Deep neural networks, gradient-boosted trees, random forests: Statistical arbitrage on the S&P 500. European Journal of Operational Research, 259(2).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2017. ImageNet classification with deep convolutional neural networks. Communications of the ACM, 60(6).
- Krizhevsky, A., Sutskever, I., & Hinton, G. E. 2012. ImageNet classification with deep convolutional neural networks. Advances in Neural Information Processing Systems, 2.
- Krollner, B., Vanstone, B., & Finnie, G. 2010. Financial time series forecasting with machine learning techniques: A survey. Proceedings of the 18th European Symposium on Artificial Neural Networks - Computational Intelligence and Machine Learning, ESANN 2010.
- LeCun, Y., Boser, B., Denker, J. S., Henderson, D., Howard, R. E., Hubbard, W. & Jackel, L. D. 1989. Backpropagation applied to handwritten zip code recognition, neural computation 1. 541-551.
- Lecun, Y., & Bengio, Y. 2010. Convolutional Networks for Images , Speech , and

Time Series Variable-Size Convolutional Networks : SDNNs. Processing.

- Liao, Z., & Wang, J. 2010. Forecasting model of global stock index by stochastic time effective neural network. *Expert Systems with Applications*, 37(1).
- Lin, M., Chen, Q., & Yan, S. 2014. Network in network. 2nd International Conference on Learning Representations, ICLR 2014 - Conference Track Proceedings.
- Nelson, D. M. Q., Pereira, A. C. M., & De Oliveira, R. A. 2017. Stock market's price movement prediction with LSTM neural networks. *Proceedings of the International Joint Conference on Neural Networks*.
- Pulido, M., Melin, P., & Castillo, O. 2014. Particle swarm optimization of ensemble neural networks with fuzzy aggregation for time series prediction of the Mexican Stock Exchange. *Information Sciences*, 280.
- Qiu, M., & Song, Y. 2016. Predicting the direction of stock market index movement using an optimized artificial neural network model. *PLoS ONE*, 11(5).
- Qiu, M., Song, Y., & Akagi, F. 2016. Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market. *Chaos, Solitons and Fractals*, 85.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088).
- Sarıca, B., Eğrioğlu, E., & Aşıkil, B. 2018. A new hybrid method for time series forecasting: AR–ANFIS. *Neural Computing and Applications*, 29(3).
- Sezer, Ö. B., Özbayoğlu, M., & Doğdu, E. 2017. A Deep Neural-Network Based Stock Trading System Based on Evolutionary Optimized Technical Analysis Parameters. *Procedia Computer Science*, 114.
- Shin, Y., & Ghosh, J. 1991. The pi-sigma network: An efficient higher-order neural network for pattern classification and function approximation. *Proceedings. IJCNN-91-Seattle: International Joint Conference on Neural Networks*.
- Simonyan, K., & Zisserman, A. 2014. Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Song, Q., & Chissom, B. S. 1993. Fuzzy time series and its models. *Fuzzy Sets and Systems*, 54(3).
- Szegedy, C., Liu, W., Jia, Y., Sermanet, P., Reed, S., Anguelov, D., Erhan, D., Vanhoucke, V., & Rabinovich, A. 2015. Going deeper with convolutions. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*.
- Tiño, P., Schittenkopf, C., & Dorffner, G. 2001. Financial volatility trading using recurrent neural networks. *IEEE Transactions on Neural Networks*, 12(4).
- Türkşen, I. B. 2008. Fuzzy functions with LSE. *Applied Soft Computing Journal*, 8(3).

- Vanstone, B., Finnie, G., & Hahn, T. 2012. Creating trading systems with fundamental variables and neural networks: The Aby case study. *Mathematics and Computers in Simulation*, 86.
- Wang, N. Y., & Chen, S. M. 2009. Temperature prediction and TAIFEX forecasting based on automatic clustering techniques and two-factors high-order fuzzy time series. *Expert Systems with Applications*, 36(2 PART 1).
- Yadav, R. N., Kalra, P. K., & John, J. 2007. Time series prediction with single multiplicative neuron model. *Applied Soft Computing Journal*, 7(4).
- Yeh, S. H., Wang, C. J., & Tsai, M. F. 2015. Deep belief networks for predicting corporate defaults. 2015 24th Wireless and Optical Communication Conference, WOCC 2015.
- Yolcu, U., Eğrioğlu, E., & Aladağ, C. H. 2013. A new linear & nonlinear artificial neural network model for time series forecasting. *Decision Support Systems*, 54(3).
- Yoshihara, A., Fujikawa, K., Seki, K., & Uehara, K. 2014. Predicting stock market trends by recurrent deep neural networks. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 8862.
- Zhang, L., Li, K., Xu, Y., Mei, J., Zhang, F., & Li, K. 2015. Maximizing reliability with energy conservation for parallel task scheduling in a heterogeneous cluster. *Information Sciences*, 319.

ÖZGEÇMİŞ

Melih KİRİŞCİ 2014 yılında Ege Üniversitesi Fen Fakültesi İstatistik Bölümü ve 2019 yılında Hoca Ahmet Yesevi Uluslararası Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği bölümünü bitirmiştir. 2018 yılında Giresun Üniversitesi Fen Bilimleri Enstitüsü İstatistik Yüksek Lisans programına başlamıştır. 2015 yılında çalışmaya başladığı Doğu Karadeniz Projesi Bölge Kalkınma İdaresi Başkanlığında halen Mühendis olarak görev yapmaktadır.

