

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÖNGÖRÜ PROBLEMİ İÇİN YENİ DERİN GERİ
BESLEMELİ MELEZ YAPAY SİNİR AĞLARI

DOKTORA TEZİ

Öğrencinin Adı SOYADI : Özlem KARAHASAN

Tezin Enstitüye Verildiği Tarih :

Enstitü Anabilim Dalı : İstatistik

Tez Danışmanı : Prof. Dr. Eren BAŞ

Haziran 2024
GİRESUN

T.C.
GİRESUN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ÖNGÖRÜ PROBLEMİ İÇİN YENİ DERİN GERİ BESLEMELİ MELEZ YAPAY SİNİR AĞLARI

DOKTORA TEZİ

Özlem KARAHASAN

Enstitü Anabilim Dalı

:

İstatistik

Bu tez 10/06/2024 tarihinde aşağıdaki jüri tarafından oybirliği ile kabul edilmiştir.

Prof. Dr.
Fatma Zehra DOĞRU
Jüri Başkanı

Prof. Dr.
Eren BAŞ
Üye

Prof. Dr.
Erol EĞRİOĞLU
Üye

Prof. Dr.
Cem KOÇAK
Üye

Prof. Dr.
Bahadır KOZ
Enstitü Müdürü

Dr. Öğr. Üyesi
Erdinç YÜCESOY
Üye

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.

Özlem KARAHASAN

27/06/2024

TEŞEKKÜR

Öncelikle doktora eğitimim esnasında öğrettikleriyle, yardımlarıyla ve güvenleriyle her daim yanımda olan sevgili danışman hocam Prof. Dr. Eren BAŞ ve sevgili hocam Prof. Dr. Erol EĞRİOĞLU'na sonsuz minnetlerimi sunmalıyım. Bu süreçte her daim destekleri ile yanımdaydılar. Verdikleri umut tohumlarını yeşertmek için öğrettikleri, unutulmaz bir vefayı gerektiriyor.

Ayrıca, doktora eğitimim boyunca üzerimde emeği olan Giresun Üniversitesi İstatistik bölümündeki tüm hocalarıma teşekkürlerimi sunarım.

Ve bu günlere gelmemde en büyük emeğe sahip olan dualarını her daim üzerimde hissettiğim canım babam Metin KARAHASAN ve canım annem Emine KARAHASAN'a en içten dileklerimle teşekkürlerimi sunarım.

İÇİNDEKİLER

TEŞEKKÜR.....	I
İÇİNDEKİLER	II
SİMGELER VE KISALTMALAR LİSTESİ	VI
ŞEKİLLER LİSTESİ	VII
TABLolar LİSTESİ.....	IX
ÖZET.....	XV
SUMMARY	XVI
 BÖLÜM 1. GİRİŞ.....	 17
 BÖLÜM 2. KAYNAK ARAŞTIRMASI.....	 26
2.1. Klasik Öngörü Yöntemleri.....	26
2.1.1. Naive yöntem	26
2.1.2. Mevsimsel naive yöntem.....	27
2.1.3. Aritmetik ortalama yöntemi	27
2.1.4. Hareketli ortalama yöntemi.....	28
2.1.5. Mevsimsel ayrıştırma yöntemleri.....	28
2.1.5.1. Klasik ayrıştırma yöntemleri.....	28
2.1.5.2. STL ayrıştırma yöntemi	30
2.1.6. Regresyon yöntemleri	30
2.1.7. Üstel düzleştirme yöntemleri	32
2.1.7.1. Basit üstel düzleştirme yöntemi	32

2.1.7.2.Holt doğrusal trend üstel düzleştirme yöntemi	33
2.1.7.3. Damped trend üstel düzleştirme yöntemi.....	33
2.1.7.4. Holt-Winters toplamsal ve çarpımsal üstel düzleştirme yöntemleri	34
2.1.8. Otoregresif bütünleşik hareketli ortalamalar modelleri ve mevsimsel otoregresif bütünleşik hareketli ortalamalar modelleri.....	35
2.1.8.1. Otoregresif hareketli ortalamalar modelleri	36
2.1.8.2. Otoregresif bütünleşik hareketli ortalamalar modelleri	37
2.1.8.3. Mevsimsel otoregresif bütünleşik hareketli ortalama modelleri.....	37
2.1.9. Eşik otoregresif modeller	38
2.2. Yapay Sinir Ağları	39
2.2.1.Yapay sinir ağı modelleri.....	41
2.2.1.1.Tek katmanlı (tabakalı) algılayıcılar	41
2.2.1.2. Çok katmanlı (tabakalı) algılayıcılar.....	42
2.2.1.3. İleri beslemeli yapay sinir ağları	43
2.2.1.4. Geri beslemeli yapay sinir ağları.....	43
2.2.2. Derin yapay sinir ağları.....	44
2.2.2.1. Basit geri beslemeli yapay sinir ağları	45
2.3. Yapay zekâ optimizasyon algoritmaları.....	47
2.3.1. Sinüs kosinüs optimizasyon algoritması	47
2.3.2. Parçacık sürü optimizasyonu algoritması.....	49
 BÖLÜM 3. MATERYAL VE YÖNTEM.....	52
3.1. Önerilen Yapay Sinir Ağı Yöntemleri	52
3.1.1. Mevsimsel bileşen içermeyen zaman serileri için önerilen yeni melez derin yapay sinir ağı (SRNN-SES)	52
3.1.2. Mevsimsel bileşen içeren zaman serileri için önerilen yapay sinir ağı modeli (SRNN-SES-S).....	54

3.2. SRNN-SES ve SRNN-SES-S İçin Öğrenme Algoritmaları.....	56
3.2.1. SRNN-SES için parçacık sürü optimizasyonu algoritmasına dayalı bir öğrenme algoritması.....	56
3.2.2. SRNN-SES-S için parçacık sürü optimizasyonu algoritmasına dayalı bir öğrenme algoritması.....	60
3.2.3. SRNN-SES için sinüs kosinüs optimizasyon algoritmasına dayalı bir öğrenme algoritması.....	63
3.2.4. SRNN-SES-S için sinüs kosinüs optimizasyon algoritmasına dayalı bir öğrenme algoritması.....	65
 BÖLÜM 4. ARAŞTIRMA BULGULARI.....	 69
4.1. Mevsimsel Bileşen İçermeyen Zaman Serileri İçin Çözümleme.....	70
4.1.1. FTSE MIB veri seti için çözümleme.....	70
4.1.2. DAX veri seti için çözümleme.....	77
4.1.3. IBEX 35 veri seti için çözümleme	84
4.1.4. BTC-USD veri seti için çözümleme	92
4.1.5. Gümüş veri seti için çözümleme	98
4.1.6. Altın veri seti için çözümleme	105
4.2. Mevsimsel Bileşen İçeren Zaman Serileri İçin Çözümleme.....	113
4.2.1. Box&Jenkins havayolu yolcuları veri seti için çözümleme.....	113
4.2.2. Ankara hava kirliliği veri seti için çözümleme	114
4.2.3. Türkiye elektrik tüketimi veri seti için çözümleme	116
4.2.4. Avustralya bira tüketimi veri seti için çözümleme	117
 BÖLÜM 5. TARTIŞMA VE SONUÇ	 120
 KAYNAKLAR	 122

ÖZGEÇMİŞ	132
----------------	-----



SİMGELER VE KISALTMALAR LİSTESİ

ARMA	:	Otoregresif Hareketli Ortalama
ARIMA	:	Otoregresif Entegre Hareketli Ortalama
BHO	:	Basit Hareketli Ortalama
CNN	:	Konvolüsyonel Sinir Ağı
DNM-ANN	:	Dentritik Nöron Model
GRU-ANN	:	Geçitli Geri Beslemeli Birim Yapay Sinir Ağı
MSE	:	Hata Kareler Ortalaması
RMSE	:	Hata Kareler Ortalamasının Karekökü
LSTM-ANN	:	Uzun Kısa Dönem Hafıza Yapay Sinir Ağı
MHO	:	Merkezsiz Hareketli Ortalama
MLP	:	Çok Katmanlı Algılayıcı
PSO	:	Parçacık Sürü Optimizasyonu
PS-ANN	:	Pi-Sigma Yapay Sinir Ağları
RNN	:	Geri Beslemeli Yapay Sinir Ağı
SARIMA	:	Mevsimsel Otoregresif Bütünleşik Hareketli Ortalama
SCO	:	Sinüs Kosinüs Optimizasyon
SES	:	Basit Üstel Düzleştirme
SMN	:	Tek Çarpımsal Nöron
SRNN	:	Basit Geri Beslemeli Yapay Sinir Ağı
STL	:	Loess ile Mevsimsel ve Trend Ayırıştırma Yöntemi

ŞEKİLLER LİSTESİ

Şekil 2.1. Klasik toplamsal ayrıştırma yöntemi akış diyagramı.....	29
Şekil 2.2. Klasik çarpımsal ayrıştırma yöntemi akış diyagramı.....	29
Şekil 2.3. McCulloch-Pitts nöron model.....	39
Şekil 2.4. Rosenblatt'ın basit algılayıcısı.....	41
Şekil 2.5. ADALINE yapay sinir ağı.....	41
Şekil 2.6. Tek çıktılı çok katmanlı mimari.....	42
Şekil 2.7. Çok çıktılı çok katmanlı mimari.....	43
Şekil 2.8. Çok gizli tabakalı tek çıktılı çok katmanlı derin mimari.....	44
Şekil 2.9. Çok gizli tabakalı çok çıktılı çok katmanlı derin mimari.....	45
Şekil 2.10. Basit geri beslemeli yapay sinir ağı mimarisi.....	46
Şekil 3.1. Mevsimsel bileşen içermeyen zaman serileri için önerilen yapay sinir ağı mimarisi.....	53
Şekil 3.2. Mevsimsel bileşen içeren zaman serileri için önerilen yapay sinir ağı mimarisi.....	55
Şekil 4.1. Rastgele elde edilen 10 adet FTSE MIB veri setine ait zaman serisi grafikleri.....	72
Şekil 4.2. Rastgele elde edilen 10 adet DAX zaman serisi grafikleri.....	79
Şekil 4.3. Rastgele elde edilen 10 adet IBEX 35 veri setlerine ait zaman serisi grafikleri.....	86
Şekil 4.4. Rastgele elde edilen 10 adet BTC-USD veri setine ait zaman serisi grafikleri.....	93
Şekil 4.5. Rastgele elde edilen 10 adet gümüş veri setine ait zaman serisi grafikleri.....	100
Şekil 4.6. Rastgele elde edilen 10 adet altın veri setine ait zaman serisi grafikleri.....	107
Şekil 4.7. BJ veri setine ait zaman serisi grafiği.....	113
Şekil 4.8. AHK veri setine ait zaman serisi grafiği.....	115
Şekil 4.9. TET veri setine ait zaman serisi grafiği.....	116

Şekil 4.10. ABT veri setine ait zaman serisi grafiği	118
--	-----



TABLÖLAR LİSTESİ

Tablo 2.1. Trend ve mevsimsel bileşen içerip içermediği durumlara göre regresyon yöntemleri	31
Tablo 3.1. SRNN-SES-PSO yöntemi için bir parçacığın pozisyonlarının durumu ...	58
Tablo 3.2. SRNN-SES-S-PSO yöntemi için bir parçacığın pozisyonlarının durumu	61
Tablo 3.3. SRNN-SES-SCO yöntemi için bir pozisyonun konumlarının durumu	64
Tablo 3.4. SRNN-SES-S-SCO yöntemi için bir pozisyonun konumlarının durumu.	67
Tablo 4.1. Veri setlerine ait bilgiler	69
Tablo 4.2. Rastgele elde edilen 10 adet FTSE MIB veri setine ait bilgiler.....	71
Tablo 4.3. FTSE MIB Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	71
Tablo 4.4. FTSE MIB Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	73
Tablo 4.5. FTSE MIB Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	73
Tablo 4.6. FTSE MIB Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	73
Tablo 4.7. FTSE MIB Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	74
Tablo 4.8. FTSE MIB Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	74
Tablo 4.9. FTSE MIB Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	74
Tablo 4.10. FTSE MIB Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	75
Tablo 4.11. FTSE MIB Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	75

Tablo 4.12. FTSE MIB Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	75
Tablo 4.13. FTSE MIB zaman serileri için ortalama istatistiğine göre önerilen yöntemden ve Naive yöntemden elde edilen sonuçlar	77
Tablo 4.14. Rastgele elde edilen 10 adet DAX veri setine ait bilgiler	78
Tablo 4.15. DAX Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	78
Tablo 4.16. DAX Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	80
Tablo 4.17. DAX Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	80
Tablo 4.18. DAX Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	80
Tablo 4.19. DAX Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	81
Tablo 4.20. DAX Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	81
Tablo 4.21. DAX Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	81
Tablo 4.22. DAX Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	82
Tablo 4.23. DAX Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	82
Tablo 4.24. DAX Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	82
Tablo 4.25. 10 adet DAX veri seti için ortalama istatistiğine göre önerilen yöntemden ve Naive yöntemden elde edilen sonuçlar	84
Tablo 4.26. Rastgele elde edilen 10 adet IBEX 35 veri setine ait bilgiler	85
Tablo 4.27. IBEX 35 Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	85
Tablo 4.28. IBEX 35 Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	87

Tablo 4.29. IBEX 35 Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	87
Tablo 4.30. IBEX 35 Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	87
Tablo 4.31. IBEX 35 Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	88
Tablo 4.32. IBEX 35 Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	88
Tablo 4.33. IBEX 35 Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	88
Tablo 4.34. IBEX 35 Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	89
Tablo 4.35. IBEX 35 Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	89
Tablo 4.36. IBEX 35 Seri 10 veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri.....	89
Tablo 4.37. 10 adet IBEX 35 veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar.....	91
Tablo 4.38. Rastgele elde edilen 10 BTC-USD veri setine ait bilgiler	92
Tablo 4.39. BTC-USD Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	92
Tablo 4.40. BTC-USD Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	94
Tablo 4.41. BTC-USD Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	94
Tablo 4.42. BTC-USD Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	94
Tablo 4.43. BTC-USD Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	95
Tablo 4.44. BTC-USD Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	95

Tablo 4.45. BTC-USD Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	95
Tablo 4.46. BTC-USD Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	96
Tablo 4.47. BTC-USD Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	96
Tablo 4.48. BTC-USD Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	96
Tablo 4.49. 10 adet BTC-USD veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar.....	98
Tablo 4.50. Rastgele elde edilen 10 adet gümüş veri setine ait bilgiler.....	99
Tablo 4.51. Gümüş Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	99
Tablo 4.52. Gümüş Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	101
Tablo 4.53. Gümüş Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	101
Tablo 4.54. Gümüş Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	101
Tablo 4.55. Gümüş Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	102
Tablo 4.56. Gümüş Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	102
Tablo 4.57. Gümüş Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	102
Tablo 4.58. Gümüş Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	103
Tablo 4.59. Gümüş Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	103
Tablo 4.60. Gümüş Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	103

Tablo 4.61. 10 adet gümüş veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar.....	105
Tablo 4.62. Rastgele elde edilen 10 adet altın veri setine ait bilgiler	106
Tablo 4.63. Altın Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	106
Tablo 4.64. Altın Seri 2 seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	108
Tablo 4.65. Altın Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	108
Tablo 4.66. Altın Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	108
Tablo 4.67. Altın Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	109
Tablo 4.68. Altın Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	109
Tablo 4.69. Altın Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	109
Tablo 4.70. Altın Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	110
Tablo 4.71. Altın Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	110
Tablo 4.72. Altın Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	110
Tablo 4.73. Altın Serileri için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar	112
Tablo 4.74. BJ veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	114
Tablo 4.75. AHK veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	115
Tablo 4.76. TET veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	117

Tablo 4.77. ABT veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri	118
Tablo 4.78. Mevsimsel bileşen içeren seriler için ortalama istatistiğine göre önerilen yöntemlerden ve S-Naive yöntemden elde edilen sonuçlar	119



ÖNGÖRÜ PROBLEMİ İÇİN YENİ DERİN GERİ BESLEMELİ MELEZ YAPAY SINIR AĞLARI

ÖZET

Öngörü problemlerinin çözümünde hem klasik öngörü yöntemleri hem de makine öğrenmesi yöntemleri kullanılmaktadır. Makine öğrenmesi yöntemlerinden biri olan derin yapay sinir ağları bu problemlerin çözümünde yaygın olarak kullanılmaktadır. Derin yapay sinir ağlarının bir türü olan basit geri beslemeli yapay sinir ağları, kullandıkları parametre sayısının diğer geri beslemeli ağlara göre az olması nedeniyle öngörü problemlerinin çözümünde sıklıkla tercih edilmektedir. Diğer yandan klasik öngörü yöntemlerinden biri olan basit üstel düzleştirme yöntemi, öngörü problemlerinin çözümündeki başarısıyla dikkat çekmektedir. Bu çalışmada öngörü problemlerinde başarılı sonuçlar veren bu iki yöntemin bir arada kullanıldığı melez yaklaşımlar önerilmektedir. Önerilen yapay sinir ağlarının eğitiminde sinüs kosinüs optimizasyon ve parçacık sürü optimizasyon algoritmalarına dayalı yeni eğitim algoritmaları önerilmektedir. Bu eğitim algoritmalarında aşırı uyum ve yerel optimum problemlerinin önüne geçmek amacıyla yeniden başlatma ve erken durdurma gibi iki farklı çözüm stratejisi kullanılmaktadır. Önerilen yöntemlerin öngörü performansı mevsimsel bileşen içeren ve içermeyen çeşitli zaman serileri kullanılarak analiz edilmiştir. Önerilen yöntemlerin hem sığ ve derin yapay sinir ağları hem de rastgele yürüyüş yönteminden daha iyi öngörü sonuçları üretebildiği görülmüştür.

Anahtar Kelimeler: Basit Geri Beslemeli Yapay Sinir Ağı, Öngörü, Parçacık Sürü Optimizasyon Algoritması, Sinüs Kosinüs Optimizasyon Algoritması, Üstel Düzleştirme

NEW DEEP RECURRENT HYBRID NEURAL NETWORKS FOR FORECASTING PROBLEM

SUMMARY

Both classical forecasting methods and machine learning methods are used to solve forecasting problems. Deep artificial neural networks, one of the machine learning methods, are widely used in solving these problems. Simple recurrent neural networks, which are a type of deep artificial neural networks, are frequently preferred in solving forecasting problems due to the small number of parameters they use compared to other recurrent networks. On the other hand, simple exponential smoothing method, which is one of the classical forecasting methods, draws attention with its success in solving forecasting problems. In this study, hybrid approaches are proposed in which these two methods, which give successful results in forecasting problems, are used together. New training algorithms based on sine cosine optimisation and particle swarm optimisation algorithms are proposed for training the proposed neural networks. In these training algorithms, two different solution strategies such as restart, and early stopping are used to avoid overfitting and local optimum problems. The forecasting performance of the proposed methods are analysed using various time series with and without seasonal component. It is observed that the proposed methods can produce better forecasting results than both shallow and deep artificial neural networks and random walk method.

Keywords: Exponential Smoothing, Forecasting, Particle Swarm Optimization Algorithm, Simple Recurrent Artificial Neural Network, Sine Cosine Optimization Algorithm

BÖLÜM 1. GİRİŞ

Derin yapay sinir ağları, günümüzde en yaygın kullanılan makine öğrenme yöntemlerinden biri olarak bilinmektedir. Uzun kısa dönem hafıza yapay sinir ağı (LSTM-ANN) (Hochreiter ve Schmidhuber) [1], basit geri beslemeli yapay sinir ağı (SRNN), geçitli geri beslemeli birim yapay sinir ağı (GRU-ANN) (Cho ve ark.) [2] gibi farklı derin yapay sinir ağları son yıllarda özellikle zaman serisi öngörü problemlerinde sıklıkla kullanılmaktadır. Derin yapay sinir ağları, sıg yapay sinir ağlarından daha iyi sonuç verebilmektedir. Aynı zamanda zaman serilerinin öngörü probleminde klasik öngörü yaklaşımları da sıkça kullanılmakta ve başarılı öngörü performansı göstermektedir. Öngörü çalışmalarında klasik öngörü yöntemleri ve yapay sinir ağı yöntemleri ayrı ayrı tercih edilebilmektedir. Derin yapay sinir ağlarının klasik öngörü yöntemleri ile birlikte kullanılarak ortaya konacak yeni bir ağ mimari yapısının, her iki yaklaşımında avantajlarına sahip olacağından öngörü performansının arttırılabileceği düşünülebilir. Bu motivasyon ile, bu tez kapsamında bir yapay sinir ağı yöntemi olan SRNN ve klasik bir öngörü yöntemi olan basit üstel düzleştirme (SES) yönteminin birleşiminden oluşan hibrit modeller (SRNN-SES ve SRNN-SES-S) önerilmiştir. SRNN-SES modeli, mevsimsel bileşen içermeyen zaman serileri için tasarlanırken SRNN-SES-S modeli ise mevsimsel bileşen içeren zaman serileri için tasarlanmıştır. Önerilen SRNN-SES ve SRNN-SES-S yöntemlerinin eğitimi için sezgisel optimizasyon algoritmalarından olan parçacık sürü optimizasyonu (PSO) algoritması (Kennedy ve Eberhart) [3] ve sinüs kosinüs optimizasyonu (SCO) algoritmasına (Mirjalili) [4] dayalı eğitim algoritmaları geliştirilmiştir.

Literatürde derin yapay sinir ağları kullanılarak gerçekleştirilen çalışmalar incelendiğinde, ilgili çalışmaların ağırlıklı olarak öngörü problemi üzerine olduğu görülmekle birlikte sınıflama problemi için de sıklıkla kullanılmaktadır. Zaman serisi analizi üzerine yapılan çalışmalar incelendiğinde de derin yapay sinir ağlarının,

özellikle ekonomi, sağlık, enerji kaynakları, hidroloji, mühendislik, jeoloji ve meteorolojik veri setlerinde sıklıkla kullanıldığı söylenebilir. Derin yapay sinir ağları hakkında bir literatür özeti aşağıda verilmektedir.

SRNN yönteminin ekonomi ve finans alanında sıklıkla tercih edildiği gözlemlenmiştir. Krtek ve Vosvrda [5] çalışmasında, bir simülasyon hisse senedinin fiyat tahmini SRNN yöntemi ile gerçekleştirilmiştir. Abdulkarim [6] çalışmasında, uluslararası havayolu yolcuları, S&P500 borsa endeksi ve Mackay-Glass kaotik zaman serisi verileri SRNN ve Elman-Jordan RNN yöntemleri ile analiz edilmiştir. Wang ve ark. [7] çalışmasında, SSE, TWSE, KOSPI ve Nikkesi225 borsalarına ait hisse senetleri fiyat tahmini Elman RNN yöntemi ile gerçekleştirilmiştir. Edet [8] çalışmasında, S&P500 borsası hisse senedi fiyat tahmini SRNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Samarawickrama ve Fernando [9] çalışmasında, günlük borsa fiyat tahmini için SRNN yöntemi kullanılmıştır. Ranjit ve ark. [10] çalışmasında, Nepal Rupisi'nin Euro, İngiliz sterlini ve Amerika Birleşik Devletleri doları karşısındaki değer tahmini SRNN yöntemi ile gerçekleştirilmiştir. Samarawickrama ve Fernando [11] çalışmasında, Sri Lanka rupisi üzerinden günlük Amerika Birleşik Devletleri doları, İngiltere sterlini ve EURO döviz kurları değer tahmini çok katmanlı algılayıcı (MLP), SRNN, LSTM-ANN, GRU-ANN ve konvolüsyonel sinir ağı (CNN) yöntemleri ile gerçekleştirilmiştir. Aggarwal ve Sahani [12] çalışmasında, birçok farklı ülkeye ait döviz kuru veri setlerinin analizi SRNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Dutta ve ark. [13] çalışmasında, Bitcoin fiyat tahmini LSTM-ANN, geri beslemeli yapay sinir ağı (RNN) ve GRU-ANN yöntemleri kullanılarak gerçekleştirilmiştir. Vaheb [14] çalışmasında, Goldman Sachs ve genel elektrik hisselerinin fiyat tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir. Berradi ve ark. [15] çalışmasında, IAM.PA ve ORA.PA borsalarına ait hisse senetleri fiyat tahmini Elman RNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Fan ve ark. [16] çalışmasında, borsa fiyat tahmini RNN yöntemi ile gerçekleştirilmiştir. Bas ve ark. [17] çalışmasında, SRNN'nin eğitimi PSO algoritması ile gerçekleştirilmiş ve yöntemin öngörü performansının değerlendirilmesinde Dow Jones ve Nikkei zaman serileri analiz edilmiştir. Zaychenko ve ark. [18] çalışmasında, New York menkul kıymetler borsası hisse senedi

fiyat tahmini SRNN yöntemi ile gerçekleştirilmiştir. Bas ve ark. [19] çalışmasında, Dow Jones ve Nikkei borsaları hisse senedi fiyat tahmini SRNN yöntemi ile gerçekleştirilmiştir. Jovanovic ve ark. [20] çalışmasında, Nikkei borsası hisse senedi fiyat tahmini SRNN yöntemi ile gerçekleştirilmiştir. Mendoza ve ark. [21] çalışmasında, S&P500 borsası, Almanya birleşik borsası, Amsterdam borsası ve İsviçre borsası endeksleri hisse senedi fiyat tahmini SRNN yöntemi ile gerçekleştirilmiştir. Almosova ve Andresen [22] çalışmasında, Amerika Birleşik Devletleri TÜFE enflasyon tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir. Song ve Choi [23] çalışmasında, DAX, DOW ve S&P500 borsaları hisse senedi fiyat tahmini CNN-LSTM-ANN ve GRU-ANN-CNN yöntemleri ile gerçekleştirilmiştir. Barkan ve ark. [24] çalışmasında, TÜFE'ye göre ayrıştırılmış enflasyon bileşenlerinin tahmini hiyerarşik RNN yöntemi ile gerçekleştirilmiştir. Vaguri ve ark. [25] çalışmasında, Relaxo Footwear ve Reliance Communications şirketleri hisse senedi fiyat tahmini RNN yöntemi ile gerçekleştirilmiştir. Cansu ve ark. [26] çalışmasında, FTSE borsası hisse senedi fiyat tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir.

SRNN yönteminin tercih edildiği diğer bir alan ise tıp alanı olduğu gözlemlenmiştir. Taneja ve ark. [27] çalışmasında, dijital stetoskop kullanılarak hastanelerde yapılan bir klinik denemeden toplanan verilerin sınıflandırılmasında SRNN, LSTM-ANN yöntemleri kullanılmıştır. Zeroual ve ark. [28] çalışmasında, COVID-19 hastalarının ve hayatta kalanların sayısının tahmini SRNN, LSTM-ANN, çift yönlü LSTM-ANN ve GRU-ANN yöntemleriyle gerçekleştirilmiştir. Qiu ve ark. [29] çalışmasında, kalp atış hızı verisinin analizi SRNN yöntemi ile gerçekleştirilmiştir. ArunKumar ve ark. [30] çalışmasında, Covid-19 tahmini LSTM-ANN, RNN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Amole ve ark. [31] çalışmasında, COVID-19 salgınının enerji tüketimi üzerindeki etkisini analiz etmek amacıyla SRNN yöntemi kullanılmıştır. Hallez ve ark. [32] çalışmasında, çocuklar ve yetişkinlere uygulanan nöropsikolojik testlerden elde edilen verilerin analizi bilişsel ve plastik RNN saat yöntemi gerçekleştirilmiştir.

Enerji kaynaklarına olan ilgi son yıllarda artış göstermektedir. SRNN yöntemi kullanılarak yapılan çalışmalar, özellikle elektrik, güneş ve rüzgâr enerjisi tahmini

üzerine olduğu gözlemlenmiştir. Su ve ark. [33] çalışmasında, Tayvan'daki kimyasal buhar biriktirme ekipmanından toplanan veriler SRNN yöntemi ile analiz edilmiştir. Garcia ve ark. [34] çalışmasında, petrol kuyularından petrol üretim tahmini SRNN yöntemi ile test edilmiştir. Ribeiro ve ark. [35] çalışmasında, Brezilya sanayi sitesi enerji tüketimi ve üretim akışı verisi SRNN yöntemi ile test edilmiştir. Brester ve ark. [36] çalışmasında, Elenia elektrik şebekesi arızası verisi SRNN yöntemi ile analiz edilmiştir. Paramasivan [37] çalışmasında, rüzgâr enerjisi tahmini SRNN, LSTM-ANN, GRU-ANN ve çift yönlü RNN yöntemleri ile gerçekleştirilmiştir. Muludi ve ark. [38] çalışmasında, Twitter API kullanılarak Twitter'dan toplanan Endonezya'daki enerji bağımsızlığı ile ilgili veriler SRNN yöntemi ile analiz edilmiştir. Ribeiro ve ark. [39] çalışmasında, İrlanda'da bulunan soğutmasız bir lojistik tesisten elde edilen veriler SRNN yöntemi ile analiz edilmiştir. Jaihuni ve ark. [40] çalışmasında, güneş radyonu tahmini LSTM-ANN, GRU-ANN, çift yönlü LSTM-ANN, çift yönlü GRU-ANN ve SRNN yöntemleri kullanılarak gerçekleştirilmiştir. Faisal ve ark. [41] çalışmasında, Bangladeş'in birçok şehrindeki güneş radyasyonu tahmini RNN, LSTM-ANN ve GRU-ANN yöntemleri ile test edilmiştir. Rhouma ve Said [42] çalışmasında, güneş enerjisi tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir. Jankauskas ve ark. [43] çalışmasında, rüzgâr santrallerinden elektrik üretimi tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir. Smyl ve ark. [44] çalışmasında, birçok Avrupa ülkesinin saatlik elektrik tüketim tahmini SRNN yöntemi ile gerçekleştirilmiştir. Rajasekaran ve ark. [45] çalışmasında, tek değişkenli güneş ışıınımı tahmini, çok değişkenli sıcaklık tahmini ve tek değişkenli rüzgâr hızı tahmini SRNN-LSTM-ANN ile gerçekleştirilmiştir. Alshammari [46] çalışmasında, saatlik rüzgâr hızı ve yönü tahmini RNN yöntemi ile gerçekleştirilmiştir. Cao ve ark. [47] çalışmasında, kanalizasyon arıtımında hareketsizleştirilmiş FeCu nanopartiküllerinin tahmini RNN yöntemi ile gerçekleştirilmiştir.

Coğrafya, jeoloji, meteoroloji ve hidroloji alanındaki çalışmalar incelendiğinde SRNN yönteminin tercih edildiği gözlemlenmiştir. Al-Hajj ve ark. [48] çalışmasında, Birleşik Arap Emirlikleri'ndeki ulusal meteoroloji ve sismoloji merkezi tarafından toplanılan hava durumu verisi SRNN yöntemi ile analiz edilmiştir. Johannesen ve ark. [49] çalışmasında, Sidney Bölgesi yük ölçüm verisinin analizi SRNN, GRU-ANN ve

LSTM-ANN yöntemleri ile gerçekleştirilmiştir. Gholami ve ark. [50] çalışmasında, İran'ın Kerman iline ait rüzgâr erozyonu verisi ile arazinin atmosferik toz emisyonlarına karşı duyarlılığı SRNN yöntemi ile analiz edilmiştir. Huang ve ark. [51] çalışmasında, deprem tahmini SRNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Sadhukhan ve ark. [52] çalışmasında, depremler ve yükselen küresel sıcaklıklar arasındaki ilişki tahmini SRNN yöntemi ile gerçekleştirilmiştir. Waseem ve ark. [53] çalışmasında, hava kalitesini ölçen PM2.5 konsantrasyonlarının tahmininde LSTM-ANN yöntemi kullanılmıştır. Sankalp ve ark. [54] çalışmasında, üst toprağın ne kadar yağmurlu ve kurak olduğu hakkında bilgi veren yüzey toprağı ıslaklığı tahmini SRNN, GRU-ANN yöntemleri ile gerçekleştirilmiştir. Gholami ve ark. [55] çalışmasında, Güney İran'ın Hormozgan eyaleti Şamil-Minab ovası arazisinin oyuntu erozyonuna duyarlılığının analizi SRNN yöntemi ile gerçekleştirilmiştir. Nketiah ve ark. [56] çalışmasında, atmosferik sıcaklık, çiğlenme noktası sıcaklığı, bağıl nem, hava basıncı ve kümülatif rüzgâr hızı verileri kullanılarak RNN yöntemine dayalı çok değişkenli zaman serisi tahmin modelleri oluşturulmuştur. Apaydın ve ark. [57] çalışmasında, Türkiye'de bulunan Ermenek hidroelektrik baraj rezervuarına gelen günlük akış tahmini SRNN, çift yönlü LSTM-ANN, GRU-ANN ve LSTM-ANN yöntemleri ile analiz edilmiştir. Müller ve ark. [58] çalışmasında, Amerika Birleşik Devletleri'ndeki yeraltı suyu seviyesi gözlem verilerinin analizi SRNN yöntemi ile gerçekleştirilmiştir. Sharma [59] çalışmasında, su deposu hidrolojik barajının ve bir doğal su deposunun akışının günlük akış tahmini SRNN yöntemi ile gerçekleştirilmiştir. Namdari ve ark. [60] çalışmasında, kentsel suyun kısa vadeli tahmini tek boyutlu SRNN, GRU-ANN, LSTM-ANN ve CNN yöntemleri ile gerçekleştirilmiştir. Jhong ve ark. [61] çalışmasında, Tayvan Wu Nehri'nin su seviyesi tahmini LSTM-ANN yöntemi ile gerçekleştirilmiştir.

SRNN yöntemin kullanıldığı diğer bir alan ise ulaşım olduğu gözlemlenmiştir. Fandango ve Wiegand [62] çalışmasında, kısa vadeli trafik akışı tahmini SRNN yöntemi ile gerçekleştirilmiştir. Liu ve ark. [63] çalışmasında, Guangzhou metro istasyonu yolcu akış tahmini LSTM-ANN ve SRNN yöntemleri ile gerçekleştirilmiştir. Fandango ve Kapoor [64] çalışmasında, trafik akış tahmini RNN yöntemi ile gerçekleştirilmiştir. Diunugala ve Mombeuil [65] çalışmasında, Sri

Lanka'ya gelen turist sayısı tahmini SRNN yöntemi ile gerçekleştirilmiştir. Pereira ve ark. [66] çalışmasında, Hollanda otoyolu trafik akış hızı veri seti SRNN yöntemi ile analiz edilmiştir. Nanyonga ve ark. [67] çalışmasında, hava taşımacılığı sistemindeki güvenlik olayı raporlarından oluşan veri seti kullanılarak uçuş aşamaları SRNN yöntemi ile sınıflandırılmıştır. Shepelev ve ark. [68] çalışmasında, karayolu trafiğinin uzay-zamansal bağımlılıklarının tahmini CNN ve LSTM-ANN yöntemleri ile gerçekleştirilmiştir.

SRNN yönteminin mühendislik alanında da sıklıkla tercih edildiği gözlemlenmiştir. Lima ve ark. [69] çalışmasında, sabit disk sürücülerinin arıza tahmini SRNN yöntemi ile gerçekleştirilmiştir. Markova ve Shopov [70] çalışmasında, Ueda, Pickover ve Burke-Shaw kaotik çekici verisinin analizi SRNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Mersha ve ark. [71] çalışmasında, F-16 savaş uçağının hücum açısı tahmini SRNN, LSTM-ANN, GRU-ANN, LSTM-ANN-GRU-ANN, SRNN-GRU-ANN ve SRNN-LSTM-ANN yöntemleri ile gerçekleştirilmiştir. Hun ve ark. [72] çalışmasında, Turnigy Graphene, LG ve Samsung marka pillere ait şarj tahmini SRNN yöntemi ile gerçekleştirilmiştir. Ayodeji ve ark. [73] çalışmasında, Turbofan uçak motoru veri seti analizi SRNN yöntemi ile gerçekleştirilmiştir. Essa ve ark. [74] çalışmasında, otonom araçların kontrolünde bir aracın yana kayma açısını doğrudan ölçebilen sensör sorunu tahmini SRNN, LSTM-ANN ve GRU-ANN yöntemleri ile gerçekleştirilmiştir. Rastegarpanah ve ark. [75] çalışmasında, Nissan Leaf 2011 pil modülünün yüzeyi üzerinde manuel olarak oluşturulan on poligonal yüzey yolu üzerinden toplanan veriler SRNN yöntemi ile analiz edilmiştir. Rezaei ve ark. [76] çalışmasında, alüminyum alaşımlarının kantitatif analizi SRNN, LSTM-ANN, GRU-ANN, Evrişimli-SRNN, Evrişimli-LSTM-ANN ve Evrişimli-GRU-ANN yöntemleri ile gerçekleştirilmiştir. Amemiya ve ark. [77] çalışmasında, model yanlılığı düzeltmesinde uzay-zamansal kaotik sistemlerin veri asimilasyonunu ve öngörülebilirliğini incelemek için kullanılan idealize edilmiş bir dinamik sistem olan Lorenz-96 sistemi SRNN yöntemi ile analiz edilmiştir.

SRNN yönteminin farklı birçok alanda da kullanıldığı gözlemlenmiştir. Ture ve Jovic [78] çalışmasında, Freebase alt kümesinin kullanıldığı basit soruların sınıflandırılması

problemi SRNN yöntemi ile test edilmiştir. Salehinejad ve Rahnamayan [79] çalışmasında, müşteri davranışlarını modelleme ve tahmin etmede SRNN yöntemi kullanılmıştır. Smirnov ve Nguifo [80] çalışmasında, Kaliforniya Üniversitesi'nden alınan çeşitli zaman serilerinin sınıflandırılması SRNN yöntemi ile gerçekleştirilmiştir. Günel ve ark. [81] çalışmasında, adi diferansiyel denklemler için Dirichlet sınır değer problemlerinin çözümü SRNN yöntemi ile gerçekleştirilmiştir. Mubarak ve ark. [82] çalışmasında, kurs videolarının öğrenciler tarafından tıklanması ile elde edilen veri setinin analizi LSTM-ANN, SRNN ve GRU-ANN yöntemleri kullanılarak gerçekleştirilmiştir. Chandra ve ark. [83] çalışmasında, finans, güneş lekesi, lazer, Henon, Lorenz, Mackey-Glass ve Rossler zaman serilerinin analizi SRNN, LSTM-ANN ve çift yönlü LSTM-ANN yöntemleri ile gerçekleştirilmiştir. Verma ve Dubey [84] çalışmasında, hastalıklı ve dezenfekte edilmiş pirinç bitkisinden elde edilen görüntüler zaman serisine dönüştürülmüş ve dönüştürülen bu zaman serisinin analizi LSTM-ANN-SRNN yöntemi ile gerçekleştirilmiştir. Kimani ve ark. [85] çalışmasında, çeşitli konuşma kayıtlarını içeren LibriSpeech veri seti kullanılarak konuşmayı metne dönüştürmek amacıyla SRNN yöntemi kullanılmıştır. Priyanka ve ark. [86] çalışmasında, film öneri filtrelerinin verimliliği SRNN yöntemi ile test edilmiştir. Choi ve Lee [87] çalışmasında, internet film veri tabanı, ortam algılama ile etkinlik tanıma ve popüler meyveleri içeren görsel veri setleri kullanılarak SRNN ve GRU-ANN yöntemlerinin tahmin performansı test edilmiştir. Walid ve ark. [88] çalışmasında, tuz üretim miktarı tahmini SRNN yöntemi ile gerçekleştirilmiştir.

Literatür incelendiğinde, SRNN yöntemi farklı birçok alanda kullanılan bir yöntem olarak karşımıza çıkmaktadır. LSTM-ANN ve GRU-ANN gibi yöntemlerin hibrit yaklaşımlarının oldukça sık tercih edildiği gözlemlenmiştir. Fakat SRNN yönteminin hibrit bir yaklaşımının tercih edildiği çalışmalar yok denilecek kadar azdır. Bu durum SRNN yöntemi ile farklı bir öngörü yönteminin birleştirilmesinin, öngörü literatürüne katkı sağlayacağı düşünülmektedir. Bu tez kapsamında, SRNN yöntemi ile klasik bir öngörü yöntemi olan SES yönteminin hibrit bir modeli geliştirilmiştir.

Yapay sinir ağları doğrusal olmayan zaman serilerinin öngörüsünde, başarılı öngörü performansı göstermektedir. Ancak bazı zaman serilerinin öngörüsünde SES yöntemi

daha iyi öngörü sonuçları verebilmektedir. Birçok zaman serisinin analizinde yapay sinir ağları yerine SES yöntemi tercih edilmektedir. Bu tez kapsamında tekrarlayan bir mekanizma olarak SES yönteminin kullanıldığı bir yapay sinir ağı geliştirilebileceği düşünülmektedir. Ayrıca bu iki modelin kombinasyonu elde edilirse zaman serisinin yapısına uygun bir öngörü elde edilebileceği düşünülmektedir. SES yönteminin tekrarlayan bir mekanizma olarak kullanıldığı bir SRNN yöntemi ilk kez bu tez kapsamında ele alınmıştır. Mevsimsel bileşen içeren ve içermeyen zaman serisi öngörü problemlerinin çözümü için ilk kez mimarisinde yinelenen bir mekanizma olarak SES yöntemini kullanan farklı iki SRNN yöntemi geliştirilmiştir. Öngörü problemlerinin çözümü için ilk kez SRNN ve SES yöntemleri kullanılarak tasarlanan farklı iki yapay sinir ağı mimarisi önerilmiştir. Ayrıca ağı mimarisi, aşırı uyum ve yerel optimum sorunlarından daha az etkilenen PSO ve SCO tabanlı eğitim algoritmaları kullanılarak tasarlanmıştır. Önerilen modellerin başlıca katkıları ve özgünlüğü aşağıdaki gibi listelenebilir.

- SRNN ve SES yöntemlerinin birleşiminden oluşan yeni iki farklı hibrit yapay sinir ağı önerilmektedir.
- Tasarlanan modellerin eğitimi için iki farklı eğitim algoritması önerilmiştir.
- Önerilen ağların eğitiminde yerel optimum tuzaklara yakalanma olasılığı daha düşük olan PSO ve SCO algoritmaları kullanılmıştır.
- Önerilen eğitim algoritmaları, yeniden başlatma stratejisiyle çalışarak rastgele başlangıç ağırlıklarından kaynaklanan değişkenliği azaltmakta ve sonuçları daha kararlı hale getirmektedir.
- Önerilen eğitim algoritmalarında, erken durdurma koşulu uygulanarak orantısız hataya dayalı aşırı uyum problemine çözüm sağlanmaktadır.
- Türev gerektirmeyen algoritmalar olan önerilen eğitim algoritmaları, türevi hesaplayamama sorunuyla karşılaşmamaktadır.

Önerilen yöntemlerin temel faydası, klasik bir öngörü yöntemi ile bir derin yapay sinir ağı yönteminin hibriti olması nedeniyle, öngörü problemini daha başarılı sonuçlarla çözebilmesidir. Ayrıca yöntem, eğitim sürecinde otomatik olarak SES, rastgele yürüyüş veya derin yapay sinir ağlarına dönüşebilmektedir. Sonuç olarak bu tez,

öngörü problemine alternatif çözümler üretme sorununu çözmeye çalışan çalışmalardan biridir.

Önerilen yöntemlerin öngörü performansları, mevsimsel bileşen içermeyen; İtalya borsası 40 endeksi (FTSE MIB), Almanya borsası 30 endeksi (DAX), Madrid borsası 35 endeksi (IBEX 35), bitcoin dolar (BTC-USD), gümüş ve altın zaman serileri ile mevsimsel bileşen içeren; Box&Jenkins havayolu yolcuları (BJ), Avustralya bira tüketimi (ABT), Ankara hava kirliliği (AHK), Türkiye elektrik tüketimi (TET) zaman serileri kullanılarak analiz edilmiştir. Ayrıca önerilen yöntemlerin öngörü performansları, literatürde mevcut olan MLP [89], tek çarpımsal nöron (SMN) [90], pi-sigma yapay sinir ağı (PS-ANN) [91], dentritik nöron model yapay sinir ağı (DNM-ANN) [92], GRU-ANN, LSTM-ANN ve SRNN yöntemlerinin öngörü performansları ve klasik öngörü yöntemi olan Naive ve S-Naive yöntemlerinin öngörü performansı ile karşılaştırılmıştır.

Bu tez çalışmasının ikinci bölümünde genel bilgiler başlığı altında sık kullanılan yapay sinir ağları, klasik öngörü yöntemleri ve bazı optimizasyon algoritmaları hakkında genel bilgi verilmiştir. Üçüncü bölümde önerilen yapay sinir ağı tanıtılmıştır. Önerilen yapay sinir ağının eğitimi için ortaya koyulan eğitim algoritmaları hakkında detaylı bilgi ise dördüncü bölümde verilmiştir. Tezin beşinci bölümünde tezde kullanılan veriler ve bu veriler kullanılarak elde edilen analiz sonuçları özetlenmiştir. Tezin sonuç ve tartışma kısmına ise son bölümde yer verilmiştir.

BÖLÜM 2. KAYNAK ARAŞTIRMASI

Tezin bu bölümünde zaman serisi literatüründe kullanılan bazı temel öngörü yöntemleri, bazı sığ ve derin yapay sinir ağları ile bu tez kapsamında kullanılan algoritmalar hakkında bilgi verilmektedir.

2.1. Klasik Öngörü Yöntemleri

Zaman serisi, belirli bir zaman periyodu boyunca eşit aralıklarla sıralanmış veri setidir. Bir veri setinin zaman serisi olması için zamana bağlı değişim göstermesi gerekir. Zaman serilerinin analizinde geleceğe yönelik tahmini değerleri elde etmek önemli bir yer teşkil etmektedir. Literatürde bu durum öngörü olarak ifade edilmekte ve birçok zaman serisi çalışmalarında sıklıkla karşımıza çıkmaktadır. Ekonometrik, meteorolojik, hidrolojik, çevre mühendisliği, enerji mühendisliği ve daha birçok zaman serisi analizinde öngörü yapılmaktadır. Örneğin, geçmiş ocak ayı hava durumu bilgileri göz önüne alınarak bir sonraki ocak ayı için öngöründe bulunulabilirken geçmiş yıllara ait ihracat/ithalat miktarları ile bir sonraki yılın ihracat/ithalat miktarı hakkında da öngöründe bulunmak mümkündür. Yine bir ürünün geçmiş yıllara ait üretim miktarı göz önüne alınarak bir sonraki dönem üretim miktarı hakkında öngörü elde edebiliriz. Zaman serisi öngörüsü elde edilirken belli yöntemler kullanılmaktadır. Zaman serisinin içerdiği bileşenlere göre değişen bu yöntemlerin bazıları aşağıda verilmiştir.

2.1.1. Naive yöntem

Bir zaman serisinin mevsimsel bileşen içermediği durumda kullanıldığı Naive yöntem, trende sahip zaman serilerinde kullanılabilir. Bu yöntemin serinin ortalama etrafında seyrettiği durumda en iyi sonucu vermesi beklenmektedir. Naive yöntemde

öngörüler zaman serisindeki gözlenen son gerçek değer olmakla birlikte denklem 2.1 ile elde edilmektedir.

$$\hat{x}_{t+h} = x_t \quad (2.1)$$

Burada h , öngörü adım sayısını ifade etmektedir.

2.1.2. Mevsimsel naive yöntem

Zaman serisinin belirli bir davranışı belirli periyotlarla tekrar etmesine mevsimsellik denmektedir. Zaman serisinin mevsimsel bileşen veya devirsel bileşen içerdiği durumda kullanılan yöntemdir. Mevsimsel Naive (S-Naive) yönteminde öngörü, bir önceki periyoddaki gerçek değer olmakla birlikte denklem 2.2 ile elde edilmektedir.

$$\hat{x}_{t+h} = x_{t+h-s(k+1)} \quad (2.2)$$

Burada k , $(h - 1)/s$ sayısının tam kısmını, h öngörü adım sayısını ve s ise zaman serisinin mevsimsel periyodunu ifade etmektedir.

2.1.3. Aritmetik ortalama yöntemi

Zaman serisinin ortalama etrafında seyrettiği durumda kullanılan bu yöntemde öngörüler, zaman serisinin gözlemleri için hesaplanan ortalamaya eşittir. Aritmetik ortalama yöntemi için formül denklem 2.3 ile verilmiştir.

$$\hat{x}_{t+h} = \bar{x} \quad (2.3)$$

Burada h , öngörü adım sayısıdır.

2.1.4. Hareketli ortalama yöntemi

Bu yöntem zaman serilerinin düzleştirilmesinde ve öngörülerin elde edilmesinde kullanılmaktadır. Merkezsel hareketli ortalama (MHO) ve basit hareketli ortalama (BHO) olmak üzere iki hareketli ortalama yöntemi bulunmaktadır. Hareketli ortalama yönteminde, m germe sayısı önemli bir parametre olup yöntemde ortalamaların hesaplanacağı gözlem sayısını ifade etmektedir. Zaman serilerinde mevsimsel dalgalanmaların düzleştirilmesi veya yok edilmesi için germe sayısı periyot kadar alınabilir. BHO yöntemi için formül denklem 2.4'te verildiği gibidir.

$$BHO_t = \frac{x_{t-1} + x_{t-2} + \dots + x_{t-m}}{m}; t = m + 1, m + 2, \dots, n \quad (2.4)$$

MHO yöntemi için ise formül denklem 2.5'te verildiği gibidir.

$$MHO_t = \begin{cases} \frac{x_{t-\frac{(m-1)}{2}} + x_{t-\frac{(m-1)}{2}+1} + \dots + x_t + \dots + x_{t+\frac{(m-1)}{2}-1} + x_{t+\frac{(m-1)}{2}}}{m}, & \text{Eğer } m \text{ tek ise} \\ \frac{\frac{1}{2}x_{t-\frac{m}{2}} + x_{t-\frac{m}{2}+1} + \dots + x_t + \dots + x_{t+\frac{m}{2}-1} + \frac{1}{2}x_{t+\frac{m}{2}}}{m}, & \text{Eğer } m \text{ çift ise} \end{cases} \quad (2.5)$$

2.1.5. Mevsimsel ayırıştırma yöntemleri

Mevsimsel ayırıştırma yöntemleri, klasik ayırıştırma yöntemleri ve STL ayırıştırma yöntemi olmak üzere iki başlık altında açıklanmıştır.


2.1.5.1. Klasik ayırıştırma yöntemleri

Mevsimsel ayırıştırma yönteminde amaç zaman serisinin bileşenlerine ayrılmasıdır. Mevsimsel ayırıştırmanın toplamsal ve çarpımsal olarak uygulanması mümkündür. Toplamsal ve çarpımsal ayırıştırmada, sırasıyla denklem 2.6 ve denklem 2.7 kullanılmaktadır.


$$x_t = T_t + M_t + e_t \quad (2.6)$$

$$x_t = T_t \times M_t \times e_t \quad (2.7)$$

Burada T ve M sırasıyla zaman serisindeki trend ve mevsimsel bileşenleri ifade ederken e ise hata terimini ifade etmektedir. Toplamsal ve çarpımsal klasik ayrıştırma yöntemleri için akış diyagramları Şekil 2.1. ve Şekil 2.2.'de verildiği gibidir.



Şekil 2.1. Klasik toplamsal ayrıştırma yöntemi akış diyagramı



Şekil 2.2. Klasik çarpımsal ayrıştırma yöntemi akış diyagramı

2.1.5.2. STL ayrıştırma yöntemi

Bu yöntemde klasik ayrıştırma yöntemlerinden farklı olarak mevsimsel endeks zamanla değişebilmektedir. Loess ile mevsimsel ve trend ayrıştırma yöntemi (STL), serideki aykırı değerlerden etkilenmemekle birlikte kayıp değerlerin olması durumunda da çalışabilmektedir.

2.1.6. Regresyon yöntemleri

Zaman serisi öngörü yöntemlerinden bir diğeri de regresyon analizi yöntemidir. Bu analizde bağımlı değişken ile bağımsız değişken ya da değişkenler arasındaki ilişki modellenmektedir. Kullanılan modelin yapısına göre doğrusal ve doğrusal olmayan regresyon modelleri olarak ikiye ayrılabilir. Model denklem 2.8’de verildiği gibidir.

$$y = f(x_1, x_2, \dots, x_p; \theta) + \varepsilon \quad (2.8)$$

f fonksiyonu, doğrusal veya doğrusal olmayan şekilde seçilebilmektedir. Doğrusal ya da doğrusal olmayan değişkenlerin kullanıldığı regresyon analizleri, tam ranklı doğrusal model teorisine dayanmakta olup bu model denklem 2.9 ile ifade edilmektedir.

$$Y = X\beta + \varepsilon \quad (2.9)$$

Bu eşitlikte Y bağımlı değişkeni, X açıklayıcı değişkenler matrisini ve ε hata terimini göstermektedir. β ise her bir açıklayıcı değişkene karşılık gelen parametrelerin vektörüdür. $\varepsilon \sim N(0, \sigma^2 I)$ varsayımı altında en küçük varyanslı, doğrusal ve yansız tahmin ediciler ve hipotez testleri için bilinen dağılımlara sahip test istatistikleri elde edilebilmektedir. Parametre tahminleri ve varyans tahmin edicileri denklem 2.10 ve denklem 2.11’de verilmektedir.

$$\hat{\beta} = (X'X)^{-1}X'Y \quad (2.10)$$

$$V(\hat{\beta}) = \hat{\sigma}^2 (X'X)^{-1} \quad (2.11)$$

Hipotez testleri için genel bir form denklem 2.12'de ifade edildiği gibidir.

$$F = \frac{((K-b)\beta)'[(K-b)(X'X)^{-1}(K-b)^{-1}]^{-1}((K-b)\beta)}{p\hat{\sigma}^2} \quad (2.12)$$

Burada K ve b test edilecek hipoteze göre oluşturulan matris veya vektördür. Hipotezler genel olarak denklem 2.13'te verilmektedir.

$$\begin{aligned} H_0: K\beta &= b \\ H_1: K\beta &\neq b \end{aligned} \quad (2.13)$$

Zaman serisinin trend ve mevsimsel bileşen içerip içermediği durumlara göre regresyon yöntemleri şekillenmektedir. Tablo 2.1.'de zaman serisinin trend ve mevsimsel bileşen içerip içermediği durumlarına göre regresyon yöntemleri listelenmiştir.

Tablo 2.1. Trend ve mevsimsel bileşen içerip içermediği durumlara göre regresyon yöntemleri	
Lineer Trend Yöntemi	$x_t = \beta_0 + \beta_1 t + \varepsilon_t$
Karesel Trend Yöntemi	$x_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \varepsilon_t$
Kübik Trend Yöntemi	$x_t = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 t^3 + \varepsilon_t$
Üstel Trend Yöntemi	$x_t = \beta_0 \exp(\beta_1 t + \varepsilon_t)$ $\log(x_t) = \beta_0 + \beta_1 t + \varepsilon_t$
Ters Regresyon Modeli	$x_t = \beta_0 + \frac{\beta_1}{t} + \varepsilon_t$
Fourier Terimlerini İçeren Regresyon Yöntemi	$X_t = \beta_0 + \sum_{i=1}^m \beta_i t^i + \sum_{j=1}^K \left[\alpha_j \sin\left(\frac{2\pi j t}{s}\right) + \gamma_j \cos\left(\frac{2\pi j t}{s}\right) \right] + \varepsilon_t$
Gösterge Değişkenli Regresyon Modeli	$x_t = \beta_0 + \sum_{i=1}^m \beta_i t^i + \sum_{k=1}^{s-1} D_k + \varepsilon_t$

2.1.7. Üstel düzeltirme yöntemleri

Üstel düzeltirme yöntemleri öngörü yöntemlerinde başarılı bir yöntem olarak görülmektedir. Bu yöntemler az sayıda parametre ile çalışmakta ve kolaylıkla anlaşılmaktadır. Üstel düzeltirme yöntemleri serinin bileşenlerinin zamanla güncellenmesiyle öngörülerin elde edilmesine dayanmaktadır.

2.1.7.1. Basit üstel düzeltirme yöntemi

Yapısı itibarıyla basit olan bu yöntemde, serinin seviyesinin zamanla değişimi modellenmektedir. SES yönteminde, öngörüler denklem 2.14 ile elde edilmektedir.

$$\hat{x}_{t+1} = \alpha x_t + (1 - \alpha)\hat{x}_t \quad (2.14)$$

α , düzeltirme katsayısıdır ve $0 \leq \alpha \leq 1$ aralığında değer almaktadır. α parametresinin optimal değeri, hata kareler ortalaması (MSE)'yi minimize edecek farklı optimizasyon yöntemleri ile de elde edilebilir. Bu yöntemlerden en bilinen yöntem “grid search” optimizasyon yöntemidir. Bu yöntem ile düzeltirme katsayısı $0 \leq \alpha \leq 1$ aralığında eşit parçalara bölünür. En düşük MSE'ye sahip düzeltirme katsayısı elde edilir.

SES yönteminin $ARIMA(0,1,1)$ modeli ile denkliği denklemler 2.15-2.17 ile ifade edilmektedir:

$$x_t = x_{t-1} - \emptyset e_{t-1} + e_t. \quad (2.15)$$

Burada $\emptyset$ otoregresif modelin parametresini ifade etmektedir. Denklem 2.15'ten yola çıkarak $ARIMA(0,1,1)$ modeli ile SES yönteminin denkliği denklem 2.16 ile ifade edilebilmektedir. Denklem 2.16'da $\emptyset$ yerine $1 - \alpha$ alındığında denklem 2.17 elde edilmektedir.

$$\hat{x}_t = x_{t-1} - \emptyset e_{t-1} \quad (2.16)$$

$$\hat{x}_t = \alpha x_{t-1} + (1 - \alpha)\hat{x}_{t-1} \quad (2.17)$$

Farklı bir çözüm yolu ise gecikmeli değişkenlerin üstel azalan ağırlıklar ile bir ağırlıklı ortalaması olmaktadır. Bu durum denklem 2.18’de verilmiştir.

$$\hat{x}_{t+1} = \alpha(\sum_{k=0}^{t-1}(1 - \alpha)^k x_{t-k}) \quad (2.18)$$

2.1.7.2.Holt doğrusal trend üstel düzleştirme yöntemi

Zaman serisinin trend içerdiği durumda Holt doğrusal trend üstel düzleştirme yöntemi kullanılmaktadır. Bu yöntemde serinin seviyesi ve trendin eğimi için iki üstel düzleştirme katsayısı bulunmaktadır. Yöntemde, serinin seviyesi ve trendinin zamanla güncellenmesiyle öngörüler elde edilmektedir.

Holt yönteminde öngörü denklem 2.19’daki gibi elde edilmektedir.

$$\begin{aligned} \hat{L}_t &= \lambda_1 x_t + (1 - \lambda_1) \hat{x}_t \\ \hat{b}_t &= \lambda_2 (\hat{L}_t - \hat{L}_{t-1}) + (1 - \lambda_2) \hat{b}_{t-1} \\ \hat{x}_{t+h} &= \hat{L}_t + h \hat{b}_t \end{aligned} \quad (2.19)$$

Burada, λ_1 düzleştirme katsayısını, λ_2 eğim için düzleştirme katsayısını, $\hat{L}_t$ serinin t dönemindeki seviyesini, $\hat{b}_t$ ise trend bileşeni ifade etmektedir.

2.1.7.3. Damped trend üstel düzleştirme yöntemi

Bu yöntem, Holt doğrusal üstel düzleştirme yöntemine oldukça benzemektedir. Yönteme ek olarak bir dampen (damping) parametresi eklenmektedir.

Damped trend üstel düzleştirme yönteminde öngörü denklem 2.20 ile elde edilmektedir.

$$\begin{aligned} \hat{L}_t &= \lambda_1 x_t + (1 - \lambda_1)(\hat{L}_{t-1} + \phi \hat{b}_{t-1}) \\ \hat{b}_t &= \lambda_2 (\hat{L}_t - \hat{L}_{t-1}) + (1 - \lambda_2) \phi \hat{b}_{t-1} \\ \hat{x}_{t+h} &= \hat{L}_t + (\phi + \phi^2 + \phi^h) \hat{b}_t \end{aligned} \quad (2.20)$$

Burada, $\hat{L}_t$ serinin t dönemindeki seviyesini, $\hat{b}_t$ trend bileşeni ifade ederken $\emptyset$ ise dampen parametresini ifade etmekte ve $0 < \emptyset < 1$ aralığında değer almaktadır.

2.1.7.4. Holt-Winters toplamsal ve çarpımsal üstel düzleştirme yöntemleri

Bu yöntem, trend ve mevsimsel bileşen içeren zaman serilerinin çözülmesinde kullanılmaktadır. Holt-Winters yöntemlerinde Holt doğrusal trend üstel düzleştirme yöntemine ek olarak mevsimsel bileşen için güncelleme denklemi eklenirken tahmin denklemine mevsimsel trend eklenmektedir. Holt-Winters toplamsal üstel düzleştirme yönteminde öngörü, denklem 2.21 ile elde edilmektedir.

$$\begin{aligned}\hat{L}_t &= \lambda_1(x_t - s_{t-m}) + (1 - \lambda_1)(\hat{L}_{t-1} + \hat{b}_{t-1}) \\ \hat{b}_t &= \lambda_2(\hat{L}_t - \hat{L}_{t-1})(1 - \lambda_2)\hat{b}_{t-1} \\ s_t &= \lambda_3(x_t - \hat{L}_{t-1} - \hat{b}_{t-1}) + (1 - \lambda_3)s_{t-m} \\ \hat{x}_t &= \hat{L}_t + h\hat{b}_t + s_{t+h-m(k+1)}\end{aligned}\tag{2.21}$$

Holt-Winters çarpımsal üstel düzleştirme yönteminde öngörü denklem 2.22 ile elde edilmektedir.

$$\begin{aligned}\hat{L}_t &= \lambda_1(x_t/s_{t-m}) + (1 - \lambda_1)(\hat{L}_{t-1} + \hat{b}_{t-1}) \\ \hat{b}_t &= \lambda_2(\hat{L}_t - \hat{L}_{t-1})(1 - \lambda_2)\hat{b}_{t-1} \\ s_t &= \lambda_3\left(x_t/(\hat{L}_{t-1} - \hat{b}_{t-1})\right) + (1 - \lambda_3)s_{t-m} \\ \hat{x}_{t+h} &= (\hat{L}_t + h\hat{b}_t)s_{t+h-m(k+1)}\end{aligned}\tag{2.22}$$

Burada, m zaman serisinin periyodunu, k ise $(h - 1)/m$ sayısının tam kısmını ifade etmektedir. Ayrıca, λ_1 düzleştirme katsayısını, λ_2 eğim için düzleştirme katsayısını, λ_3 mevsimsel kısım için düzleştirme katsayısını, $\hat{L}_t$ serinin t dönemdeki seviyesini, $\hat{b}_t$ trend bileşeni ve s_t mevsimsel bileşeni ifade etmektedir.

2.1.8. Otoregresif bütünleşik hareketli ortalamalar modelleri ve mevsimsel otoregresif bütünleşik hareketli ortalamalar modelleri

Otoregresif bütünleşik hareketli ortalamalar (*ARIMA*) modellerinin amacı, zaman serisinin otokorelasyon yapısına uygun doğrusal sürecin bulunmasıdır. Aynı zamanda analitik amaçla ve zaman serilerinin sistematik kısmını tahmin etmek amacıyla kullanılmaktadır. Genel *ARIMA* modelleri arasında, otoregresif model (*AR*), hareketli ortalamalar (*MA*), karma hareketli ortalama-otoregresif modeller (*ARMA*) durağan serilere uygun modeller olmaktadır.

Otoregresif Modeller: $ARIMA(p, 0, 0) = AR(p)$

$AR(p)$ gösterimi, p . dereceden *AR* modeli ifade etmektedir. Burada, p *AR* modelinin derecesini ifade etmektedir. $AR(p)$ modeli denklem 2.23'te verildiği gibidir.

$$X_t = \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t \quad (2.23)$$

Burada, $\phi_1, \phi_2, \dots, \phi_p$ otoregresif parametrelerini, ε_t beyaz gürültü sürecini ifade etmektedir.

Hareketli Ortalamalar Modeli: $ARIMA(0, 0, q) = MA(q)$

$MA(q)$ gösterimi, q . dereceden *MA* modelini ifade etmektedir. Burada, q *MA* modelinin derecesini ifade etmektedir. $MA(q)$ modeli denklem 2.24'te verildiği gibidir.

$$X_t = \mu + \varepsilon_t + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (2.24)$$

Burada, $\theta_1, \theta_2, \dots, \theta_q$ hareketli ortalamalar parametrelerini, μ X_t 'nin beklenen değerini, ε_t beyaz gürültü sürecini ifade etmektedir.

2.1.8.1. Otoregresif hareketli ortalamalar modelleri

$ARMA(p, q)$ modeli, durağan süreçlerin yalnızca AR veya MA süreçlerinde değil, her iki sürecin özelliklerine sahip olduğu durumlarda kullanılırlar. Yani zaman serisinin hem AR hem MA bileşenine sahip olması durumunda modelde bir arada kullanılmaktadırlar. Böyle durumlarda zaman serilerine daha iyi uyum sağlayacak bu modeller “otoregresif hareketli ortalama: $ARMA(p, q)$ ” modelleri olarak ifade edilmektedirler. Mevsimsel bileşen içermeyen zaman serilerinin analizinde kullanılan bu model, aynı zamana durağan zaman serilerinin analizinde kullanılmaktadır.

p adet gecikmeli değişken ve q adet gecikmeli hatanın yer aldığı $ARMA(p, q)$ modeli denklem 2.25’te verildiği gibidir.

$$x_t = \phi_0 + \phi_1 x_{t-1} + \dots + \phi_p x_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (2.25)$$

Burada, ϕ_0 zaman serisinin seviyesini, $\phi_1, \phi_2, \dots, \phi_p$ AR parametrelerini, $\theta_1, \theta_2, \dots, \theta_q$ MA parametrelerini ifade etmektedir. ε_t beyaz gürültü sürecini ifade etmektedir. Denklem 2.25’te verilen model aynı zamanda $ARMA(p, q)$ sürecini ifade etmektedir. $ARMA(p, q)$ sürecinin, ortalama, varyans, otokovaryans ve otokorelasyonları zaman serisi modellenmesi açısından önemlidir. $ARMA(p, q)$ modeli geri öteleme operatörü olan $B^k x_t = x_{t-k}$ kullanılarak denklem 2.26’daki gibi yazılabilmektedir.

$$(1 - \phi_1 B - \dots - \phi_p B^p)(x_t - \mu) = (1 - \theta_1 B - \dots - \theta_q B^q)\varepsilon_t \quad (2.26)$$

Bu denklem daha basit bir şekilde $\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p)$ ve $\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q)$ polinomları kullanılarak denklem 2.27 ile ifade edilebilmektedir.

$$\phi(B)(x_t - \mu) = \theta(B)\varepsilon_t \quad (2.27)$$

2.1.8.2. Otoregresif bütünleşik hareketli ortalamalar modelleri

Zaman serileri durağan olduklarında $AR(p)$, $MA(q)$ ve $ARMA(p, q)$ modellerinden biri uygun olmaktadır. Fakat zaman serilerinin çoğunda, ortalama ve/veya varyans zamana bağlı bir eğilim göstermektedir. Zaman serilerinin sabit bir ortalama etrafında dağılım göstermemesi veya stokastik sürecin karakteristiklerinin zamana bağlı değişimi sebebiyle durağan olmayan zaman serileri ortaya çıkmaktadır. Durağan olmayan bu serilere durağan olana kadar fark alma işlemi uygulanmaktadır. $ARIMA(p, d, q)$ modelleri, d kere fark alındığında durağan olan zaman serisine uygulandığında “durağan $ARMA$ ” modeli olarak ifade edilmektedir.

Durağan olamayan x_t zaman serisinin d . dereceden farkı alınarak durağanlaşma gerçekleştiğinde, yeni seri w_t olarak tanımlandığı varsayılın. Dönüşüm denklem 2.28’de verildiği gibidir.

$$w_t = \Delta^d x_t = (1 - B)^d x_t \quad (2.28)$$

Burada, d fark alma işlemi sayısını, Δ fark operatörünü ifade etmektedir. Aynı zamanda w_t durağanlaşmış zaman serisini belirtirken süreç $ARMA(p, q)$ süreci olmaktadır. Bu durumda model, denklem 2.29’da verildiği gibidir.

$$w_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \theta_2 \varepsilon_{t-2} - \dots - \theta_q \varepsilon_{t-q} \quad (2.29)$$

Burada, fark serisi w_t , bir $ARMA(p, q)$ sürecine sahip olduğu zaman x_t değişkeninin (p, d, q) derecesi ile bir $ARIMA(p, d, q)$ sürecine sahip olmaktadır.

2.1.8.3. Mevsimsel otoregresif bütünleşik hareketli ortalama modelleri

SARIMA modelleri mevsimsel bileşen içeren zaman serilerinin analizinde kullanılmaktadır. Bu modellere mevsimsel otoregresif ve mevsimsel hareketli ortalama terimleri eklenmektedir. Mevsimsel bileşen içeren serinin durağanlaştırılması

için mevsimsel fark alma işlemi de modele eklenmektedir. $SARIMA(q, d, q)(P, D, Q)s$, kapalı formda denklem 2.30'daki gibi ifade edilmektedir.

$$\phi(B)\Phi(B)(1-B)^d(1-B^s)^D(x_t - \mu) = \theta(B)\Theta(B)\varepsilon_t \quad (2.30)$$

Burada, $\phi(B)$, $\theta(B)$, $\Phi(B)$ ve $\Theta(B)$ polinomları ifade etmekle birlikte denklem 2.31-2.34'te verildiği gibidir.

$$\phi(B) = (1 - \phi_1 B - \dots - \phi_p B^p) \quad (2.31)$$

$$\theta(B) = (1 - \theta_1 B - \dots - \theta_q B^q) \quad (2.32)$$

$$\Phi(B) = (1 - \Phi_1 B - \dots - \Phi_P B^{sP}) \quad (2.33)$$

$$\Theta(B) = (1 - \Theta_1 B - \dots - \Theta_Q B^{sQ}) \quad (2.34)$$

2.1.9. Eşik otoregresif modeller

Bu modeller doğrusal olmayan zaman serilerinin analizinde kullanılmaktadır. Eşik otoregresif model, parçalı regresyon modeline sahiptir. Bu modellerde denklemler, zaman serisinin geçmiş değerlerinin eşik değer/değerlerle kıyaslanması sonucu elde edilen bilgiye göre kullanılmaktadır. m rejimli p . dereceden eşik otoregresif modeli $-\infty < r_1 < \dots < r_m < \infty$ ve $d > 0$ olmak üzere denklem 2.35'te verildiği gibidir.

$$x_t = \begin{cases} \phi_{0,1} + \sum_{i=1}^p \phi_{i,1} x_{t-i} + \sigma_1 \varepsilon_t, & x_{t-d} \leq r_1 \\ \phi_{0,2} + \sum_{i=1}^p \phi_{i,2} x_{t-i} + \sigma_2 \varepsilon_t, & r_1 < x_{t-d} \leq r_2 \\ \vdots \\ \phi_{0,m} + \sum_{i=1}^p \phi_{i,m} x_{t-i} + \sigma_m \varepsilon_t, & x_{m-1} \leq x_{t-d} \end{cases} \quad (2.35)$$

Burada, ε_t sıfır ortalama ve birim varyanslı rastgele hatayı, d gecikme parametresini, $r_1, \dots, r_m$ ise eşik değerleri ifade etmektedir.

2.2. Yapay Sinir Ağları


Zaman serisi çalışmalarında sıklıkla karşılaşılan öngörü, geçmiş bilgiler ışığında gelecek ile ilgili yaklaşık bilgiler elde etmeye çalışmaktadır. Bu amaçla, birçok öngörü yönteminin yanı sıra yapay sinir ağları da sıklıkla kullanılmaktadır. Bu ağlar, insan sinir sistemini basit bir şekilde taklit eden yapay zekâ yöntemlerdir. İnsan sinir sistemi, sinir adı verilen hücrelerden oluşmaktadır. Beynin haberleşme sistemini oluşturan bu sinirler, içsel ve dışsal bilgileri toplar, işler, değerlendirir, karar verir ve harekete geçilmesini sağlar.

Biyolojik sinir sisteminin basit bir taklidi olan yapay sinir ağları, McCulloch ve Pitts [93] tarafından ilk kez modellenmiştir. McCulloch ve Pitts [93] tarafından gerçekleştirilen bu nöron model Şekil 2.3.'te verilmiştir.

McCulloch ve Pitts [93] tarafından gerçekleştirilen nöron modelin çıktısı, denklem 2.36 ile hesaplanmaktadır. Burada, x_i girdileri ($i = 1, 2, \dots, n$), k . iterasyondaki girdi değerinin yokluğuna ve varlığına bağlı olarak sırasıyla 0 ya da 1 değerini alırlar. o , nöronun çıktı değerini ifade etmekte ve $k + 1$ anında elde edilecek çıktı değerini vermektedir.

$$o^{k+1} = \begin{cases} 1, & \text{Eğer } \sum_{i=1}^n w_i x_i^k \geq T \\ 0, & \text{Eğer } \sum_{i=1}^n w_i x_i^k < T \end{cases} \quad (2.36)$$

Burada, x_i girdi değeri ile bu girdi değerine karşılık gelen w_i ($w_i = \pm 1, i = 1, 2, \dots, n$) ağırlığı çarpılıp toplanır ve elde edilen değer, T eşik değerinden büyük ise nöronun $k + 1$ anındaki o^{k+1} çıktısı 1 değerini alır aksi halde nöronun çıktı değeri 0 olur.



Şekil 2.3. McCulloch-Pitts nöron model

Şekil 2.3. ile gösterilen McCulloch-Pitts [93] nöron modelinde daire şekli, biyolojik nöron yapısındaki somaya karşılık gelmektedir. Girdi sinyallerini nörona ileten bağlantılar oklarla gösterilmekte olup biyolojik sinir hücresindeki dentritlere karşılık gelmektedir. Çıktı, bir ok ile gösterilmekte ve biyolojik sinir hücresindeki aksona karşılık gelmektedir. Biyolojik sinir hücresinde gelen her sinyalin aktarımı olmamaktadır. Bu durum McCulloch-Pitts [93] nöron modelinde de geçerli olup gelen her bir sinyal aktarılmamakta ve belli bir eşik değerin üzerinde olduğunda aktarılmaktadır. Günümüzdeki yapay sinir ağı modellerinin temeli McCulloch-Pitts [93] nöron modeline dayanmaktadır.

Son zamanlardaki gelişmiş yapay sinir ağlarının temelini ilk ve temel yapay sinir ağı olarak bilinen basit algılayıcı ve ADALINE (Uyarlamalı doğrusal nöron) oluşturmaktadır.

MLP'nin temeli olan basit algılayıcı (simple perceptron), Rosenblatt [94] tarafından önerilmiştir.

Literatürde sıkça tercih edildiği görünen yapay sinir ağları, birçok avantaja sahiptir. Bu avantajlar aşağıdaki gibi sıralanabilmektedir.

- İstatistikte kullanılan modelleme tekniklerinin gerektirdiği veri ile ilgili kısıtlar bulunmamaktadır.
- Doğrusal olmayan sistemler kolayca modellenabilmektedir.

Bir yapay sinir ağı girdi, ağırlıklar, birleştirme fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş bölümden oluşmaktadır.

Girdi: Ağa dışardan gelen bilgilerin olduğu kısımdır.

Ağırlıklar: Ağa gelen girdilerin öneminin ve hücre üzerindeki etkisinin gösterildiği kısımdır.

Birleştirme Fonksiyonu: Net girdinin hesaplandığı ve girdilerin birleştirildiği kısımdır.

Aktivasyon Fonksiyonu: Net girdinin işlenerek bu girdiye karşılık sinir hücresinin ürettiği çıktının belirlendiği kısımdır.


Çıkış: Aktivasyon fonksiyonunun ürettiği değerin olduğu kısımdır.

2.2.1.Yapay sinir ağı modelleri


Yapay sinir ağı modelleri, tek katmanlı algılayıcı, çok katmanlı algılayıcı, ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere dört başlık altında sunulmuştur.

2.2.1.1.Tek katmanlı (tabakalı) algılayıcılar

Tek katmanlı algılayıcılar, sadece girdi ve çıktı katmanından oluşan modellerdir. Rosenblatt'ın [94] basit algılayıcısı, (simple perceptron) en temel tek katmanlı algılayıcıdır. Bunun yanı sıra ADALINE'de tek katmanlı algılayıcıdır. Sırası ile Şekil 2.4. ve Şekil 2.5.'te verildiği gibidir.




Şekil 2.4. Rosenblatt'ın basit algılayıcısı




Şekil 2.5. ADALINE yapay sinir ağı

2.2.1.2. Çok katmanlı (tabakalı) algılayıcılar

Çok katmanlı algılayıcılar, bir girdi vektörü ile bu girdi vektörüne karşılık gelen bir çıktı vektörü arasında doğrusal olmayan bir eşleşme sağlayan modellerdir. Çok katmanlı algılayıcılarda girdi, gizli ve çıktı katmanı olmak üzere en az üç katman bulunmaktadır. Gizli tabaka sayısı, en az bir olmakla birlikte birden fazla olduğu durumda derin yapay sinir ağı olarak adlandırılmaktadır. Çok katmanlı algılayıcıda her bir tabakaya ait birim sayısı, en az bir olmaktadır. Tabaka birimlerinin kendi aralarında bağlantıları yoktur. Bağlantılar yalnızca ileri yönlüdür. Bir yapay sinir ağının mimarisinin belirlenmesi için gizli tabaka sayısı ile tabaka birimlerinin sayısının belirlenmesi gerekmektedir. Şekil 2.6.'da tek çıktıya sahip çok katmanlı yapay sinir ağı mimari örneği, Şekil 2.7.'de ise çok çıktıya sahip çok katmanlı yapay sinir ağı mimari örneği verilmiştir.



Şekil 2.6. Tek çıktılı çok katmanlı mimari



Şekil 2.7. Çok çıktılı çok katmanlı mimari

Çok katmanlı yapay sinir ağları, katmanların bağlantı yönüne göre ileri ve geri beslemeli yapay sinir ağları olarak iki kısma ayrılabilir.

2.2.1.3. İleri beslemeli yapay sinir ağları


İleri beslemeli yapay sinir ağları, yapay sinir ağı modellerinin ilkidir. Bu ağlarda nöronlar girdiden çıktıya doğru düzenli katmanlar şeklinde oluşmaktadır. Ağın işleyişi, girdiden gizli tabakaya, oradan da çıktı tabaka yönünde yalnızca ileri doğru olmaktadır. Bir katmandan kendinden sonraki diğer katman arasında bağlantılar bulunmaktadır. Ağda bir döngü veya geri sinyal dönüşü mevcut değildir.

2.2.1.4. Geri beslemeli yapay sinir ağları


Geri besleme yapay sinir ağları, bilginin çıktıdan girdiye geri dönmesine olanak sağlayan ve böylece elde edilen çıktının ağı tekrar girdi olarak tanıttığı yapay sinir ağlarıdır. Geri beslemeli yapay sinir ağlarında nöronların çıktıları, önceki katman veya kendi katman nöron/nöronları için girdi olabilmektedir. Geri beslemeli ağlar ile ağ, daha etkin çalışmakta olup ağın öğrenme gücü artmaktadır.

2.2.2. Derin yapay sinir ağıları

Derin yapay sinir ağıları, girdi ile gizli tabaka arasında yer alan gizli tabakaların sayısının birden fazla olduğu bir yapay sinir ağı modelidir. Derin olarak ifade edilmesinin sebebi, gizli katman sayısındaki bu fazlalıktır. Ayrıca ağı katmanlarındaki nöron sayısı fazla olabilmektedir. Derin yapay sinir ağıları, doğrusal olmayan karmaşık ilişkilerin çözümünü kolaylaştırmak adına geliştirilen bir yapay sinir ağı türüdür. Bu ağı ile karmaşık ve doğrusal olmayan ilişkiler modellenebilmektedir. Derin yapay sinir ağıları, dil modelleme, görüntü sınıflandırma, video işleme, otomatik konuşma tanıma, yüz tanıma, hastalık teşhisi vb. birçok alanda sıklıkla kullanılmaktadır. Derin yapay sinir ağlarına örnek olarak SRNN, CNN [95], LSTM-ANN ve GRU-ANN verilebilir. Şekil 2.8. ve Şekil 2.9.'da derin yapay sinir ağı mimari örnekleri verilmiştir.



Şekil 2.8. Çok gizli tabakalı tek çıktılı çok katmanlı derin mimari




Şekil 2.9. Çok gizli tabakalı çok çıktılı çok katmanlı derin mimari

2.2.2.1. Basit geri beslemeli yapay sinir ağları

İleri beslemeli yapay sinir ağlarının yalnızca sistemin mevcut girdilerini kullanması, bu girdilerin tabakalar boyunca işlenmesi esnasında veri dezenformasyonuna uğramaları ve dinamik girdilerin ağ yapısına dahil edilmemesi ileri beslemeli yapay sinir ağlarının öngörü çalışmalarındaki dezavantajları olarak bilinmektedir. Bu gibi problemleri aşmak amacı ile önerilen SRNN, ağın mevcut girdilerini ardışık yapıda kullanmak yanı sıra geri beslemeli girdileri de sisteme dahil ederek her iki girdiyi de ağ yapısı içerisinde kullanabilmektedir. En basit yapıdaki derin geri beslemeli yapay sinir ağları, SRNN olarak bilinmektedir.

SRNN, girdileri ayrı ayrı değerlendirir ve bir zaman adımıdan diğerine geçen gizli katman aktivasyonları aracılığıyla bazı bilgileri de hatırlayabilmektedir. Bu özellikleri ile SRNN, bir yapay sinir ağı yapısında bulunan katmanın çıktısını tahmin etmek için belirli bir katmanın çıktısını kaydetme ve bunu girdiye geri besleme ilkesiyle çalışan bir yapay sinir ağı türüdür. Orijinal olarak dil işleme problemleri için önerilen ve kullanılan geri beslemeli bu ağlar, zaman serileri için de başarılı öngörü sonuçları üretilmektedir. Şekil 2.10.'da örnek bir SRNN mimarisi verilmiştir.



Şekil 2.10. Basit geri beslemeli yapay sinir ağı mimarisi

Şekil 2.10.'da verilen mimaride, 1 gizli tabaka, 3 gizli tabaka birimi bulunmakla birlikte x_{t-3} , x_{t-2} ve x_{t-1} girdilerin zaman adımlarına karşılık gelen öğrenme örnekleri olmaktadır.

W : Girdi ve gizli tabaka arası ağırlıkları,

R : Geri besleme ağırlıkları,

V : Gizli tabaka ve çıktı tabakası arasındaki ağırlıkları olarak ifade edilmektedir.

Ağın çıktısı denklemler 2.37-2.38 yardımıyla bulunur.

$$h_t = f(x_t W + h_{t-1} R + b_1) \quad (2.37)$$

$$\hat{x}_t = f(h_t V + b_y) \quad (2.38)$$

x_t : $1 \times p$ boyutlu (p : gecikme sayısıdır.) öğrenme örneğini ifade etmektedir. h_t : $1 \times h$ boyutlu (h : gizli tabaka birim sayısıdır.) t zamanındaki gizli değişken değerlerini göstermektedir. W : $p \times h$ boyutlu girdi ve gizli tabaka arası ağırlıklarını, R : $h \times h$ boyutlu geri besleme ağırlıklarını, b_1 : $1 \times h$ boyutlu yan değerini ifade etmektedir. V : $h \times 1$ boyutlu ve b_y : 1×1 boyutlu çıktı ağırlık ve yan değerleridir. Bu ağırlıklar ve yanlar, tüm girdiler için aynı olmakta ve paylaşılmaktadır. Bu özelliğe, SRNN de

parametre paylaşımı denilmektedir. Ayrıca f , aktivasyon fonksiyonudur. x_{t-3} , x_{t-2} ve x_{t-1} ise zaman adımlarındaki öğrenme örnekleri olarak isimlendirilmektedir.

2.3. Yapay zekâ optimizasyon algoritmaları

Optimizasyon, belirli kısıtlar altında en iyi sonucun bulunması işlemidir. Belirli sınırlamalar altında, bilinmeyen parametrelerin belirlenmesini içeren bir problem olan optimizasyon problemlerinin çözümünde, türevelere dayalı algoritmalar ve sezgisel optimizasyon algoritmaları kullanılabilir. Türevelere dayalı algoritmalar, türevlenebilir bir fonksiyonun maksimum ya da minimum değerini belirlemeyi amaçlamaktadır. Bir amaç fonksiyonun belirli noktalarda türevinin olmaması veya türevinin alınmasının zor ve karmaşık olduğu gibi durumlar ile karşılaşılabilir. Böyle bir durumda türevelere dayalı algoritmalar dezavantajlı bir duruma gelmektedir. Türevelere ihtiyaç duymamasıyla büyük bir avantaja sahip olan sezgisel optimizasyon algoritmaları, optimizasyon problemlerinde sıklıkla kullanılmaya başlanmıştır. Klasik optimizasyon algoritmalarına göre kullanımı daha kolay olan bu algoritmalar, yerel optimum problemlerinden daha az etkilenebilmektedir. Literatürde birçok sezgisel optimizasyon algoritması mevcut olmakla birlikte bu tez kapsamında kullanılan sezgisel optimizasyon algoritmalarından SCO ve PSO algoritmaları, alt başlıklar halinde açıklanmıştır.

2.3.1. Sinüs kosinüs optimizasyon algoritması

Mirjalili [4] tarafından önerilen SCO algoritması, trigonometrik dalgaların arama davranışı olarak simüle edilmesine dayanan ve optimal çözümü bulmak için sinüs veya kosinüs fonksiyonlarını kullanan popülasyon tabanlı sezgisel bir optimizasyon tekniğidir.

SCO algoritması, basit uygulanması ve daha az parametre kullanması nedeniyle son yıllarda birçok bilim insanı tarafından incelenmiştir. SCO algoritmasında, optimizasyon süreci, sinüs veya kosinüs fonksiyonu değerlerinin basit değişimi ile gerçekleştirilir. Genel olarak birçok sezgisel optimizasyon algoritması gibi SCO

algoritması da rasgele üretilen bir başlangıç popülasyonu ile başlar ve popülasyonun her bir pozisyonu denklem 2.39 ile güncellenir.

$$Z_i^{t+1} = \begin{cases} Z_i^t + r_1 \times \sin(r_2) \times |r_3 Z_{eniyi} - Z_i^t| & r_4 < 0.5 \\ Z_i^t + r_1 \times \cos(r_2) \times |r_3 Z_{eniyi} - Z_i^t| & r_4 \geq 0.5 \end{cases} \quad (2.39)$$

Burada, Z_i^{t+1} bir sonraki yinelemedeki i . pozisyonun konumunu, Z_i^t mevcut yinelemedeki i . pozisyonun konumunu göstermektedir. Z_{eniyi} hedef noktanın pozisyonunu yani popülasyonda bulunan en iyi pozisyonu ifade etmektedir. Denklem 2.39'da görüldüğü üzere SCO algoritmasında r_1, r_2, r_3 ve r_4 olmak üzere dört ana parametre vardır.

r_1 parametresi, çözüm ile hedef nokta arasındaki arama uzayında veya dışında olabilecek bir sonraki pozisyonun bölgesini (veya hareket yönünü) belirler. Kısacası, r_1 parametresinin amacı güncellenmiş çözüm için en uygun bölgeyi belirlemektir, bu bölgenin mevcut çözüm ile en iyi çözüm arasındaki alanda veya dışında olabileceği de unutulmamalıdır.

r_2 parametresi, hareketin hedefe doğru veya dışarı doğru ne kadar uzak olması gerektiğini tanımlar yani çözümün hareketinin ne kadar olması gerektiğine karar verir. Ayrıca, r_2 parametresinin amacı, mevcut çözümünden en iyi çözüm yönünde mi yoksa en iyi çözümün dışına doğru mu hareket edeceğini belirlemektir.

r_3 parametresi, hedefin mesafeyi tanımlamadaki etkisini stokastik olarak vurgulamak ($r_3 > 1$) veya önemsizleştirmek ($r_3 < 1$) amacıyla hedef için rastgele bir ağırlık getirir.

r_4 parametresi denklem 2.39'daki sinüs veya kosinüs bileşenleri arasındaki geçişi yani pozisyon güncellemesi için sinüs veya kosinüs fonksiyonunun seçilmesini sağlar.

Mirjalili [4] çalışmasında, $\lambda = 2, r_2 = (2 * \pi) * rand, r_3 = 2 * rand, r_4 = rand$ olarak alınmaktadır. $r_1 = \lambda \left(1 - \frac{t}{maksitr}\right)$ olarak hesaplanır. Burada, λ sabit, t mevcut yineleme ve $maksitr$ maksimum yineleme sayısıdır.

Algoritma 1’de SCO algoritmasının algoritma adımları verilmiştir.

Algoritma 1. SCO Algoritması

Adım 1. Rastgele üretilen bir başlangıç popülasyonu oluşturulur.

Adım 2. Popülasyondaki her bir pozisyona ait uygunluk değeri hesaplanır ve amaç fonksiyonu doğrultusunda en iyi uygunluk değerine sahip olan pozisyon saklanır.

Adım 3. Her bir pozisyon için sinüs kosinüs denklemlerinde kullanılmak üzere r_2, r_3 ve r_4 parametreleri rastgele üretilir.

Adım 4. Popülasyondaki her bir pozisyonun bir sonraki iterasyondaki pozisyonları denklem 2.39 ile elde edilir. Denklem 2.39 göz önünde bulundurularak, eğer rastgele üretilen r_4 değeri 0.5’ten küçük ise ilgili pozisyonun bir sonraki iterasyondaki pozisyonu sinüs fonksiyonu yardımı ile, eğer rastgele üretilen r_4 değeri 0.5’ten büyük veya eşit ise ilgili pozisyonun bir sonraki iterasyondaki pozisyonu kosinüs fonksiyonu yardımı ile elde edilir.

Adım 5. SCO algoritması, yineleme sayacı varsayılan maksimum yineleme sayısından daha yüksek olduğunda optimizasyon işlemini sonlandırır.

2.3.2. Parçacık sürü optimizasyonu algoritması

Popülasyon temelli sezgisel bir yöntem olan PSO algoritması, Kennedy ve Eberhart [3] tarafından balık ve kuş sürülerinin sosyal davranışlarından esinlenilerek ortaya atılan bir optimizasyon algoritmasıdır. Doğrusal olmayan problemlerin çözümünde kullanılması amaçlanmıştır. Türev bilgisine ihtiyaç duymayan basit bir algoritma olan PSO, yüksek çözüm kalitesi sunmasının yanı sıra çok iyi yakınsama özelliği ile uygulama alanlarında oldukça sık kullanılmaktadır. PSO algoritması, rastgele oluşturulan bir popülasyonla başlamakta ve sistem güncellenerek optimum çözüm

araştırılmaktadır. Standart PSO algoritmasında çözümler parçacık olarak ifade edilmekte ve denklem 2.40'ta verildiği gibi oluşturulmaktadır.

$$X_i = (x_{i1}, x_{i2}, \dots, x_{id}), i = 1, 2, \dots, ps \quad (2.40)$$

Çözümler X_i ile gösterilir ve her iterasyonda ps adet çözüm bulunmaktadır. d , problemde optimize edilecek değişken sayısını ifade etmektedir. Her bir pozisyona denk gelen hız değerleri denklem 2.41'de verildiği gibi oluşturulmaktadır.

$$V_i = (v_{i1}, v_{i2}, \dots, v_{id}), i = 1, 2, \dots, ps \quad (2.41)$$

V_i , her çözüme karşılık gelen hız vektörünü ifade etmektedir.

Parçacıkların en iyi olan pozisyonları P_{eniyi} matrisinde saklanmakta ve tüm parçacıkların en iyi durumu g_{eniyi} vektörü ile ifade edilmektedir. Sırasıyla denklem 2.42 ve denklem 2.43'te verildiği gibi oluşturulmaktadır.

$$P_{eniyi_i} = (P_{i1}, P_{i2}, \dots, P_{id}), i = 1, 2, \dots, ps \quad (2.42)$$

$$g_{eniyi} = (P_1, P_2, \dots, P_d) \quad (2.43)$$

Klasik PSO algoritmasında parçacıkların hızları denklem 2.44 ile hesaplanır.

$$v_{ij}^{k+1} = c_1 \times rand1 \times (P_{ij}^{k+1} - x_{ij}^k) + c_2 \times rand2 \times (P_j^{k+1} - x_{ij}^k) \quad (2.44)$$

$rand1$ ve $rand2$, 0 ve 1 arasında rastgele üretilen sayıları, c_1 bilişsel katsayıyı ve c_2 sosyal katsayıyı ifade etmektedir.

Hız vektörüne bağlı olacak şekilde bir parçacığın güncellenmiş yeni pozisyonu denklem 2.45 ile belirlenmektedir.

$$x_{ij}^{k+1} = x_{ij}^k + v_{ij}^{k+1}, i = 1, 2, \dots, ps; j = 1, 2, \dots, d \quad (2.45)$$

PSO algoritması, Algoritma 2’de verilmiştir.

Algoritma 2. PSO Algoritması

Adım 1. Başlangıç hız ve pozisyon değerleri rastgele olarak üretilir.

Adım 2. Popülasyondaki her bir parçacığa ait uygunluk değeri amaç fonksiyonu yardımıyla hesaplanır.

Adım 3. Amaç fonksiyonu değerine bağlı olarak P_{eniyi} matrisi ile g_{eniyi} vektörü belirlenir.

Adım 4. Hız ve pozisyon değerleri güncellenir. Güncelleme işlemi denklem 2.44 ve denklem 2.45 ile gerçekleştirilir.

Adım 5. PSO algoritması, yineleme sayacı varsayılan maksimum yineleme sayısından daha yüksek olduğunda optimizasyon işlemini sonlandırır.

BÖLÜM 3. MATERYAL VE METOT

3.1. Önerilen Yapay Sinir Ağı Yöntemleri

Önerilen yöntem hem mevsimsel olmayan zaman serilerini hem de mevsimsel zaman serilerini modellemek için yeni melez modeller sunmaktadır. Önerilen bu melez modeller SRNN ve SES yönteminin birleşiminden oluşan mimari yapılara sahiptir. Mevsimsel bileşen içeren ve içermeyen zaman serileri için oluşturulan bu iki yeni derin melez yapay sinir ağları hakkında iki başlık altında bilgi verilmiştir.

3.1.1. Mevsimsel bileşen içermeyen zaman serileri için önerilen yeni melez derin yapay sinir ağı (SRNN-SES)

Zaman serilerinin modellenmesinde ve öngörülmesinde, başarılı ve basit bir yöntem SES yöntemidir. Az sayıda parametre ile çalışan bu yöntem birçok zaman serisinin modellenmesinde yeterli düzeyde öngörü sonuçları üretebilmektedir. SES yöntemi, bir tür geri besleme mekanizmasına sahip olup yeni yapay sinir ağı mimarileri oluşturulmasına ilham olabilmektedir. Bu çalışmada son yıllarda öngörü probleminin çözümünde sıkça kullanılmaya başlanan derin yapay sinir ağlarından SRNN yöntemi ile klasik öngörü yöntemlerinden biri olan SES yönteminin bir araya getirildiği bir yeni derin geri beslemeli yapay sinir ağı mimarisi oluşturulmuştur. Bu yeni mimari Şekil 3.1.'de verilmiştir. Önerilen bu ağın mimarisi iki kısımdan oluşmaktadır. İlk kısım SRNN hücrelerinin hiyerarşik bir yapıda birleştirilmesinden oluşmaktadır.

Şekil 3.1.'deki SRNN hücrelerinden oluşan birinci kısmın çıktısı ($\hat{y}_t^{SRNN}$) denklemler 3.1-3.3 ile hesaplanır. Burada, $X_{t-k}, k = 1, 2, \dots, h$ zaman serisinin gecikmeli değişkenlerinden oluşan h zaman adımlı girdilerin k adım gecikmesini, $W^1; p \times h$ boyutlu ve $W^j; h \times h, j = 2, \dots, m$ girdi ile gizli tabaka arası ağırlıklarını, $R^j; h \times$


$h, j = 1, 2, \dots, m$ boyutlu geri besleme ağırlıklarını, $b^j; 1 \times h, j = 1, 2, \dots, m$ boyutlu gizli tabaka arası yan değerlerini, h_t^j ; t zaman adımında j . gizli tabakadaki SRNN hücresinin çıktısını, $V_{FC}; h \times 1$ boyutlu çıktı tabakası için ağırlıkları, $b_{FC}; 1 \times 1$ boyutlu çıktı tabakası için yan değerini, σ lojistik aktivasyon fonksiyonunu ve $\hat{y}_t^{SRNN}$ ise birinci kısmın çıktısını ifade etmektedir.

$$h_{t-k}^1 = \sigma(X_{t-k}W^1 + h_{t-k-1}R^1 + b^1) = f(h_{t-k-1}^1, X_{t-k}, \theta^1), k = 1, 2, \dots, h \quad (3.1)$$

$$h_{t-k}^j = \sigma(h_{t-k}^{j-1}W^j + h_{t-k-1}^jR^j + b^j) = f(h_{t-k-1}^j, h_{t-k}^{j-1}, \theta^j), k = 1, 2, \dots, h, j = 2, \dots, m \quad (3.2)$$

$$\hat{y}_t^{SRNN} = \sigma(V_{FC}h_{t-1}^m + b_{FC}) \quad (3.3)$$

Şekil 3.1.'deki ikinci kısım SES yapısının olduğu kısımdır ve burada y_{t-1} girdiyi ifade etmektedir. Bu kısımdaki B , geri öteleme operatörünü göstermektedir. Bu operatör sayesinde ağıın kombine çıktısı üstel düzleştirme yöntemine geri besleme girdisi oluşturmaktadır.



Şekil 3.1. Mevsimsel bileşen içermeyen zaman serileri için önerilen yapay sinir ağı mimarisi

Şekil 3.1.'de bir SRNN hücresinin girdileri zaman adımlarına göre $X_t = (y_t, y_{t-1}, \dots, y_{t-p+1})$ 'nin gecikmeli değişkenidir. Örneğin, Şekil 3.1.'deki SRNN hücresinin bir girdisi $X_{t-1} = (y_{t-1}, y_{t-2}, \dots, y_{t-p})$ şeklindedir. SRNN'nin çıktısı zaman serisinin bir adım öngörüsü ($\hat{y}_t^{SRNN}$)'dür. $\hat{y}_t^{SRNN}$ $p + 1$. gözlem için aynı zamanda önerilen ağıın da çıktısını oluştururken, $t > p + 1$ için önerilen ağıın çıktısı β

kombinasyon parametresine göre üstel düzeltirme ile SRNN'nin kombine edilmiş çıktısıdır. Önerilen ağ, $\beta = 0$ için üstel düzeltirme modeline dönerken, $\beta = 1$ için ise SRNN'ye dönüşmektedir. $0 < \beta < 1$ için ise öngörü her iki yöntemin tahminlerinden elde edilen ağırlıklı bir tahmin olmaktadır. Önerilen ağın çıktısı denklem 3.4'teki gibi hesaplanmaktadır.


$$\hat{y}_t = \begin{cases} \hat{y}_t^{SRNN} & , \quad t = p + 1 \\ \beta \hat{y}_t^{SRNN} + (1 - \beta)(\alpha \hat{y}_{t-1} + (1 - \alpha)y_{t-1}) & , \quad t > p + 1 \end{cases} \quad (3.4)$$

Burada, α zaman serisinin mevsimsel bileşen içermediği durumda üstel düzeltirme parametresini, β SRNN'den gelen çıktı ile zaman serisinin mevsimsel bileşen içermediği durumdaki çıktısı için bir kombinasyon parametresini ifade etmektedir.

3.1.2. Mevsimsel bileşen içeren zaman serileri için önerilen yapay sinir ağı modeli (SRNN-SES-S)

Mevsimsel bileşen içeren zaman serilerinin modellenmesinde, mevsimsel gecikmeye sahip zaman serisinin değişkenleri ve modelin mevsimsel gecikmelerde geri beslenmesi büyük önem taşımaktadır. Örneğin, mevsimsel bir otoregresif bütünleşik hareketli ortalamalar modelinde hem hatanın hem de zaman serisinin gecikmeli değişkenleri modelde girdiler olarak yer alabilmektedir. Bu tez kapsamında, SES'nin mevsimsel bileşen içeren zaman serilerini modelleyebilmesi için mevsimsel gecikmeleri içerecek şekilde bir modifikasyon gerçekleştirilmiştir. Mevsimsel bileşen içeren zaman serilerinin modellenmesi için Şekil 3.2.'de verilen yeni melez derin yapay sinir ağı mimarisi verilmiştir. Mimarının birinci kısmı SRNN yönteminden oluşurken, ikinci kısım mevsimsel olarak uyarlanmış SES yönteminden oluşmaktadır. Her iki kısmın çıktıları, mimarının son kısmında γ_1 kombinasyon parametresi ile kombine edilmektedir.

Burada, s zaman serisinin periyodunu, y_{t-1} ve y_{t-s} girdileri ifade etmektedir. B geri öteleme operatörüdür.



Şekil 3.2. Mevsimsel bileşen içeren zaman serileri için önerilen yapay sinir ağı mimarisi

Şekil 3.2.'de bir SRNN hücresinin girdisi, zaman adımlarına göre $X_t = (y_t, y_{t-1}, \dots, y_{t-p+1})$ 'nin gecikmeli değişkenleridir. SRNN'nin çıktısı zaman serisinin bir adım öngörüsü ($\hat{y}_t^{SRNN}$)'dür. Önerilen SRNN-SES-S derin melez yapay sinir ağının çıktısı, denklem 3.5'te verildiği gibi hesaplanmaktadır. Önerilen yeni yapay sinir ağlarında, ilk p gözlem için tahmin verilemez iken $p + 1$. gözlemin tahmini $\hat{y}_t^{SRNN}$ ile aynı olmaktadır. $p + 1 < t \leq p + s$ zaman aralığındaki tahminler ve $t > p + s$ için tahminler kombine tahminler olarak hesaplanmaktadır. Denklem 3.5'te β parametresi, SRNN ile mevsimsel olmayan üstel düzeltirme için bir kombinasyon parametresidir. γ_2 parametresi ise SRNN ile mevsimsel üstel düzeltirme için bir kombinasyon parametresidir. γ_3 parametresi, üstel düzeltirmedeki mevsimsel kısımdaki tahmin ile gerçek değer arasındaki kombinasyon parametresidir. γ_1 parametresi ise her iki kısmın çıktılarını kombine eden parametredir.

$$\hat{y}_t = \begin{cases} \hat{y}_t^{SRNN} & , t = p + 1 \\ \beta \hat{y}_t^{SRNN} + (1 - \beta)(\alpha \hat{y}_{t-1} + (1 - \alpha)y_{t-1}) & , p + 1 < t \leq p + s \\ \gamma_1 (\beta \hat{y}_t^{SRNN} + (1 - \beta)(\alpha \hat{y}_{t-1} + (1 - \alpha)y_{t-1})) + (1 - \gamma_1)(\gamma_2 \hat{y}_{t-s}^{SRNN} + (1 - \gamma_2)(\gamma_3 \hat{y}_{t-s} + (1 - \gamma_3)y_{t-s})) & , t > p + s \end{cases} \quad (3.5)$$

Ayrıca α zaman serisinin mevsimsel bileşen içermediği durumda üstel düzeltirme parametresi olmaktadır.

3.2. SRNN-SES ve SRNN-SES-S İçin Öğrenme Algoritmaları

Önerilen yöntemler için hem PSO hem de SCO algoritmalarına dayalı yeni öğrenme algoritmaları dört başlık altında açıklanmıştır. Öncelikle ilk iki başlık altında önerilen yöntemlerin PSO algoritması ile olan öğrenme algoritmaları; üçüncü ve dördüncü başlıklar altında ise SCO algoritması ile gerçekleştirilen öğrenme algoritmaları detaylı bir şekilde açıklanmıştır.

3.2.1. SRNN-SES için parçacık sürü optimizasyonu algoritmasına dayalı bir öğrenme algoritması

Önerilen yöntem, SRNN-SES'nin eğitiminde kullanılan algoritmalarından biri PSO algoritmasıdır. Bu algoritma kullanılarak oluşturulan öğrenme algoritması, Algoritma 3'te adım adım açıklanmıştır.

Algoritma 3. SRNN-SES-PSO Algoritması

Adım 1. Veri seti eğitim ($n_{eğitim}$), geçerlilik ($n_{geçerlilik}$) ve test (n_{test}) seti olmak üzere üç kısma ayrılır ve uzunlukları belirlenir. n , toplam gözlem sayısı olmakla birlikte denklem 3.6'de ifade edildiği gibidir.

$$n_{eğitim} + n_{geçerlilik} + n_{test} = n \quad (3.6)$$

Adım 2. Önerilen ağın hiper parametre değerleri (p, h, m) belirlenir. Hiper parametre değerleri için birer evrensel küme ($p \in [p_{alt}, p_{üst}], h \in [h_{alt}, h_{üst}], m \in [m_{alt}, m_{üst}]$) tanımlanmıştır.

Hiperparametrelerin olası değerleri belirlenir. Burada hiper parametre değerleri, gecikme sayısı (p), gizli tabaka birim sayısı (h), gizli tabaka sayısı (m) için alt ve üst sınırdır.

Adım 3. PSO algoritmasında kullanılacak parametreler belirlenir. Bu parametreler; başlangıç bilişsel bileşen katsayısı (c_1^i), bitiş bilişsel bileşen katsayısı (c_1^f), başlangıç sosyal bileşen katsayısı (c_2^i), bitiş sosyal bileşen katsayısı (c_2^f), başlangıç eylemsizlik ağırlığı (w^i), bitiş eylemsizlik ağırlığı (w^f), hızlar için sınır değeri ($vmaps$), maksimum iterasyon sayısı ($maksitr$), parçacık sayısı (ps), yeniden başlatma stratejisi için limit değeri ($limit1$) ve erken durdurma kuralı için limit değeri ($limit2$) olarak verilebilir.

Adım 4. $p = p_{alt}$, $h = h_{alt}$ ve $m = m_{alt}$ yapılır.

Adım 5. PSO algoritmasının başlangıç pozisyon ve hız değerleri oluşturulur. Bir SRNN'deki girdi tabakasına ait parametre sayısı $q_1 = hp + h^2 + h$, gizli tabakaya ait parametre sayısı $q_2 = 2h^2 + h$ ve mevsimsel olmayan parametre sayısı ise $q_3 = h + 3$ olmaktadır. Toplam pozisyon sayısı $q_1 + (m - 1)q_2 + q_3$ 'tür. Bu pozisyonlar ağırlıklar, yanlar, üstel düzleştirme ve kombinasyon parametrelerinden oluşmaktadır. Bir SRNN'de pozisyonlar $P_{i,k}$, $i = 1, 2, \dots, ps$, $k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_3$ ile ifade edilmektedir. m adet gizli tabaka sayısına sahip SRNN için parametre değerleri denklem 3.7'de belirtildiği gibi ifade edilebilir.

$$\Theta^1 = \begin{bmatrix} W^1 \\ R^1 \\ b^1 \end{bmatrix}, \Theta^2 = \begin{bmatrix} W^2 \\ R^2 \\ b^2 \end{bmatrix}, \dots, \Theta^m = \begin{bmatrix} W^m \\ R^m \\ b^m \end{bmatrix} \quad (3.7)$$

Üstel düzleştirme ve kombinasyon parametreleri zaman serinin mevsimsel bileşen içermediği durumda (α ve β), $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. Ayrıca tüm hız değerleri ($v_{i,k}$, $i = 1, 2, \dots, ps$, $k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_3$) ile tüm ağırlık ve yan değerleri de $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. SRNN-SES-PSO yönteminde, bir parçacığın pozisyonlarının durumu Tablo 3.1.'de verilmiştir.

Tablo 3.1. SRNN-SES-PSO yöntemi için bir parçacığın pozisyonlarının durumu

Parametre	Θ^1	Θ^2	...	Θ^m
Boyut	$(p + h + 1) \times h$	$(2 \times h + 1) \times h$	...	$(2 \times h + 1) \times h$
Parametre	V_o	b_o	α	β
Boyut	$h \times 1$	1×1	1×1	1×1

Adım 6. Her bir parçacık için uygunluk fonksiyonu değerleri denklem 3.8’de ifade edilen MSE değeri ile hesaplanır. Popülasyon için g_{eniyi} vektörü ve P_{eniyi} matrisi oluşturulur. g_{eniyi} popülasyondaki en iyi parçacık vektörü P_{eniyi} ise popülasyondaki en iyi pozisyon matrisidir.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (3.8)$$

Adım 7. Yeni hız ve pozisyonlar denklemler 3.9-3.11 yardımıyla hesaplanmaktadır. Burada, itr mevcut iterasyon sayısını ifade etmektedir. Denklemlerde r_1 ve r_2 $U[0,1]$ aralığında düzgün dağılımdan rastgele üretilmektedir.

$$v_{i,k}^{(itr)} = w^{(itr)} v_{i,k}^{(itr-1)} + c_1^{(itr)} r_1 (P_{eniyi_{i,k}}^{(itr)} - P_{i,k}^{(itr)}) + c_2^{(itr)} r_2 (g_{eniyi_k}^{(itr)} - P_{i,k}^{(itr)}) \quad (3.9)$$

$$v_{i,k}^{(itr)} = \min(v_{maks}, \max(-v_{maks}, v_{i,k}^{(itr)})) \quad (3.10)$$

$$P_{i,k}^{(itr)} = P_{i,k}^{(itr-1)} + v_{i,k}^{(itr)} \quad (3.11)$$

Eylemsizlik ağırlığı, sosyal ve bilişsel katsayılar denklemler 3.12-3.14 ile hesaplanır.

$$w^{(itr)} = (w_1^i - w_2^i) \frac{maksitr - itr}{maksitr} + w_2^i \quad (3.12)$$

$$c_1^{(itr)} = (c_1^f - c_1^i) \frac{itr}{maksitr} + c_1^i \quad (3.13)$$

$$c_2^{(itr)} = (c_2^i - c_2^f) \frac{maksitr - itr}{maksitr} + c_2^f \quad (3.14)$$

Ayrıca serinin mevsimsel olmadığı durumda, α ve β parametrelerinin pozisyonları denklem 3.15 kullanılarak $[0,1]$ aralığında sınırlandırılmıştır.

$$P_{i,k}^{(itr)} = \min \left(1, \max \left(0, P_{i,k}^{(itr)} \right) \right), i = 1, 2, \dots, pn; k = q_1 + (m - 1)q_2 + q_3 - 2, \dots, q_1 + (m - 1)q_2 + q_3 \quad (3.15)$$

Adım 8. g_{eniyi} vektörü ve P_{eniyi} matrisi güncellenir.

Adım 9. Yeniden başlatma stratejisi sayacı ($rsc = rsc + 1$) artırılır. Eğer $rsc > limit1$ olursa tüm hız ve pozisyon değerleri yeniden üretilir ve sayaç sıfırlanır.

Adım 10. Erken durdurma kuralı, denklem 3.16 ile kontrol edilir. Burada, esc başarısızlık sayacıdır. $MSE_{eniyi}^{(t)}$, MSE 'nin t . yinelemedeki uygunluk değeridir.

$$esc = \begin{cases} esc + 1, & \frac{MSE_{eniyi}^{(t)} - MSE_{eniyi}^{(t-1)}}{MSE_{eniyi}^{(t)}} < \varepsilon \\ 0, & \text{diğer durumlarda} \end{cases} \quad (3.16)$$

Eğer $esc > Limit2$ ise algoritma durdurulur aksi halde Adım 7'ye geri dönülür.

Adım 11. Geçerlilik seti için hata kareler ortalamasının karekökü (RMSE) değerleri denklem 3.17 yardımıyla hesaplanır.

$$RMSE = \sqrt{\frac{1}{n_{geçerlilik}} \sum_{t=n_{eğitim}+1}^{n_{eğitim}+n_{geçerlilik}} (y_t - \hat{y}_t)^2} \quad (3.17)$$

Adım 12. $p = p + 1$ yapılır ve eğer $p \leq p_{üst}$ ise; $h = h + 1$ yapılır ve eğer $h \leq h_{üst}$ ise; $m = m + 1$ yapılır ve eğer $m \leq m_{üst}$ ise; Adım 5'e gidilir. Aksi halde Adım 13'e geçilir.

Adım 13. Geçerlilik seti performansına göre en iyi hiper parametre değerleri seçilir.

Adım 14. Elde edilen en iyi hiper parametre değerlerinde, eğitim ve geçerliliği birleştirip yeni bir eğitim seti ile rastgele başlangıçlar üzerinden 30 defa eğitilip ağın test seti performansı hesaplanır. Burada tekrar sayısının 30 olarak alınması, deneysel çalışmalarda test edilerek yeterli bir doğruluğu sağlaması üzerine tercih edilmiştir.

3.2.2. SRNN-SES-S için parçacık sürü optimizasyonu algoritmasına dayalı bir öğrenme algoritması

Önerilen yöntem SRNN-SES-S'nin eğitiminde kullanılan algoritmalarından biri PSO algoritmasıdır. Bu algoritma kullanılarak oluşturulan öğrenme algoritması Algoritma 4'te adım adım açıklanmıştır.

Algoritma 4. SRNN-SES-S-PSO Algoritması

Adım 1. Veri seti eğitim ($n_{eğitim}$), geçerlilik ($n_{geçerlilik}$) ve test (n_{test}) seti olmak üzere üç kısma ayrılır ve uzunlukları belirlenir. n , toplam gözlem sayısı olmakla birlikte denklem 3.6'da ifade edildiği gibidir.

Adım 2. Önerilen ağın hiper parametre değerleri (p, h, m) belirlenir. Hiper parametre değerleri için birer evrensel küme ($p \in [p_{alt}, p_{üst}], h \in [h_{alt}, h_{üst}], m \in [m_{alt}, m_{üst}]$) tanımlanmıştır.

Hiperparametrelerin olası değerleri belirlenir. Burada hiper parametre değerleri, p, h, m için alt ve üst sınırdır.

Adım 3. PSO algoritmasında kullanılacak parametreler belirlenir. Bu parametreler; başlangıç bilişsel bileşen katsayısı (c_1^i), bitiş bilişsel bileşen katsayısı (c_1^f), başlangıç sosyal bileşen katsayısı (c_2^i), bitiş sosyal bileşen katsayısı (c_2^f), başlangıç eylemsizlik ağırlığı (w^i), bitiş eylemsizlik ağırlığı (w^f), hızlar için sınır değeri (v_{maps}), maksimum iterasyon sayısı ($maksitr$), parçacık sayısı (ps), yeniden başlatma stratejisi için limit değeri ($limit1$) ve erken durdurma kuralı için limit değeri ($limit2$) olarak verilebilir.

Adım 4. $p = p_{alt}$, $h = h_{alt}$ ve $m = m_{alt}$ yapılır.

Adım 5. PSO algoritmasının başlangıç pozisyon ve hız değerleri oluşturulur. Bir SRNN'deki girdi tabakasına ait parametre sayısı $q_1 = hp + h^2 + h$, gizli tabakaya ait parametre sayısı $\theta_2 = 2h^2 + h$ ve mevsimsel parametre sayısı ise $q_4 = h + 6$ olmaktadır. Toplam pozisyon sayısı $q_1 + (m - 1)q_2 + q_4$ 'tür. Bu pozisyonlar ağırlıklar, yanlar, üstel düzleştirme ve kombinasyon parametrelerinden oluşmaktadır. Bir SRNN'de pozisyonlar $P_{i,k}$, $i = 1, 2, \dots, ps$, $k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_4$ ile ifade edilmektedir. m adet gizli tabaka sayısına sahip SRNN için parametreler denklem 3.7'de verildiği gibidir.

Üstel düzleştirme ve kombinasyon parametreleri $(\alpha, \gamma_1, \gamma_2, \gamma_3$ ve $\beta)$, $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. Ayrıca tüm hız değerleri $(v_{i,k}, i = 1, 2, \dots, ps, k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_4)$ ile tüm ağırlık ve yan değerleri de $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. SRNN-SES-S-PSO yönteminde bir parçacığın pozisyonlarının durumu Tablo 3.2.'de verilmiştir.

Tablo 3.2. SRNN-SES-S-PSO yöntemi için bir parçacığın pozisyonlarının durumu

Parametre	θ^1	θ^2	...	θ^m	V_o	b_o
Boyut	$(p + h + 1) \times h$	$(2 \times h + 1) \times h$	...	$(2 \times h + 1) \times h$	$h \times 1$	1×1
Parametre	α	γ_1	γ_2	γ_3	β	
Boyut	1×1	1×1	1×1	1×1	1×1	

Adım 6. Her bir parçacık için uygunluk fonksiyonu değerleri denklem 3.8'de ifade edilen MSE değeri ile hesaplanır. Popülasyon için g_{eniye} vektörü ve P_{eniye} matrisi oluşturulur. g_{eniye} popülasyondaki en iyi parçacık vektörü P_{eniye} ise popülasyondaki en iyi pozisyon matrisidir.

Adım 7. Yeni hız ve pozisyonlar denklemler 3.9-3.11 yardımıyla hesaplanır. Bu denklemlerde itr , mevcut iterasyon sayısını ifade etmektedir. Denklemlerde r_1 ve r_2 $U[0,1]$ aralığında düzgün dağılımdan rastgele üretilmektedir.

Eylemsizlik ağırlığı, sosyal ve bilişsel katsayılar denklemler 3.12-3.14 ile hesaplanır.

Ayrıca serinin mevsimsel olmadığı durumda, α ve β parametrelerinin pozisyonları denklem 3.15 kullanılarak $[0,1]$ aralığında sınırlandırılmıştır.

Adım 8. g_{eniyi} vektörü ve P_{eniyi} matrisi güncellenir.

Adım 9. Yeniden başlatma stratejisi sayacı ($rsc = rsc + 1$) artırılır. Eğer $rsc > limit1$ olursa tüm hız ve pozisyon değerleri yeniden üretilir ve sayaç sıfırlanır.

Adım 10. Erken durdurma kuralı denklem 3.16 ile kontrol edilir. Burada, esc başarısızlık sayacıdır. $MSE_{eniyi}^{(t)}$ MSE 'nin t . yinelemedeki uygunluk değeridir.

Eğer $esc > Limit2$ ise algoritma durdurulur aksi halde Adım 7'ye geri dönülür.

Adım 11. Geçerlilik seti için RMSE değerleri, denklem 3.17 yardımıyla hesaplanır.

Adım 12. $p = p + 1$ yapılır ve eğer $p \leq p_{üst}$ ise; $h = h + 1$ yapılır ve eğer $h \leq h_{üst}$ ise; $m = m + 1$ yapılır ve eğer $m \leq m_{üst}$ ise; Adım 5'e gidilir. Aksi halde Adım 13'e geçilir.

Adım 13. Geçerlilik seti performansına göre en iyi hiper parametre değerleri seçilir.

Adım 14. Elde edilen en iyi hiper parametre değerlerinde, eğitim ve geçerliliği birleştirip yeni bir eğitim seti ile rastgele başlangıçlar üzerinden 30 defa eğitilip ağın test seti performansı hesaplanır. Burada tekrar sayısının 30 olarak alınması, deneysel çalışmalarda test edilerek yeterli bir doğruluğu sağlaması üzerine tercih edilmiştir.

3.2.3. SRNN-SES için sinüs kosinüs optimizasyon algoritmasına dayalı bir öğrenme algoritması

Önerilen yöntem SRNN-SES'nin eğitiminde kullanılan algoritmalarından biri SCO algoritmasıdır. Bu algoritma kullanılarak oluşturulan öğrenme algoritması Algoritma 5'te adım adım açıklanmıştır.

Algoritma 5. SRNN-SES-SCO Algoritması

Adım 1. Veri seti eğitim ($n_{eğitim}$), geçerlilik ($n_{geçerlilik}$) ve test (n_{test}) seti olmak üzere üç kısma ayrılır ve uzunlukları belirlenir. n , toplam gözlem sayısı olmakla birlikte denklem 3.6'da ifade edildiği gibidir.

Adım 2. Önerilen ağın hiper parametre değerleri (p, h, m) belirlenir. Hiper parametre değerleri için birer evrensel küme ($p \in [p_{alt}, p_{üst}], h \in [h_{alt}, h_{üst}], m \in [m_{alt}, m_{üst}]$) tanımlanmıştır.

Hiperparametrelerin olası değerleri belirlenir. Burada hiper parametre değerleri, p, h, m için alt ve üst sınırdır.

Adım 3. SCO algoritmasında kullanılacak parametreler belirlenir. Bu parametreler;

r_1 : Bir sonraki pozisyonun hareket yönünü belirleyen parametre

r_2 : Mevcut pozisyonun hareket yönünü belirleyen parametre

r_3 : Hedef için rastgele ağırlık parametresi

r_4 : Sinüs ya da kosinüs fonksiyonlarından hangisinin kullanılacağını belirleyen parametre

pn : Popülasyondaki pozisyonların sayısı

$maksitr$: Maksimum iterasyon sayısı

$limit1$: Yeniden başlatma stratejisi için limit değeri

$limit2$: Erken durdurma kuralı için limit değeri olarak verilebilir.

Adım 4. $p = p_{alt}$, $h = h_{alt}$ ve $m = m_{alt}$ yapılır.

Adım 5. SCO algoritmasının başlangıç konum değerleri oluşturulur. Bir SRNN'deki girdi tabakasına ait parametre sayısı $q_1 = hp + h^2 + h$, gizli tabakaya ait parametre sayısı $q_2 = 2h^2 + h$ ve mevsimsel olmayan parametre sayısı ise $q_3 = h + 3$ olmaktadır. Toplam konum sayısı $q_1 + (m - 1)q_2 + q_3$ 'tür. Bu konumlar ağırlıklar, yanlar, üstel düzleştirme ve kombinasyon parametrelerinden oluşmaktadır. Bir SRNN'de konumlar $P_{i,k}$, $i = 1, 2, \dots, ps$, $k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_3$ ile ifade edilmektedir. Burada, h gizli tabaka birim sayısını ifade etmektedir. m adet gizli tabaka sayısına sahip SRNN için pozisyonlar denklem 3.7'de verildiği gibidir.

Üstel düzleştirme ve kombinasyon parametreleri zaman serisinin mevsimsel bileşen içermediği durumda (α ve β), $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. Ayrıca tüm hız değerleri ($v_{i,k}$, $i = 1, 2, \dots, ps$, $k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_3$) ile tüm ağırlık ve yan değerleri de $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. SRNN-SES-SCO yönteminde bir pozisyonun konumlarının durumu Tablo 3.3.'te verilmiştir.

Tablo 3.3. SRNN-SES-SCO yöntemi için bir pozisyonun konumlarının durumu

Parametre	Θ^1	Θ^2	...	Θ^m
Boyut	$(p + h + 1) \times h$	$(2 \times h + 1) \times h$	...	$(2 \times h + 1) \times h$
Parametre	V_o	b_o	α	β
Boyut	$h \times 1$	1×1	1×1	1×1

Adım 6. Her bir parçacık için uygunluk fonksiyonu değerleri denklem 3.8'de ifade edilen MSE değeri ile hesaplanır. En düşük MSE değerine sahip olan pozisyon en iyi uygunluk değerine sahip pozisyon (Z_{eniyi}) olarak belirlenir.

Adım 7. Popülasyondaki yeni konumlar denklem 2.39 ile belirlenir.

Adım 8. Z_{eniyi} pozisyonu güncellenir.

Adım 9. Yeniden başlatma stratejisi sayacı ($rsc = rsc + 1$) arttırılır. Eğer $rsc > limit1$ olursa tüm hız ve pozisyon değerleri yeniden üretilir ve sayaç sıfırlanır.

Adım 10. Erken durdurma kuralı denklem 3.16 ile kontrol edilir. Burada, esc başarısızlık sayacıdır. $MSE_{eniyi}^{(t)}$ MSE 'nin t . yinelemedeki uygunluk değeridir.

Eğer $esc > Limit2$ ise algoritma durdurulur aksi halde Adım 7'ye geri dönülür.

Adım 11. Geçerlilik seti için RMSE değerleri, denklem 3.17 yardımıyla hesaplanır.

Adım 12. $p = p + 1$ yapılır ve eğer $p \leq p_{üst}$ ise; $h = h + 1$ yapılır ve eğer $h \leq h_{üst}$ ise; $m = m + 1$ yapılır ve eğer $m \leq m_{üst}$ ise; Adım 5'e gidilir. Aksi halde Adım 13'e geçilir.

Adım 13. Geçerlilik seti performansına göre en iyi hiper parametre değerleri seçilir.

Adım 14. Elde edilen en iyi hiper parametre değerlerinde, eğitim ve geçerliliği birleştirip yeni bir eğitim seti ile rastgele başlangıçlar üzerinden 30 defa eğitilip ağın test seti performansı hesaplanır. Burada tekrar sayısının 30 olarak alınması, deneysel çalışmalarda test edilerek yeterli bir doğruluğu sağlaması üzerine tercih edilmiştir.

3.2.4. SRNN-SES-S için sinüs kosinüs optimizasyon algoritmasına dayalı bir öğrenme algoritması

Önerilen yöntem SRNN-SES-S'nin eğitiminde kullanılan algoritmalarından biri SCO algoritmasıdır. Bu algoritma kullanılarak oluşturulan öğrenme algoritması Algoritma 6'da adım adım açıklanmıştır.

Algoritma 6. SRNN-SES-S-SCO Algoritması

Adım 1. Veri seti eğitim ($n_{eğitim}$), geçerlilik ($n_{geçerlilik}$) ve test (n_{test}) seti olmak üzere üç kısma ayrılır ve uzunlukları belirlenir. n , toplam gözlem sayısı olmakla birlikte denklem 3.6’da ifade edildiği gibidir.

Adım 2. Önerilen ağın hiper parametre değerleri (p, h, m) belirlenir. Hiper parametre değerleri için birer evrensel küme ($p \in [p_{alt}, p_{üst}], h \in [h_{alt}, h_{üst}], m \in [m_{alt}, m_{üst}]$) tanımlanmıştır.

Hiper parametrelerin olası değerleri belirlenir. Burada hiper parametre değerleri, p, h, m için alt ve üst sınırdır.

Adım 3. SCO algoritmasında kullanılacak parametreler belirlenir. Bu parametreler;

r_1 : Bir sonraki pozisyonun hareket yönünü belirleyen parametre

r_2 : Mevcut pozisyonun hareket yönünü belirleyen parametre

r_3 : Hedef için rastgele ağırlık parametresi

r_4 : Sinüs ya da kosinüs fonksiyonlarından hangisinin kullanılacağını belirleyen parametre

pn : Popülasyondaki pozisyonların sayısı

$maksitr$: Maksimum iterasyon sayısı

$limit1$: Yeniden başlatma stratejisi için limit değeri

$limit2$: Erken durdurma kuralı için limit değeri olarak verilebilir.

Adım 4. $p = p_{alt}$, $h = h_{alt}$ ve $m = m_{alt}$ yapılır.

Adım 5. SCO algoritmasının başlangıç konum değerleri oluşturulur. Bir SRNN’deki girdi tabakasına ait parametre sayısı $q_1 = hp + h^2 + h$, gizli tabakaya ait parametre sayısı $q_2 = 2h^2 + h$ ve mevsimsel parametre sayısı ise $q_4 = h + 6$ olmaktadır. Toplam konum sayısı $q_1 + (m - 1)q_2 + q_4$ ’tür. Bu konumlar ağırlıklar, yanlar, üstel düzleştirme ve kombinasyon parametrelerinden oluşmaktadır. Bir SRNN’de konumlar

$P_{i,k}, i = 1, 2, \dots, ps, k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_4$ ile ifade edilmektedir. m adet gizli tabaka sayısına sahip SRNN için parametreler denklem 3.7’de verildiği gibidir.

Üstel düzleştirme ve kombinasyon parametreleri $(\alpha, \gamma_1, \gamma_2, \gamma_3$ ve $\beta)$, $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. Ayrıca tüm hız değerleri $(v_{i,k}, i = 1, 2, \dots, ps, k = 1, 2, \dots, q_1 + (m - 1)q_2 + q_4)$ ile tüm ağırlık ve yan değerleri $U(0,1)$ aralığında düzgün dağılımdan rastgele üretilir. SRNN-SES-S-SCO yönteminde bir pozisyonun konumlarının durumu Tablo 3.4.’te verilmiştir.

Tablo 3.4. SRNN-SES-S-SCO yöntemi için bir pozisyonun konumlarının durumu

Parametre	θ^1	θ^2	...	θ^m	V_o	b_o
Boyut	$(p + h + 1) \times h$	$(2 \times h + 1) \times h$	...	$(2 \times h + 1) \times h$	$h \times 1$	1×1
Parametre	α	γ_1	γ_2	γ_3	β	
Boyut	1×1	1×1	1×1	1×1	1×1	

Adım 6. Her bir parçacık için uygunluk fonksiyonu değerleri denklem 3.8’de ifade edilen MSE değeri ile hesaplanır. En düşük MSE değerine sahip olan pozisyon en iyi uygunluk değerine sahip pozisyon (Z_{eniyi}) olarak belirlenir.

Adım 7. Popülasyondaki yeni konumlar denklem 2.39 ile belirlenir.

Adım 8. Z_{eniyi} pozisyonu güncellenir.

Adım 9. Yeniden başlatma stratejisi sayacı ($rsc = rsc + 1$) arttırılır. Eğer $rsc > limit1$ olursa tüm hız ve pozisyon değerleri yeniden üretilir ve sayaç sıfırlanır.

Adım 10. Erken durdurma kuralı denklem 3.16 ile kontrol edilir. Burada, esc başarısızlık sayacıdır. $MSE_{eniyi}^{(t)}$ MSE’nin t . yinelemedeki uygunluk değeridir.

Eğer $esc > Limit2$ ise algoritma durdurulur aksi halde Adım 7’ye geri dönlür.

Adım 11. Geçerlilik seti için RMSE değerleri, denklem 3.17 yardımıyla hesaplanır.

Adım 12. $p = p + 1$ yapılır ve eğer $p \leq p_{üst}$ ise; $h = h + 1$ yapılır ve eğer $h \leq h_{üst}$ ise; $m = m + 1$ yapılır ve eğer $m \leq m_{üst}$ ise; Adım 5'e gidilir. Aksi halde Adım 13'e geçilir.

Adım 13. Geçerlilik seti performansına göre en iyi hiper parametre değerleri seçilir.

Adım 14. Elde edilen en iyi hiper parametre değerlerinde, eğitim ve geçerliliği birleştirip yeni bir eğitim seti ile rastgele başlangıçlar üzerinden 30 defa eğitilip ağın test seti performansı hesaplanır. Burada tekrar sayısının 30 olarak alınması, deneysel çalışmalarda test edilerek yeterli bir doğruluğu sağlaması üzerine tercih edilmiştir.



BÖLÜM 4. ARAŞTIRMA BULGULARI

Bu tez kapsamında önerilen yöntemlerin öngörü performanslarını test etmek amacıyla 10 farklı veri seti kullanılmıştır. Bu veri setleri; FTSE MIB, DAX, IBEX 35, BTC-USD, gümüş, altın, BJ, ABT, AHK, TET'dir. Veri setlerine ait ayrıntılı bilgi Tablo 4.1.'de verildiği gibidir.

Tablo 4.1. Veri setlerine ait bilgiler			
Veri Seti	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
FTSE MIB	15.09.2015-18.03.2021	Günlük	2009
DAX	07.07.2016-30.03.2022	Günlük	1986
IBEX 35	20.03.2015-11.08.2022	Günlük	2020
BTC-USD	01.01.2015-21.11.2022	Günlük	2882
GÜMÜŞ	02.01.2015-18.11.2022	Günlük	1991
ALTIN	02.01.2015-21.11.2022	Günlük	1992
BJ	Ocak 1949-Kasım 1959	Aylık	144
AHK	Mart 1994-Nisan 2005	Aylık	134
TET	Ocak 2002- Aralık 2012	Aylık	144
ABT	Q1 1956-Q1 1994	Çeyreklik	148

Önerilen yöntemlerin (SRNN-SES ve SRNN-SES-S) öngörü performansını test etmek amacıyla kullanılan alternatif yöntemler MLP, SMN, PS-ANN, DNM-ANN, GRU-ANN, LSTM-ANN, SRNN, Naive ve S-Naive yöntemleridir. Veriler eğitim, geçerlilik ve test olmak üzere blok yapıda üç kısma ayrılmıştır ve bu sayede daha kapsamlı ve genel bir karşılaştırma yapılması sağlanmaktadır. Tez kapsamında önerilen yöntemlerin öngörü performansı hem SCO hem de PSO algoritması ile eğitilmiş ağlar üzerinden test edilmiştir. Elde edilen analiz sonuçlarının alternatif yöntemlerle karşılaştırma işlemi, bir hata kriteri olan RMSE değerinin ortalama, medyan, standart sapma, çeyrekler arası fark, minimum ve maksimum istatistikleri ile gerçekleştirilmiştir. Bu istatistikler sırasıyla denklemler 4.1-4.4'te verildiği gibidir.

$$Ortalama = \frac{\sum_{i=1}^n X_i}{n} \quad (4.1)$$

$$Standart Sapma = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n-1}} \quad (4.2)$$

$$Medyan = \begin{cases} X_j, & j = \frac{n+1}{2}, n \text{ tek ise} \\ \frac{X_j + X_{j+1}}{2}, & j = \frac{n}{2}, n \text{ çift ise} \end{cases} \quad (4.3)$$

$$\text{Çeyrekler Arası Fark} = Q_3 - Q_1 \quad (4.4)$$

Burada Q_1 birinci çeyreği ve Q_3 üçüncü çeyreği ifade etmektedir. Zaman serileri analizleri, mevsimsel bileşen içeren ve içermeyen zaman serileri olmak üzere iki başlık altında verilmiştir.

4.1. Mevsimsel Bileşen İçermeyen Zaman Serileri İçin Çözümleme

Mevsimsel bileşen içermeyen zaman serileri için SRNN-SES ve alternatif yöntemler için gizli tabaka sayısı 1 – 2 arasında birer artırılarak, gizli tabaka birim sayısı 1 – 5 arasında birer artırılarak değiştirilmiştir. Her bir yöntem rasgele başlangıç ağırlıkları kullanılarak 30 kez uygulanmıştır. Test ve geçerlilik veri setlerinin uzunlukları veri setlerinin boyutlarına göre farklılık göstermiştir. Test ve geçerlilik veri setlerinin uzunlukları, FTSE MIB, DAX, IBEX35, BTC-USD, gümüş ve altın veri setleri için 250 gözlem içeren veri setlerinde (1-5 numaralı veri setleri) 20, 500 gözlem içeren veri setlerinde (6-10 numaralı veri setleri) 40 olarak belirlenmiştir. Burada toplam verinin %84'ü eğitim, %16'sı ise geçerlilik ve test olarak kullanılmıştır. Mevsimsel bileşen içermeyen zaman serilerinin çözümleri alt başlıklar altında verilmiştir. Test seti öngörü performansı, RMSE değeri kullanılarak hesaplanmıştır.

4.1.1. FTSE MIB veri seti için çözümleme

FTSE MIB borsası, İtalya piyasalarındaki en popüler 40 hisse senedinden oluşmaktadır. FTSE MIB borsasına ait 2015-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele

beşer veri setine ayrılmıştır. Veri setlerine ait bilgiler Tablo 4.2.’de, veri setlerine ait grafikler ise Şekil 4.1.’de verilmiştir.


Tablo 4.2. Rastgele elde edilen 10 adet FTSE MIB veri setine ait bilgiler

Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	22.05.2018-17.05.2019	Günlük	250
2	29.01.2018-24.01.2019	Günlük	250
3	24.06.2019-18.06.2020	Günlük	250
4	27.11.2019-20.11.2020	Günlük	250
5	25.03.2020-18.03.2021	Günlük	250
6	22.08.2016-5.01.2021	Günlük	500
7	15.01.2019-5.01.2021	Günlük	500
8	16.11.2018-9.11.2020	Günlük	500
9	16.12.2015-30.11.2017	Günlük	500
10	15.09.2015-30.08.2017	Günlük	500

Şekil 4.1 ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, önerilen yöntemler ile çözümlenmiş ve elde edilen analiz sonuçları, literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.3.-4.12.’de verilmiştir.

Tablo 4.3. FTSE MIB Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0093	0,0092	0,0006	0,0006	0,0087	0,0108	2	-	1
SMN	0,0098	0,0098	0,0011	0,0021	0,0088	0,0109	2	-	-
PS-ANN	0,0085	0,0086	0,0003	0,0004	0,0080	0,0091	4	-	1
DNM-ANN	0,0092	0,0091	0,0004	0,0004	0,0086	0,0105	2	-	2
GRU-ANN	0,0115	0,0113	0,0008	0,0009	0,0107	0,0139	2	1	1
LSTM-ANN	0,0136	0,0136	0,0014	0,0019	0,0111	0,0166	4	1	1
SRNN	0,0113	0,0113	0,0002	0,0003	0,0111	0,0117	4	1	1
SRNN-SES-SCO	0,0085	0,0085	0,0001	0,0001	0,0085	0,0088	3	1	1
SRNN-SES-PSO	0,0085	0,0085	0,0000	0,0000	0,0085	0,0085	5	3	1



Şekil 4.1. Rastgele elde edilen 10 adet FTSE MIB veri setine ait zaman serisi grafikleri

Tablo 4.4. FTSE MIB Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0218	0,0215	0,0022	0,0025	0,0170	0,0277	5	-	2
SMN	0,0196	0,0189	0,0008	0,0017	0,0189	0,0206	2	-	-
PS-ANN	0,0196	0,0196	0,0014	0,0021	0,0175	0,0225	5	-	2
DNM-ANN	0,0199	0,0200	0,0013	0,0012	0,0170	0,0223	5	-	2
GRU-ANN	0,0544	0,0324	0,0339	0,0472	0,0252	0,1168	2	4	2
LSTM-ANN	0,0525	0,0444	0,0235	0,0351	0,0269	0,1105	5	5	1
SRNN	0,0192	0,0193	0,0010	0,0011	0,0177	0,0230	5	1	2
SRNN-SES-SCO	0,0114	0,0114	0,0001	0,0001	0,0112	0,0118	3	3	1
SRNN-SES-PSO	0,0115	0,0115	0,0000	0,0000	0,0115	0,0115	3	4	2

Tablo 4.5. FTSE MIB Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0401	0,0396	0,0057	0,0048	0,0269	0,0530	2	-	2
SMN	0,0404	0,0454	0,0067	0,0137	0,0317	0,0455	2	-	-
PS-ANN	0,0335	0,0329	0,0036	0,0043	0,0280	0,0443	4	-	2
DNM-ANN	0,0387	0,0377	0,0057	0,0078	0,0291	0,0500	3	-	2
GRU-ANN	0,1108	0,1163	0,0287	0,0458	0,0403	0,1491	3	5	1
LSTM-ANN	0,0684	0,0660	0,0173	0,0301	0,0364	0,0985	5	2	2
SRNN	0,0449	0,0450	0,0027	0,0014	0,0398	0,0525	4	1	2
SRNN-SES-SCO	0,0203	0,0202	0,0006	0,0004	0,0191	0,0216	4	1	2
SRNN-SES-PSO	0,0206	0,0206	0,0001	0,0003	0,0204	0,0206	2	5	2

Tablo 4.6. FTSE MIB Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0245	0,0241	0,0021	0,0035	0,0212	0,0287	2	-	2
SMN	0,0275	0,0219	0,0067	0,0132	0,0210	0,0346	2	-	-
PS-ANN	0,0235	0,0233	0,0008	0,0010	0,0216	0,0247	5	-	1
DNM-ANN	0,0245	0,0241	0,0021	0,0033	0,0213	0,0293	2	-	2
GRU-ANN	0,0519	0,0412	0,0208	0,0245	0,0336	0,0936	2	2	2
LSTM-ANN	0,0860	0,0871	0,0093	0,0158	0,0705	0,1001	2	4	2
SRNN	0,0327	0,0324	0,0016	0,0014	0,0301	0,0382	2	1	2
SRNN-SES-SCO	0,0204	0,0202	0,0004	0,0003	0,0198	0,0216	2	4	2
SRNN-SES-PSO	0,0207	0,0208	0,0001	0,0002	0,0206	0,0208	5	5	2

Tablo 4.7. FTSE MIB Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0470	0,0472	0,0024	0,0026	0,0422	0,0532	3	-	1
SMN	0,0446	0,0437	0,0010	0,0019	0,0437	0,0457	2	-	-
PS-ANN	0,0438	0,0441	0,0031	0,0032	0,0366	0,0506	5	-	2
DNM-ANN	0,0460	0,0466	0,0033	0,0053	0,0368	0,0502	4	-	2
GRU-ANN	0,0420	0,0411	0,0076	0,0079	0,0242	0,0557	4	2	1
LSTM-ANN	0,0396	0,0391	0,0048	0,0050	0,0285	0,0514	3	1	1
SRNN	0,0320	0,0336	0,0036	0,0061	0,0251	0,0364	5	1	2
SRNN-SES-SCO	0,0095	0,0095	0,0000	0,0000	0,0095	0,0095	2	1	1
SRNN-SES-PSO	0,0095	0,0095	0,0000	0,0000	0,0095	0,0095	2	4	2

Tablo 4.8. FTSE MIB Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0135	0,0134	0,0019	0,0025	0,0107	0,0182	3	-	2
SMN	0,0133	0,0126	0,0009	0,0018	0,0126	0,0145	2	-	-
PS-ANN	0,0160	0,0154	0,0031	0,0039	0,0107	0,0245	5	-	2
DNM-ANN	0,0136	0,0137	0,0017	0,0016	0,0102	0,0173	4	-	2
GRU-ANN	0,0145	0,0141	0,0017	0,0016	0,0126	0,0198	2	1	2
LSTM-ANN	0,0157	0,0159	0,0020	0,0038	0,0125	0,0192	4	1	1
SRNN	0,0136	0,0133	0,0009	0,0017	0,0125	0,0150	2	1	2
SRNN-SES-SCO	0,0101	0,0101	0,0000	0,0000	0,0099	0,0101	5	5	2
SRNN-SES-PSO	0,0100	0,0100	0,0001	0,0001	0,0100	0,0101	4	4	1

Tablo 4.9. FTSE MIB Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0156	0,0155	0,0013	0,0018	0,0135	0,0185	2	-	1
SMN	0,0168	0,0189	0,0028	0,0055	0,0134	0,0206	2	-	-
PS-ANN	0,0142	0,0140	0,0014	0,0014	0,0121	0,0182	3	-	2
DNM-ANN	0,0168	0,0166	0,0026	0,0030	0,0127	0,0252	4	-	2
GRU-ANN	0,0201	0,0197	0,0016	0,0026	0,0178	0,0239	2	1	2
LSTM-ANN	0,0235	0,0230	0,0036	0,0048	0,0174	0,0311	4	1	1
SRNN	0,0186	0,0186	0,0010	0,0013	0,0166	0,0201	2	1	2
SRNN-SES-SCO	0,0125	0,0125	0,0001	0,0000	0,0125	0,0127	4	4	2
SRNN-SES-PSO	0,0126	0,0126	0,0001	0,0002	0,0126	0,0127	2	4	1

Tablo 4.10. FTSE MIB Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0213	0,0216	0,0015	0,0023	0,0184	0,0246	2	-	2
SMN	0,0213	0,0187	0,0035	0,0071	0,0187	0,0259	2	-	-
PS-ANN	0,0193	0,0191	0,0008	0,0007	0,0175	0,0213	2	-	2
DNM-ANN	0,0241	0,0231	0,0037	0,0046	0,0192	0,0336	5	-	2
GRU-ANN	0,0326	0,0305	0,0047	0,0058	0,0269	0,0429	4	2	1
LSTM-ANN	0,0293	0,0295	0,0027	0,0032	0,0249	0,0364	4	1	1
SRNN	0,0292	0,0255	0,0139	0,0015	0,0236	0,0838	2	3	2
SRNN-SES-SCO	0,0174	0,0173	0,0001	0,0002	0,0172	0,0178	4	3	2
SRNN-SES-PSO	0,0175	0,0175	0,0001	0,0001	0,0173	0,0175	2	4	1

Tablo 4.11. FTSE MIB Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0316	0,0308	0,0049	0,0046	0,0247	0,0444	4	-	1
SMN	0,0269	0,0266	0,0004	0,0008	0,0265	0,0274	2	-	-
PS-ANN	0,0263	0,0262	0,0013	0,0016	0,0233	0,0288	3	-	2
DNM-ANN	0,0318	0,0315	0,0039	0,0038	0,0221	0,0430	4	-	2
GRU-ANN	0,0491	0,0448	0,0287	0,0135	0,0185	0,1816	5	2	2
LSTM-ANN	0,0259	0,0258	0,0057	0,0061	0,0162	0,0413	3	1	2
SRNN	0,0246	0,0245	0,0052	0,0071	0,0121	0,0341	2	3	2
SRNN-SES-SCO	0,0061	0,0062	0,0001	0,0001	0,0060	0,0062	3	5	1
SRNN-SES-PSO	0,0061	0,0061	0,0000	0,0000	0,0061	0,0061	3	1	1

Tablo 4.12. FTSE MIB Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0088	0,0083	0,0021	0,0017	0,0071	0,0138	2	-	2
SMN	0,0091	0,0092	0,0032	0,0014	0,0072	0,0106	3	-	-
PS-ANN	0,0112	0,0112	0,0004	0,0005	0,0100	0,0120	5	-	1
DNM-ANN	0,0102	0,0091	0,0029	0,0025	0,0074	0,0178	2	-	2
GRU-ANN	0,0116	0,0115	0,0033	0,0021	0,0089	0,0164	2	1	1
LSTM-ANN	0,0104	0,0098	0,0024	0,0019	0,0085	0,0180	2	1	2
SRNN	0,0098	0,0096	0,0007	0,0007	0,0090	0,0123	4	3	1
SRNN-SES-SCO	0,0074	0,0074	0,0001	0,0000	0,0073	0,0080	2	3	2
SRNN-SES-PSO	0,0074	0,0074	0,0000	0,0000	0,0074	0,0074	2	3	1

Tablolar 4.3.-4.12.'de verilen RMSE deęerlerine gre elde edilen istatistikler incelendięinde, ortalama istatistięine gre SRNN-SES-SCO ve SRNN-SES-PSO'nun ngr performansı aısından 10 verinin 9'unda daha dřk RMSE deęerine sahip olmasıyla %90 bařarılı olduęu gzlemlenmiřtir. Tm istatistikler incelendięinde, 5 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tm istatistiklerde en iyi yntem olduęu sonucuna varılmıřtır.

Ortalama istatistięi incelendięinde, 1-9-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 2-3-4-7-8 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu ve 6 numaralı veri setinde ise SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir.

Medyan istatistięi incelendięinde, 1-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 2-3-4-7-8 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu ve 6-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir.

Standart sapma istatistięi incelendięinde, 7-8 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 6 numaralı veri setinde SRNN-SES-SCO'nun en iyi yntem olduęu ve 1-2-3-4-9-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir.

eyrekler arası fark istatistięi incelendięinde, 10 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 6-7 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu ve 1-2-3-4-8-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir.

Minimum istatistięi incelendięinde, 1 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yntem olduęu, 2-3-4-6-8-9 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu, 7 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yntem olduęu, SRNN-SES-PSO'nun nc en iyi

yöntem olduğu, 10 numaralı veri setinde SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun dördüncü en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 6-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu ve 1-2-3-4-8-9-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen öngörü sonuçları Tablo 4.13.'te verilmiştir.

Tablo 4.13. FTSE MIB zaman serileri için ortalama istatistiğine göre önerilen yöntemden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0085	0,0085	0,0086
2	0,0114	0,0115	0,0114
3	0,0203	0,0206	0,0202
4	0,0204	0,0207	0,0202
5	0,0095	0,0095	0,0095
6	0,0101	0,0100	0,0101
7	0,0125	0,0126	0,0125
8	0,0174	0,0175	0,0173
9	0,0061	0,0061	0,0062
10	0,0074	0,0074	0,0074

Analiz sonuçları incelendiğinde, SRNN-SES-SCO ve SRNN-SES-PSO'nun 1-9 numaralı veri setlerinde Naive yöntemden daha iyi olduğu sonucuna varılmıştır. 6 numaralı veri seti incelendiğinde, SRNN-SES-PSO yönteminin Naive yöntemden daha iyi olduğu gözlemlenmiştir. Tablo 4.13. incelendiğinde, analiz sonuçlarının ya Naive yönteme oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.1.2. DAX veri seti için çözümleme

DAX borsası, Almanya piyasalarındaki en büyük 30 hisse senedinden oluşmaktadır. DAX borsasına ait 2016-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele beşer veri setine ayrılmıştır. Veri setlerine ait bilgiler Tablo 4.14.'te, veri setlerine ait grafikler ise Şekil 4.2.'de verilmiştir.


Tablo 4.14. Rastgele elde edilen 10 adet DAX veri setine ait bilgiler

Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	12.06.2018-10.06.2019	Günlük	250
2	17.08.2021-12.08.2022	Günlük	250
3	09.05.2017-04.05.2018	Günlük	250
4	17.01.2019-14.01.2020	Günlük	250
5	20.07.2016-17.07.2017	Günlük	250
6	12.06.2019-04.06.2021	Günlük	500
7	07.07.2016-29.06.2018	Günlük	500
8	27.12.2017-20.12.2019	Günlük	500
9	20.02.2019-11.02.2021	Günlük	500
10	07.04.2020-30.03.2022	Günlük	500

Şekil 4.2. ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, önerilen yöntem SRNN-SES-PSO ve SRNN-SES-SCO ile çözümlenmiş ve elde edilen analiz sonuçları, literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.15.-4.24.'te verilmiştir.

Tablo 4.15. DAX Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0209	0,0207	0,0018	0,0029	0,0181	0,0251	3	-	1
SMN	0,0215	0,0211	0,0010	0,0020	0,0204	0,0232	5	-	-
PS-ANN	0,0221	0,0219	0,0027	0,0033	0,0173	0,0303	5	-	2
DNM-ANN	0,0195	0,0194	0,0008	0,0009	0,0179	0,0211	2	-	2
GRU-ANN	0,0209	0,0209	0,0022	0,0025	0,0168	0,0266	4	1	2
LSTM-ANN	0,0206	0,0204	0,0019	0,0017	0,0181	0,0261	2	1	1
SRNN	0,0228	0,0224	0,0027	0,0031	0,0188	0,0329	4	3	2
SRNN-SES-SCO	0,0193	0,0195	0,0006	0,0005	0,0167	0,0197	4	4	2
SRNN-SES-PSO	0,0192	0,0192	0,0000	0,0000	0,0192	0,0192	5	1	1



Şekil 4.2. Rastgele elde edilen 10 adet DAX zaman serisi grafikleri

Tablo 4.16. DAX Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0203	0,0202	0,0036	0,0052	0,0152	0,0317	5	-	1
SMN	0,0138	0,0140	0,0002	0,0005	0,0136	0,0140	2	-	-
PS-ANN	0,0164	0,0164	0,0009	0,0010	0,0150	0,0188	5	-	1
DNM-ANN	0,0168	0,0154	0,0036	0,0050	0,0121	0,0269	2	-	2
GRU-ANN	0,0203	0,0203	0,0054	0,0093	0,0129	0,0309	2	1	2
LSTM-ANN	0,0192	0,0177	0,0060	0,0046	0,0133	0,0373	5	1	2
SRNN	0,0224	0,0192	0,0093	0,0121	0,0134	0,0466	3	1	2
SRNN-SES-SCO	0,0150	0,0147	0,0023	0,0000	0,0132	0,0271	2	2	2
SRNN-SES-PSO	0,0147	0,0147	0,0000	0,0000	0,0147	0,0147	5	5	1

Tablo 4.17. DAX Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0099	0,0099	0,0007	0,0011	0,0089	0,0121	5	-	2
SMN	0,0145	0,0140	0,0037	0,0053	0,0095	0,0214	5	-	-
PS-ANN	0,0096	0,0095	0,0006	0,0009	0,0087	0,0111	4	-	2
DNM-ANN	0,0102	0,0101	0,0010	0,0009	0,0078	0,0128	5	-	2
GRU-ANN	0,0126	0,0126	0,0014	0,0015	0,0101	0,0181	5	1	2
LSTM-ANN	0,0126	0,0125	0,0011	0,0013	0,0105	0,0155	2	1	2
SRNN	0,0166	0,0181	0,0025	0,0046	0,0117	0,0185	2	4	1
SRNN-SES-SCO	0,0085	0,0085	0,0000	0,0000	0,0085	0,0086	2	3	2
SRNN-SES-PSO	0,0085	0,0085	0,0000	0,0000	0,0085	0,0086	5	3	2

Tablo 4.18. DAX Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0192	0,0188	0,0023	0,0028	0,0147	0,0241	4	-	2
SMN	0,0182	0,0174	0,0009	0,0019	0,0173	0,0192	2	-	-
PS-ANN	0,0173	0,0172	0,0018	0,0015	0,0145	0,0247	5	-	2
DNM-ANN	0,0194	0,0196	0,0018	0,0024	0,0155	0,0236	5	-	2
GRU-ANN	0,0419	0,0393	0,0172	0,0262	0,0083	0,0734	3	3	2
LSTM-ANN	0,0166	0,0169	0,0028	0,0032	0,0132	0,0247	4	1	2
SRNN	0,0271	0,0167	0,0232	0,0038	0,0113	0,0734	4	3	2
SRNN-SES-SCO	0,0082	0,0082	0,0001	0,0000	0,0080	0,0082	2	1	1
SRNN-SES-PSO	0,0081	0,0081	0,0000	0,0000	0,0081	0,0081	3	4	1

Tablo 4.19. DAX Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0089	0,0085	0,0014	0,0010	0,0076	0,0145	4	-	1
SMN	0,0101	0,0107	0,0015	0,0015	0,0073	0,0118	4	-	-
PS-ANN	0,0095	0,0094	0,0016	0,0022	0,0070	0,0141	5	-	2
DNM-ANN	0,0089	0,0088	0,0007	0,0009	0,0070	0,0101	3	-	2
GRU-ANN	0,0309	0,0146	0,0319	0,0163	0,0105	0,1128	2	4	2
LSTM-ANN	0,0372	0,0281	0,0233	0,0384	0,0106	0,0909	2	3	1
SRNN	0,0095	0,0092	0,0010	0,0001	0,0091	0,0142	3	1	2
SRNN-SES-SCO	0,0077	0,0077	0,0000	0,0000	0,0077	0,0077	5	4	2
SRNN-SES-PSO	0,0077	0,0077	0,0000	0,0000	0,0077	0,0077	2	4	2

Tablo 4.20. DAX Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0813	0,0816	0,0062	0,0055	0,0715	0,1026	2	-	2
SMN	0,0768	0,0770	0,0003	0,0007	0,0763	0,0772	2	-	-
PS-ANN	0,0754	0,0747	0,0056	0,0047	0,0637	0,0962	5	-	2
DNM-ANN	0,0829	0,0835	0,0073	0,0101	0,0669	0,0973	2	-	2
GRU-ANN	0,0826	0,0854	0,0126	0,0182	0,0485	0,1038	4	2	1
LSTM-ANN	0,0710	0,0709	0,0073	0,0104	0,0559	0,0857	2	1	2
SRNN	0,0580	0,0604	0,0069	0,0074	0,0390	0,0657	5	1	2
SRNN-SES-SCO	0,0101	0,0100	0,0002	0,0000	0,0100	0,0109	2	1	1
SRNN-SES-PSO	0,0102	0,0103	0,0002	0,0004	0,0100	0,0104	4	2	1

Tablo 4.21. DAX Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0158	0,0164	0,0023	0,0038	0,0114	0,0195	4	-	1
SMN	0,0134	0,0146	0,0014	0,0027	0,0119	0,0147	2	-	-
PS-ANN	0,0123	0,0123	0,0005	0,0006	0,0116	0,0137	4	-	1
DNM-ANN	0,0139	0,0140	0,0012	0,0022	0,0122	0,0158	2	-	1
GRU-ANN	0,0173	0,0168	0,0017	0,0026	0,0148	0,0210	2	1	2
LSTM-ANN	0,0233	0,0219	0,0055	0,0065	0,0140	0,0377	2	2	2
SRNN	0,0160	0,0155	0,0017	0,0019	0,0135	0,0202	4	2	2
SRNN-SES-SCO	0,0109	0,0109	0,0000	0,0000	0,0107	0,0109	5	1	1
SRNN-SES-PSO	0,0108	0,0108	0,0000	0,0000	0,0108	0,0109	2	4	2

Tablo 4.22. DAX Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0091	0,0085	0,0018	0,0025	0,0066	0,0144	5	-	1
SMN	0,0098	0,0098	0,0022	0,0048	0,0065	0,0123	3	-	-
PS-ANN	0,0081	0,0079	0,0015	0,0013	0,0062	0,0139	4	-	2
DNM-ANN	0,0076	0,0073	0,0011	0,0015	0,0061	0,0107	2	-	2
GRU-ANN	0,0310	0,0197	0,0248	0,0380	0,0084	0,0967	2	3	1
LSTM-ANN	0,0128	0,0128	0,0022	0,0039	0,0095	0,0163	5	1	1
SRNN	0,0098	0,0095	0,0008	0,0014	0,0087	0,0115	5	2	2
SRNN-SES-SCO	0,0056	0,0056	0,0000	0,0000	0,0055	0,0057	3	5	2
SRNN-SES-PSO	0,0056	0,0056	0,0000	0,0000	0,0056	0,0056	5	4	2

Tablo 4.23. DAX Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0745	0,0744	0,0029	0,0047	0,0684	0,0808	2	-	2
SMN	0,0709	0,0703	0,0024	0,0023	0,0680	0,0803	5	-	-
PS-ANN	0,0717	0,0716	0,0018	0,0015	0,0677	0,0770	3	-	2
DNM-ANN	0,0754	0,0754	0,0070	0,0088	0,0613	0,0912	2	-	2
GRU-ANN	0,0676	0,0685	0,0064	0,0077	0,0534	0,0825	4	1	1
LSTM-ANN	0,0753	0,0719	0,0131	0,0163	0,0547	0,1072	4	2	1
SRNN	0,0524	0,0541	0,0048	0,0074	0,0395	0,0608	3	1	2
SRNN-SES-SCO	0,0123	0,0122	0,0005	0,0002	0,0121	0,0145	3	2	2
SRNN-SES-PSO	0,0124	0,0125	0,0002	0,0001	0,0121	0,0126	5	1	2

Tablo 4.24. DAX Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0325	0,0317	0,0029	0,0028	0,0291	0,0417	3	-	1
SMN	0,0338	0,0288	0,0059	0,0117	0,0286	0,0405	2	-	-
PS-ANN	0,0304	0,0297	0,0025	0,0012	0,0285	0,0395	2	-	2
DNM-ANN	0,0363	0,0365	0,0055	0,0086	0,0265	0,0468	5	-	2
GRU-ANN	0,0479	0,0436	0,0101	0,0093	0,0399	0,0862	2	2	1
LSTM-ANN	0,0470	0,0468	0,0048	0,0042	0,0405	0,0647	3	1	1
SRNN	0,0368	0,0368	0,0019	0,0020	0,0335	0,0410	4	2	2
SRNN-SES-SCO	0,0247	0,0246	0,0001	0,0001	0,0246	0,0249	2	1	2
SRNN-SES-PSO	0,0248	0,0248	0,0001	0,0002	0,0246	0,0248	2	1	2

Tablolar 4.15.-4.24.'te verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, ortalama istatistiğine göre SRNN-SES-SCO ve SRNN-SES-PSO'nun öngörü performansı açısından 10 verinin 9'unda daha düşük RMSE değerine sahip olmasıyla %90 başarılı olduğu gözlemlenmiştir. Tüm istatistikler incelendiğinde, 3 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tüm istatistiklerde en iyi yöntem olduğu sonucuna varılmıştır.

Ortalama istatistiği incelendiğinde, 5-8 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 6-9-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 1-4-7 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde, SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Medyan istatistiği incelendiğinde, 5-8 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 6-9-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 1-4-7 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde ise SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Standart sapma istatistiği incelendiğinde, 5-6-7-8-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu ve 1-2-4-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu gözlemlenmiştir. Çeyrekler arası fark istatistiği incelendiğinde, 2-4-5-7-8 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 6-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu ve 1-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu gözlemlenmiştir.

Minimum istatistiği incelendiğinde, 6-9-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 1-4-7-8 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 2 numaralı veri setinde SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun ise yedinci en iyi

yöntem olduğu ve 5 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun dördüncü en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 5-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 1-4-6-8-9-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde SRNN-SES-SCO'nun dördüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen sonuçlar Tablo 4.25.'te verilmiştir.

Tablo 4.25. 10 adet DAX veri seti için ortalama istatistiğine göre önerilen yöntemden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0193	0,0192	0,0197
2	0,0150	0,0147	0,0147
3	0,0085	0,0085	0,0085
4	0,0082	0,0081	0,0082
5	0,0077	0,0077	0,0077
6	0,0101	0,0102	0,0100
7	0,0109	0,0108	0,0109
8	0,0056	0,0056	0,0056
9	0,0123	0,0124	0,0122
10	0,0247	0,0248	0,0246

Analiz sonuçları incelendiğinde, SRNN-SES-SCO ve SRNN-SES-PSO'nun 1 numaralı veri setinde Naive yöntemden daha iyi olduğu sonucuna varılmıştır. 4-7 numaralı veri setleri incelendiğinde, SRNN-SES-PSO'nun Naive yönteminden daha iyi olduğu gözlemlenmiştir. Tablo 4.25. incelendiğinde, analiz sonuçlarının ya Naive yöntemle oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.1.3. IBEX 35 veri seti için çözümleme

IBEX 35 borsası, Madrid borsasında işlem gören 35 hisse senedinden oluşmaktadır. IBEX 35 borsasına ait 2015-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele beşer veri setine

ayrılmıştır. Veri setine ait bilgiler Tablo 4.26.'da, veri setlerine ait grafikler ise Şekil 4.3.'te verilmiştir.


Tablo 4.26. Rastgele elde edilen 10 adet IBEX 35 veri setine ait bilgiler

Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	28.12.2015-14.12.2016	Günlük	250
2	29.11.2017-21.11.2018	Günlük	250
3	05.05.2021-25.04.2022	Günlük	250
4	29.06.2020-17.06.2021	Günlük	250
5	23.08.2021-11.08.2022	Günlük	250
6	22.11.2018-05.11.2020	Günlük	500
7	20.03.2015-28.02.2017	Günlük	500
8	20.01.2020-29.12.2021	Günlük	500
9	22.07.2020-01.07.2022	Günlük	500
10	15.01.2019-24.12.2020	Günlük	500

Şekil 4.3. ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, önerilen yöntem SRNN-SES-PSO ve SRNN-SES-SCO ile çözümlenmiş ve elde edilen analiz sonuçları literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.27.-4.36.'da verilmiştir.

Tablo 4.27. IBEX 35 Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0109	0,0109	0,0004	0,0004	0,0102	0,0119	3	-	1
SMN	0,0122	0,0109	0,0024	0,0000	0,0108	0,0164	2	-	-
PS-ANN	0,0110	0,0109	0,0004	0,0003	0,0105	0,0121	3	-	2
DNM-ANN	0,0119	0,0118	0,0011	0,0011	0,0102	0,0147	4	-	2
GRU-ANN	0,0174	0,0174	0,0007	0,0008	0,0154	0,0186	2	1	2
LSTM-ANN	0,0195	0,0196	0,0022	0,0031	0,0158	0,0261	4	2	1
SRNN	0,0218	0,0178	0,0069	0,0149	0,0164	0,0323	5	3	2
SRNN-SES-SCO	0,0101	0,0100	0,0003	0,0001	0,0098	0,0108	5	3	1
SRNN-SES-PSO	0,0108	0,0108	0,0002	0,0003	0,0106	0,0114	5	3	1



Şekil 4.3. Rastgele elde edilen 10 adet IBEX 35 veri setlerine ait zaman serisi grafikleri

Tablo 4.28. IBEX 35 Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0128	0,0131	0,0032	0,0059	0,0080	0,0190	4	-	2
SMN	0,0094	0,0094	0,0006	0,0011	0,0087	0,0100	2	-	-
PS-ANN	0,0078	0,0078	0,0000	0,0000	0,0077	0,0079	3	-	1
DNM-ANN	0,0098	0,0099	0,0010	0,0014	0,0082	0,0130	4	-	2
GRU-ANN	0,0141	0,0130	0,0041	0,0035	0,0097	0,0292	4	2	1
LSTM-ANN	0,0137	0,0133	0,0028	0,0049	0,0097	0,0193	4	1	2
SRNN	0,0734	0,0850	0,0255	0,0003	0,0106	0,0852	3	4	2
SRNN-SES-SCO	0,0083	0,0084	0,0002	0,0001	0,0079	0,0084	2	1	2
SRNN-SES-PSO	0,0084	0,0084	0,0000	0,0000	0,0084	0,0084	5	2	1

Tablo 4.29. IBEX 35 Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0124	0,0122	0,0008	0,0012	0,0112	0,0141	3	-	1
SMN	0,0124	0,0116	0,0014	0,0031	0,0115	0,0147	2	-	-
PS-ANN	0,0118	0,0119	0,0005	0,0005	0,0108	0,0126	4	-	2
DNM-ANN	0,0130	0,0123	0,0014	0,0023	0,0115	0,0158	2	-	1
GRU-ANN	0,0178	0,0161	0,0055	0,0040	0,0114	0,0339	5	3	1
LSTM-ANN	0,0150	0,0152	0,0008	0,0012	0,0132	0,0167	4	1	2
SRNN	0,0152	0,0152	0,0002	0,0003	0,0150	0,0156	3	1	1
SRNN-SES-SCO	0,0108	0,0108	0,0002	0,0004	0,0105	0,0111	4	2	2
SRNN-SES-PSO	0,0107	0,0107	0,0000	0,0000	0,0107	0,0107	3	3	2

Tablo 4.30. IBEX 35 Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0371	0,0367	0,0045	0,0054	0,0284	0,0494	4	-	2
SMN	0,0330	0,0324	0,0009	0,0017	0,0316	0,0341	2	-	-
PS-ANN	0,0320	0,0320	0,0020	0,0015	0,0275	0,0372	3	-	2
DNM-ANN	0,0359	0,0375	0,0056	0,0038	0,0218	0,0443	4	-	2
GRU-ANN	0,0313	0,0311	0,0051	0,0069	0,0180	0,0393	2	1	2
LSTM-ANN	0,0345	0,0354	0,0050	0,0067	0,0240	0,0451	3	1	1
SRNN	0,0254	0,0291	0,0072	0,0091	0,0085	0,0320	2	1	2
SRNN-SES-SCO	0,0049	0,0049	0,0000	0,0000	0,0049	0,0049	5	5	2
SRNN-SES-PSO	0,0049	0,0049	0,0000	0,0000	0,0049	0,0049	2	4	1

Tablo 4.31. IBEX 35 Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0072	0,0072	0,0005	0,0006	0,0062	0,0090	4	-	2
SMN	0,0079	0,0078	0,0010	0,0019	0,0069	0,0089	2	-	-
PS-ANN	0,0078	0,0078	0,0002	0,0002	0,0073	0,0085	5	-	1
DNM-ANN	0,0073	0,0072	0,0007	0,0008	0,0064	0,0096	5	-	2
GRU-ANN	0,0112	0,0106	0,0023	0,0019	0,0085	0,0176	5	2	1
LSTM-ANN	0,0094	0,0091	0,0012	0,0015	0,0073	0,0127	4	1	2
SRNN	0,0089	0,0089	0,0004	0,0004	0,0082	0,0099	2	2	1
SRNN-SES-SCO	0,0078	0,0079	0,0004	0,0009	0,0071	0,0084	2	3	2
SRNN-SES-PSO	0,0078	0,0078	0,0000	0,0000	0,0077	0,0078	5	3	1

Tablo 4.32. IBEX 35 Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0206	0,0212	0,0029	0,0039	0,0148	0,0264	2	-	1
SMN	0,0239	0,0255	0,0061	0,0108	0,0143	0,0321	4	-	-
PS-ANN	0,0165	0,0161	0,0017	0,0014	0,0138	0,0214	2	-	2
DNM-ANN	0,0170	0,0166	0,0021	0,0033	0,0136	0,0219	2	-	2
GRU-ANN	0,0501	0,0388	0,0506	0,0132	0,0220	0,2434	4	4	1
LSTM-ANN	0,0418	0,0387	0,0176	0,0188	0,0204	0,0912	2	3	2
SRNN	0,0220	0,0220	0,0012	0,0020	0,0200	0,0240	4	3	2
SRNN-SES-SCO	0,0138	0,0136	0,0003	0,0003	0,0136	0,0145	2	2	1
SRNN-SES-PSO	0,0138	0,0138	0,0000	0,0000	0,0138	0,0138	3	1	1

Tablo 4.33. IBEX 35 Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0126	0,0124	0,0029	0,0040	0,0092	0,0187	5	-	1
SMN	0,0099	0,0098	0,0015	0,0029	0,0085	0,0114	2	-	-
PS-ANN	0,0083	0,0082	0,0004	0,0005	0,0077	0,0091	5	-	1
DNM-ANN	0,0099	0,0095	0,0022	0,0023	0,0073	0,0160	4	-	2
GRU-ANN	0,0126	0,0121	0,0022	0,0031	0,0098	0,0178	2	1	2
LSTM-ANN	0,0155	0,0150	0,0032	0,0038	0,0103	0,0238	2	1	2
SRNN	0,0142	0,0127	0,0077	0,0032	0,0103	0,0539	5	3	2
SRNN-SES-SCO	0,0068	0,0069	0,0000	0,0000	0,0068	0,0069	3	4	1
SRNN-SES-PSO	0,0069	0,0069	0,0000	0,0000	0,0068	0,0069	3	4	2

Tablo 4.34. IBEX 35 Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0156	0,0153	0,0019	0,0009	0,0132	0,0241	5	-	2
SMN	0,0150	0,0135	0,0017	0,0034	0,0135	0,0169	2	-	-
PS-ANN	0,0144	0,0142	0,0012	0,0010	0,0130	0,0186	3	-	2
DNM-ANN	0,0149	0,0149	0,0012	0,0015	0,0129	0,0172	3	-	2
GRU-ANN	0,0188	0,0184	0,0016	0,0021	0,0162	0,0223	5	1	1
LSTM-ANN	0,0193	0,0193	0,0015	0,0019	0,0165	0,0226	4	1	2
SRNN	0,0210	0,0184	0,0132	0,0011	0,0174	0,0910	5	3	2
SRNN-SES-SCO	0,0128	0,0128	0,0001	0,0001	0,0127	0,0130	4	5	2
SRNN-SES-PSO	0,0128	0,0128	0,0000	0,0000	0,0128	0,0128	4	2	1

Tablo 4.35. IBEX 35 Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0170	0,0168	0,0020	0,0026	0,0136	0,0226	3	-	2
SMN	0,0174	0,0174	0,0032	0,0063	0,0142	0,0206	2	-	-
PS-ANN	0,0149	0,0149	0,0003	0,0003	0,0144	0,0156	4	-	1
DNM-ANN	0,0167	0,0169	0,0020	0,0023	0,0130	0,0205	2	-	2
GRU-ANN	0,0306	0,0286	0,0070	0,0090	0,0211	0,0497	2	4	1
LSTM-ANN	0,0255	0,0256	0,0032	0,0040	0,0210	0,0328	2	2	2
SRNN	0,0319	0,0349	0,0063	0,0128	0,0226	0,0399	4	4	2
SRNN-SES-SCO	0,0133	0,0133	0,0001	0,0000	0,0132	0,0135	3	1	2
SRNN-SES-PSO	0,0133	0,0133	0,0000	0,0000	0,0132	0,0133	4	2	1

Tablo 4.36. IBEX 35 Seri 10 veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0297	0,0282	0,0054	0,0074	0,0239	0,0485	4	-	2
SMN	0,0369	0,0340	0,0096	0,0115	0,0200	0,0508	4	-	-
PS-ANN	0,0216	0,0214	0,0008	0,0011	0,0199	0,0235	4	-	1
DNM-ANN	0,0289	0,0277	0,0057	0,0072	0,0213	0,0470	5	-	2
GRU-ANN	0,0424	0,0408	0,0082	0,0105	0,0305	0,0635	2	2	2
LSTM-ANN	0,0423	0,0386	0,0098	0,0165	0,0289	0,0618	5	1	2
SRNN	0,0341	0,0327	0,0044	0,0028	0,0301	0,0499	3	2	2
SRNN-SES-SCO	0,0187	0,0187	0,0002	0,0001	0,0181	0,0191	2	1	1
SRNN-SES-PSO	0,0188	0,0188	0,0000	0,0000	0,0188	0,0188	2	1	2

Tablolar 4.27.-4.36.'da verilen RMSE deęerlerine gre elde edilen istatistikler incelendięinde, ortalama istatistięine gre SRNN-SES-SCO ve SRNN-SES-PSO'nun ngr performansı aısından 10 verinin 9'unda daha dřk RMSE deęerine sahip olmasıyla %90 bařarılı olduęu gzlemlenmiřtir. Tm istatistikler incelendięinde, 4 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tm istatistiklerde en iyi yntem olduęu sonucuna varılmıřtır.

Ortalama istatistięi incelendięinde, 6-8-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 1-7-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu, 3 numaralı veri setinde SRNN-SES-PSO'nun en iyi yntem olduęu, 2 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yntem olduęu, SRNN-SES-PSO'nun nc en iyi yntem olduęu ve 5 numaralı veri setinde ise SRNN-SES-SCO ve SRNN-SES-PSO'nun nc en iyi yntem olduęu gzlemlenmiřtir.

Medyan istatistięi incelendięinde, 8-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir. 1-6-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yntem olduęu, 3 numaralı veri setinde SRNN-SES-PSO'nun en iyi yntem olduęu, 2 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yntem olduęu ve 5 numaralı veri setinde SRNN-SES-PSO'nun ikinci en iyi yntem olduęu, SRNN-SES-SCO'nun nc en iyi yntem olduęu gzlemlenmiřtir.

Standart sapma istatistięi incelendięinde, 1-2-3-5-6-8-9-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yntem olduęu gzlemlenmiřtir.

eyrekler arası fark istatistięi incelendięinde, 9 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yntem olduęu, 2-3-5-6-8-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yntem olduęu ve 1 numaralı veri setinde ise SRNN-SES-SCO'nun ikinci en iyi yntem olduęu, SRNN-SES-PSO'nun nc en iyi yntem olduęu gzlemlenmiřtir.

Minimum istatistiği incelendiğinde, 1-3-8-10 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 2 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yöntem olduğu, SRNN-SES-PSO'nun beşinci en iyi yöntem olduğu, 5 numaralı veri setinde SRNN-SES-SCO'nun dördüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun altıncı en iyi yöntem olduğu ve 9 numaralı veri setinde ise SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 3-5-6-8-9-10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu, 1 numaralı veri setinde SRNN-SES-SCO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde ise SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemlerden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen sonuçlar Tablo 4.37.'de verilmiştir.

Tablo 4.37. 10 adet IBEX 35 veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0101	0,0108	0,0100
2	0,0083	0,0084	0,0084
3	0,0108	0,0107	0,0111
4	0,0049	0,0049	0,0049
5	0,0078	0,0078	0,0084
6	0,0138	0,0138	0,0136
7	0,0068	0,0069	0,0069
8	0,0128	0,0128	0,0128
9	0,0133	0,0133	0,0133
10	0,0187	0,0188	0,0187

Analiz sonuçları incelendiğinde, SRNN-SES-SCO ve SRNN-SES-PSO'nun 3-5 numaralı veri setlerinde Naive yöntemden daha iyi olduğu sonucuna varılmıştır. 2-7 numaralı veri setleri incelendiğinde, SRNN-SES-SCO yönteminin Naive yönteminden daha iyi olduğu gözlemlenmiştir. Tablo 4.37. incelendiğinde, analiz sonuçlarının ya Naive yöntemle oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.1.4. BTC-USD veri seti için çözümleme

BTC-USD, 2008’te ortaya çıkmış merkezi olmayan bir dijital para birimidir. BTC-USD’ye ait 2016-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele beşer veri setine ayrılmıştır. Veri setine ait bilgiler Tablo 4.38.’de verilmiştir.

Tablo 4.38. Rastgele elde edilen 10 BTC-USD veri setine ait bilgiler


Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	30.11.2021-06.08.2022	Günlük	250
2	12.12.2018-18.08.2019	Günlük	250
3	01.01.2016-06.09.2016	Günlük	250
4	29.01.2016-04.10.2016	Günlük	250
5	09.11.2016-16.07.2017	Günlük	250
6	26.06.2020-07.11.2021	Günlük	500
7	29.08.2016-10.01.2018	Günlük	500
8	24.04.2020-05.09.2021	Günlük	500
9	04.08.2016-16.12.2017	Günlük	500
10	23.01.2021-06.06.2022	Günlük	500

Şekil 4.4. ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, SRNN-SES-PSO ve SRNN-SES-SCO ile çözümlenmiş ve elde edilen analiz sonuçları, literatürde mevcut birçok yöntemden elde edilen analiz sonuçları ile karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.39.-4.48.’de verilmiştir.

Tablo 4.39. BTC-USD Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0436	0,0440	0,0113	0,0111	0,0261	0,0732	4	-	2
SMN	0,0303	0,0303	0,0000	0,0000	0,0303	0,0303	1	-	-
PS-ANN	0,0494	0,0460	0,0135	0,0189	0,0343	0,0821	4	-	2
DNM-ANN	0,0507	0,0500	0,0070	0,0059	0,0314	0,0663	2	-	2
GRU-ANN	0,1134	0,1066	0,0646	0,0469	0,0427	0,4040	5	3	1
LSTM-ANN	0,0531	0,0507	0,0135	0,0173	0,0336	0,0976	1	1	1
SRNN	0,0827	0,0677	0,0682	0,0267	0,0487	0,4313	2	3	2
SRNN-SES-SCO	0,0322	0,0321	0,0004	0,0000	0,0318	0,0334	4	3	2
SRNN-SES-PSO	0,0321	0,0321	0,0000	0,0000	0,0321	0,0321	4	3	1

Veri setlerine ait grafikler Şekil 4.4.'te verilmiştir.



Şekil 4.4. Rastgele elde edilen 10 adet BTC-USD veri setine ait zaman serisi grafikleri

Tablo 4.40. BTC-USD Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0616	0,0617	0,0091	0,0110	0,0423	0,0827	2	-	2
SMN	0,0629	0,0624	0,0115	0,0191	0,0455	0,0812	4	-	-
PS-ANN	0,0494	0,0484	0,0067	0,0081	0,0389	0,0648	5	-	2
DNM-ANN	0,0595	0,0620	0,0100	0,0081	0,0350	0,0777	3	-	2
GRU-ANN	0,0616	0,0597	0,0125	0,0164	0,0416	0,0922	3	1	2
LSTM-ANN	0,0729	0,0731	0,0116	0,0125	0,0529	0,1066	2	1	1
SRNN	0,0622	0,0615	0,0030	0,0031	0,0578	0,0711	3	2	1
SRNN-SES-SCO	0,0350	0,0347	0,0010	0,0002	0,0347	0,0398	5	3	1
SRNN-SES-PSO	0,0355	0,0356	0,0002	0,0000	0,0347	0,0356	3	3	2

Tablo 4.41. BTC-USD Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0258	0,0255	0,0048	0,0060	0,0150	0,0334	1	-	2
SMN	0,0242	0,0229	0,0027	0,0041	0,0175	0,0274	2	-	-
PS-ANN	0,0254	0,0246	0,0051	0,0044	0,0155	0,0404	4	-	2
DNM-ANN	0,0279	0,0277	0,0061	0,0082	0,0136	0,0388	5	-	2
GRU-ANN	0,0846	0,0811	0,0422	0,0592	0,0187	0,1692	4	5	1
LSTM-ANN	0,0752	0,0594	0,0475	0,0564	0,0217	0,1955	4	3	2
SRNN	0,1696	0,1806	0,0357	0,0018	0,0318	0,1853	1	4	1
SRNN-SES-SCO	0,0114	0,0114	0,0001	0,0000	0,0114	0,0121	1	1	1
SRNN-SES-PSO	0,0116	0,0114	0,0002	0,0005	0,0114	0,0119	5	4	1

Tablo 4.42. BTC-USD Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0190	0,0179	0,0056	0,0073	0,0100	0,0322	3	-	2
SMN	0,0198	0,0210	0,0036	0,0055	0,0137	0,0277	4	-	-
PS-ANN	0,0162	0,0158	0,0032	0,0051	0,0097	0,0223	5	-	2
DNM-ANN	0,0161	0,0172	0,0033	0,0035	0,0066	0,0204	2	-	2
GRU-ANN	0,0207	0,0196	0,0065	0,0100	0,0093	0,0364	1	2	1
LSTM-ANN	0,0230	0,0211	0,0082	0,0136	0,0084	0,0392	4	1	1
SRNN	0,0431	0,0178	0,0576	0,0081	0,0092	0,1736	3	3	2
SRNN-SES-SCO	0,0065	0,0065	0,0000	0,0000	0,0065	0,0065	1	1	1
SRNN-SES-PSO	0,0065	0,0065	0,0000	0,0000	0,0065	0,0065	2	1	1

Tablo 4.43. BTC-USD Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0609	0,0607	0,0071	0,0068	0,0400	0,0773	2	-	2
SMN	0,0582	0,0499	0,0104	0,0210	0,0498	0,0711	2	-	-
PS-ANN	0,0562	0,0560	0,0025	0,0031	0,0512	0,0636	5	-	1
DNM-ANN	0,0681	0,0660	0,0105	0,0098	0,0521	0,0985	5	-	2
GRU-ANN	0,0938	0,0900	0,0157	0,0235	0,0743	0,1289	5	2	2
LSTM-ANN	0,0874	0,0817	0,0177	0,0093	0,0725	0,1655	5	2	2
SRNN	0,0741	0,0716	0,0065	0,0064	0,0663	0,0914	2	1	2
SRNN-SES-SCO	0,0367	0,0367	0,0000	0,0000	0,0367	0,0368	1	1	1
SRNN-SES-PSO	0,0367	0,0367	0,0000	0,0000	0,0367	0,0367	1	4	1

Tablo 4.44. BTC-USD Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,1328	0,1359	0,0194	0,0267	0,0840	0,1637	5	-	2
SMN	0,1349	0,1337	0,0078	0,0142	0,1239	0,1501	4	-	-
PS-ANN	0,1291	0,1294	0,0051	0,0053	0,1201	0,1417	3	-	2
DNM-ANN	0,1244	0,1264	0,0264	0,0515	0,0864	0,1681	2	-	2
GRU-ANN	0,1269	0,1260	0,0139	0,0214	0,1034	0,1656	4	1	2
LSTM-ANN	0,1363	0,1362	0,0184	0,0264	0,0958	0,1715	2	1	2
SRNN	0,1235	0,1225	0,0048	0,0070	0,1155	0,1347	4	3	1
SRNN-SES-SCO	0,0336	0,0336	0,0000	0,0000	0,0336	0,0338	1	1	2
SRNN-SES-PSO	0,0337	0,0338	0,0001	0,0002	0,0336	0,0338	3	2	2

Tablo 4.45. BTC-USD Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,7931	0,8082	0,0439	0,0553	0,6720	0,8549	4	-	2
SMN	0,7601	0,7549	0,0175	0,0167	0,7404	0,8129	4	-	-
PS-ANN	0,6645	0,6644	0,0049	0,0035	0,6540	0,6776	5	-	1
DNM-ANN	0,7336	0,7448	0,0710	0,1371	0,5915	0,8401	5	-	2
GRU-ANN	0,5751	0,5760	0,0608	0,1002	0,4799	0,7168	1	1	2
LSTM-ANN	0,7088	0,6969	0,0970	0,1284	0,5840	0,9517	1	1	2
SRNN	0,5400	0,5535	0,0767	0,1354	0,3996	0,6388	1	1	2
SRNN-SES-SCO	0,0788	0,0788	0,0000	0,0000	0,0788	0,0788	1	1	1
SRNN-SES-PSO	0,0788	0,0788	0,0000	0,0000	0,0788	0,0788	1	2	2

Tablo 4.46. BTC-USD Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0391	0,0381	0,0035	0,0033	0,0356	0,0485	1	-	2
SMN	0,0432	0,0414	0,0067	0,0073	0,0342	0,056	4	-	-
PS-ANN	0,0452	0,0442	0,0061	0,0089	0,0361	0,0574	5	-	2
DNM-ANN	0,044	0,0429	0,0056	0,0079	0,0362	0,0587	5	-	2
GRU-ANN	0,2527	0,1124	0,2588	0,2237	0,0694	0,8498	3	5	2
LSTM-ANN	0,3865	0,3854	0,2004	0,3387	0,0944	0,7439	5	5	1
SRNN	0,0418	0,041	0,0029	0,0011	0,0393	0,0534	1	1	2
SRNN-SES-SCO	0,0311	0,0311	0,0000	0,0000	0,0310	0,0311	4	1	1
SRNN-SES-PSO	0,0311	0,0311	0,0000	0,0000	0,0311	0,0311	2	2	1

Tablo 4.47. BTC-USD Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,8787	0,8806	0,0219	0,0256	0,8061	0,9226	3	-	2
SMN	0,8768	0,8777	0,0168	0,0193	0,8209	0,9035	5	-	-
PS-ANN	0,8212	0,8209	0,0042	0,0032	0,8132	0,8368	3	-	1
DNM-ANN	0,877	0,8834	0,0235	0,0457	0,8362	0,9117	4	-	2
GRU-ANN	0,8781	0,7491	0,3574	0,2746	0,5677	1,965	2	2	2
LSTM-ANN	1,2316	1,2345	0,3762	0,7338	0,6792	1,9567	3	4	1
SRNN	0,5619	0,5444	0,0442	0,0787	0,4961	0,6419	3	1	2
SRNN-SES-SCO	0,0685	0,0685	0,0000	0,0000	0,0685	0,0688	1	1	1
SRNN-SES-PSO	0,0685	0,0685	0,0001	0,0001	0,0685	0,0686	4	5	1

Tablo 4.48. BTC-USD Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,1195	0,1205	0,0112	0,0131	0,0914	0,1418	4	-	1
SMN	0,1142	0,1162	0,0167	0,0312	0,0934	0,1451	5	-	-
PS-ANN	0,0928	0,0934	0,0059	0,0052	0,0693	0,101	4	-	2
DNM-ANN	0,0954	0,0952	0,0074	0,0113	0,0838	0,1095	2	-	2
GRU-ANN	0,2193	0,1743	0,1229	0,2555	0,0498	0,3921	1	4	1
LSTM-ANN	0,1133	0,1155	0,0163	0,024	0,0826	0,1402	3	1	2
SRNN	0,1027	0,1039	0,0066	0,0068	0,0795	0,1125	5	1	2
SRNN-SES-SCO	0,0396	0,0396	0,0001	0,0000	0,0392	0,0396	2	4	1
SRNN-SES-PSO	0,0394	0,0393	0,0001	0,0002	0,0392	0,0396	3	2	2

Tablolar 4.39.-4.48.'de verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, ortalama istatistiğine göre SRNN-SES-SCO ve SRNN-SES-PSO'nun öngörü performansı açısından 10 verinin 9'unda daha düşük RMSE değerine sahip olmasıyla %90 başarılı olduğu gözlemlenmiştir. Tüm istatistikler incelendiğinde, 4-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tüm istatistiklerde en iyi yöntem olduğu sonucuna varılmıştır.

Ortalama istatistiği incelendiğinde, 5-8-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 2-3-6 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 10 numaralı veri setinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 1 numaralı veri setinde ise SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu, SRNN-SES-SCO'nun ise üçüncü en iyi yöntem olduğu gözlemlenmiştir.

Medyan istatistiği incelendiğinde, 3-5-8-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 2-6 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 10 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 1 numaralı veri setinde ise SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Standart sapma istatistiği incelendiğinde, 5-8-10 numaralı veri setlerinde SRNN-SES-PSO ve SRNN-SES-SCO'nun en iyi yöntem olduğu, 1-2 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu, 3-6-9 numaralı veri setlerinde ise SRNN-SES-SCO'nun ise en iyi yöntem olduğu gözlemlenmiştir.

Çeyrekler arası fark istatistiği incelendiğinde, 1-5-8 numaralı veri setlerinde SRNN-SES-PSO ve SRNN-SES-SCO'nun en iyi yöntem olduğu, 2 numaralı veri setinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 3-6-9-10 numaralı veri setlerinde ise SRNN-SES-SCO'nun ise en iyi yöntem olduğu gözlemlenmiştir.

Minimum istatistiği incelendiğinde, 2-3-5-6-9-10 numaralı veri setlerinde SRNN-SES-PSO ve SRNN-SES-SCO'nun en iyi yöntem olduğu, 8 numaralı veri setinde

SRNN-SES-SCO'nun en iyi yöntem olduğu ve 1 numaralı veri setinde ise SRNN-SES-SCO'nun dördüncü en iyi yöntem olduğu, SRNN-SES-PSO'nun beşinci en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 6-8-10 numaralı veri setlerinde SRNN-SES-PSO ve SRNN-SES-SCO'nun en iyi yöntem olduğu, 2-3-5-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 1 numaralı veri setinde ise SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu, SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemlerden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen sonuçlar Tablo 4.49.'da verilmiştir.

Tablo 4.49. 10 adet BTC-USD veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0322	0,0321	0,0321
2	0,0350	0,0355	0,0347
3	0,0114	0,0116	0,0114
4	0,0065	0,0065	0,0065
5	0,0367	0,0367	0,0367
6	0,0336	0,0337	0,0336
7	0,0788	0,0788	0,0788
8	0,0311	0,0311	0,0311
9	0,0685	0,0685	0,0685
10	0,0396	0,0394	0,0396

10 numaralı veri setine ait istatistikler incelendiğinde, SRNN-SES-PSO yönteminin Naive yönteminden daha iyi olduğu gözlemlenmiştir. Tablo 4.49. incelendiğinde, analiz sonuçlarının ya Naive yöntemle oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.1.5. Gümüş veri seti için çözümleme

Gümüş zaman serisine ait 2015-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele beşer veri setine ayrılmıştır. Veri setine ait bilgiler Tablo 4.50.'de, veri setlerine ait grafikler Şekil 4.5.'te verilmiştir.


Tablo 4.50. Rastgele elde edilen 10 adet gümüş veri setine ait bilgiler

Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	03.09.2015-28.08.2016	Günlük	250
2	05.12.2016-30.11.2017	Günlük	250
3	14.10.2018-10.10.2019	Günlük	250
4	17.08.2021-08.08.2022	Günlük	250
5	02.09.2021-24.08.2022	Günlük	250
6	09.12.2015-01.12.2017	Günlük	500
7	01.10.2020-19.09.2022	Günlük	500
8	02.09.2020-22.08.2022	Günlük	500
9	15.11.2017-11.11.2019	Günlük	500
10	30.09.2019-22.09.2021	Günlük	500

Şekil 4.5. ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, önerilen yöntem SRNN-SES-PSO ve SRNN-SES-SCO ile çözümlenmiş ve elde edilen analiz sonuçları literatürde mevcut birçok yöntemden elde edilen analiz sonuçları ile karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.51.-4.60.'ta verilmiştir.

Tablo 4.51. Gümüş Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0221	0,0218	0,0024	0,0036	0,0186	0,0266	2	-	1
SMN	0,0193	0,0187	0,0012	0,0024	0,0169	0,0211	2	-	-
PS-ANN	0,0181	0,0181	0,0002	0,0002	0,0179	0,0185	5	-	1
DNM-ANN	0,0233	0,0231	0,0034	0,0025	0,0167	0,0325	5	-	2
GRU-ANN	0,0268	0,0241	0,0069	0,0046	0,0209	0,0485	4	1	2
LSTM-ANN	0,0248	0,0243	0,0022	0,0022	0,0216	0,0300	2	1	2
SRNN	0,0239	0,0216	0,0048	0,0024	0,0207	0,0380	2	1	2
SRNN-SES-SCO	0,0133	0,0133	0,0000	0,0000	0,0133	0,0133	2	1	1
SRNN-SES-PSO	0,0133	0,0133	0,0000	0,0000	0,0133	0,0133	3	1	2



Şekil 4.5. Rastgele elde edilen 10 adet gümüş veri setine ait zaman serisi grafikleri

Tablo 4.52. Gümüş Seri 2 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0136	0,0136	0,0004	0,0005	0,0124	0,0144	2	-	2
SMN	0,0152	0,0154	0,0012	0,0022	0,0137	0,0169	4	-	-
PS-ANN	0,0141	0,0140	0,0005	0,0006	0,0126	0,0152	3	-	2
DNM-ANN	0,0132	0,0132	0,0004	0,0004	0,0123	0,0140	2	-	2
GRU-ANN	0,0175	0,0170	0,0022	0,0034	0,0147	0,0237	5	2	2
LSTM-ANN	0,0167	0,0163	0,0025	0,0017	0,0137	0,0267	5	3	2
SRNN	0,0168	0,0168	0,0010	0,0011	0,0143	0,0183	5	3	2
SRNN-SES-SCO	0,0134	0,0135	0,0001	0,0002	0,0130	0,0135	2	2	2
SRNN-SES-PSO	0,0134	0,0134	0,0000	0,0000	0,0134	0,0135	2	5	1

Tablo 4.53. Gümüş Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0193	0,0189	0,0019	0,0017	0,0172	0,0259	4	-	2
SMN	0,0211	0,0171	0,0052	0,0082	0,0170	0,0317	2	-	-
PS-ANN	0,0193	0,0189	0,0018	0,0030	0,0168	0,0235	4	-	2
DNM-ANN	0,0200	0,0192	0,0022	0,0031	0,0176	0,0254	4	-	2
GRU-ANN	0,0822	0,0677	0,0523	0,1133	0,0215	0,1441	2	2	2
LSTM-ANN	0,0237	0,0234	0,0016	0,0023	0,0210	0,0288	2	1	2
SRNN	0,0243	0,0239	0,0010	0,0013	0,0230	0,0266	4	1	2
SRNN-SES-SCO	0,0186	0,0186	0,0000	0,0000	0,0186	0,0186	2	1	1
SRNN-SES-PSO	0,0186	0,0186	0,0000	0,0000	0,0186	0,0186	2	4	2

Tablo 4.54. Gümüş Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0563	0,0570	0,0044	0,0038	0,0450	0,0619	5	-	1
SMN	0,0459	0,0460	0,0015	0,0030	0,0442	0,0476	2	-	-
PS-ANN	0,0477	0,0459	0,0070	0,0080	0,0378	0,0675	5	-	2
DNM-ANN	0,0444	0,0434	0,0048	0,0077	0,0372	0,0571	2	-	2
GRU-ANN	0,0377	0,0372	0,0024	0,0029	0,0344	0,0458	3	1	2
LSTM-ANN	0,1166	0,1327	0,0444	0,0803	0,0432	0,1826	2	3	1
SRNN	0,0508	0,0404	0,0370	0,0058	0,0346	0,1864	5	3	2
SRNN-SES-SCO	0,0233	0,0232	0,0005	0,0001	0,0228	0,0258	2	1	2
SRNN-SES-PSO	0,0230	0,0229	0,0001	0,0000	0,0229	0,0232	3	3	2

Tablo 4.55. Gümüş Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0193	0,0190	0,0018	0,0024	0,0166	0,0239	2	-	2
SMN	0,0334	0,0341	0,0119	0,0260	0,0178	0,0497	5	-	-
PS-ANN	0,0249	0,0232	0,0059	0,0092	0,0153	0,0369	4	-	2
DNM-ANN	0,0267	0,0252	0,0056	0,0063	0,0211	0,0469	4	-	2
GRU-ANN	0,0405	0,0391	0,0069	0,0111	0,0295	0,0576	3	2	1
LSTM-ANN	0,0328	0,0316	0,0055	0,0065	0,0240	0,0490	3	2	2
SRNN	0,1136	0,1423	0,0489	0,0986	0,0252	0,1447	3	4	2
SRNN-SES-SCO	0,0158	0,0158	0,0001	0,0001	0,0158	0,0161	5	5	1
SRNN-SES-PSO	0,0160	0,0161	0,0001	0,0002	0,0159	0,0161	4	4	1

Tablo 4.56. Gümüş Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0134	0,0133	0,0009	0,0013	0,0118	0,0152	3	-	2
SMN	0,0146	0,0157	0,0012	0,0024	0,0132	0,0160	2	-	-
PS-ANN	0,0131	0,0130	0,0003	0,0004	0,0125	0,0138	4	-	1
DNM-ANN	0,0133	0,0130	0,0010	0,0008	0,0118	0,0158	4	-	2
GRU-ANN	0,0161	0,0158	0,0008	0,0012	0,0149	0,0184	2	1	1
LSTM-ANN	0,0183	0,0176	0,0033	0,0026	0,0140	0,0282	3	2	1
SRNN	0,0155	0,0155	0,0006	0,0010	0,0143	0,0172	4	1	2
SRNN-SES-SCO	0,0122	0,0122	0,0000	0,0000	0,0121	0,0122	5	3	1
SRNN-SES-PSO	0,0122	0,0122	0,0000	0,0001	0,0122	0,0122	3	1	1

Tablo 4.57. Gümüş Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0484	0,0490	0,0094	0,0117	0,0300	0,0759	5	-	2
SMN	0,0429	0,0409	0,0023	0,0045	0,0407	0,0454	2	-	-
PS-ANN	0,0433	0,0423	0,0057	0,0069	0,0313	0,0547	5	-	2
DNM-ANN	0,0467	0,0471	0,0048	0,0056	0,0342	0,0552	3	-	1
GRU-ANN	0,0500	0,0456	0,0133	0,0079	0,0364	0,1087	3	2	2
LSTM-ANN	0,0449	0,0415	0,0102	0,0114	0,0329	0,0783	5	1	2
SRNN	0,0363	0,0363	0,0031	0,0052	0,0310	0,0415	3	2	2
SRNN-SES-SCO	0,0202	0,0201	0,0003	0,0006	0,0200	0,0210	5	3	2
SRNN-SES-PSO	0,0206	0,0206	0,0001	0,0001	0,0205	0,0207	3	1	2

Tablo 4.58. Gümüş Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,1303	0,1305	0,0030	0,0046	0,1231	0,1353	2	-	2
SMN	0,1309	0,1305	0,0041	0,0056	0,1268	0,1472	3	-	-
PS-ANN	0,1273	0,1272	0,0022	0,0029	0,1220	0,1321	4	-	2
DNM-ANN	0,1281	0,1278	0,0033	0,0047	0,1228	0,1362	2	-	2
GRU-ANN	0,1312	0,1143	0,0479	0,0494	0,0806	0,2339	2	2	2
LSTM-ANN	0,1040	0,1038	0,0094	0,0168	0,0898	0,1230	3	1	2
SRNN	0,1240	0,1051	0,0502	0,0149	0,0849	0,2339	5	3	2
SRNN-SES-SCO	0,0203	0,0201	0,0007	0,0006	0,0198	0,0226	5	4	1
SRNN-SES-PSO	0,0203	0,0202	0,0002	0,0005	0,0202	0,0206	5	5	2

Tablo 4.59. Gümüş Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0175	0,0175	0,0015	0,0023	0,0150	0,0217	4	-	2
SMN	0,0184	0,0218	0,0037	0,0074	0,0143	0,0220	2	-	-
PS-ANN	0,0181	0,0178	0,0024	0,0032	0,0146	0,0242	5	-	2
DNM-ANN	0,0170	0,0171	0,0015	0,0019	0,0147	0,0209	2	-	2
GRU-ANN	0,0375	0,0223	0,0383	0,0036	0,0209	0,1493	4	1	2
LSTM-ANN	0,0229	0,0222	0,0017	0,0026	0,0210	0,0277	4	1	2
SRNN	0,0213	0,0212	0,0005	0,0006	0,0207	0,0226	2	2	2
SRNN-SES-SCO	0,0153	0,0153	0,0003	0,0002	0,0151	0,0165	3	2	2
SRNN-SES-PSO	0,0153	0,0154	0,0000	0,0001	0,0153	0,0154	3	4	2

Tablo 4.60. Gümüş Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0368	0,0359	0,0061	0,0090	0,0261	0,0475	3	-	2
SMN	0,0410	0,0396	0,0059	0,0100	0,0306	0,0515	5	-	-
PS-ANN	0,0342	0,0331	0,0064	0,0057	0,0260	0,0592	4	-	2
DNM-ANN	0,0416	0,0417	0,0039	0,0040	0,0288	0,0483	4	-	2
GRU-ANN	0,0445	0,0424	0,0078	0,0099	0,0274	0,0622	3	1	2
LSTM-ANN	0,0447	0,0436	0,0081	0,0067	0,0318	0,0725	3	1	2
SRNN	0,0367	0,0369	0,0032	0,0054	0,0297	0,0409	2	2	2
SRNN-SES-SCO	0,0178	0,0178	0,0000	0,0000	0,0178	0,0180	3	5	1
SRNN-SES-PSO	0,0179	0,0179	0,0000	0,0000	0,0178	0,0179	2	1	1

Tablolar 4.51.-4.60.'ta verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, ortalama istatistiğine göre SRNN-SES-SCO ve SRNN-SES-PSO'nun öngörü performansı açısından 10 verinin 9'unda daha düşük RMSE değerine sahip olmasıyla %90 başarılı olduğu gözlemlenmiştir. Tüm istatistikler incelendiğinde, 1 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tüm istatistiklerde en iyi yöntem olduğu sonucuna varılmıştır.

Ortalama istatistiği incelendiğinde, 3-6-8-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 4 numaralı veri setinde SRNN-SES-PSO'nun en iyi yöntem olduğu, 5-7-10 numaralı veri setlerinde ise SRNN-SES-SCO'nun en iyi yöntem olduğu, 2 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Medyan istatistiği incelendiğinde, 3-6 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 4 numaralı veri setinde SRNN-SES-PSO'nun en iyi yöntem olduğu, 5-7-8-9-10 numaralı veri setlerinde ise SRNN-SES-SCO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde ise SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu, SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu gözlemlenmiştir.

Standart sapma istatistiği incelendiğinde, 3-5-6-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu ve 2-4-7-8-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu gözlemlenmiştir. Çeyrekler arası fark istatistiği incelendiğinde, 3-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 2-4-7-8-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 5-6 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu gözlemlenmiştir.

Minimum istatistiği incelendiğinde, 10 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 4-7-8 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 2 numaralı veri setinde SRNN-SES-PSO'nun beşinci en iyi yöntem olduğu, SRNN-SES-SCO'nun dördüncü en iyi yöntem olduğu,

3 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun beşinci en iyi yöntem olduğu, 5 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yöntem olduğu, SRNN-SES-PSO'nun üçüncü en iyi yöntem olduğu, 6 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yöntem olduğu, SRNN-SES-PSO'nun üçüncü en iyi yöntem olduğu ve 9 numaralı veri setinde ise SRNN-SES-SCO'nun beşinci en iyi yöntem olduğu, SRNN-SES-PSO'nun altıncı en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 2-3-5-6 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu ve 4-7-8-9-10 numaralı veri setlerinde ise SRNN-SES-PSO'nun en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemlerden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen sonuçlar Tablo 4.61.'de verilmiştir.

Tablo 4.61. 10 adet gümüş veri seti için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0133	0,0133	0,0133
2	0,0134	0,0134	0,0135
3	0,0186	0,0186	0,0186
4	0,0233	0,0230	0,0232
5	0,0158	0,0160	0,0158
6	0,0122	0,0122	0,0122
7	0,0202	0,0206	0,0200
8	0,0203	0,0203	0,0198
9	0,0153	0,0153	0,0152
10	0,0178	0,0179	0,0178

Analiz sonuçları incelendiğinde, SRNN-SES-PSO ve SRNN-SES-SCO'nun 2 numaralı veri setinde Naive yöntemden daha iyi olduğu sonucuna varılmıştır. 4 numaralı veri seti incelendiğinde, SRNN-SES-PSO'nun Naive yöntemden daha iyi olduğu gözlemlenmiştir. Tablo 4.61. incelendiğinde, analiz sonuçlarının ya Naive yönteme oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.1.6. Altın veri seti için çözümleme

Altın zaman serisine ait 2015-2022 yılları arasında günlük olarak gözlemlenen veri seti elde edilmiş ve bu veri seti 250 ve 500 gözlemden oluşan rastgele beşer veri setine

ayrılmıştır. Veri setine ait bilgiler Tablo 4.62.'de, veri setlerine ait grafikler Şekil 4.6.'da verilmiştir.


Tablo 4.62. Rastgele elde edilen 10 adet altın veri setine ait bilgiler

Seri No	Başlangıç-Bitiş Tarihleri	Gözlemlenme Sıklığı	Gözlem Sayısı
1	31.03.2020-28.03.2021	Günlük	250
2	26.02.2020-22.02.2021	Günlük	250
3	19.10.2017-16.09.2018	Günlük	250
4	17.07.2019-13.07.2020	Günlük	250
5	09.03.2016-08.03.2017	Günlük	250
6	12.03.2019-05.03.2021	Günlük	500
7	12.03.2015-07.03.2017	Günlük	500
8	21.08.2016-16.08.2018	Günlük	500
9	13.04.2015-04.04.2017	Günlük	500
10	30.07.2015-24.07.2017	Günlük	500

Şekil 4.6. ve zaman serisi otokorelasyonları incelendiğinde, mevsimsel bileşen içermediği gözlemlenen bu seriler, önerilen yöntem SRNN-SES-PSO ve SRNN-SES-SCO ile çözümlenmiş ve elde edilen analiz sonuçlar literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablolar 4.63.-4.72.'de verilmiştir.

Tablo 4.63. Altın Seri 1 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	0,0079	0,0079	0,0007	0,0008	0,0069	0,0101	5	-	1
SMN	0,0081	0,0074	0,0010	0,0022	0,0074	0,0096	2	-	-
PS-ANN	0,0093	0,0089	0,0017	0,0019	0,0070	0,0147	5	-	2
DNM-ANN	0,0090	0,0080	0,0025	0,0017	0,0071	0,0180	5	-	1
GRU-ANN	0,0115	0,0110	0,0026	0,0026	0,0089	0,0229	4	1	2
LSTM-ANN	0,0234	0,0166	0,0217	0,0079	0,0101	0,0876	5	2	2
SRNN	0,0100	0,0100	0,0003	0,0003	0,0092	0,0107	5	1	1
SRNN-SES-SCO	0,0078	0,0079	0,0001	0,0002	0,0077	0,0079	2	5	1
SRNN-SES-PSO	0,0077	0,0077	0,0000	0,0000	0,0077	0,0079	2	4	1



Şekil 4.6. Rastgele elde edilen 10 adet altın veri setine ait zaman serisi grafikleri

Tablo 4.64. Altın Seri 2 seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0131	0,0126	0,0126	0,0018	0,0108	0,0173	3	-	1
SMN	0,0133	0,0117	0,0117	0,0041	0,0117	0,0157	2	-	-
PS-ANN	0,0117	0,0117	0,0117	0,0004	0,0109	0,0128	5	-	1
DNM-ANN	0,0150	0,0147	0,0147	0,0030	0,0125	0,0201	4	-	2
GRU-ANN	0,0178	0,0177	0,0177	0,0026	0,0133	0,0243	3	1	1
LSTM-ANN	0,0317	0,0291	0,0291	0,0137	0,0170	0,0564	5	2	2
SRNN	0,0167	0,0166	0,0166	0,0004	0,0160	0,0176	4	1	2
SRNN-SES-SCO	0,0100	0,0100	0,0000	0,0000	0,0099	0,0100	3	5	2
SRNN-SES-PSO	0,0100	0,0100	0,0001	0,0001	0,0099	0,0100	4	3	1

Tablo 4.65. Altın Seri 3 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0077	0,0072	0,0026	0,0045	0,0046	0,0136	3	-	2
SMN	0,0058	0,0056	0,0003	0,0006	0,0055	0,0061	2	-	-
PS-ANN	0,0066	0,0062	0,0017	0,0024	0,0044	0,0114	4	-	2
DNM-ANN	0,0060	0,0057	0,0012	0,0019	0,0044	0,0088	3	-	2
GRU-ANN	0,0092	0,0078	0,0039	0,0047	0,0052	0,0191	4	3	1
LSTM-ANN	0,0073	0,0069	0,0017	0,0026	0,0050	0,0111	3	1	2
SRNN	0,0068	0,0065	0,0011	0,0009	0,0054	0,0102	3	1	2
SRNN-SES-SCO	0,0057	0,0057	0,0001	0,0001	0,0054	0,0058	2	3	2
SRNN-SES-PSO	0,0057	0,0057	0,0000	0,0000	0,0057	0,0057	3	4	1

Tablo 4.66. Altın Seri 4 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0397	0,0394	0,0018	0,0018	0,0360	0,0447	5	-	1
SMN	0,0397	0,0407	0,0011	0,0021	0,0384	0,0407	2	-	-
PS-ANN	0,0378	0,0375	0,0017	0,0016	0,0347	0,0423	5	-	2
DNM-ANN	0,0401	0,0405	0,0017	0,0031	0,0366	0,0432	5	-	2
GRU-ANN	0,0653	0,0578	0,0338	0,0391	0,0215	0,1332	4	4	2
LSTM-ANN	0,0340	0,0334	0,0036	0,0058	0,0286	0,0409	3	1	1
SRNN	0,0396	0,0325	0,0247	0,0023	0,0266	0,1289	2	3	2
SRNN-SES-SCO	0,0066	0,0066	0,0000	0,0000	0,0066	0,0066	2	1	1
SRNN-SES-PSO	0,0066	0,0066	0,0000	0,0000	0,0066	0,0066	5	1	1

Tablo 4.67. Altın Seri 5 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0073	0,0071	0,0005	0,0007	0,0067	0,0089	4	-	2
SMN	0,0101	0,0105	0,0038	0,0072	0,0064	0,0160	5	-	-
PS-ANN	0,0074	0,0071	0,0008	0,0011	0,0064	0,0094	5	-	2
DNM-ANN	0,0077	0,0072	0,0012	0,0012	0,0065	0,0120	4	-	2
GRU-ANN	0,0217	0,0165	0,0123	0,0116	0,0110	0,0550	2	3	2
LSTM-ANN	0,0117	0,0116	0,0011	0,0013	0,0103	0,0160	3	1	1
SRNN	0,0102	0,0102	0,0002	0,0003	0,0096	0,0106	5	1	2
SRNN-SES-SCO	0,0062	0,0062	0,0001	0,0000	0,0062	0,0066	2	4	1
SRNN-SES-PSO	0,0062	0,0062	0,0000	0,0000	0,0062	0,0062	4	3	1

Tablo 4.68. Altın Seri 6 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0073	0,0071	0,0005	0,0007	0,0067	0,0089	4	-	2
SMN	0,0101	0,0105	0,0038	0,0072	0,0064	0,0160	5	-	-
PS-ANN	0,0074	0,0071	0,0008	0,0011	0,0064	0,0094	5	-	2
DNM-ANN	0,0077	0,0072	0,0012	0,0012	0,0065	0,0120	4	-	2
GRU-ANN	0,0217	0,0165	0,0123	0,0116	0,0110	0,0550	2	3	2
LSTM-ANN	0,0117	0,0116	0,0011	0,0013	0,0103	0,0160	3	1	1
SRNN	0,0102	0,0102	0,0002	0,0003	0,0096	0,0106	5	1	2
SRNN-SES-SCO	0,0116	0,0116	0,0000	0,0000	0,0116	0,0116	3	2	2
SRNN-SES-PSO	0,0116	0,0116	0,0000	0,0000	0,0116	0,0116	3	4	2

Tablo 4.69. Altın Seri 7 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0097	0,0096	0,0006	0,0010	0,0084	0,0112	4	-	2
SMN	0,0123	0,0116	0,0027	0,0028	0,0082	0,0166	4	-	-
PS-ANN	0,0084	0,0084	0,0002	0,0002	0,0082	0,0090	5	-	1
DNM-ANN	0,0092	0,0092	0,0009	0,0012	0,0073	0,0108	2	-	2
GRU-ANN	0,0114	0,0111	0,0008	0,0011	0,0099	0,0137	2	1	2
LSTM-ANN	0,0200	0,0175	0,0088	0,0037	0,0135	0,0557	2	3	1
SRNN	0,0126	0,0115	0,0037	0,0017	0,0100	0,0245	5	3	2
SRNN-SES-SCO	0,0068	0,0068	0,0000	0,0000	0,0068	0,0068	2	4	2
SRNN-SES-PSO	0,0068	0,0068	0,0000	0,0000	0,0067	0,0068	5	4	1

Tablo 4.70. Altın Seri 8 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0060	0,0058	0,0005	0,0003	0,0054	0,0079	3	-	2
SMN	0,0089	0,0073	0,0031	0,0032	0,0055	0,0147	5	-	-
PS-ANN	0,0056	0,0056	0,0001	0,0002	0,0054	0,0060	4	-	1
DNM-ANN	0,0057	0,0056	0,0003	0,0003	0,0050	0,0066	2	-	2
GRU-ANN	0,0128	0,0106	0,0055	0,0074	0,0072	0,0317	2	4	1
LSTM-ANN	0,0081	0,0080	0,0009	0,0008	0,0068	0,0115	4	1	2
SRNN	0,0071	0,0071	0,0001	0,0001	0,0069	0,0075	5	3	1
SRNN-SES-SCO	0,0055	0,0055	0,0001	0,0001	0,0054	0,0058	2	4	1
SRNN-SES-PSO	0,0057	0,0057	0,0000	0,0000	0,0057	0,0057	4	3	2

Tablo 4.71. Altın Seri 9 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0093	0,0090	0,0013	0,0020	0,0073	0,0119	3	-	2
SMN	0,0117	0,0109	0,0033	0,0074	0,0079	0,0166	4	-	-
PS-ANN	0,0083	0,0083	0,0004	0,0004	0,0075	0,0094	3	-	2
DNM-ANN	0,0088	0,0091	0,0011	0,0011	0,0065	0,0104	2	-	2
GRU-ANN	0,0136	0,0135	0,0023	0,0034	0,0100	0,0180	2	3	1
LSTM-ANN	0,0132	0,0132	0,0013	0,0019	0,0116	0,0159	4	1	2
SRNN	0,0118	0,0111	0,0040	0,0020	0,0095	0,0322	5	3	2
SRNN-SES-SCO	0,0063	0,0062	0,0001	0,0000	0,0062	0,0068	5	4	2
SRNN-SES-PSO	0,0063	0,0063	0,0000	0,0000	0,0062	0,0063	5	5	1

Tablo 4.72. Altın Seri 10 için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	0,0086	0,0086	0,0007	0,0011	0,0074	0,0103	3	-	2
SMN	0,0110	0,0120	0,0024	0,0041	0,0076	0,0143	4	-	-
PS-ANN	0,0086	0,0084	0,0008	0,0013	0,0071	0,0106	4	-	2
DNM-ANN	0,0081	0,0082	0,0007	0,0008	0,0066	0,0097	2	-	2
GRU-ANN	0,0109	0,0108	0,0012	0,0018	0,0089	0,0142	2	2	1
LSTM-ANN	0,0189	0,0182	0,0046	0,0054	0,0115	0,0298	5	3	1
SRNN	0,0111	0,0095	0,0061	0,0013	0,0083	0,0336	4	3	2
SRNN-SES-SCO	0,0065	0,0065	0,0000	0,0000	0,0065	0,0065	2	1	1
SRNN-SES-PSO	0,0065	0,0065	0,0000	0,0000	0,0065	0,0065	4	4	1

Tablolar 4.63.-4.72.'de verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, ortalama istatistiğine göre SRNN-SES-SCO ve SRNN-SES-PSO'nun öngörü performansı açısından 10 verinin 9'unda daha düşük RMSE değerine sahip olmasıyla %90 başarılı olduğu gözlemlenmiştir. Tüm istatistikler incelendiğinde, 4-10 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun tüm istatistiklerde en iyi yöntem olduğu sonucuna varılmıştır.

Ortalama istatistiği incelendiğinde, 2-3-5-7-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 1 numaralı veri setinde SRNN-SES-PSO'nun en iyi yöntem olduğu, 8 numaralı veri setinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 6 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun altıncı en iyi yöntem olduğu gözlemlenmiştir.

Medyan istatistiği incelendiğinde, 2-5-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 8-9 numaralı veri setlerinde SRNN-SES-SCO'nun en iyi yöntem olduğu, 1 numaralı veri setinde SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu, SRNN-SES-SCO'nun üçüncü en iyi yöntem olduğu, 3-6 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun ikinci en iyi yöntem olduğu gözlemlenmiştir.

Standart sapma istatistiği incelendiğinde, 6-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 1-3-5-8-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 2 numaralı veri setinde SRNN-SES-SCO'nun en iyi yöntem olduğu gözlemlenmiştir.

Çeyrekler arası fark istatistiği incelendiğinde, 5-6-7-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 1-3-8 numaralı veri setlerinde SRNN-SES-PSO'nun ve 2 numaralı veri setinde SRNN-SES-SCO'nun en iyi yöntem olduğu gözlemlenmiştir.

Minimum istatistiği incelendiğinde, 2-5-9 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 7 numaralı veri setinde SRNN-SES-

PSO'nun en iyi yöntem olduğu, 1 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun beşinci en iyi yöntem olduğu, 3 numaralı veri setinde SRNN-SES-SCO'nun beşinci en iyi yöntem olduğu, SRNN-SES-PSO'nun yedinci en iyi yöntem olduğu, 6 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun yedinci en iyi yöntem olduğu ve 8 numaralı veri setinde SRNN-SES-SCO'nun ikinci en iyi yöntem olduğu, SRNN-SES-PSO'nun dördüncü en iyi yöntem olduğu gözlemlenmiştir.

Maksimum istatistiği incelendiğinde, 1-2-7 numaralı veri setlerinde SRNN-SES-SCO ve SRNN-SES-PSO'nun en iyi yöntem olduğu, 3-5-8-9 numaralı veri setlerinde SRNN-SES-PSO'nun en iyi yöntem olduğu ve 6 numaralı veri setinde SRNN-SES-SCO ve SRNN-SES-PSO'nun dördüncü en iyi yöntem olduğu gözlemlenmiştir.

Önerilen yöntemlerden elde edilen ortalama istatistikleri ve klasik bir öngörü yöntemi olan Naive yöntemden elde edilen sonuçlar Tablo 4.73.'te verilmiştir.

Tablo 4.73. Altın Serileri için ortalama istatistiğine göre önerilen yöntemlerden ve Naive yöntemden elde edilen sonuçlar

Seri No	SRNN-SES-SCO	SRNN-SES-PSO	NAİVE
1	0,0078	0,0077	0,0079
2	0,0100	0,0100	0,0100
3	0,0057	0,0057	0,0058
4	0,0066	0,0066	0,0066
5	0,0062	0,0062	0,0062
6	0,0116	0,0116	0,0116
7	0,0068	0,0068	0,0068
8	0,0055	0,0057	0,0055
9	0,0063	0,0063	0,0062
10	0,0065	0,0065	0,0065


Analiz sonuçları incelendiğinde, önerilen yöntemlerin 1-3 numaralı veri setlerinde Naive yöntemden daha iyi olduğu sonucuna varılmıştır. Tablo 4.73. incelendiğinde, analiz sonuçlarının ya Naive yöntemle oldukça yakın ya da Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

4.2. Mevsimsel Bileşen İçeren Zaman Serileri İçin Çözümleme

Mevsimsel bileşen içeren zaman serileri için SRNN-SES-S ve alternatif yöntemler için gizli tabaka sayısı 1 – 2 arasında birer arttırılarak ve gizli tabaka birim sayısı 1 – s arasında birer arttırılarak değiştirilmiştir. Burada s mevsimsel periyodu ifade etmektedir. Her bir yöntem rasgele başlangıç ağırlıkları kullanılarak 30 kez uygulanmıştır. Test ve geçerlilik veri setlerinin uzunlukları veri setlerinin boyutlarına göre farklılık göstermiştir. Test ve geçerlilik veri setlerinin uzunlukları BJ, AHK, ABT ve TET veri setleri için 12 olarak belirlenmiştir. BJ, AHK ve TET serileri aylık olduğundan test ve geçerlilik veri setleri bir yılı içerecek şekilde 12 olarak alınmıştır. ABT serisi ise çeyreklik olduğu için üç yılı kapsayacak şekilde test ve geçerlilik veri setleri veri setinin boyutunun da yeterli olması nedeniyle benzer şekilde 12 olarak alınmıştır. Test seti öngörü performansı, RMSE değeri kullanılarak hesaplanmıştır.

4.2.1. Box&Jenkins havayolu yolcuları veri seti için çözümleme

Box&Jenkins havayolu yolcuları (BJ), Ocak 1949-Kasım 1959 tarihleri arasında aylık olarak gözlemlenen uluslararası havayolu yolcularını içeren, klasik Box&Jenkins hava yolu veri seti olan ve toplamda 144 gözlemden oluşan mevsimsel bir veri setidir. Veri setine ait grafik Şekil 4.7.'de verilmiştir.



Şekil 4.7. BJ veri setine ait zaman serisi grafiği

Mevsimsel bileşen içeren bu zaman serisinin mevsimsel farkı alınarak, önerilen yöntem SRNN-SES-S ile çözümlenmiş ve elde edilen sonuçlar literatürde mevcut

birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablo 4.74.'te verilmiştir.


Tablo 4.74. BJ veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	20,9182	20,7875	0,7289	0,8538	19,9175	22,8086	12	-	1
SMN	21,1931	21,1508	0,3629	0,4575	20,2250	21,9134	11	-	-
PS-ANN	22,7148	22,2608	1,9853	2,8130	20,0405	28,4872	10	-	2
DNM-ANN	22,6195	22,6022	0,4416	0,0077	21,7119	23,8625	9	-	2
GRU-ANN	22,4521	22,5704	0,5158	0,3496	21,3407	23,5071	10	2	1
LSTM-ANN	22,7667	22,8113	0,7129	0,3201	21,6183	25,6507	3	1	1
SRNN	22,9684	22,8710	1,3461	0,7031	20,9343	27,1464	3	1	2
SRNN-SES-S-SCO	23,7852	23,5216	1,5571	2,4318	22,1082	28,0843	12	12	2
SRNN-SES-S-PSO	22,3589	22,4052	0,8865	0,5105	20,2367	24,8266	9	8	2

Tablo 4.74.'te verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, BJ veri setinde SRNN-SES-S-SCO'nun, ortalama, medyan ve minimum istatistiklerinde sonuncu sırada, standart sapma, çeyrekler arası fark ve maksimum istatistiklerinde sekizinci sırada yer aldığı gözlemlenmiştir. SRNN yönteminden daha iyi sonuç verdiği gözlemlenen SRNN-SES-S-PSO'nun analiz sonuçlarına bakıldığında ise ortalama istatistiğinde üçüncü, medyan ve minimum istatistiklerinde dördüncü, çeyrekler arası fark ve maksimum istatistiklerinde beşinci sırada yer aldığı gözlemlenirken standart sapma istatistiğinde altıncı sırada yer aldığı gözlemlenmiştir.

4.2.2. Ankara hava kirliliği veri seti için çözümleme

Ankara hava kirliliği (AHK), Mart 1994-Nisan 2005 tarihleri arasında aylık olarak gözlemlenen ve 134 gözlemde oluşan mevsimsel bir veri setidir. Veri setine ait grafik Şekil 4.8.'de verilmiştir.



Şekil 4.8. AHK veri setine ait zaman serisi grafiği

Mevsimsel bileşen içeren bu zaman serisi, önerilen yöntem SRNN-SES-S ile çözümlenmiş ve elde edilen sonuçlar literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablo 4.75.'te verilmiştir.

Tablo 4.75. AHK veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri


Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	5,7341	5,6440	0,5162	0,4773	5,1565	7,8135	12	-	2
SMN	6,3301	6,3921	0,1561	0,1454	5,9265	6,5628	9	-	-
PS-ANN	6,2509	6,2155	0,2163	0,0797	6,0712	7,3316	6	-	2
DNM-ANN	6,5088	6,5594	0,4096	0,1637	5,4293	7,2756	12	-	2
GRU-ANN	6,6497	6,5556	0,6081	0,8421	5,6491	8,1406	11	1	2
LSTM-ANN	6,7307	6,7271	0,2115	0,2384	6,2396	7,3477	10	1	2
SRNN	6,7112	6,7477	0,1087	0,2084	6,5482	6,9415	6	1	1
SRNN-SES-S-SCO	6,2447	6,1027	0,7184	0,7079	5,1818	8,5323	4	8	1
SRNN-SES-S-PSO	9,2615	8,6772	3,4380	3,3306	4,9901	22,3387	11	8	2

Tablo 4.75.'te verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, AHK veri setinde SRNN-SES-S-SCO'nun ortalama, medyan ve minimum istatistiklerinde, SRNN yönteminden daha iyi sonuç verdiği gözlemlenmiştir. SRNN-SES-S-SCO'nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında, ortalama ve medyan istatistiklerinde ikinci sırada, minimum

istatistiğinde üçüncü sırada, çeyrekler arası fark istatistiğinde yedinci sırada, standart sapma ve maksimum istatistiklerinde ise sekizinci sırada yer aldığı gözlemlenmiştir. SRNN-SES-S-PSO'nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında ise minimum istatistiğinde, en iyi yöntem olduğu gözlemlenirken, ortalama, medyan, standart sapma, çeyrekler arası fark ve maksimum istatistiklerinde ise sonuncu sırada yer aldığı gözlemlenmiştir.

4.2.3. Türkiye elektrik tüketimi veri seti için çözümleme

Ocak 2002-Aralık 2012 tarihleri arasında aylık olarak gözlemlenen ve 144 gözlemden oluşan mevsimsel bir veri seti olan Türkiye elektrik tüketimi (TET)'ne ait grafik Şekil 4.9.'da verilmiştir.



Şekil 4.9. TET veri setine ait zaman serisi grafiği

Mevsimsel bileşen içeren bu zaman serisi, önerilen yöntem SRNN-SES-S ile çözümlenmiş ve elde edilen analiz sonuçları, literatürde mevcut birçok yöntemden elde edilen sonuçlarla karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablo 4.76.'da verilmiştir.


Tablo 4.76. TET veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	<i>p</i>	<i>h</i>	<i>m</i>
MLP	722966159,2	715471182,1	40912920,6	55570645,8	676220654,5	843059964,3	11	-	1
SMN	611510204,4	593571066,5	62880165,2	1761696,7	563137516,9	803268262,5	4	-	-
PS-ANN	611778863,5	611425775,4	26973159,4	38071729,7	550952536,4	658152900,6	11	-	1
DNM-ANN	759128097,1	849193831,9	179915789,7	327726354,3	464325628,1	927360036,3	12	-	1
GRU-ANN	761003940,4	744860772,6	126077746,6	172559022,7	602238532,7	1078961716,1	11	1	2
LSTM-ANN	717190021,8	705633861,8	76020561,2	111431503,1	583829733,2	907710267,9	12	1	1
SRNN	839118839,9	831565477,8	112126907,5	150632124,9	683440001,5	1111302055,9	12	2	2
SRNN-SES-S-SCO	606475844,1	590911222,7	62301211,7	29820202,0	544038133,2	869270029,7	11	9	1
SRNN-SES-S-PSO	652138282,1	617221643,9	118795439,3	67097915,3	552260234,7	1043960961,8	2	5	1

Tablo 4.76.'da verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde TET veri setinde, SRNN-SES-S-SCO ve SRNN-SES-S-PSO'nun ortalama, medyan, çeyrekler arası fark, minimum ve maksimum istatistiklerinde, SRNN yönteminden daha iyi olduğu sonucuna varılırken, standart sapma istatistiğinde ise SRNN-SES-S-SCO'nun daha iyi olduğu sonucuna varılmıştır. SRNN-SES-S-SCO'nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında, çeyrekler arası fark ve minimum istatistiklerinde ikinci sırada, standart sapma istatistiğinde üçüncü sırada ve maksimum istatistiğinde ise dördüncü sırada yer aldığı gözlemlenmiştir. SRNN-SES-S-PSO'nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında ise ortalama, medyan ve minimum istatistiklerinde dördüncü sırada, çeyrekler arası fark istatistiğinde beşinci sırada, standart sapma ve maksimum istatistiklerinde ise yedinci sırada yer aldığı gözlemlenmiştir.

4.2.4. Avustralya bira tüketimi veri seti için çözümleme

Avustralya bira tüketimi (ABT), 1956-1994 yılları arasında çeyreklik olarak gözlemlenen ve 148 gözlemden oluşan mevsimsel bir veri setidir. Veri setine ait grafik Şekil 4.10.'da verilmiştir.



Şekil 4.10. ABT veri setine ait zaman serisi grafiği

Mevsimsel bileşen içeren bu zaman serisi, önerilen yöntem SRNN-SES-S ile çözümlenmiş ve elde edilen analiz sonuçları, literatürde mevcut birçok yöntemden elde edilen analiz sonuçları ile karşılaştırılmıştır. Elde edilen analiz sonuçları ve en iyi hiper parametre değerleri Tablo 4.77.’de verilmiştir.

Tablo 4.77. ABT veri seti için tüm yöntemlerden elde edilen analiz sonuçları ve en iyi hiper parametre değerleri

Yöntemler	Ortalama	Medyan	Standart Sapma	Çeyrekler Arası Fark	Minimum	Maksimum	p	h	m
MLP	20,0386	19,8473	0,8173	0,9355	18,8896	20,0386	4	-	2
SMN	22,3418	22,4517	0,3091	0,0640	21,1469	22,3418	4	-	-
PS-ANN	20,4217	20,4182	0,0238	0,0256	20,3835	20,4217	4	-	1
DNM-ANN	19,5453	19,4517	1,0031	1,1608	17,9208	19,5453	4	-	2
GRU-ANN	23,4962	23,7666	2,8018	5,2688	16,7949	23,4962	2	3	2
LSTM-ANN	19,9611	19,7616	1,1261	1,4604	18,1943	19,9611	4	1	1
SRNN	24,9891	26,8736	3,5225	0,2213	17,5292	24,9891	4	3	2
SRNN-SES-S-SCO	23,5682	23,5130	1,2640	1,9098	20,2913	23,5682	4	1	2
SRNN-SES-S-PSO	21,7456	22,0939	3,2657	3,7882	14,9976	21,7456	2	4	2

Tablo 4.77.’de verilen RMSE değerlerine göre elde edilen istatistikler incelendiğinde, ABT veri setinde SRNN-SES-S-SCO ve SRNN-SES-S-PSO’nun ortalama, medyan, standart sapma ve maksimum istatistiklerinde SRNN yönteminden daha iyi olduğu gözlemlenmiştir. SRNN-SES-S-SCO’nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında, standart sapma istatistiğinde altıncı sırada, medyan, çeyrekler arası fark ve minimum istatistiklerinde yedinci sırada, ortalama ve

maksimum istatistiklerinde sekizinci sırada yer aldığı gözlemlenmiştir. SRNN-SES-S-PSO'nun analiz sonuçları ile diğer yöntemlerden elde edilen analiz sonuçları kıyaslandığında ise minimum istatistiğinde en iyi yöntem olduğu, ortalama ve maksimum istatistiklerinde beşinci sırada, medyan istatistiğinde beşinci sırada, standart sapma ve çeyrekler arası fark istatistiklerinde ise sekizinci sırada yer aldığı gözlemlenmiştir.

Önerilen yöntemlerden ve klasik bir öngörü yöntemi olan S-Naive yöntemden elde edilen ortalama istatistikleri Tablo 4.78.'de verilmiştir.

Tablo 4.78. Mevsimsel bileşen içeren seriler için ortalama istatistiğine göre önerilen yöntemlerden ve S-Naive yöntemden elde edilen sonuçlar

Seri Adı	SRNN-SES-S-SCO	SRNN-SES-S-PSO	S-NAİVE
BJ	23,7852	22,3589	23,2887
AHK	6,2447	9,2615	6,8069
TET	606475844,1	652138282,1	685208038,8
ABT	23,5682	21,7456	22,0859

Sonuçlar incelendiğinde, önerilen yöntemlerin TET veri setinde S-Naive yöntemden daha iyi olduğu sonucuna varılmıştır. Tablo 4.78. incelendiğinde, analiz sonuçlarının ya S-Naive yöntemine oldukça yakın ya da S-Naive yöntemden daha iyi olduğu sonucuna varılmıştır.

BÖLÜM 5. TARTIŞMA VE SONUÇ

Günümüzde en popüler makine öğrenme yöntemlerinden biri derin yapay sinir ağları olarak bilinmektedir. Farklı birçok derin yapay sinir ağı, son yıllarda özellikle zaman serisi öngörü problemlerinde sıklıkla kullanılmakta ve başarılı öngörü performansı gösterebilmektedir. Diğer yandan zaman serilerinin öngörü probleminde klasik öngörü yaklaşımları da kullanılmakta ve başarılı öngörü performansı gösterebilmektedir. Öngörü problemlerinin çözümünde klasik öngörü yöntemleri ve yapay sinir ağı yöntemleri ayrı ayrı tercih edilebilmektedir. Derin yapay sinir ağları ve klasik öngörü yöntemlerinin birlikte kullanılarak ortaya konacak yeni bir ağ yapısının, derin yapay sinir ağlarının öngörü performansını arttıracakı düşünülmektedir. Bu amaçla, bu tez kapsamında SRNN ve SES yöntemlerinin birleşiminden oluşan SRNN-SES ve SRNN-SES-S hibrit modelleri önerilmiştir. Önerilen bu modellerden biri (SRNN-SES-S) mevsimsel bileşen içeren zaman serileri için tasarlanırken diğeri (SRNN-SES) mevsimsel bileşen içermeyen zaman serileri için tasarlanmıştır. Önerilen bu iki yöntemin eğitiminde farklı iki sezgisel optimizasyon algoritması olan PSO ve SCO algoritmaları kullanılmıştır. Kullanılan bu algoritmalarda, aşırı uyum ve yerel optimum problemlerine engel olabilmek amacıyla yeniden başlatma ve erken durdurma çözüm stratejileri geliştirilmiştir.

Önerilen SRNN-SES ve SRNN-SES-S yöntemlerden elde edilen analiz sonuçları, literatürde mevcut yedi farklı yapay sinir ağı yöntemleri ile klasik öngörü yöntemi olan Naive ve S-Naive yöntemlerinden elde edilen sonuçlarla karşılaştırılmıştır. Karşılaştırma işlemi bir hata kriteri olan RMSE değerinin ortalama, medyan, standart sapma, çeyrekler arası fark, minimum ve maksimum istatistikleri ile gerçekleştirilmiştir.

Mevsimsel bileşen içermeyen zaman serileri, yapay sinir ağları yöntemleri ile karşılaştırıldığında, önerilen SRNN-SES yönteminin öngörü performansının %90 başarı yüzdesine sahip olduğu gözlemlenmiştir. SRNN-SES yöntemi, klasik bir öngörü yöntemi olan Naive yöntem ile karşılaştırıldığında ise her iki yöntemin benzer sonuçlar verdiği gözlemlenmiştir. Mevsimsel bileşen içeren zaman serileri, yapay sinir ağları yöntemleri ile karşılaştırıldığında, önerilen yöntemin mevsimsel serilerde oldukça başarılı sonuçlar ürettiği görülmektedir. Genel olarak önerilen yöntemlerin SRNN yöntemine göre oldukça başarılı öngörü sonuçlarının elde edilebildiği görülmüştür. Gelecek çalışmalarda önerilen yöntemin performansını artırılması için farklı üstel düzeltirme yöntemi ile yeni mimarilerin oluşturulması planlanmaktadır. Ayrıca LSTM-ANN gibi farklı derin yapay sinir ağları ile üstel düzeltirme yöntemlerinin melezlendiği yeni mimari yapıların önerilmesi de bir başka gelecek çalışması olarak planlanmaktadır.

KAYNAKLAR

- [1] Kennedy, J., & Eberhart, R., Particle swarm optimization. In Proceedings of IEEE International Conference on Neural Networks, 4, 1942-1948, 1995.
- [2] Hochreiter, S., & Schmidhuber, J., Long short-term memory. Neural computation, 9(8), 1735-1780, 1997.
- [3] Cho, K., Van Merriënboer, B., Bahdanau, D., & Bengio, Y., On the properties of neural machine translation: Encoder-decoder approaches. arXiv preprint arXiv:1409.1259, 2014.
- [4] Mirjalili, S., SCA: a sine cosine algorithm for solving optimization problems. Knowl.-Based Syst., 96, 120-133, 2016.
- [5] Krtek, J., & Vosvrda, M., Comparing Neural Networks and ARMA Models in Artificial Stock Market. Bulletin of the Czech Econom. Soc., 18(28), 2011.
- [6] Abdulkarim, S. A., Time series prediction with simple recurrent neural networks. Bayero J. Pure Appl. Sci., 9(1), 19-24, 2016.
- [7] Wang J., Wang J., Fang W., & Niu H., Financial time series prediction using elman recurrent random neural networks. Comput. Intell. Neurosci., 2016.
- [8] Edet S., Recurrent neural networks in forecasting S&P 500 index. Available at SSRN 3001046, 2017.
- [9] Samarawickrama, A. J. P., & Fernando, T. G. I., A recurrent neural network approach in predicting daily stock prices an application to the Sri Lankan stock market. In 2017 IEEE International Conference on Industrial and Information Systems (ICIIS), (pp. 1-6). IEEE, 2017.
- [10] Ranjit, S., Shrestha, S., Subedi, S., & Shakya, S., Comparison of algorithms in foreign exchange rate prediction. In 2018 IEEE 3rd International Conference on Computing, Communication and Security (ICCCS), (pp. 9-13). IEEE, 2018.
- [11] Samarawickrama, A. J. P., & Fernando, T. G. I., Multi-step-ahead prediction of exchange rates using artificial neural networks: A study on selected sri

- lankan foreign exchange rates. In 2019 14th Conference on Industrial and Information Systems (ICIIS), (pp. 488-493). IEEE, 2019.
- [12] Aggarwal, P., & Sahani, A. K., Comparison of neural networks for foreign exchange rate prediction. In 2020 IEEE 15th International Conference on Industrial and Information Systems (ICIIS), (pp. 415-419). IEEE, 2020.
 - [13] Dutta, A., Kumar, S., Basu, & M., A gated recurrent unit approach to bitcoin price prediction. *Journal of Risk and Financial Management*, 13(2), 23, 2020.
 - [14] Vaheb H., Asset Price Forecasting using Recurrent Neural Networks. arXiv:2010.06417, 2020.
 - [15] Berradi, Z., Lazaar, M., Omara, H., & Mahboub, O., Effect of architecture in recurrent neural network applied on the prediction of stock price. *IAENG Int. J. Comput. Sci.*, 47(3), 436-441, 2020.
 - [16] Fan, M. H., Chen, M. Y., & Liao, E. C., A deep learning approach for financial market prediction: Utilization of Google trends and keywords. *Granul. Comput.*, 6(1), 207-216, 2021.
 - [17] Bas, E., Egrioglu, E., & Kolemen, E., Training simple recurrent deep artificial neural network for forecasting using particle swarm optimization. *Granul. Comput.*, 7(2), 411-420, 2021.
 - [18] Zaychenko, Y., Hamidov, G., & Gasanov, A., Investigation of computational intelligence methods in forecasting problems at stock exchanges. *Syst. Res. Inf. Tech.*, (2), 35-49, 2021.
 - [19] Bas, E., Egrioglu, E., & Kolemen, E., Training simple recurrent deep artificial neural network for forecasting using particle swarm optimization. *Granul. Comput.*, 7(2), 411-420, 2022.
 - [20] Jovanovic, L., Milutinovic, N., Gajevic, M., Krstovic, J., Rashid, T. A., & Petrovic, A., Sine cosine algorithm for simple recurrent neural network tuning for stock market prediction. In 2022 30th Telecommunications Forum (TELFOR), (pp. 1-4), IEEE, 2022.
 - [21] Mendoza, C., Kristjanpoller, W., & Minutolo, M. C., Market index price prediction using Deep Neural Networks with a Self-Similarity approach. *Appl. Soft Comput.*, 146, 110700, 2023.
 - [22] Almosova, A., & Andresen, N., Nonlinear inflation forecasting with recurrent neural networks. *J. Forecast.*, 42(2), 240-259, 2023.

- [23] Song, H., & Choi, H., Forecasting stock market indices using the recurrent neural network based hybrid models: Cnn-lstm, gru-cnn, and ensemble models. *Appl. Sci.*, 13(7), 4644, 2023.
- [24] Barkan, O., Benchimol, J., Caspi, I., Cohen, E., Hammer, A., & Koenigstein, N., Forecasting CPI inflation components with hierarchical recurrent neural networks. *Int. J. Forecast.*, 39(3), 1145-1162, 2023.
- [25] Vanguri, N. Y., Pazhanirajan, S., & Kumar, T. A., Competitive feedback particle swarm optimization enabled deep recurrent neural network with technical indicators for forecasting stock trends. *Int. J. Intell. Robot. Appl.*, 7(2), 385-405, 2023.
- [26] Cansu, T., Kolemen, E., Karahasan, Ö., Bas, E., & Egrioglu, E., A new training algorithm for long short-term memory artificial neural network based on particle swarm optimization. *Granul. Comput.*, 8(6), 1645-1658, 2023.
- [27] Taneja, A., Gulati, Y., Chugh, T., Joshi, P., & Thakur, N., Heart Audio Classification Using Deep Learning. In 2020 19th IEEE International Conference on Machine Learning and Applications (ICMLA), (pp. 485-488). IEEE, 2020.
- [28] Zeroual A., Harrou F., Dairi A., & Sun Y., Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. *Chaos Solit. amp; Fractals*, 140: 110121, 2020.
- [29] Qiu, X., White, J., & Schmidt, D. C., A Study of Machine Learning Models for Personalized Heart Rate Forecasting in Mountain Biking. In *icSPORTS* (pp. 87-94). (2021).
- [30] ArunKumar, K. E., Kalaga, D. V., Kumar, C. M. S., Kawaji, M., & Brenza, T. M., Forecasting of COVID-19 using deep layer recurrent neural networks (RNNs) with gated recurrent units (GRUs) and long short-term memory (LSTM) cells. *Chaos Solit. amp; Fractals*, 146, 110861, 2021.
- [31] Amole, A. O., Oladipo, S., Ighravwe, D., Makinde, K. A., & Ajibola, J., Comparative Analysis of Deep Learning Techniques Based COVID-19 Impact Assessment on Electricity Consumption in Distribution Network. *Niger. J. Technol. Dev.*, 20(3), 2023.
- [32] Hallez, Q., Mermillod, M., & Droit-Volet, S., Cognitive and plastic recurrent neural network clock model for the judgment of time and its variations. *Sci. Rep.*, 13(1), 3852, 2023.

- [33] Su, Y. C., Lin, T. H., Cheng, F. T., & Wu, W. M., Accuracy and real-time considerations for implementing various virtual metrology algorithms. *IEEE Trans. Semicond. Manuf.*, 21(3), 426-434, 2008.
- [34] Garcia, J., Levy, A., Tung, A., Yang, R. M., & Kaynig, F. V., Applying deep learning to petroleum well data. Harvard University, Harv. John A Paulson Sch. Eng. Appl. Sci., 1-9, 2018.
- [35] Ribeiro, A. M. N., do Carmo, P. R. X., Rodrigues, I. R., Sadok, D., Lynn, T., & Endo, P. T., Short-term firm-level energy-consumption forecasting for energy-intensive manufacturing: a comparison of machine learning and deep learning models. *Algorithms*, 13(11), 274, 2020.
- [36] Brester, C., Niska, H., Cizek, R., & Kolehmainen, M., Weather-based fault prediction in electricity networks with artificial neural networks. In 2020 IEEE Congress on Evolutionary Computation (CEC), (pp. 1-8). IEEE, 2020.
- [37] Paramasivan, S. K., Deep Learning Based Recurrent Neural Networks to Enhance the Performance of Wind Energy Forecasting: A Review. *Rev. d'Intelligence Artif.*, 35(1), 1-10, 2021.
- [38] Muludi, K., Akbar, M. S., Shofiana, D. A., & Syarif, A., Sentiment Analysis Of Energy Independence Tweets Using Simple Recurrent Neural Network. *IJCCS (Indones. J. Comput. Cybern. Syst.)*, 15(4), 339-348, 2021.
- [39] Ribeiro, A. M. N., do Carmo, P. R. X., Endo, P. T., Rosati, P., & Lynn, T., Short-and Very Short-Term Firm-Level Load Forecasting for Warehouses: A Comparison of Machine Learning and Deep Learning Models. *Energies*, 15(3), 750, 2022.
- [40] Jaihuni, M., Basak, J. K., Khan, F., Okyere, F. G., Sihalath, T., Bhujel, A., ... & Kim, H. T., A novel recurrent neural network approach in forecasting short term solar irradiance. *ISA Trans.*, 121, 63-74, 2022.
- [41] Faisal, A. F., Rahman, A., Habib, M. T. M., Siddique, A. H., Hasan, M., & Khan, M. M., Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of Bangladesh. *Results Eng.*, 100365, 2022.
- [42] Rhouma, A., & Said, Y., Solar energy forecasting based on complex valued auto-encoder and recurrent neural network. *Int. J. Adv. Comput. Sci. Appl.*, 14(4), 2023.
- [43] Jankauskas, M., Serackis, A., Pomornacki, R., Šapurov, M., & Baškys, A., Short-term wind energy forecasting with advanced recurrent neural network

- models: a comparative study. In 2023 IEEE 10th Jubilee Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE), (pp. 1-5), IEEE, 2023.
- [44] Smyl, S., Dudek, G., & Pelka, P., ES-dRNN: a hybrid exponential smoothing and dilated recurrent neural network model for short-term load forecasting. *IEEE Trans. Neural Netw. Learn. Syst.*, 2023.
 - [45] Rajasekaran, U., Sriram, G. K., Malini, A., & Sharma, V., Hybrid Explainable SRNN-LSTM Architecture for Irradiance. Temp. Wind Speed Forecast., 2023.
 - [46] Alshammari, A., Generation forecasting employing Deep Recurrent Neural Network with metaheuristic feature selection methodology for Renewable energy power plants. *Sustain. Energy Technol. Assess.*, 55, 102968, 2023.
 - [47] Cao, D., Chan, M., & Ng, S., Modeling and forecasting of nanoFeCu treated sewage quality using recurrent neural network (RNN). *Computation*, 11(2), 39, 2023.
 - [48] Al-Hajj, R., Assi, A., & Fouad, M. M., A predictive evaluation of global solar radiation using recurrent neural models and weather data. In 2017 IEEE 6th International Conference on Renewable Energy Research and Applications (ICRERA), (pp. 195-199). IEEE, 2017.
 - [49] Johannesen, N. J., Kolhe, M. L., & Goodwin, M., Comparing Recurrent Neural Networks using Principal Component Analysis for Electrical Load Predictions. In 2021 6th International Conference on Smart and Sustainable Technologies (SpliTech), (pp. 1-6). IEEE, 2021.
 - [50] Gholami, H., Mohammadifar, A., Golzari, S., Kaskaoutis, D. G., & Collins, A. L., Using the Boruta algorithm and deep learning models for mapping land susceptibility to atmospheric dust emissions in Iran. *Aeolian Res.*, 50, 100682, 2021.
 - [51] Huang, Y., Han, X., & Zhao, L., Recurrent neural networks for complicated seismic dynamic response prediction of a slope system. *Eng. Geol.*, 289, 106198, 2021.
 - [52] Sadhukhan, B., Chakraborty, S., & Mukherjee, S., Investigating the relationship between earthquake occurrences and climate change using RNN-based deep learning approach. *Arab. J. Geosci.*, 15(1), 1-27, 2022.
 - [53] Waseem, K. H., Mushtaq, H., Abid, F., Abu-Mahfouz, A. M., Shaikh, A., Turan, M., & Rasheed, J., Forecasting of air quality using an optimized recurrent neural network. *Processes*, 10(10), 2117, 2022.

- [54] Sankalp, S., Rao, U. M., Patra, K. C., & Sahoo, S. N., Modeling gated recurrent unit (GRU) neural network in forecasting surface soil wetness for drought districts of Odisha. *Dev. Environ. Sci.*, 14, 217-229, 2023.
- [55] Gholami, H., Mohammadifar, A., Golzari, S., Song, Y., & Pradhan, B., Interpretability of simple RNN and GRU deep learning models used to map land susceptibility to gully erosion. *Sci. Total Environ.*, 166960, 2023.
- [56] Nketiah, E. A., Chenlong, L., Yingchuan, J., & Aram, S. A., Recurrent neural network modeling of multivariate time series and its application in temperature forecasting. *Plos one*, 18(5), e0285713, 2023.
- [57] Apaydin, H., Feizi, H., Sattari, M. T., & Colak, M. S., Shamshirband, S., Chau, K. W., Comparative analysis of recurrent neural network architectures for reservoir inflow forecasting. *Water*, 12(5), 1500, 2020.
- [58] Müller, J., Park, J., Sahu, R., Varadharajan, C., & Arora, B., Faybishenko, B., Agarwal, D., Surrogate optimization of deep neural networks for groundwater predictions. *J. Glob. Optim.*, 81(1), 203-231, 2021.
- [59] Sharma, P., Forecasting of the Reservoir in Flow with Recurrent Neural Network Architecture. In *2023 2nd International Conference on Edge Computing and Applications (ICECAA)*, (pp. 1145-1150). IEEE, 2023.
- [60] Namdari, H., Haghighi, A., & Ashrafi, S. M., Short-term urban water demand forecasting; application of 1D convolutional neural network (1D CNN) in comparison with different deep learning schemes. *Stoch Environ. Res. Risk Assess.*, 1-16, 2023.
- [61] Jhong, Y. D., Chen, C. S., Jhong, B. C., Tsai, C. H., & Yang, S. Y., Optimization of LSTM parameters for flash flood forecasting using genetic algorithm. *Water Resour. Manag.*, 1-24, 2024.
- [62] Fandango, A., & Wiegand, R. P., Towards investigation of iterative strategy for data mining of short-term traffic flow with recurrent neural networks. In *Proceedings of the 2nd International Conference on Information System and Data Mining*, (pp. 65-69). 2018.
- [63] Liu Y., Qin Y., Guo J., Cai C., Wang Y., & Jia L., Short-term forecasting of rail transit passenger flow based on long short-term memory neural network. In *2018 International Conference on Intelligent Rail Transportation (ICIRT)*, pp: 1-5. IEEE, 2018.

- [64] Fandango A., & Kapoor A., Investigation of Iterative and Direct Strategies with Recurrent Neural Networks for Short-Term Traffic Flow Forecasting. In *Advances in Computing and Data Sciences: Second International Conference, ICACDS*, pp:433-441, 2018.
- [65] Diunugala, H. P., & Mombeuil, C., Modeling and predicting foreign tourist arrivals to Sri Lanka: A comparison of three different methods. *J. Tour., Herit. amp; Serv. Mark. (JTHSM)*, 6(3), 3-13, 2020.
- [66] Pereira, M., Lang, A., & Kulcsár, B., Short-term traffic prediction using physics-aware neural networks. *arXiv preprint arXiv:2109.10253*, 2021.
- [67] Nanyonga, A., Wasswa, H., Molloy, O., Turhan, U., & Wild, G., Natural Language Processing and Deep Learning Models to Classify Phase of Flight in Aviation Safety Occurrences. In *2023 IEEE Region 10 Symposium (TENSYP)*, (pp. 1-6). IEEE, 2023.
- [68] Shepelev, V., Slobodin, I., Almetova, Z., Nevolin, D., & Shvecov, A., A hybrid traffic forecasting model for urban environments based on convolutional and recurrent neural networks. *Trans. Res. Procedia*, 68, 441-446, 2023.
- [69] Lima, F. D. S., Pereira, F. L. F., Chaves, I. C., Gomes, J. P. P., & Machado, J. C., Evaluation of recurrent neural networks for hard disk drives failure prediction. In *2018 7th Brazilian Conference on Intelligent Systems (BRACIS)*, (pp. 85-90). IEEE, 2018.
- [70] Markova, V. D., & Shopov, V. K., Deep Learning Approach for Identification of Non-linear Dynamic Systems. In *2020 International Conference on Information Technologies (InfoTech)*, (pp. 1-4). IEEE, 2020.
- [71] Mersha, B. W., Jansen, D. N., & Ma, H., Angle of attack prediction using recurrent neural networks in flight conditions with faulty sensors in the case of F-16 fighter jet. *Complex amp; Intell. Syst.*, 1-13, 2021.
- [72] Hun, R., Zhang, S., Singh, G., Qian, J., Chen, Y., & Chiang, P. Y., LISA: A Transferable Light-weight Multi-Head Self-Attention Neural Network Model for Lithium-Ion Batteries State-of-Charge Estimation. In *2021 3rd International Conference on Smart Power & Internet Energy Systems (SPIES)*, (pp. 464-469). IEEE, 2021.
- [73] Ayodeji, A., Wang, W., Su, J., Yuan, J., & Liu, X., An empirical evaluation of attention-based multi-head models for improved turbofan engine remaining useful life prediction. *arXiv preprint arXiv:2109.01761*, 2021.

- [74] Essa, M. G., Elias, C. M., & Shehata, O. M., Comprehensive Performance Assessment of Various NN-based Side-Slip Angle Estimators (ANN-SSE). In 2021 IEEE 93rd Vehicular Technology Conference (VTC2021-Spring), (pp. 1-6). IEEE, 2021.
- [75] Rastegarpanah, A., Hathaway, J., & Stolkin, R., Vision-guided MPC for robotic path following using learned memory-augmented model. *Front. Robot. AI*, 8, 2021.
- [76] Rezaei, F., Khaliliyan, P., Rezaei, M., Karimi, P., & Ashrafxhani, B., A comparison between Recurrent Neural Networks and classical machine learning approaches In Laser induced breakdown spectroscopy. *arXiv preprint arXiv:2304.08500*, 2023.
- [77] Amemiya, A., Shlok, M., & Miyoshi, T., Application of Recurrent Neural Networks to Model Bias Correction: Idealized Experiments With the Lorenz-96 Model. *J. Adv. Model. Earth Syst.*, 15(2), e2022MS003164, 2023.
- [78] Ture, F., & Jojic, O., No Need to Pay Attention: Simple Recurrent Neural Networks Work! (for Answering" Simple" Questions). *arXiv preprint arXiv:1606.05029*, 2016.
- [79] Salehinejad, H., & Rahnamayan, S., Customer shopping pattern prediction: A recurrent neural network approach. In 2016 IEEE symposium series on computational intelligence (SSCI), (pp. 1-6). IEEE, 2016.
- [80] Smirnov, D., & Nguifo, E. M., Time series classification with recurrent neural networks. *Adv. Anal.L. Temporal Data*, 8, 2018.
- [81] Günel, K., İşman, G., & Kocakula, M., Simple recurrent neural networks for the numerical solutions of ODEs with Dirichlet boundary conditions. *Balıkesir Üniv. Fen Bilim. Enst. Derg.*, 20(3), 143-153, 2018.
- [82] Mubarak, A. A., Cao, H., Zhang, W., & Zhang, W., Visual analytics of video-clickstream data and prediction of learners' performance using deep learning models in MOOCs' courses. *Comput. Appl. Eng. Educ.*, 29(4), 710-732, 2021.
- [83] Chandra, R., Goyal, S., & Gupta, R., Evaluation of deep learning models for multi-step ahead time series prediction. *IEEE Access*, 9, 83105-83123, 2021.
- [84] Verma, T., & Dubey, S., Prediction of diseased rice plant using video processing and LSTM-simple recurrent neural network with comparative study. *Multimed.Tools Appl.*, 80(19), 29267-29298, 2021.

- [85] Kimani, M., Nderu, L., Ndirangu, D., & Tobias, M., Bidirectional Long short-term memory and Recurrent Neural Network model for speech recognition. *Sciences*, 2023.
- [86] Priyanka, S., Saravanan, P., Indragandhi, V., & Subramaniaswamy, V., Neural Collaborative Filtering-Based Hybrid Recommender System for Online Movies Recommendation. *Intell. Soft Comput. Syst. Green Energy*, 287-301, 2023.
- [87] Choi, W., & Lee, S., Performance evaluation of deep learning architectures for load and temperature forecasting under dataset size constraints and seasonality. *Energy and Build.*, 288, 113027, 2023.
- [88] Walid, M., Fajariyah, D., Hozairi, H., & Satria, B., Implementation Of Artificial Neural Network And Recurrent Neural Network Methods To Predict The Amount Of Salt Production. *NJCA (Nusantara J. Comput. Appl.)*, 8(1), 32-38, 2023.
- [89] McCulloch, W. S., & Pitts, W., A logical calculus of the ideas immanent in nervous activity. *Bull. Math. Biophys.*, 5(4), 115-133, 1943.
- [90] Rosenblatt, F., The perceptron: a probabilistic model for information storage and organization in the brain. *Psychol. Rev.*, 65(6), 386, 1958.
- [91] McClelland, J. L., Rumelhart, D. E., & PDP Research Group, *Parallel distributed processing*, (Vol. 2, pp. 20-21), Cambridge, MA: MIT press, 1986.
- [92] Yadav, R. N., Kalra, P. K., & John, J., Time series prediction with single multiplicative neuron model. *Appl. Soft Comput.*, 7(4), 1157-1163, 2007.
- [93] Shin, Y., & Ghosh, J., The pi-sigma network: An efficient higher-order neural network for pattern classification and function approximation. In *IJCNN-91-Seattle International Joint Conference on Neural Networks*, (Vol. 1, pp. 13-18). IEEE, 1991.
- [94] Todo, Y., Tamura, H., Yamashita, K., & Tang, Z., Unsupervised learnable neuron model with nonlinear interaction on dendrites. *Neural Netw.*, 60, 96-103, 2014.
- [95] Shea, K., & Nash, R., An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*, 2015.

- [96] <https://finance.yahoo.com/quote/DAX/history?period1=1420156800&period2=1640822400&interval=1d&filter=history&frequency=1d&includeAdjustedClose=true>, Erişim Tarihi: 05.10.2022.
- [97] <https://finance.yahoo.com/quote/GC%3DF/history?period1=978393600&period2=1640822400&interval=1d&filter=history&frequency=1d&includeAdjustedClose=true>, Erişim Tarihi: 05.06.2022.
- [98] <https://finance.yahoo.com/quote/BTC-USD/history?period1=1420070400&period2=1640908800&interval=1d&filter=history&frequency=1d&includeAdjustedClose=true>, Erişim Tarihi: 05.06.2022.
- [99] <https://finance.yahoo.com/quote/SI%3DF/history?period1=978393600&period2=1640822400&interval=1d&filter=history&frequency=1d&includeAdjustedClose=true>, Erişim Tarihi: 05.06.2022.
- [100] <https://finance.yahoo.com/quote/%5EIBEX/history?period1=978393600&period2=1640822400&interval=1d&filter=history&frequency=1d&includeAdjustedClose=true>, Erişim Tarihi: 05.06.2022.
- [101] <https://tr.investing.com/indices/it-mib-40-historical-data>, Erişim Tarihi: 05.06.2022.
- [102] <https://www.tuik.gov.tr/>, Erişim Tarihi: 05.06.2022.
- [103] Box and Jenkins (1976): Times Series Analysis: Forecasting and Control, p.

ÖZGEÇMİŞ

Özlem KARAHASAN ilk, orta ve lise eğitimini 2012 yılında tamamladı. 2012 yılında başladığı Karadeniz Teknik Üniversitesi Ekonometri Bölümü'nü 2016 yılında bitirdi. 2016 yılında başladığı Karadeniz Teknik Üniversitesi Ekonometri Anabilim Dalında yüksek lisans eğitimini 2019 yılında bitirdi. 2019 yılında Giresun Üniversitesi İstatistik Anabilim Dalında doktora eğitimine başladı.