



GİRESUN
ÜNİVERSİTESİ



FEN BİLİMLERİ ENSTİTÜSÜ

**ÖNGÖRÜ PROBLEMİ İÇİN EŞİK DEĞERLİ TEK
ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR
AĞLARI**

**İSTATİSTİK
ANA BİLİM DALI**

**Yüksek Lisans Tezi
Asiye Nur YILDIRIM
172116002**

2020

GİRESUN

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

**ÖNGÖRÜ PROBLEMİ İÇİN EŞİK DEĞERLİ TEK
ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR
AĞLARI**

YÜKSEK LİSANS TEZİ

Asiye Nur YILDIRIM

**Enstitü Ana Bilim Dalı : Fen Bilimleri Enstitüsü/ İstatistik Ana
Bilim Dalı**
Tez Danışmanı : Doç. Dr. Eren BAŞ

2020

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

**ÖNGÖRÜ PROBLEMİ İÇİN EŞİK DEĞERLİ TEK
ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR
AĞLARI**

YÜKSEK LİSANS TEZİ

Asiye Nur YILDIRIM

**Enstitü Ana Bilim Dalı : Fen Bilimleri Enstitüsü/ İstatistik
Ana Bilim Dalı**

**Bu tez 17/01/2020 tarihinde aşağıdaki jüri tarafından oybirliği / oyçokluğu ile
kabul edilmiştir.**

**Prof. Dr.
Vedide Rezan USLU
Jüri Başkanı**

**Doç. Dr.
Ufuk YOLCU
Üye**

**Doç. Dr.
Eren BAŞ
Üye**

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

BEYAN

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

Asiye Nur YILDIRIM

24/01/2020

TEŞEKKÜR

Tez çalışmamın araştırılmasında, yürütülmesinde ve oluşumunda bana yol gösteren, ilgi ve desteğini esirgemeyen değerli danışman hocam Doç. Dr. Eren BAŞ'a ve yüksek lisans eğitimim boyunca bilgi ve tecrübelerinden yararlandığım bütün hocalarıma şükranlarımı sunarım.

Hayatımın her aşamasında büyük emeği olan, sevgi ve hoşgörülerini esirgemeyen değerli aileme ve çalışmalarımı destekleyen arkadaşlarıma teşekkür ederim.

İÇİNDEKİLER

TEŞEKKÜR	I
İÇİNDEKİLER	II
SİMGELER VE KISALTMALAR LİSTESİ.....	III
ŞEKİLLER LİSTESİ.....	IV
TABLolar LİSTESİ.....	V
ÖZET	VI
SUMMARY	VII
1. GİRİŞ	1
2. YAPAY SİNİR AĞLARI.....	3
2.1. Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	4
2.1.1. Biyolojik Sinir Hücresi	4
2.1.2. Yapay Sinir Hücresi.....	4
2.1.3. Yapay Sinir Ağının Yapısı.....	7
3. TEK ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR AĞLARI.....	9
3.1. Eşik Değerli Tek Çarpımsal Nöron Model YSA	10
4. SEZGİSEL YÖNTEMLER.....	11
4.1. Armoni Arama Algoritması.....	11
4.2. Geliştirilmiş Parçacık Sürü Optimizasyonu	16
5. ÖNERİLEN YÖNTEMLER	20
6. UYGULAMALAR	30
6.1. Avusturalya Bira Tüketimi Zaman Serisinin Analizi	31
6.2. Türkiye Elektrik Tüketimi Zaman Serisinin Analizi	35
6.3. Tayvan Vadeli İşlem Borsası Zaman Serisinin Analizi	39
7. SONUÇ VE ÖNERİLER.....	42
8. KAYNAKLAR	43
ÖZGEÇMİŞ.....	

SİMGELER VE KISALTMALAR LİSTESİ

ARAR	: Armoni Arama Algoritması
AUST	: Avusturalya Bira Tüketimi
ED-TÇNM-YSA	: Eşik Değerli Tek Çarpımsal Nöron Model Yapay Sinir Ağları
GPSO	: Geliştirilmiş Parçacık Sürü Optimizasyonu
HKOK	: Hata Kareler Ortalaması Karekökü
OMYH	: Ortalama Mutlak Yüzde Hata
PSO	: Parçacık Sürü Optimizasyonu
TAIFEX	: Tayvan Vadeli İşlem Borsası
TÇNM-YSA	: Tek Çarpımsal Nöron Model Yapay Sinir Ağları
TEC	: Türkiye Elektrik Tüketimi
YSA	: Yapay Sinir Ağları

ŞEKİLLER LİSTESİ

Şekil 2.1. Biyolojik Bir Sinir Hücresi	4
Şekil 2.2. Temel Bir YSA Hücresi.....	5
Şekil 2.3. Yapay Sinir Ağı Genel Yapısı	7
Şekil 3.1. TÇNM-YSA'nın Genel Yapısı	9
Şekil 3.2. Eşik Değerli TÇNM-YSA	10
Şekil 4.1. Dört Enstrümanlı Bir Orkestra.....	12
Şekil 5.1. m, q Girdili Model İçin Oluşturulan Yeni Armoni.....	24
Şekil 5.2. w'_1 için elde edilen komşu değerler vektörü.....	25
Şekil 5.3. (m, q) girdili model için PAR işlemi sonucu güncellenen armoni.....	25
Şekil 6.1. AUST Zaman Serisi Grafiği	31
Şekil 6.2. AUST test kümesi ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörülerin birlikte grafiği	34
Şekil 6.3. TEC zaman serisi grafiği	35
Şekil 6.4. TEC test kümesi ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörülerin birlikte grafiği.....	38
Şekil 6.5. TAIEX zaman serisi grafiği.....	39

TABLÖLAR LİSTESİ

Tablo 2.1. Diğer Aktivasyon Fonksiyonları.....	6
Tablo 6.1. AUST test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	32
Tablo 6.2. AUST test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	32
Tablo 6.3. AUST test verisine ait analiz sonuçları.....	33
Tablo 6.4. TEC test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	36
Tablo 6.5. TEC test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	36
Tablo 6.6. TEC test verisine ait analiz sonuçları	37
Tablo 6.7. TAIEX test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	40
Tablo 6.8. TAIEX test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri	40
Tablo 6.9. TAIEX test verisine ait analiz sonuçları.....	40

ÖNGÖRÜ PROBLEMİ İÇİN EŞİK DEĞERLİ TEK ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR AĞLARI

ÖZET

Tek çarpımsal nöron model yapay sinir ağları, zaman serileri öngörü problemlerinde sıklıkla kullanıldığından ve gizli tabaka birim sayısı problemi bulundurmadığından yapay sinir ağları literatüründe önemli bir yere sahiptir. Tek çarpımsal nöron model yapay sinir ağları ile ilgili yapılan çalışmalarda, eğitim sürecinden elde edilen model tek bir modeldir. Bu tez çalışmasında, literatürdeki diğer birçok yapay sinir ağı modelinden farklı olarak, tek çarpımsal nöron model yapay sinir ağlarının çıktısını elde etmek için bir eşik değeri belirlenmiştir. Elde edilen eşik değeri ile ağı çıktısının hesaplanmasında hangi ağırlıkların ve yan değerlerin kullanıldığı belirlenmektedir. Sistemin optimal ağırlıklarını ve yan değerlerini belirlemek için kullanılan eşik değere dayalı tek çarpımsal nöron modelinin eğitimi için, armoni arama algoritması ve parçacık sürüsü optimizasyonu yöntemleri kullanılmıştır. Önerilen yöntemin performansını değerlendirmek için üç farklı gerçek hayat zaman serisi analiz edilmiş ve hem bu tez çalışmasında önerilen yöntemlerden elde edilen sonuçlar hem de literatürdeki popüler birçok yapay sinir ağı yönteminden elde edilen sonuçlar karşılaştırılmıştır.

Anahtar Kelimeler: Yapay sinir ağları, çarpımsal nöron model, eşik değeri, armoni arama algoritması, parçacık sürüsü optimizasyonu.

THRESHOLD SINGLE MULTIPLICATIVE NEURON MODEL ARTIFICIAL NEURAL NETWORKS FOR FORECASTING PROBLEM

SUMMARY

Single multiplicative neuron models artificial neural networks, which are frequently used in time series forecasting problems and do not have any restriction on the number of hidden layer unit, have an important place in artificial neural networks literature. In the studies about single multiplicative neuron models artificial neural networks, the model obtained from training process is a single model. In this thesis, differently from many other artificial neural network models in the literature, a threshold value is determined to obtain the output of the system of single multiplicative neuron models artificial neural networks. According to obtained threshold value, it is determined which weights and biases are used for the calculation of the output of the network. It has been separately used harmony search algorithm and particle swarm optimization for training the single multiplicative neuron model based on a threshold value, which is used to determine the optimal weights and bias of the system. To evaluate the performance of the proposed method, three different real life time series were analysed and the results obtained from both the methods' proposed in this thesis and many popular artificial neural network methods in the literature were compared.

Keywords: Artificial neural networks, multiplicative neuron model, threshold, harmony search algorithm, particle swarm optimization.

1. GİRİŞ

Yaygın olarak kullanılan yapay zekâ yöntemlerinden biri olan yapay sinir ağları, insan beyninden esinlenerek geliştirilmiş ve insanın öğrenme sürecinin matematiksel olarak modellenmesine dayanmaktadır.

Yapay sinir hücrelerinin yani nöronların bir araya gelerek oluşturduğu yapay sinir ağları (YSA), genelde üç tabakadan oluşmaktadır. Bunlar: girdi tabakası, gizli tabaka ve çıktı tabakasıdır. Girdi tabakasından gelen bilgiler alınarak ara tabakalara gönderilmekte, çıktı tabakasında ise ara tabakalardan gelen bilgi ile ağın çıktısı üretilmektedir. Ara tabaka olarak da adlandırılan gizli tabakada ise girdi tabakasından gelen bilgiler işlenerek çıktı tabakasına gönderilmektedir. YSA'da gizli tabaka, ağın performansında önemli bir etkiye sahip olmasına rağmen, gizli tabaka birim sayısının belirlenmesi yapay sinir ağlarının kullanımında bir problem olarak ortaya çıkmaktadır. Bu problemi önlemek amacıyla, Yadav ve ark. (2007), gizli tabaka birim sayısının belirlenmesi problemini içermeyen, hesaplama zamanı ve üstün öngörü performansı nedeniyle öngörü problemlerinde sıkça kullanılan tek çarpımsal nöron modelli yapay sinir ağlarını (TÇNM-YSA) önermişlerdir.

Ardından Zhao ve Yang (2009), zaman serisi öngörü problemleri için eğitimi PSO'ya dayalı TÇNM-YSA önermişlerdir. Wu ve ark. (2013) enerji tüketimi tahmini için çarpımsal nöron modele dayalı çevrimiçi eğitim algoritması kullanmıştır. Henao ve ark. (2013) elektrik talebini tahmin etmek için mevsimsel bütünleşik otoregresif hareketli ortalama ve TÇNM-YSA kullanan bir hibrit yöntem önermişlerdir. Wu ve ark. (2015) saatlik rüzgâr hızı tahmini için TÇNM-YSA kullanmışlardır. Cui ve ark. (2015) zaman serisi öngörü problemi için eğitimi geliştirilmiş ateş böceği sürüsü optimizasyon algoritması ile yapılan yeni bir TÇNM-YSA önermişlerdir. Bas (2016) zaman serisi öngörü problemi için TÇNM-YSA'nın eğitiminde diferansiyel gelişim algoritmasını kullanmıştır. Cagcag Yolcu ve ark. (2018) zaman serisi öngörü problemi için otoregresif katsayılı bir TÇNM-YSA önermişlerdir. Kolay (2019) zaman serisi

öngörü problemi için sinüs kosinüs algoritmasına dayalı yeni bir TÇNM-YSA önermiştir.

Tüm bu çalışmalarda adı geçen TÇNM-YSA'nın eğitimi sonunda elde edilen model tek bir modeldir. Bu tez çalışmasında, diğer birçok YSA modelinden farklı olarak, TÇNM-YSA'da ağırlık çıktısını elde etmek için bir eşik değeri kullanılmıştır. Bu eşik değeri ile ağırlık çıktısını elde etmek için hangi ağırlık ve yan değerlerinin kullanılacağı belirlenmiştir. Yani TÇNM-YSA literatüründeki çalışmalardan farklı olarak, ilk kez bir eşik değeri yardımı ile iki farklı model elde edilmiştir.

Eşik değerli tek çarpımsal nöron model yapay sinir ağı (ED-TÇNM-YSA) olarak adlandırılan bu yeni YSA'nın eğitilmesinde yani optimum ağırlık, yan ve eşik değerlerinin bulunmasında TÇNM-YSA literatüründe ilk kez armoni arama algoritması (ARAR) ve geliştirilmiş parçacık sürü optimizasyonu (GPSO) kullanılmıştır. ARAR ve GPSO ile eğitilen ED-TÇNM-YSA'nın performansının değerlendirilmesinde ise ilk olarak Avusturalya bira tüketimi zaman serisi, daha sonra Türkiye elektrik tüketimi zaman serisi ve son olarak Tayvan vadeli işlem borsası zaman serisi kullanılmış ve elde edilen analiz sonuçları literatürdeki birçok YSA modeli ile karşılaştırılmıştır.

Bu tezin ikinci bölümünde YSA ile ilgili temel kavramlar, üçüncü bölümünde TÇNM-YSA ve ED-TÇNM-YSA ile ilgili bilgiler verilmiştir. Dördüncü bölümde sezgisel yöntemler ve bunlardan ARAR ve GPSO yöntemleri ile ilgili bilgiler verilmiştir. Beşinci bölümde bu tez çalışmasında önerilen yöntemler olan armoni arama algoritmasına dayalı ED-TÇNM-YSA (ARAR-ED-TÇNM-YSA) ve geliştirilmiş parçacık sürü optimizasyonuna dayalı ED-TÇNM-YSA (GPSO-ED-TÇNM-YSA) yöntemlerinin ayrı ayrı algoritmaları detaylı olarak verilmiştir. Altıncı bölümde uygulamalar başlığı altında, ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinin, farklı gerçek hayat zaman serilerine uygulanmasından elde edilen sonuçlar ile literatürdeki birçok YSA modelinden elde edilen analiz sonuçlarının karşılaştırılması olarak değerlendirilmesi verilmiştir. Son olarak yedinci bölümde sonuç ve öneriler verilmektedir.

2. YAPAY SİNİR AĞLARI

İnsan beyninin öğrenme, yeni bilgiler üretme ve keşfedebilmesi amacı ile ilk olarak sinir sisteminin en temel ögesi nöron adı verilen sinir hücreleri incelenmiş ve ilk kez McCulloch ve Pitts (1943) biyolojik bir nöronun matematiksel modelini oluşturmuşlardır. Günümüz YSA temelini oluşturan bu model insan beyninin özelliklerine benzer şekilde, örneklerden elde edilen bilgiler ile öğrenme, ilişkilendirme, sınıflandırma, genelleme, özellik belirleme ve optimizasyon gibi alanlarda uygulanmaktadır.

YSA'nın özellikleri uygulanan ağ modeline göre değişmekle birlikte, bütün modeller makine öğrenmesi gerçekleştirmekte ve olayları öğrenerek benzer olaylar karşısında benzer kararlar vermeye çalışmaktadır. YSA'nın olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekmektedir. YSA'lar bu örnekleri kullanarak olay ile ilgili genelleme yapabilecek yeteneği elde eder. Bu nedenle örneklerin oluşturulması ve toplanması YSA'da büyük bir öneme sahiptir.


YSA eğitiminden yani YSA'nın genelleme yeteneği elde etmesinden ya da örnekteki olaylar arasındaki ilişkilerin belirlenmesinden sonra bu ağlar eksik bilgiler ile çalışabilmekte ve yeni örneklerde eksik bilgi olmasına rağmen sonuç üretebilmektedir. Yine ağa eksik bilgi içeren bir örüntü veya şekil verildiğinde, bu örüntü veya şekil tamamlanabilmektedir. YSA'nın eksik bilgilerle çalışabilmesi hatalara karşı toleranslı olmalarını sağlamaktadır.

Yapay sinir ağlarının sağladığı bu avantajlı özelliklerinin yanında; ağ yapısının belirlenmesinde, ağ parametrelerinin seçiminde belirli bir standart olmaması, problemlerin sadece nümerik bilgilerle gösterilebilmesi, eğitimin nasıl biteceğinin bilinmemesi ve ağın davranışlarını açıklayamaması dezavantaj sağlamasına rağmen YSA ile her problem için değişik şekillerde çözümler üretilebilmekte ve başarılı uygulamalar yapılmaktadır.

2.1.Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

2.1.1. Biyolojik Sinir Hücresi

YSA'lar biyolojik sinir sisteminden etkilenecek geliştirilmiştir. Biyolojik bir sinir sisteminin en temel ögesi nöronlar yani sinir hücreleri gövde ve uzantılar olarak iki kısımdan oluşmaktadır. Nöronun gövdesine soma adı verilmektedir. Nöronun uzantıları ise akson ve dentritlerden oluşmaktadır. Şekil 2.1'de biyolojik bir sinir hücresi şematik olarak gösterilmektedir.




Şekil 2.1. Biyolojik Bir Sinir Hücresi (Öztemel, E., 2016)

Biyolojik bir sinir hücresinde, gelen sinyalleri dentritler çekirdeğe iletir. Çekirdek gelen sinyalleri bir araya toplar ve aksona iletir. Toplanan bu sinyaller, akson tarafından işlenerek sinapslara gönderilir. Sinapslar da yeni üretilen sinyalleri diğer sinir hücrelerine iletirler. YSA ise biyolojik sinir hücresine göre çok daha basit bir yapıya sahiptir ve yapay sinir ağlarında nöronlar ve nöronlar arasındaki bağlantılar yapay modelde yer almaktadır.

2.1.2. Yapay Sinir Hücresi

Temel bir yapay sinir ağı hücresinde girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olarak beş temel elaman bulunmaktadır. Şekil 2.2'de temel bir YSA hücresi verilmektedir.



Şekil 2.2. Temel Bir YSA Hücresi (Kahraman, H.T.,2016)

Girdiler: x_i ile gösterilen giriş verileri, dış ortamdan girilen bilgiler olabildiği gibi başka hücrelerden alınan bilgilerde olabilmektedir. Bunlar ağıın öğrenmesi istenen örnekler tarafından belirlenir.

Ağırlıklar: Yapay sinir ağı hücresine gelen bilginin önemini ve hücre üzerindeki etkisini gösterir. Her bir girdinin kendine ait bir w_i ağırlığı vardır.

Toplama Fonksiyonu: Hücreye gelen net girişi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. Yaygın olarak kullanılan fonksiyon türü toplamsaldır ve Eşitlik (1)'de verilmektedir. Bu modelde gelen sinyallerin toplamsal olarak birleştiği varsayılmaktadır.

$$net = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Aktivasyon Fonksiyonu: Aktivasyon fonksiyonu hücreye gelen net girdiyi işleyerek hücrenin bu girdiye karşılık üreteceği çıktıyı belirler. Farklı doğrusal olmayan yapılarda alınarak, doğrusal olmayan ilişkilerin modellenmesi mümkün olabilmektedir. Literatürde en sık kullanılan aktivasyon fonksiyonlarından biri lojistik ya da sigmoid aktivasyon fonksiyonudur ve Eşitlik (2)'de verilmektedir.

$$f(net) = \frac{1}{1 + \exp(-\lambda \times net)} \quad (2)$$

Sigmoid aktivasyon fonksiyonu sürekli ve türevi alınabilir bir fonksiyondur. λ parametresi eğitim parametresi olarak adlandırılmakta ve 0 ile 1 arasında değer almaktadır. Diğer sık kullanılan bir aktivasyon fonksiyonu ise hiperbolik tanjant aktivasyon fonksiyonudur ve Eşitlik (3)'de verilmektedir.

$$f(net) = \frac{\exp(net) - \exp(-net)}{\exp(net) + \exp(-net)} \quad (3)$$

Hiperbolik tanjant aktivasyon fonksiyonu, sigmoid fonksiyona benzer bir fonksiyondur. Hiperbolik tanjant fonksiyonu -1 ile 1 arasında değer almaktadır. Aktivasyon fonksiyonu olarak kullanılan diğer fonksiyonlar ise Tablo 2.1'de verilmektedir.


Tablo 2.1. Diğer Aktivasyon Fonksiyonları

Doğrusal Aktivasyon Fonksiyonu $f(net) = \alpha \times net$	Toplama fonksiyonundan çıkan sonuç α sabit sayısı ile çarpılarak hücre çıktısı hesaplanır.
Eşik Aktivasyon Fonksiyonu $f(net) = \begin{cases} \alpha, & net > \theta \\ \beta, & net \leq \theta \end{cases}$	Gelen net girdinin bir θ eşik değerinden büyük ya da küçük olmasına göre hücre çıktısı α ve β değerini alır.
Rampa Aktivasyon Fonksiyonu $f(net) = \begin{cases} a & ; net \geq \alpha \\ \frac{\gamma - \delta}{\alpha - \beta} net + \frac{\alpha\delta + \beta\gamma}{\alpha - \beta} & ; \beta < net < \alpha \\ \delta & ; net \leq \beta \end{cases}$	Doğrusal ve eşik fonksiyonu bir araya gelmesi ile oluşmaktadır. Burada $\beta < net < \alpha$ aralığında doğrusal fonksiyon $net \geq \alpha$ ve $net \leq \beta$ içinde eşik fonksiyon özelliği göstermektedir.
Gauss Aktivasyon Fonksiyonu $f(net) = \exp(-\frac{net^2}{\sigma^2})$	Fonksiyonun tepesinden geçen ve $f(net)$ eksenine paralel olan eksene göre simetrik ve σ varyans değerine sahip bir fonksiyondur.

Çıktı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Üretilen çıktı dışarı veya bir başka hücreye gönderilir.

2.1.3. Yapay Sinir Ağının Yapısı

YSA, yapay sinir hücrelerinin bir araya gelerek oluşturduğu yapılardır. Genel olarak hücreler girdi tabakası, gizli tabaka ve çıktı tabakası olarak üç tabaka halindedir. Şekil 2.3'te yapay sinir ağı genel yapısı verilmektedir.



Şekil 2.3. Yapay Sinir Ağı Genel Yapısı (Kahraman, H.T., 2016)

Girdi Tabakası: Dış dünyadan bilgilerin geldiği tabakadır. Girdi sayısı kadar hücre bulunmaktadır ve girdiler herhangi bir işleme uğramadan gizli tabakaya iletilir.


Gizli Tabaka : Girdi tabakasından gelen bilgiler işlenerek bir sonraki tabakaya iletilir. Birden fazla gizli tabaka bulunabildiği gibi, bu tabakadaki hücre sayıları da farklı olabilmektedir. Gizli tabakaların ve buradaki nöron sayılarının artması hesaplama karmaşıklığını ve süresini artırmasına rağmen YSA'nın daha karmaşık problemlerin çözümünde de kullanılabilmesini sağlar.

Çıktı Tabakası: Gizli tabakadan gelen bilgileri işleyerek ağın çıktısını üreten tabakadır. Üretilen çıktı dış dünyaya gönderilir ya da bu çıktı kullanılarak ağın yeni ağırlık değerleri hesaplanır.



3. TEK ÇARPIMSAL NÖRON MODELLİ YAPAY SİNİR AĞLARI

Literatürde kullanılan birçok farklı YSA türünden biri olan TÇNM-YSA'nın, YSA'nın temel problemlerinden biri olan gizli tabaka birim sayısına ihtiyaç duymaması ve bu nedenle karmaşık bir işlem yapısına sahip olmaması ve yine uygulama kolaylığı nedeni ile son yıllarda araştırmacılar tarafından sıklıkla kullanılan bir YSA türü olmasına sebep olmuştur. TÇNM-YSA ilk kez Yadav ve ark. (2007) tarafından ortaya atılmış ve literatürdeki birçok çalışma ile başarılı öngörü performansı kanıtlanmıştır. TÇNM-YSA'nın genel yapısı Şekil 3.1 ile verilmiştir.



Şekil 3.1. TÇNM-YSA'nın Genel Yapısı


Şekil 3.1'de verilen m girdili $(x_i, i = 1, 2, \dots, m)$ nöron modelde m adet ağırlık değeri (w_i) ve m adet yan değeri (b_i) bulunmaktadır. Şekil 3.1'de, $\Phi = (w_1, w_2, \dots, w_m, b_1, b_2, \dots, b_m)$ 'dir ve lojistik aktivasyon fonksiyonu ile çarpımsal nöron modelin çıktısı Eşitlik (4) ve Eşitlik (5) ile hesaplanmaktadır.

$$net = \prod_{i=1}^n (w_i x_i + b_i) \quad (4)$$

$$o = f(net) = \frac{1}{1 + \exp(-net)} \quad (5)$$

3.1. Eşik Değerli Tek Çarpımsal Nöron Model YSA

Eşik değeri ile iki yapıya bir model elde edilen eşik değeri tek çarpımsal nöron modelin mimarisi Şekil 3.2’de verilmektedir.



Şekil 3.2. Eşik Değerli TÇNM-YSA

Bu şekilde, birinci çarpımsal nöron için $X_{t-1}, X_{t-2}, \dots, X_{t-m}$ ve ikinci çarpımsal nöron için $X_{t-1}, X_{t-2}, \dots, X_{t-q}$ girdileri ifade etmektedir. Ağın çıktısının elde edilmesinde, hangi modelin ağırlık ve yan değerlerinin kullanılması gerektiği Eşitlik (6) da verilen bir δ parametresi ile belirlenir.

$$\delta = \begin{cases} 1 & X_{t-d} < c \\ 0 & X_{t-d} \geq c \end{cases} \quad (6)$$

Eşitlik (6)’da c eşik değeri, d rasgele üretilen bir tamsayısı değerini ve X_{t-d} eşik değeriyle karşılaştırılacak olan gecikmeyi ifade etmektedir. Bu eşitlikten elde edilen δ değerine göre, kullanılacak olan modelin girdi sayısına bağlı olarak belirlenen ağırlık ve yan değerleri ile ağın net değeri Eşitlik (7) ile hesaplanır ve ağın çıktısı Eşitlik (8) ile elde edilir.

$$net = \begin{cases} \prod_{j=1}^m w_j X_{t-j} + b_j & \delta = 1 \\ \prod_{j=1}^q \theta_j X_{t-j} + a_j & \delta = 0 \end{cases} \quad (7)$$

$$\hat{X}_t = \frac{1}{1 + \exp(-net)} \quad (8)$$

4. SEZGİSEL YÖNTEMLER

Gerçek hayatta karşılaşılan problemlerin birçoğu sonsuz çözüm kümesine sahiptir ya da çözümler değerlendirilemeyecek kadar fazladır. Bu sorunun önüne geçmek amacıyla, kabul edilebilir zaman aralığında, kabul edilebilir bir çözüm için sezgisel yöntemler geliştirilmiştir. Bu algoritmalar optimum çözümü bulmak için doğada gözlemlenen süreçleri ya da olayları taklit ederek arama yapan tekniklerdir.

Sezgisel algoritmalar:

- Sezgisel problem çözme tekniğidir.
- Sonucun doğruluğunu garanti etmezler, kanıtlanabilirlik aranmamaktadır.
- Optimum süre içerisinde çözüm elde edeceklerini garanti ederler.
- Çeşitli alternatif hareketlerden etkili olanlara karar vererek en iyiye yakın çözüm yolu bulmak amaçlanmaktadır.
- Genellikle en iyiye yakın çözüm yoluna hızlı ve kolay bir şekilde ulaşırlar.

Literatürde yer alan genetik algoritma, karınca kolonisi algoritması, PSO ve yapay arı kolonisi önemli sezgisel yöntemlerdendir. Son yıllarda artan çalışmalarla gündeme gelen ARAR'da güçlü bir araştırma yöntemi olarak literatürde yer almaktadır.

4.1. Armoni Arama Algoritması

ARAR Geem ve ark. (2001) tarafından önerilen ve bir orkestradaki müzisyenlerin çaldıkları notalar ile armonik açıdan en iyi melodinin elde edilmesi prensibine dayanan bir optimizasyon algoritmasıdır. Farklı enstrümanlar ile çalınan nota ve tonların estetik kalitesi, müzik çalışmalarında pratik yaparak iyileştirilirken, fonksiyon çözümünde bu iyileştirme birbirini takip eden iterasyonlarla gerçekleştirilmektedir (Geem, 2006).

Armoni arama algoritmasının

- Birden fazla çözümle birçok yönde optimum çözüm araması
- Hem sürekli hem de kesikli değişkenler için kullanılabilmesi

önemli avantajlarındanır.

Şekil 4.1’de görüldüğü gibi orkestrada dört ayrı müzisyen olduğunu ve her bir müzisyenin belleğinde dört farklı nota olduğunu varsayalım.



Şekil 4.1. Dört Enstrümanlı Bir Orkestra

Bu dört farklı müzisyenden; birinci müzisyenin belleğinde $\{Do, Re, Mi, Fa\}$, ikinci müzisyenin belleğinde $\{Mi, La, Si, Sol\}$, üçüncü müzisyenin belleğinde $\{La, Mi, Sol, Si\}$, dördüncü müzisyenin belleğinde $\{Fa, Si, La, Re\}$ notaları olsun. Birinci müzisyenin $\{Do\}$, ikinci müzisyenin $\{Mi\}$, üçüncü müzisyenin $\{La\}$ ve dördüncü müzisyenin $\{Re\}$ notalarını çalması durumunda $\{Do, Mi, La, Re\}$ notaları bir armoni oluşturur. Oluşturulan bu armoni, müzisyenlerin belleklerindeki estetik açıdan elde edilebilecek en güzel armoniye ulaşmaya kadar devam etmektedir.

Armoni arama algoritmasında her müzisyen bir karar değişkeni ve her bir müzisyenin belleğindeki her bir nota da o karar değişkenine ait farklı bir çözüme karşılık gelmektedir. Her bir müzisyenin belleğinden seçilen notalar ile farklı farklı çözüm vektörleri elde edilir. Örneğin; $\{Do, Mi, La, Re\}$, $\{Do, Sol, Si, La\}$, $\{Re, La, Sol, Fa\}$ her bir müzisyenin belleğinden alınan notalar ile oluşturulmuş farklı çözüm vektörleridir.

Armoni arama algoritmasında amaç elde edilen çözüm vektörünün bellekteki en kötü çözümden daha iyi olup olmadığının araştırılmasıdır. Eğer elde edilen çözüm vektörü amaç fonksiyonuna göre, bellekteki en kötü çözüm vektöründen daha iyi ise, elde edilen çözüm vektörü en kötü çözüm vektörü ile yer değiştirilir aksi halde bellekte tutulur.

ARAR algoritması adımlar halinde aşağıda verilmiştir.

Adım 1. Algoritma Parametrelerin Belirlenmesi

Algoritmada kullanılacak olan parametreler aşağıdaki gibidir ve başlangıçta belirlenmektedir.

- HM : Armoni belleği (Harmony Memory)
- HMS : Armoni belleği kapasitesi (Harmony Memory Search)
- $HMCR$: Armoni belleğini dikkate alma oranı (Harmony Memory Considering Rate)
- PAR : Ton ayarlama oranı (Pitch Adjusting Rate)
- n : Değişken sayısı

Adım 2. Armoni Belleğinin Oluşturulması

ARAR algoritması için HM Eşitlik (9)'daki gibi oluşturulur.

$$HM = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1n} \\ x_{21} & x_{22} & \cdots & x_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ x_{HMS1} & x_{HMS2} & x_{HMS3} & x_{HMSn} \end{bmatrix} = \begin{bmatrix} x'_1 \\ x'_2 \\ \vdots \\ x'_{HMS} \end{bmatrix} \quad (9)$$

Burada; x_{ij} ($i = 1, 2, \dots, HMS$; $j = 1, 2, \dots, n$), j . müzisyenin belleğindeki i . nota değeri olarak ifade edilir ve $U(0,1)$ dağılımı ile rasgele üretilir. Örneğin; x_{12} 2. müzisyenin belleğindeki 1. notanın değeri ve x_{34} 4. müzisyenin belleğindeki 3. notanın değeridir. ARAR algoritmasında her bir çözüm vektörü $x'_i, i = 1, 2, \dots, HMS$ ile

gösterilir. ARAR algoritmasında toplamda HMS adet çözüm vektörü bulunmaktadır. Birinci çözüm vektörüne ait gösterim Eşitlik (10)'da verilmiştir.

$$x'_1 = [x_{11}, x_{12}, \dots, x_{1n}] \quad (10)$$

Adım 3. Amaç Fonksiyonu Değerlerinin Hesaplanması

$$\begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ x_{HMS1} & x_{HMS2} & x_{HMS3} & x_{HMSn} \end{bmatrix} = \begin{bmatrix} x'_1 \\ x'_2 \\ \vdots \\ x'_{HMS} \end{bmatrix} \Rightarrow \begin{bmatrix} f(x'_1) \\ f(x'_2) \\ \vdots \\ f(x'_{HMS}) \end{bmatrix} \quad (11)$$

Rasgele üretilen her bir çözüm vektörü için amaç fonksiyonu değerleri hesaplanır. Burada, $f(x'_1)$ birinci çözüm vektörü için hesaplanan amaç fonksiyonu değerini ifade etmektedir.

Adım 4. Yeni Armoni Geliştirilmesi

Literatürde 0,7 ile 0,95 arasında değer alan $HMCR$ olasılığı HM 'de bulunan mevcut değerlerden bir değer seçme olasılığı iken $(1 - HMCR)$ değeri ise olası değer aralıklarından rastgele bir değer seçme oranıdır. (Geem, 2006) Yeni vektör için ilk karar değişkeninin değeri (x_{i1yeni}) belirtilen HM aralığında herhangi bir değerden seçilir.

Örneğin yeni x_{11} değeri $HMCR$ olasılığı ile x_{11} ve x_{HMS1} değeri arasında, yeni x_{12} değeri $HMCR$ olasılığı x_{12} ile x_{HMS2} değeri arasında rasgele seçilen bir değer olmakta aksi halde bu değerler $(1 - HMCR)$ olasılığı ile armoni belleğinde bulunan en küçük değer ile en yüksek değer arasında üretilen rasgele bir değer olmaktadır. (Guney ve Onay, 2011)

Buna göre yeni armoni Eşitlik (12) yardımı ile rnd , $U(0,1)$ arasında rasgele üretilen sayının $HMCR$ ilişkisine göre elde edilir.

$$x_{ijyeni} = \begin{cases} x_{ij} \in \{x_{ij}; i = 1, 2, \dots, HMS\} & \text{eğer } rnd < HMCR \\ U(0,1)x(max - min) + min & \text{diğer durumda} \end{cases} \quad (12)$$

Ton ayarlama işlemi, $HMCR$ olasılığı ile bellekten seçilen her bir karar değişkenine uygulanıp uygulanamayacağına PAR parametresi ile karar verilir.

$$x_{ijyenipitch} = \begin{cases} Evet & rnd < PAR \\ Hayır & diğer durumda \end{cases} \quad (13)$$

Eşitlik (13)'da rnd , $U(0,1)$ arasında rasgele üretilen bir sayıdır. Eğer üretilen bu rasgele sayı PAR oranından küçük ise bu değer kendisine en yakın değer ile değiştirilir. Örneğin algoritma 0,40'lık bir PAR değeri için $(0,40 \times HMCR)$ olasılığı ile vektör içinden bir komşu değer seçecektir. Eğer her bir x_{ijyeni} karar değişkeni için ton ayarlaması yapılacaksa ve x_{ijyeni} 'nin karar değişkeninin alabileceği değerler vektörü içinde k .sıradaki değer olduğu varsayılırsa $x_{ijyeni}(k)$ 'nin ayarlanmış yeni değeri:

$$x_{ij} \leftarrow x_{ij}(k \pm m) \quad (14)$$

Eşitlik (14)'de ki $m \in \{\dots, -2, -1, 1, 2, \dots\}$ komşuluk indeksidir.

Literatürde $HMCR$ için 0,7-0,95 arasındaki değerler ve PAR için ise 0,05-0,7 arasındaki değerler olası değerlerdir. (Geem, 2006)

Adım 5. Armoni Belleğinin Güncellenmesi

Eğer yeni armoni vektörü HM içerisindeki en kötü vektörden amaç fonksiyonuna göre daha iyi ise en kötü vektör bellekten çıkarılır ve çıkarılan bu vektör yerine yeni armoni vektörü HM 'ye dâhil edilir.

Adım 6. Durdurma Koşulu Kontrolü

Adım 4 – 6 işlemleri sonlandırma kriteri sağlanana kadar tekrarlanır.

4.2. Geliştirilmiş Parçacık Sürü Optimizasyonu

PSO, Kennedy ve Eberhart (1995) tarafından önerilen ve kuş sürülerinin davranışlarından esinlenerek geliştirilmiş bir optimizasyon algoritmasıdır. PSO doğrusal olmayan problemlerin çözümü için tasarlanmıştır ve parametre ve değişken sayılarının çok olduğu optimizasyon problemlerine çözüm bulmak için kullanılmaktadır (Xiaohui, 2006). Türev bilgisine ihtiyaç duymaması da önemli avantajlarındandır.

Kuşların uzayda yerini bilmedikleri yiyeceği aramaları, bir probleme çözüm aramaya benzetilmektedir. PSO'da parçacık olarak adlandırılan her bir çözüm, arama uzayındaki bir kuştur. Parçacık hareket ettiğinde bulunduğu koordinatların fonksiyondaki değeri yani parçacığın başarı değeri; kuşun yiyeceğe uzaklığının bir ölçüsüdür. Bir parçacık koordinatlarını, hızını ve elde ettiği en yüksek başarıya sahip koordinatları hafızasında tutmalıdır. Çözüm uzayındaki koordinat ve hız değerlerinin değişimi, komşularının en iyi koordinatları ve kendi en iyi koordinatlarının bir birleşimidir. Bu benzetimle ortaya çıkan PSO'da başarılı sonuçlar elde edilmiş olsa da, yakınsama hızını artırmak amacı ile birçok katkı sağlanmıştır. İlk katkı Shi ve Eberhart (1998) tarafından eylemsizlik ağırlığı (inertia weight) (w) yaklaşımının ortaya konulmasıdır. Bu yaklaşım ile bir önceki iterasyondaki hız değeri, hız güncellenmesine dâhil edilmiştir. Diğer bir katkı ise bilişsel, sosyal katsayı değerlerinin ve eylemsizlik ağırlığının iterasyonlar içinde doğrusal olarak değiştirilmesidir.

Yapılan katkılarla geliştirilmiş PSO (GPSO) adımlar halinde aşağıda verilmiştir.

Adım 1. Algoritma Parametrelerin Belirlenmesi

Algoritmada kullanılacak olan parametreler aşağıdaki gibidir ve başlangıçta belirlenmektedir.

- Parçacık sayısı (Ps)
- Parçacık pozisyonları (PP)
- Parçacık hızları (V)
- Bilişsel katsayı (c_1)
- Sosyal katsayı (c_2)
- Eylemsizlik ağırlığı (w)
- Değişken sayısı (n)

Adım 2. Parçacık pozisyonları ve hızların rasgele belirlenmesi.

GPSO’da değişken ve parçacık sayısı dikkate alınarak, $Ps \times n$ boyutlu parçacık pozisyon (PP) ve hız (V) değerleri sırasıyla Eşitlik (15-16)’deki gibi oluşturulur.

$$PP = \begin{bmatrix} P_{11} & P_{12} & \cdots & P_{1n} \\ P_{21} & P_{22} & \cdots & P_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ P_{Ps1} & P_{Ps2} & \cdots & P_{Psn} \end{bmatrix} \quad (15)$$

$$V = \begin{bmatrix} V_{11} & V_{12} & \cdots & V_{1n} \\ V_{21} & V_{22} & \cdots & V_{2n} \\ \vdots & \vdots & \vdots & \vdots \\ V_{Ps1} & V_{Ps2} & \cdots & V_{Psn} \end{bmatrix} \quad (16)$$

Burada; P_{ij} j . parçacığın i . pozisyon değeri; V_{ij} j . parçacığın i . hız değeri olarak ifade edilir ve $U(0,1)$ aralığında rasgele üretilir ($i = 1, 2, \dots, Ps ; j = 1, 2, \dots, n$).

Adım 3. Amaç fonksiyonu değerine bağlı olarak P_{best} ve G_{best} belirlenmesi.

Rasgele üretilen her bir çözüm vektörü için amaç fonksiyonu değerleri hesaplanır. Parçacıkların en iyi pozisyonları P_{best} vektörlerinde saklanır. Tüm parçacıkların en iyi durumu ise P_{best_g} ya da G_{best} ile gösterilir. Eşitlik (17-18)'de P_{best} ve G_{best} vektörleri verilmektedir.

$$P_{best\ i} = [P_{i1} \ P_{i2} \ \dots \ P_{in}]; \ i = 1, 2, \dots, Ps \quad (17)$$

$$P_{best_g} = G_{best} = [P_{g1} \ P_{g2} \ \dots \ P_{gn}] \quad (18)$$

Adım 4. w eylemsizlik ağırlığı, c_1 bilişsel katsayı ve c_2 sosyal katsayı bileşenlerinin güncellenmesi.

PSO'nun yakınsama hızını artırmak amacıyla w , c_1 ve c_2 katsayıları değerleri iterasyonlar içinde Eşitlik (19-21)'deki gibi güncellenir.

$$w = (w_{max} - w_{min}) \times \frac{maxk - k}{maxk} + w_{min} \quad (19)$$

$$c_1 = (c_{1f} - c_{1i}) \times \frac{k}{maxk} + c_{1i} \quad (20)$$

$$c_2 = (c_{2f} - c_{2i}) \times \frac{k}{maxk} + c_{2i} \quad (21)$$

Burada (c_{1f}, c_{1i}) bilişsel katsayı için; (c_{2f}, c_{2i}) sosyal katsayı için; (w_{max}, w_{min}) eylemsizlik ağırlığı için maksimum ve minimum değerlerdir. $maxk$ maksimum iterasyon sayısı, k ise geçerli iterasyon sayısını göstermektedir.

Adım 5. Yeni hız ve pozisyonların hesaplanması ve güncellenmesi.

Yeni hız ve pozisyon değerleri Eşitlik (22-23) ile hesaplanır.

$$V_{ij}^{k+1} = w \times V_{ij}^k + c_1 \times \text{rand}_1 \times (P_{\text{best}_{ij}}^k - P_{ij}^k) + c_2 \times \text{rand}_2 \times (G_{\text{best}_{ij}}^k - P_{ij}^k) \quad (22)$$

$$P_{ij}^{k+1} = P_{ij}^k + V_{ij}^{k+1} \quad (23)$$

Adım 6. Durdurma Koşulu Kontrolü

Sonlandırma kriteri sağlanana kadar Adım 3- Adım 5 işlemleri tekrarlanır.



5. ÖNERİLEN YÖNTEMLER

Bu tez çalışmasının daha önceki bölümlerinde de belirtildiği gibi TÇNM-YSA'da dâhil olmak üzere literatürdeki birçok YSA modelinden elde edilen model tek bir modeldir. Bu tez çalışmasında ise literatürdeki birçok YSA modelinden farklı olarak TÇNM-YSA için tek bir model yerine bir eşik değer yardımı ile (ED-TÇNM-YSA) iki farklı model elde edilmiştir. ED-TÇNM-YSA için elde edilen modellerin yapısında bulunan ağırlık ve yan değerlerinin elde edilmesinde GPSO yöntemi ve TÇNM-YSA literatüründe ilk kez ARAR yöntemi kullanılmış ve önerilen yöntemler ile TÇNM-YSA'nın eşik değer varlığındaki (ED-TÇNM-YSA) performansı araştırılmıştır. ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerine ait algoritmalar sırası ile Algoritma 1 ve 2'de verilmiştir.

Algoritma 1: Eşik Değerli Tek Çarpımsal Nöron Modelin ARAR Algoritması İle Eğitimi (ARAR-ED-TÇNM-YSA)

Adım 1. ARAR-ED-TÇNM-YSA'nın eğitimi sürecinde kullanılan parametrelerin belirlenmesi.

- m : Eşik değerden önce kurulan model için girdi sayısı
- q : Eşik değerden sonra kurulan model için girdi sayısı
- HM : Armoni belleği
- HMS : Armoni belleği kapasitesi
- $HMCR$: Armoni belleğini dikkate alma oranı
- PAR : Ton ayarlama oranı
- c : Eşik değer
- d : Eşik değer ile karşılaştırılacak gecikme

Adım 2. Armoni belleğinin oluşturulması.

Burada TÇNM’de kullanılacak girdi sayısına (m, q) bağlı olarak ağırlık, yan, alternatif ağırlık ve alternatif yan değerleri; bunlara ek olarak eşik değer ve eşik değer ile karşılaştırılacak gecikme değerlerinin bulunduğu bir armoni oluşturulur. Armoni belleği kapasitesi kadar armoni üretilerek $HMS \times (2 \times (q + m) + 2)$ boyutlu armoni belleği (HM) oluşturulur. Eşitlik (24)’te verilen w_{ij} , b_{ij} , θ_{ij} , a_{ij} ($i = 1:HMS$, $j = 1:m$) parametreleri $U(0,1)$ aralığında üretilen rasgele değerleri; c_i ($i = 1:HMS$) zaman serisinin en küçük ve en büyük değerleri arasında üretilen rasgele değerleri ve d_i ($i = 1:HMS$) bir ile eğitim kümesinin maksimum uzunluğu arasında üretilen rasgele tamsayı değerlerini ifade etmektedir.

$$HM = \begin{bmatrix} w_{11} & \dots & w_{1m} & b_{11} & \dots & b_{1m} & \theta_{11} & \dots & \theta_{1q} & a_{11} & \dots & a_{1q} & c_1 & d_1 \\ w_{21} & \dots & w_{2m} & b_{21} & \dots & b_{2m} & \theta_{21} & \dots & \theta_{2q} & a_{21} & \dots & a_{2q} & c_2 & d_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{HMS1} & \dots & w_{HMSm} & b_{HMS1} & \dots & b_{HMSm} & \theta_{HMS1} & \dots & \theta_{HMSq} & a_{HMS1} & \dots & a_{HMSq} & c_{HMS} & d_{HMS} \end{bmatrix} \quad (24)$$

w_{ij} ; i .armonide, j .girdiye karşılık gelen ağırlık değerini, b_{ij} ; i .armonide, j .girdiye karşılık gelen yan değerini ($i = 1:HMS$, $j = 1:m$), θ_{ij} ; i .armonide, j .girdiye karşılık gelen alternatif ağırlık değerini, a_{ij} ; i .armonide, j .girdiye karşılık gelen alternatif yan değerini ($i = 1:HMS$, $j = 1:q$), c_i ; i .armonideki eşik değeri ve d_i ; i .armonideki eşik değer ile karşılaştırılacak gecikmeyi ifade etmektedir ($i = 1:HMS$).

Örneğin; $m = 2, q = 3, HMS = 3$ olarak alınsın. O halde HM Eşitlik (25)’deki gibi elde edilebilir.

$$HM = \begin{bmatrix} w_{11} & w_{12} & b_{11} & b_{12} & \theta_{11} & \theta_{12} & \theta_{13} & a_{11} & a_{12} & a_{13} & c_1 & d_1 \\ w_{21} & w_{22} & b_{21} & b_{22} & \theta_{21} & \theta_{22} & \theta_{23} & a_{21} & a_{22} & a_{23} & c_2 & d_2 \\ w_{31} & w_{32} & b_{31} & b_{32} & \theta_{31} & \theta_{32} & \theta_{33} & a_{31} & a_{32} & a_{33} & c_3 & d_3 \end{bmatrix} \quad (25)$$

Burada, w_{31} ; üçüncü armonide, birinci girdiye karşılık gelen ağırlık değerini, b_{31} ; üçüncü armonide, birinci girdiye karşılık gelen yan değerini, θ_{21} ; ikinci armonide, birinci girdiye karşılık gelen alternatif ağırlık değerini, a_{21} ; ikinci armonide, birinci

girdiye karşılık gelen alternatif yan değerini, c_1 ; birinci armonideki eşik değeri ve d_2 ; ikinci armonideki eşik değeri ile karşılaştırılacak gecikmeyi ifade etmektedir.

Adım 3. Amaç fonksiyonu değerinin hesaplanması.

Her bir armoni için amaç fonksiyonu değerleri hesaplanır. Eşitlik (26)'de verilen eşik değeri c ile karşılaştırılacak gecikme X_{t-d_i} ilişkisine göre, hangi ağırlık ve yan değerlerinin kullanılacağı belirlenir. Burada eşik değeri, eşik değeri ile karşılaştırılacak gecikmeden büyük ise Eşitlik (27); küçük ise Eşitlik (28) kullanılarak $\hat{X}_t$ hesaplanır.

$$\hat{X}_t = \begin{cases} \frac{1}{1+\exp(-net1)} & X_{t-d_i} < c_i \\ \frac{1}{1+\exp(-net2)} & X_{t-d_i} > c_i \end{cases} \quad (26)$$

$$net1 = \prod_{j=1}^m w_{ij}X_{t-j} + b_{ij} \quad (27)$$

$$net2 = \prod_{j=1}^q \theta_{ij}X_{t-j} + a_{ij} \quad (28)$$

Burada; $\hat{X}_t$ elde edilen öngörü (çıktı) değerini ve X_{t-d_i} ise ilgili eşik değeri ile karşılaştırılacak d .gecikmeye ait değeri ifade eder.

Elde edilen çıktı değerleri ile hedef değerler kullanılarak hata kareler ortalaması karekök ($HKOK$) kriteri ile her bir armonin amaç fonksiyonu değeri hesaplanır. Her bir armoni için $HKOK$ değeri Eşitlik (29) ile ifade edilir.

$$HKOK = \sqrt{\frac{\sum_{t=1}^n (X_t - \hat{X}_t)^2}{n}} \quad (29)$$

Adım 4. Yeni armoni geliştirilmesi.

Bu adımda $HMCR$ ve PAR parametreleri esas alınarak yeni armoni geliştirilir.

Adım 4.1. İlk olarak, yeni armoninin değişken değerlerinin (armonide belleğinde bulunan tüm ağırlık ve yan değerleri, eşik değer ve eşik değer ile karşılaştırılacak gecikme değeri) bellekten seçilip seçilmeyeceğine *HMCR* ile karar verilmektedir. Literatürde *HMCR* için 0,7-0,95 arasındaki değerler ve *PAR* için ise 0,05-0,7 arasındaki değerler olası değerlerdir. (Geem, 2006)

$$w'_j = \begin{cases} w'_j \in \{w_{ij}; i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, m\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(w_{ij}) - \min(w_{ij})) + \min(w_{ij}); i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, m & d. d. \end{cases} \quad (30)$$

$$b'_j = \begin{cases} b'_j \in \{b_{ij}; i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, m\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(b_{ij}) - \min(b_{ij})) + \min(b_{ij}); i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, m & d. d. \end{cases} \quad (31)$$

$$\theta'_j = \begin{cases} \theta'_j \in \{\theta_{ij}; i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, q\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(\theta_{ij}) - \min(\theta_{ij})) + \min(\theta_{ij}); i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, q & d. d. \end{cases} \quad (32)$$

$$a'_j = \begin{cases} a'_j \in \{a_{ij}; i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, q\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(a_{ij}) - \min(a_{ij})) + \min(a_{ij}); i = 1, 2, \dots, \text{HMS}, j = 1, 2, \dots, q & d. d. \end{cases} \quad (33)$$

$$c' = \begin{cases} c' \in \{c_i; i = 1, 2, \dots, \text{HMS}\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(c_i) - \min(c_i)) + \min(c_i); i = 1, 2, \dots, \text{HMS} & d. d. \end{cases} \quad (34)$$

$$d' = \begin{cases} d' \in \{d_i; i = 1, 2, \dots, \text{HMS}\} & \text{rnd} < \text{HMCR} \\ U(0,1)x(\max(d_i) - \min(d_i)) + \min(d_i); i = 1, 2, \dots, \text{HMS} & d. d. \end{cases} \quad (35)$$

w'_j : *HMCR* işlemi sonucu elde edilen j. girdi için ağırlık değeri

b'_j : *HMCR* işlemi sonucu elde edilen j. girdi için yan değeri

θ'_j : *HMCR* işlemi sonucu elde edilen j. girdi için alternatif ağırlık değeri

a'_j : *HMCR* işlemi sonucu elde edilen j. girdi için alternatif yan değeri

c' : $HMCR$ işlemi sonucu elde edilen eşik değer

d' : $HMCR$ işlemi sonucu elde edilen eşik değer ile karşılaştırılacak olan gecikme

Örneğin $rnd_w < HMCR$ veya $rnd_b < HMCR$ ise; w'_j değeri w_{11} ile w_{HMS1} değeri arasında, b'_j değeri b_{11} ile b_{HMS1} değeri arasında rasgele seçilen bir değer olmaktadır. Aksi durumda bu ağırlık ve yan değerler, eşik değer ve eşik değer ile karşılaştırılacak gecikme; armoni belleğinde bulunan ve her bir değişken için en küçük değer ile en yüksek değer arasında üretilen rasgele bir değer olmaktadır (Guney and Onay, 2011). (m, q) girdili model için oluşturulan yeni armoni Şekil 5.1 'de verilmektedir.

w'_1	$\dots$	w'_m	b'_1	$\dots$	b'_m	θ'_1	$\dots$	θ'_q	a'_1	$\dots$	a'_q	c'	d'
--------	---------	--------	--------	---------	--------	-------------	---------	-------------	--------	---------	--------	------	------

Şekil 5.1. (m, q) Girdili Model İçin Oluşturulan Yeni Armoni

Adım 4.2. $HMCR$ dikkate alınarak yapılan işlemler sonucu oluşan yeni armonide bellekten seçilen değişken değerleri için PAR parametresi ile karar verilen ton ayarlama işlemi yapılmaktadır.

$$wp'_j = \begin{cases} w'_j \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ w'_j & d.d. \end{cases} \quad (36)$$

$$bp'_j = \begin{cases} b'_j \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ b'_j & d.d. \end{cases} \quad (37)$$

$$\theta p'_j = \begin{cases} \theta'_j \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ \theta'_j & d.d. \end{cases} \quad (38)$$

$$ap'_j = \begin{cases} a'_j \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ a'_j & d.d. \end{cases} \quad (39)$$

$$cp' = \begin{cases} c' \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ c' & d.d. \end{cases} \quad (40)$$

$$dp' = \begin{cases} d' \pm \text{depth}(PAR \times HMCR) & \text{rnd} < PAR \\ d' & d.d. \end{cases} \quad (41)$$

Burada $depth$, komşuluk derinlik indeksi olup, $depth \in \{\dots, -2, -1, 1, 2, \dots\}$ 'dir. Eşitlik (36-41)'de verilen rnd yani rasgele üretilen sayı, PAR oranından küçük ise değişken değerleri kendisine en yakın komşu değer ile değiştirilir. Örneğin algoritma 0,40'lık bir PAR değeri için $(0,40 \times HMCR)$ olasılığı ile komşuluk derinlik indeksi ($depth$) kullanarak hazırlanan vektör içinden bir komşu değer seçecektir. Örneğin w'_j değişkeni için ton ayarlaması yapılacaksa ve w'_j 'nin değişkeninin alabileceği değerler vektörü içinde k .sıradaki değer olduğu varsayılırsa $w'_j(k)$ 'nin ayarlanmış yeni değeri Eşitlik (42) ile verilmiştir.

$$wp'_j \leftarrow w'_j \pm k(PAR \times HMCR) \quad (42)$$

Örneğin, $w'_1 = 0,80$, $HMCR = 0,90$, $PAR = 0,40$, $depth = 2$ olarak alınsın. O halde komşu değerler vektörü $0,80 \pm 2(0,40 \times 0,90)$ işlemi gözetilerek Şekil 5.2'deki gibi elde edilir.

0,08	0,44	0,80	1,16	1,52
------	------	------	------	------

Şekil 5.2. w'_1 için elde edilen komşu değerler vektörü

PAR işlemi sonucu güncellenen armoni Şekil 5.3'de verilmiştir.

wp'_1	$\dots$	wp'_m	bp'_1	$\dots$	bp'_m	$\theta p'_1$	$\dots$	$\theta p'_q$	ap'_1	$\dots$	ap'_q	cp'	dp'
---------	---------	---------	---------	---------	---------	---------------	---------	---------------	---------	---------	---------	-------	-------

Şekil 5.3. (m, q) girdili model için PAR işlemi sonucu güncellenen armoni

Adım 5. Armoni belleği güncellenmesi

$HMCR$ ve PAR işlemleri sonucu elde edilen armoni için amaç fonksiyonu değeri hesaplanarak, HM içerisindeki amaç fonksiyonu değeri en kötü olan yani $HKOK$ değeri en yüksek olan armoni ile karşılaştırma yapılır. Burada $HMCR$ ve PAR işlemleri sonucu elde edilen armoninin $HKOK$ değeri, bellekteki en kötü $HKOK$ değerine sahip armoniden küçük ise bellekteki armoni bellekten çıkartılır ve yerine $HMCR$ ve PAR işlemleri sonucu elde edilen armoni belleğe alınır eğer değilse HM içerisinde herhangi

bir deęişiklik yapılmaz. Eşitlik (43)'de verilen HM 'de amaç fonksiyonu yüksek olan k .armoni yerine $HMCR$ ve PAR işlemleri sonucu elde edilen armoni HM matris yapısına dâhil edilerek, HM güncellenmesi tamamlanır.

$$HM = \begin{bmatrix} w_{11} & \cdots & w_{1m} & b_{11} & \cdots & b_{1m} & \theta_{11} & \cdots & \theta_{1q} & a_{11} & \cdots & a_{1q} & c_1 & d_1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ wp'_{k1} & \cdots & wp'_{km} & bp'_{k1} & \cdots & bp'_{km} & \theta p'_{k1} & \cdots & \theta p'_{kq} & ap'_{k1} & \cdots & ap'_{kq} & cp'_k & dp'_k \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{HMS1} & \cdots & w_{HMSm} & b_{HMS1} & \cdots & b_{HMSm} & \theta_{HMS1} & \cdots & \theta_{HMSq} & a_{HMS1} & \cdots & a_{HMSq} & c_{HMS} & d_{HMS} \end{bmatrix} \quad (43)$$

Adım 6. Durdurma koşulu kontrolü

Maksimum iterasyon sayısına ulaşmış ya da $HKOK$ değeri belirli bir hata ($\mathcal{E}$) değerinden küçük ise durdurma koşulu sağlanmış olur. Aksi halde Adım 4- Adım 6 işlemleri tekrarlanır.

Algoritma 2: Eşik Değerli Tek Çarpımsal Nöron Modelin GPSO Algoritması İle Eğitimi (GPSO-ED-TÇNM-YSA)

Adım 1. GPSO-ED-TÇNM-YSA'nın eğitimi sürecinde kullanılan parametrelerin belirlenmesi.

- m : Eşik değerden önce kurulan model için girdi sayısı
- q : Eşik değerden sonra kurulan model için girdi sayısı
- Ps : Parçacık sayısı
- PP : Parçacık pozisyon matrisi
- V : Parçacık hız matrisi
- c_1 : Bilişsel katsayı
- c_2 : Sosyal katsayı
- w : Eylemsizlik ağırlığı
- C : Eşik değeri
- d : Eşik değeri ile karşılaştırılacak gecikme

Adım 2. Parçacık pozisyonları ve hızların rasgele belirlenmesi.

Bu adımda, TÇNM-YSA’da kullanılacak girdi sayısına (m, q) bağlı olarak ağırlık, yan, alternatif ağırlık ve alternatif yan değerleri; bunlara ek olarak eşik değer ve eşik değer ile karşılaştırılacak gecikme değerlerinin bulunduğu bir parçacık pozisyon matrisi ve parçacık hız değerleri matrisi oluşturulur. Girdi sayıları ve parçacık sayısı dikkate alınarak, $Ps \times [2(m + q) + 2]$ boyutlu pozisyon ve hız değerleri Eşitlik (44-45) ile verilmiştir. ($i = 1:Ps$, $j = 1:2(m + q) + 2$)

$$PP = \begin{bmatrix} w_{11} & \dots & w_{1m} & b_{11} & \dots & b_{1m} & \theta_{11} & \dots & \theta_{1q} & a_{11} & \dots & a_{1q} & C_1 & d_1 \\ w_{21} & \dots & w_{2m} & b_{21} & \dots & b_{2m} & \theta_{21} & \dots & \theta_{2q} & a_{21} & \dots & a_{2q} & C_2 & d_2 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ w_{Ps1} & \dots & w_{Psm} & b_{Ps1} & \dots & b_{Psm} & \theta_{Ps1} & \dots & \theta_{Psq} & a_{Ps1} & \dots & a_{Psq} & C_{Ps} & d_{Ps} \end{bmatrix} = \begin{bmatrix} P_{1j} \\ P_{2j} \\ \vdots \\ P_{ij} \end{bmatrix} \quad (44)$$

$$V = \begin{bmatrix} V_{W11} & \dots & V_{W1m} & V_{b11} & \dots & V_{b1m} & V_{\theta11} & \dots & V_{\theta1q} & V_{a11} & \dots & V_{a1q} & V_{C1} & V_{d1} \\ V_{W21} & \dots & V_{W2m} & V_{b21} & \dots & V_{b2m} & V_{\theta21} & \dots & V_{\theta2q} & V_{a21} & \dots & V_{a2q} & V_{C2} & V_{d1} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ V_{WP s1} & \dots & V_{WP sm} & V_{bPs1} & \dots & V_{bPsm} & V_{\thetaPs1} & \dots & V_{\thetaPsq} & V_{aPs1} & \dots & V_{aPsm} & V_{Cps} & V_{dps} \end{bmatrix} \quad (45)$$

Adım 3. Amaç fonksiyonu değerine bağlı olarak P_{best} ve G_{best} belirlenmesi.

Her bir parçacık için amaç fonksiyonu değeri hesaplanır. Eşitlik (46)’de verilen C eşik değeri ile karşılaştırılacak X_{t-d_i} gecikme ilişkisine göre, hangi ağırlık ve yan değerlerinin kullanılacağı belirlenir.

Elde edilen çıktı değerleri ile hedef değerler kullanılarak hata kareler ortalaması karekökü ile her bir parçacığın amaç fonksiyonu değeri Eşitlik (29) ile hesaplanır. Burada parçacıkların en iyi pozisyonları $P_{best}; P_{ij}$ ($i = 1:Ps$, $j = 1:2(m + q) + 2$) vektörlerinde saklanır. Tüm parçacıkların en iyi konumu G_{best} ise HKOK’nın minimum olduğu g .parçacık P_{gj} vektörüdür. Eşitlik (47-48)’de P_{best} ve G_{best} vektörleri verilmektedir.

$$\hat{X}_t = \begin{cases} \frac{1}{1+\exp(-net1)} & X_{t-d_i} < c_i \\ \frac{1}{1+\exp(-net2)} & X_{t-d_i} > c_i \end{cases} \quad (46)$$

$$P_{best\ i} = [P_{i1} \ P_{i2} \ \dots \ P_{i(2x(m+q)+2)}]; \ i = 1, 2, \dots, Ps \quad (47)$$

$$G_{best} = [P_{g1} \ P_{g2} \ \dots \ P_{g(2x(m+q)+2)}] \quad (48)$$

Adım 4. w eylemsilik ağırlığı, c_1 bilişsel katsayı ve c_2 sosyal katsayı bileşenlerinin güncellenmesi.

GPSO'da w , c_1 ve c_2 katsayıları değerleri iterasyonlar içinde Eşitlik (49-51)'deki gibi güncellenir.

$$w = (w_{max} - w_{min}) \times \frac{maxk - k}{maxk} + w_{min} \quad (49)$$

$$c_1 = (c_{1f} - c_{1i}) \times \frac{k}{maxk} + c_{1i} \quad (50)$$

$$c_2 = (c_{2f} - c_{2i}) \times \frac{k}{maxk} + c_{2i} \quad (51)$$

Burada (c_{1f}, c_{1i}) bilişsel katsayı için; (c_{2f}, c_{2i}) sosyal katsayı için; (w_{max}, w_{min}) eylemsizlik ağırlığı için maksimum ve minimum değerlerdir. $maxk$ maksimum iterasyon sayısı, k ise geçerli iterasyon sayısını göstermektedir.

Adım 5. Yeni hız ve pozisyonların hesaplanması ve güncellenmesi.

Yeni hız ve pozisyon değerleri Eşitlik (52-63) ile hesaplanır. Burada c_1 ve c_2 sırası ile bilişsel ve sosyal katsayı olup, Kennedy ve Eberhart(1999)'ın çalışmasında da olduğu gibi, birçok çalışmada $c_1 = c_2 = 2$ alınarak iyi sonuçlar elde edildiği görülmektedir. $rand_1$ ve $rand_2$ ise 0 ile 1 aralığında tanımlı rasgele seçilen değerlerdir.

$$V_{w_{ij}}^{k+1} = w \times V_{w_{ij}}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - w_{ij}^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - w_{ij}^k) \quad (52)$$

$$V_{b_{ij}}^{k+1} = w \times V_{b_{ij}}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - b_{ij}^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - b_{ij}^k) \quad (53)$$

$$V_{\theta_{ij}}^{k+1} = w \times V_{\theta_{ij}}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - \theta_{ij}^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - \theta_{ij}^k) \quad (54)$$

$$V_{a_{ij}}^{k+1} = w \times V_{a_{ij}}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - a_{ij}^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - a_{ij}^k) \quad (55)$$

$$V_{C_i}^{k+1} = w \times V_{C_i}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - C_i^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - C_i^k) \quad (56)$$

$$V_{d_i}^{k+1} = w \times V_{d_i}^k + c_1 \times rand_1 \times (P_{best_{ij}}^k - d_i^k) + c_2 \times rand_2 \times (G_{best_{ij}}^k - d_i^k) \quad (57)$$

$$w_{ij}^{k+1} = w_{ij}^k + V_{w_{ij}}^{k+1} \quad (58)$$

$$b_{ij}^{k+1} = b_{ij}^k + V_{b_{ij}}^{k+1} \quad (59)$$

$$\theta_{ij}^{k+1} = \theta_{ij}^k + V_{\theta_{ij}}^{k+1} \quad (60)$$

$$a_{ij}^{k+1} = a_{ij}^k + V_{a_{ij}}^{k+1} \quad (61)$$

$$C_i^{k+1} = C_i^k + V_{C_i}^{k+1} \quad (62)$$

$$d_i^{k+1} = d_i^k + V_{d_i}^{k+1} \quad (63)$$

Adım 6. Durdurma koşulu kontrolü

Maksimum iterasyon sayısına ulaşmış ya da *HKOK* değeri belirli bir hata (ϵ) değerinden küçük ise durdurma koşulu sağlanmış olur. Aksi halde Adım 3- Adım 5 işlemleri tekrarlanır.

6. UYGULAMALAR


Bu tez çalışmasında önerilen yöntemler, literatürde sıklıkla analiz edilen Avusturalya Bira Tüketimi (AUST) zaman serisi, Türkiye Elektrik Tüketimi (TEC) zaman serisi ve Tayvan Vadeli İşlem Borsası (TAIFEX) zaman serisi verilerine uygulanmıştır. AUST zaman serisi 1957 yılının ikinci çeyreği ile 1994 yılının ilk çeyreği arasındaki gözlem değerlerine sahiptir. TEC zaman serisi ise 2002 yılının Ocak ayı ile 2013 yılının Aralık ayı arasında aylık olarak gözlem değerlerine sahiptir. TAIFEX zaman serisi ise 03.08.1998 ve 30.09.1998 arasında günlük gözlem değerlerine sahiptir.

İlgili zaman serilerinin analizi aşamasında MATLAB programı kullanılmış olup, bu üç zaman serisinin test kümesi performansı önerilen yöntem dışında literatürde mevcut olan birçok yöntemle karşılaştırılmıştır. Bu amaçla *HKOK* ve Eşitlik (64)'de verilen ortalama mutlak yüzde hata (*OMYH*) kriteri kullanılmıştır.

$$OMYH = \frac{1}{n} \sum_{t=1}^n \left| \frac{x_t - \hat{x}_t}{x_t} \right| \quad (64)$$

6.1. Avusturalya Bira Tüketimi Zaman Serisinin Analizi

Bu tez çalışmasında önerilen ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri ilk olarak grafiği Şekil 6.1’de verilen AUST zaman serisi verisine uygulanmıştır.



Şekil 6.1. AUST Zaman Serisi Grafiği

AUST zaman serisi ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinin dışında, geri yayılım öğrenme algoritmasına dayalı TÇNM-YSA (GY-TÇNM-YSA), PSO’ya dayalı çok katmanlı YSA (PSO-ÇK-YSA), radyal tabanlı YSA (RT-YSA), PSO’ya dayalı TÇNM-YSA (PSO-TÇNM-YSA), çok katmanlı ileri beslemeli YSA (ÇK-İB-YSA), Elman (1990) tarafından önerilen Elman Tip geri beslemeli YSA (E-YSA), Aladağ ve ark. (2013) tarafından önerilen PSO’ya dayalı çarpımsal mevsimsel YSA (ÇAR-S-YSA), budanmış ortalama nöron modeline dayanan çok katmanlı ileri besleme YSA (BO-ÇK-İB-YSA), Shin ve Gosh (1991) tarafından önerilen PSO’ya dayalı pi sigma YSA (PSO-PS-YSA) ve Bas (2016) tarafından önerilen DGA’ya dayalı TÇNM-YSA (DGA-TÇNM-YSA) yöntemleri ile analiz edilmiştir.

148 adet gözlem sayısına sahip AUST zaman serisinin analizinde son 16 gözlem test kümesi olarak alınmıştır. Modelin girdi sayısı m ve q değerleri 2, 4, 8 ve parçacık sayısı/armoni sayısı (ps/HMS) 30 olarak alınmıştır.

Önerilen ilk yöntem olan ARAR-ED-TÇNM-YSA'da $HMCR$ için 0,70; 0,80; 0,90 değerleri ile PAR için 0,30; 0,35; 0,40 değerleri denenmiş ve ayrıca iterasyon sayısı 200 olarak alınmıştır. Yapılan denemeler sonucunda en iyi çözüm $HMCR = 0,70$ ve $PAR = 0,40$ olduğunda; girdi sayısı $m = 8$ ve $q = 4$ iken elde edilmiş ve bu çözüme ait optimum parametre değerleri Tablo 6.1'de verilmiştir.

Tablo 6.1. AUST test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

w	0,740472	0,151606	0,65484	0,909055	0,714076	0,643523	0,899232	0,65181
b	0,945342	0,730423	0,856619	0,326691	0,977044	0,981082	0,607802	-0,25125
θ	0,231552	0,401213	0,259036	0,577178				
a	0,020208	0,928204	0,309112	-0,14196				
c	456,1342							
d	2							

Önerilen ikinci yöntem olan GPSO-ED-TÇNM-YSA yönteminde iterasyon sayısı 200 olarak alınarak yapılan denemeler sonucunda en iyi çözüm girdi sayısının $m = 4$ ve $q = 4$ olduğu durumda elde edilmiş ve bu çözüme ait optimum parametre değerleri Tablo 6.2'de verilmiştir.

Tablo 6.2. AUST test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

w	-0,65816	1,019225	1,385271	0,829994
b	1,788215	1,433376	1,345779	-0,44127
θ	2,399214	1,159766	0,635079	1,23846
a	-0,03449	-0,46995	0,904242	1,907434
C	409,0012			
d	10			


AUST zaman serisinin analizinde hem ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri hem de bu yöntemler ile karşılaştırılacak olan bazı YSA yöntemleri için $HKOK$ ve $OMYH$ kriterlerine göre elde edilen değerler Tablo 6.3'de verilmektedir.

Tablo 6.3. AUST test verisine ait analiz sonuçları

Yöntemler	<i>HKOK</i>	<i>OMYH</i>
GY-TÇNM-YSA	74,2551	0,0983
PSO-ÇK-YSA	44,7780	0,0856
RT-YSA	41,7000	0,0686
<u>ARAR-ED-TÇNM-YSA</u>	<u>33,3907</u>	<u>0,0633</u>
PSO-TÇNM-YSA	26,7831	0,0489
ÇK-İB-YSA	24,1052	0,0476
E-YSA	22,6581	0,0436
ÇAR-S-YSA	22,1700	0,0394
BO-ÇK-İB-YSA	21,0623	0,0399
PSO-PS-YSA	20,0886	0,0352
DGA-TÇNM-YSA	19,7819	0,0372
<u>GPSO-ED-TÇNM-YSA</u>	<u>18,8777</u>	<u>0,0331</u>

Tablo 6.3 incelendiğinde, AUST zaman serisinin analizi için, GPSO-ED-TÇNM-YSA'nın, *HKOK* ve *OMYH* kriterleri bakımından hem ARAR-ED-TÇNM-YSA yönteminden hem de karşılaştırılan diğer tüm yöntemlerden daha düşük *HKOK* ve *OMYH* değerlerine sahip olduğu görülmektedir. ARAR-ED-TÇNM-YSA yöntemi ise *HKOK* ve *OMYH* kriterleri bakımından yalnızca GY-TÇNM-YSA, PSO-ÇK-YSA ve RT-YSA yöntemlerinden daha iyi sonuç vermektedir. O halde GPSO-ED-TÇNM-YSA yönteminin AUST zaman serisinin analizi için ARAR-ED-TÇNM-YSA yönteminden daha iyi performans sağladığı söylenebilir.

Şekil 6.2'de AUST test verisine ait gerçek gözlem değerleri ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörü değerlerinin grafiği verilmektedir.




Şekil 6.2. AUST test kümesi ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörülerin birlikte grafiği

Şekil 6.2’de de görüldüğü gibi, AUST test kümesine ait gerçek gözlem değerleri ile GPSO-ED-TÇNM-YSA yönteminden elde edilen öngörülerin ARAR-ED-TÇNM-YSA yönteminden elde edilen öngörülere göre daha uyumlu olduğu görülmektedir.

6.2. Türkiye Elektrik Tüketimi Zaman Serisinin Analizi

Bu tez çalışmasında önerilen ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri ikinci olarak grafiği Şekil 6.3’de verilen AUST zaman serisi verisine uygulanmıştır.



Şekil 6.3. TEC zaman serisi grafiği

TEC zaman serisi ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinin dışında, GY-TÇNM-YSA, ÇK-İB-YSA, YYA-TÇNM-YSA, PSO-ÇK-YSA, TÇNM-YSA, Eğrioğlu ve Dalar (2017) tarafından önerilen deterministik trend ve mevsimsellik bileşenlerine sahip YSA (DT&M-YSA), PSO-PS-YSA, PSO-TÇNM-YSA, GB-PS-YSA yöntemleri ile analiz edilmiştir.

144 adet gözlem sayısına sahip TEC zaman serisinin analizinde son 12 gözlem test kümesi olarak alınmıştır. Modelin girdi sayısı 5 ile 15 arasında birer artırılarak, parçacık sayısı/armoni sayısı (ps/HMS) 30 olduğunda denemeler yapılmıştır.

Önerilen ilk yöntem olan ARAR-ED-TÇNM-YSA’da $HMCR$ için 0,70; 0,80; 0,90 değerleri ve PAR için 0,30; 0,35; 0,40 değerleri denenmiş ve ayrıca iterasyon sayısı olarak alınmıştır. Yapılan denemeler sonucunda en iyi çözüm $HMCR = 0,70$ ve $PAR = 0,40$ olduğu; girdi sayısının $m = 12$ ve $q = 10$ iken elde edilmiş ve bu çözüme ait parametre değerleri Tablo 6.4’de verilmiştir.

Tablo 6.4. TEC test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

	0,8887	0,7219	0,7152	0,8139	0,8950	0,3588
w	0,3199	0,2292	0,6236	0,7547	0,8716	0,9476
	0,4266	0,7595	0,4118	0,3310	0,7537	0,7895
b	0,3801	0,8208	0,6552	0,9515	0,8452	-0,3392
	0,8312	0,3969	0,3661	0,9892	0,4912	
θ	0,2352	0,7170	0,7096	0,2152	0,0276	
	0,4481	0,0604	0,7276	0,6235	0,7889	
a	0,1032	0,2835	0,4189	0,5710	0,1775	
c	21087127239,3576					
d	4					

Önerilen ikinci yöntem olan GPSO-ED-TÇNM-YSA’da iterasyon sayısı 200 iken yapılan denemeler sonucunda en iyi çözüm girdi sayısının $m = 14$ ve $q = 6$ olduğu durumda elde edilmiştir ve bu çözüme ait optimum parametre değerleri Tablo 6.5’de verilmiştir.

Tablo 6.5. TEC test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

	0,0355	-0,0679	0,2911	0,3104	0,3404	0,1375	-0,5496
w	-0,2526	-0,9464	1,2602	-0,6809	1,5633	0,7459	-0,6587
	0,6331	0,4798	0,6998	0,7390	1,2423	0,4282	1,9943
b	1,4965	1,7918	2,4443	1,7035	-0,6615	0,9592	1,4456
θ	-0,2011	1,1454	0,3563	0,0357	0,3328	0,8762	
a	1,0004	0,5122	-0,0013	0,5295	-0,1626	0,8019	
C	14995143592,5183						
d	7						


TEC zaman serisinin analizinde hem ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri hem de bu yöntemler ile karşılaştırılacak olan bazı YSA yöntemleri için *HKOK* ve *OMYH* kriterlerine göre elde edilen değerler Tablo 6.6’da verilmektedir.

Tablo 6.6. TEC test verisine ait analiz sonuçları

Yöntemler	<i>HKOK</i>	<i>OMYH</i>
GY-TÇNM-YSA	4243944603	19,54%
ÇK-İB-YSA	1065900000	3,98%
YYA-TÇNM-YSA	924149635	3,73%
PSO-ÇK-YSA	915190000	3,39%
TÇNM-YSA	813260000	3,01%
DT&M-YSA	810300852	2,47%
<u>ARAR-ED-TÇNM-YSA</u>	<u>772262044</u>	<u>3,15%</u>
PSO-PS-YSA	697763268	2,81%
PSO-TÇNM-YSA	672790000	2,89%
GB-PS-YSA	651383248	2,22%
<u>GPSO-ED-TÇNM-YSA</u>	<u>605542432</u>	<u>2,38%</u>

Tablo 6.6 incelendiğinde, TEC zaman serisinin analizi için, GPSO-ED-TÇNM-YSA'nın, *HKOK* kriteri bakımından hem ARAR-ED-TÇNM-YSA yönteminden hem de karşılaştırılan diğer tüm yöntemlerden daha düşük *HKOK* değerine sahip olduğu ve *OMYH* kriteri bakımından ise GB-PS-YSA yöntemi dışında ARAR-ED-TÇNM-YSA yöntemi de dâhil olmak üzere diğer tüm yöntemlerden daha düşük *OMYH* değerine sahip olduğu görülmektedir. ARAR-ED-TÇNM-YSA yöntemi ise hem GB-PS-YSA, PSO-TÇNM-YSA ve PSO-PS-YSA yöntemlerinden hem de GPSO-ED-TÇNM-YSA yönteminden daha yüksek *HKOK* ve *OMYH* değerlerine sahiptir. O halde GPSO-ED-TÇNM-YSA yönteminin TEC zaman serisinin analizi için ARAR-ED-TÇNM-YSA yönteminden daha güvenilir öngörü sonuçları ürettiği söylenebilir.

Şekil 6.4'de TEC test verisine ait gerçek gözlem değerleri ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörü değerlerinin grafiği verilmektedir.




Şekil 6.4. TEC test kümesi ile ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinden elde edilen öngörülerin birlikte grafiği

Şekil 6.4’de de görüldüğü gibi, TEC test kümesine ait gerçek gözlem değerleri ile GPSO-ED-TÇNM-YSA yönteminden elde edilen öngörülerin ARAR-ED-TÇNM-YSA yönteminden elde edilen öngörülere göre daha uyumlu olduğu görülmektedir.

6.3. Tayvan Vadeli İşlem Borsası Zaman Serisinin Analizi

Bu tez çalışmasında önerilen ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri ikinci olarak grafiği Şekil 6.5’de verilen TAIFEX zaman serisi verisine uygulanmıştır.



Şekil 6.5. TAIFEX zaman serisi grafiği

TAIFEX zaman serisi ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemlerinin dışında, GY-TÇNM-YSA, PSO-PS-YSA, Lee ve ark. (2007), Lee ve ark. (2008), PSO-TÇNM-YSA, Hsu ve ark. (2010), YAK-TÇNM-YSA ve DGA-TÇNM-YSA çalışmaları ile analiz edilmiştir.

47 adet gözlem sayısına sahip TAIFEX zaman serisinin analizinde son 16 gözlem test kümesi olarak alınmıştır. Modelin girdi sayısı 1 ile 10 arasında birer artırılarak, parçacık sayısı/armoni sayısı (ps/HMS) 30 olduğunda denemeler yapılmıştır.

Önerilen ilk yöntem olan ARAR-ED-TÇNM-YSA’da $HMCR$ için 0,70; 0,80; 0,90 değerleri ve PAR için 0,30; 0,35; 0,40 değerleri denenmiş ve ayrıca iterasyon sayısı olarak alınmıştır. Yapılan denemeler sonucunda en iyi çözüm $HMCR = 0,70$ ve $PAR = 0,40$ olduğu; girdi sayısının $m = 1$ ve $q = 1$ iken elde edilmiş ve bu çözüme ait optimum parametre değerleri Tablo 6.7’de verilmiştir.

Tablo 6.7. TAIFEX test verisi için ARAR-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

w	b	θ	a	c	d
0,9846	-0,5670	0,6284	0,7031	7048,6751	9

Önerilen ikinci yöntem olan GPSO-ED-TÇNM-YSA’da iterasyon sayısı 200 iken yapılan denemeler sonucunda en iyi çözüm girdi sayısının $m = 10$ ve $q = 2$ olduğu durumda elde edilmiş ve bu çözüme ait optimum parçacık/ parametre değerleri Tablo 6.8’de verilmiştir.

Tablo 6.8. TAIFEX test verisi için GPSO-ED-TÇNM-YSA ile elde edilen optimum parametre değerleri

w	1,0253	-0,3851	-1,0446	0,6366	0,5266
b	-0,8417	1,6641	0,4522	0,5322	0,7826
θ	-0,5328	0,4642	1,6442	0,0116	0,6940
a	1,3608	18,6949	1,6084	1,9027	0,0571
c	0,5033	0,3349			
d	0,3898	0,4733			
	7162,7812				
	7				

TAIFEX zaman serisinin analizinde hem ARAR-ED-TÇNM-YSA ve GPSO-ED-TÇNM-YSA yöntemleri hem de bu yöntemler ile karşılaştırılacak olan bazı YSA yöntemleri için *HKOK* ve *OMYH* kriterlerine göre elde edilen değerler Tablo 6.9’de verilmektedir.

Tablo 6.9. TAIFEX test verisine ait analiz sonuçları

Yöntemler	<i>HKOK</i>	<i>OMYH</i>
GY-TÇNM-YSA	108,1627	1.17%
Lee ve ark. (2008)	102,9600	1.14%
PS-YSA	94,1439	1.01%
Lee ve ark. (2007)	93,4900	1.09%
PSO-TÇNM-YSA	88,5839	0.87%
Hsu ve ark.	80,0200	0.87%
YAK-TÇNM-YSA	79,8623	0.95%
DGA-TÇNM-YSA	79,2514	0.95%
<u>ARAR-ED-TÇNM-YSA</u>	<u>77,4153</u>	<u>0,88%</u>
<u>GPSO-ED-TÇNM-YSA</u>	<u>77,0761</u>	<u>0,87%</u>

Tablo 6.9 incelendiğinde, TAIFEX zaman serisinin analizi için, hem GPSO-ED-TÇNM-YSA yönteminin hem de ARAR-ED-TÇNM-YSA yönteminin *HKOK* ve *OMYH* kriterleri bakımından diğer tüm yöntemlerden daha düşük *HKOK* ve *OMYH* değerlerine sahip olduğu görülmekte ve GPSO-ED-TÇNM-YSA yöntemi ile ARAR-ED-TÇNM-YSA yönteminin birbirine çok yakın sonuçlar ürettiği görülmektedir.



7. SONUÇ VE ÖNERİLER

Bu çalışmada TÇNM-YSA literatüründeki çalışmalardan farklı olarak tek bir model yerine bir eşik değeri yardımı ile elde edilen iki farklı model elde edilmiş ve TÇNM-YSA'nın eğitimi neticesinde elde edilen parametreler ARAR ve GPSO yöntemleriyle elde edilmiştir. Önerilen yöntemlerin performansı değerlendirilirken üç farklı gerçek hayat zaman serisi kullanılmıştır.

Yöntemlerin performansı tüm zaman serisinde de incelendiğinde; GPSO'ya dayalı eşik değeri çarpımsal nöron model YSA'da, ARAR'a dayalı eşik değeri çarpımsal nöron model YSA'dan daha iyi sonuç elde edildiği görülmektedir.

Gelecek çalışmalarda eşik değeri mantığının diğer bazı yapay sinir ağı modellerine uygulanması ve tek bir eşik değeri yerine birden çok eşik değeri kullanılarak farklı modeller elde edilmesi ve aynı zamanda farklı zaman serisi verileri üzerinde de analizler yapılması planlanmaktadır.

8. KAYNAKLAR

- Aladag, C.H., Yolcu, U., Egrioglu, E. (2013). A New Multiplicative Seasonal Neural Network Model Based On Particle Swarm Optimization. *Neural Processing Letters*, 37(3), 251-262.
- Bas, E. (2016). The training of multiplicative neuron model based artificial neural networks with differential evolution algorithm for forecasting. *Journal of Artificial Intelligence and Soft Computing Research*, 6(1), 5-11.
- Cagcag Yolcu, O., Bas, E., Egrioglu, E. , Yolcu, U. (2018). Single multiplicative neuron model artificial neural network with autoregressive coefficient for time series modelling, *Neural Processing Letters*, 47(3), 1133-1147
- Cui, H., Feng, J., Guo, J., Wang, T. (2015). A novel single multiplicative neuron model trained by an improved glowworm swarm optimization algorithm for time series prediction. *Knowledge*, 88, 195-209.
- Egrioglu, E., Aladag, C.H., Yolcu, U., Bas, E., Dalar, A.Z. (2017) A new neural network model with deterministic trend and seasonality components for time series forecasting. *Advances in Time Series Forecasting*, 2, 76-92.
- Elman, J.L. (1990). Finding Structure in Time. *Cognitive Science*, 14, 179-211.
- Geem, Z. W. (2006). Optimal Cost Design Of Water Distribution Networks Using Harmony Search. *Engineering Optimization*, 38(3), 259-277.
- Geem, Z. W., Kim, J. H. , Loganathan, G. V. (2001). A New Heuristic Optimization Algorithm: Harmony Search. *Simulation*, 76(2), 60-68.
- Guney, K. , Onay M. (2011). Optimal Synthesis of Linear Antenna Arrays Using a Harmony Search Algorithm. *Expert Systems with Applications*. doi: 10.1016/j.eswa.2011.06.015.
- Henao, J.D.V., Mejia, V.M.R. , Cardona, C.J.F. (2013). Electricity Demand Forecasting Using A SARIMA-Multiplicative Single Neuron Hybrid Model. *Dyna*, 80(180), 4-8.

- Hsu, L.Y., Horng, S.J., Kao, T.W., Chen, Y.H., Run, R.S., Chen, R.J. (2010) Temperature prediction and TAIEX forecasting based on fuzzy relationship and MTPSO techniques. *Expert Systems with Applications*, 37, 2756–2770.
- <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf>
- <https://yapayzeka.ai/yapay-zeka-5-sezgisel-algoritmalar/>
- Kahraman, H.T. (2016) Yapay Zekâya Giriş, yayımlanmamış ders notu, Endüstri Mühendisliği Bölümü, Karadeniz Teknik Üniversitesi, Trabzon.
- Kennedy, J., Eberhart, R.C. (1995). Particle Swarm Optimization. In *Proceedings Of IEEE International Conference On Neural Networks*, 1942-1948.
- Kennedy, J., Eberhart, R.C. (1999). The particle swarm: social adaptation in information processing systems, in: D.Corne, M.Dorigo, F. Glover (Eds.), *New Ideas in Optimization*, McGraw-Hill, Cambridge, UK, 379-387.
- Kolay, E. (2019). A Novel Multiplicative Neuron Model Based On Sine Cosine Algorithm For Time Series Prediction. *Anadolu University Journal Of Science And Technology A - Applied Sciences And Engineering*, 20(2), 153-160
- Lee, L.W., Wang, L.H., Chen, S.M. (2007) Temperature prediction and TAIEX forecasting based on fuzzy logical relationships and genetic algorithms. *Expert Systems with Applications*, 33, 539–550.
- Lee, L.W., Wang, L.H., Chen, S.M. (2008) Temperature prediction and TAIEX forecasting based on high-order fuzzy logical relationships and genetic simulated annealing techniques. *Expert Systems with Applications*, 34, 328–336.
- McCulloch, Warren S. , Pitts., W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5, 115-133.
- Öztemel, E., 2016, Yapay Sinir Ağları, Papatya Yayıncılık
- Shi, Y. , Eberhart, R.C. (1998). A Modified Particle Swarm Optimizers. *Proceedings of the IEEE International Conference on Evolutionary Computation*, IEEE Press, Piscataway, NJ, 69-73.
- Shin,Y. , Ghosh, J. (1991) The pi-sigma network: An efficient higher-order

neural network for pattern classification and function approximation. IJCNN-91-Seattle Yapay Sinir Ağları Ortak konferansı. DOI: 10.1109/IJCNN.1991.155142

- Wu, X., Mao, J., Du, Z., Chang, Y. (2013). Online training algorithms based single multiplicative neuron model for energy consumption forecasting. *Energy*, 59, 126-132.
- Wu, X., Zhu, Z., Su, X., Fan, S., Du, Z., Chang, Y., Zeng, Q. (2015). A study of single multiplicative neuron model with nonlinear filters for hourly wind speed prediction. *Energy*, 88, 194-201.
- Xiaohui, H. 2006. PSO Tutorial. <http://www.swarmintelligence.org/tutorials.php>
- Yadav, R.N., Kalra, P.K., John, J. (2007). Time series prediction with single multiplicative neuron model. *Applied Soft Computing*, 7, 1157-1163.
- Yolcu, U., Egrioglu, E., Aladag, C.H. (2013) A new linear & nonlinear artificial neural network model for time series forecasting. *Decision Support Systems*, 1340–1347.
- Zhao, L., Yang, Y. (2009). PSO-based single multiplicative neuron model for time series prediction. *Expert Systems with Applications*, 36(2), 2805-2812.

ÖZGEÇMİŞ

Asiye Nur YILDIRIM, 30 Mart 1995 tarihinde Görele’de doğmuştur. 2009-2013 yılları arasında Tirebolu Anadolu Lisesi’nde lise öğrenimini tamamlamıştır. 2013 yılında başladığı Karadeniz Teknik Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümünü 2017 yılında bitirmiş ve YILKA Gıda San. Tic. Ve Paz. LTD. ŞTİ.’de endüstri mühendisi olarak çalışmaya başlamıştır. 2018 yılı bahar dönemi Giresun Üniversitesi Fen Bilimleri Enstitüsü İstatistik ABD Yüksek Lisans programına başlamıştır. 2017 yılında endüstri mühendisi olarak çalışmaya başladığı firmada halen endüstri mühendisi olarak görev yapmaktadır.