



Düzce Üniversitesi Bilim ve Teknoloji Dergisi

Araştırma Makalesi

Güve-Alev Optimizasyon Algoritması Kullanarak *Pleurotus cornucopiae* var. *citrinopileatus* Mantarı Ekstraksiyon Koşullarının Optimizasyonu

 Ayşenur GÜRGEN *

Orman Endüstri Mühendisliği, Orman Fakültesi, Karadeniz Teknik Üniversitesi, Trabzon, TÜRKİYE

* Sorumlu yazarın e-posta adresi: ayşenur.yilmaz@ktu.edu.tr

DOI: 10.29130/dubited.1053119

ÖZ

Bu çalışmanın amacı, *Pleurotus cornucopiae* var. *citrinopileatus* mantarı ekstraksiyon koşullarının yapay zekâ metotlarıyla optimize edilmesidir. Bu amaç doğrultusunda %0, 30, 60, 90 etanol oranı kullanılarak, 1, 2 ve 4 mg/mL ekstrakt konsantrasyonunda elde edilen ekstraktların, 1,2, 3, 4,2 ve 6 pH koşullarındaki antioksidan aktiviteleri mevcut bir deneysel çalışmadan elde edilmiştir. Ekstraksiyon koşullarının modellenmesi Yapay Sinir Ağları (YSA) ile yapılmış ve Güve-Alev Optimizasyon (GAO) algoritması kullanılarak optimize edilmiştir. En iyi tahmin modelini elde etmek için farklı gizli nöron sayıları denenmiş ve en uygun gizli nöron sayısı 5 olarak bulunmuştur. Elde edilen bu modelin hata karelerinin ortalaması ve ortalama mutlak yüzde hatası tüm veri seti için sırasıyla 1,79 ve %3,24 olarak bulunmuştur. Optimizasyon süreci sonrasında maksimum antioksidan aktivite %56,76 olarak bulunmuştur ve bu sonucu elde etmek için optimum ekstraksiyon parametreleri %66,34 etanol oranı, 4 mg/mL ekstrakt konsantrasyonu ve 2,36 pH olarak belirlenmiştir. Bu çalışma, YSA ve GAO algoritmasının birlikte kullanılması ile ekstraksiyon koşullarının optimizasyonunda zaman, emek ve maliyet verimliliği sağlandığını ortaya koymuştur.

Anahtar Kelimeler: Ekstraksiyon koşulları, Güve-Alev Optimizasyon Algoritması, *Pleurotus cornucopiae* var. *citrinopileatus*, Yapay Sinir Ağları

Optimizing *Pleurotus cornucopiae* var. *citrinopileatus* Mushroom Extraction Conditions Using Moth-Flame Optimization Algorithm

ABSTRACT

The aim of this study is to optimize the extraction conditions of *Pleurotus cornucopiae* var. *citrinopileatus* using artificial intelligence methods. For this purpose, the antioxidant activities of the extracts -which were prepared 1, 2 and 4 mg/mL extract concentrations using 0, 30, 60, 90 % ethanol ratio- at 1,2, 3, 4.2 and 6 pH conditions were obtained from an previous experimental study. The extraction conditions were modelled using Artificial Neural Networks (ANN) and optimized using Moth-Flame Optimization (MFO) algorithm. In order to obtain the best prediction model, different numbers of hidden neurons were tried and the optimal number of hidden neurons was found to be 5. The mean of squares of error and mean absolute percent error of this model were found to be 1.79 and 3.24%, respectively, for the all data set. After the optimization process, the maximum antioxidant activity was found to be 56.76%, and the optimum extraction parameters were determined as 66.34% ethanol ratio, 4 mg/mL extract concentration and 2.36 pH to obtain this result. This study revealed that the use ANN and MFO algorithm integration provides time, labor and cost efficiency in the optimization of extraction conditions.

Keywords: Extraction conditions, Moth-Flame Optimization algorithm, *Pleurotus cornucopiae* var. *citrinopileatus*, Artificial Neural Network

I. GİRİŞ

Makrofunguslar, eski çağlardan beri dünya çapında değerli bir besin kaynağı ve geleneksel ilaçlar olarak kullanılmaktadırlar [1]. Doğada iki binden fazla mantar türü olmasına karşın yaygın olarak kullanılanların sayısı yaklaşık 25 olup bunların çok azı ticari olarak yetiştirilmektedir [2]. İstiridye mantarları *Pleurotus* spp., dünyada en çok üretilen üçüncü yenilebilir mantardır [3]. Bu mantarlar, hidrolize edici ve oksitleyici enzimleri salgılama [4] ve tarımsal atıklardan oluşan karmaşık organik bileşiklere ve endüstriyel yan ürünlere geniş bir dönüşüm adaptasyonu kabiliyetine sahiptirler [5]. Dolayısıyla, istiridye mantarlarının üretimi, bertarafı sorun haline gelen diğer organik atıkların yönetimine oranla daha az problem teşkil etmektedir. [6]. Polisakkaritler, diyet lifi, ergosterol, B vitaminleri, D vitamini ve mineraller dahil olmak üzere çeşitli biyoaktif bileşikler içeren istiridye mantarlarının besin değeri oldukça yüksektir [7], [8]. Ayrıca istiridye mantarlarının antioksidan, antimikrobiyal, antiviral, antibakteriyel, antitümör, antiinflamatuar, antikanser, antidiyabetik gibi çok çeşitli tıbbi özelliklere sahip oldukları yapılan birçok çalışma ile kanıtlanmıştır [9], [15].

Pleurotus türleri arasında, *Pleurotus cornucopiae*, mantar bünyesinden tıbbi metabolitlerin izolasyonu ile cins içinde önemli bir tür olarak ortaya çıkmaktadır [16]. Yapılan bir çalışmada *Pleurotus* cinsinin 18 farklı türünün antioksidan, antitümörjenik, antihipertansif, antitrombotik, antidiyabetik ve antiinflamatuar özellikleri araştırılmıştır. Aynı çalışmada mantarların amino asit, β -glukan ve polifenol içerikleri de ölçülmüştür. Çalışmaya konu olan türler arasında, *Pleurotus cornucopiae* var. *citrinopileatus* (sarı istiridye) mantarının en yüksek β -glukan içeriğine ve DPPH (1,1-Difenil-2-pikrilhidrazil radikali) süpürme oranı verilerine göre en yüksek antioksidan aktiviteye sahip olduğu görülmüştür. Ayrıca bu mantar anjiyotensin dönüştürücü enzim (ACE) aktivitesi üzerinde en yüksek inhibitör etkiyi göstermiştir. Son olarak, sarı istiridye, anti-diyabetik ve antiinflamatuar özellikler sergilemiştir. Çalışılan tüm mantarlar arasında, araştırmacılar sarı istiridyenin umut verici fonksiyonel bir gıda potansiyelinde olduğunu vurgulamışlardır [17].

Mantarların yapılan çalışmalar ile kanıtlanan tıbbi özellikleri bünyelerinde bulduklarını biyoaktif bileşikler sayesinde ve biyoaktif bileşiklerin ekstraksiyonu, bu bileşikleri kullanmada ilk adımdır [18]. Biyoaktif bileşiklerin ekstraksiyonu için en yaygın olarak kullanılan solventler etanol, metanol, aseton gibi çözücüler veya bunların su ile karışımının kullanıldığı çözeltilerdir [19]. Ayrıca bu bileşiklerin ekstraksiyonunun, ekstraksiyon sıcaklığı, zamanı, solvent türü ve oranı, ekstraksiyon konsantrasyonu, solvent-katı oranı, partikül boyutu ve pH gibi farklı ekstraksiyon koşullarından etkilendiği yapılan birçok çalışma ile bildirilmiştir [20], [24]. Dolayısıyla ekstraksiyon koşullarının optimize edilmesi, hedef bileşiklerden en verimli şekilde yararlanmak için çok önemli bir adımdır.

Araştırmacılar ekstraksiyon koşullarını optimizasyon çalışmalarında cevap yüzey metodunu sıklıkla kullanılmaktadırlar [21], [25], [26]. Bu metot, uygulanabilir alanın küçük bölümleri üzerinde bazı polinom tahminleri yoluyla orijinal problemi basitleştirmeye çalışır, fakat gerçek dünya problemleri genellikle çok karmaşık olduğundan, polinom tahmini, amaç fonksiyonunun temsiliyi sağlamada iyi performans göstermeyebilir. Ayrıca yerel minimum ya da yerel maksimum içinde sıkışıp kalmak bu metodun dezavantajlarından birisidir [29]. Bu sorunları aşmak için optimizasyon çalışmalarında yapay zekâ tekniklerinden biri olan Yapay Sinir Ağları (YSA) kullanımı alternatif bir çözüm olabilir. YSA, verilerden öğrenme, genellemeler yapma, sınırsız sayıda değişkenle çalışma gibi birçok önemli özelliğe sahiptir ve oldukça karmaşık, doğrusal olmayan problemleri ele almak için etkili bir yöntemdir [30], [32]. Ayrıca yüksek doğrulukta tahmin etme yeteneği birçok çalışma tarafından kanıtlanmıştır [33], [35].

Optimizasyon teknikleri, makineler ile optimum tasarımları bulmada kullanılan en iyi araçlardan biri olarak kabul edilmektedir. Genel olarak algoritmalar deterministik ve stokastik algoritmalar olmak üzere ikiye ayrılmaktadır. Deterministik algoritmalar, benzer başlangıç noktasına sahip belirli bir problem için aynı cevabı güvenilir bir şekilde belirleyebilmektedir. Bununla birlikte, bu davranış, deterministik optimizasyon teknikleri için bir dezavantaj olarak kabul edilebilecek yerel optimal tuzağa neden olmaktadır. Yerel optimal durgunluk, bir algoritmanın yerel çözümlerde tuzağa

düşmesine ve sonuç olarak gerçek global optimumu bulunamamasına sebep olmaktadır. Gerçek problemler çok fazla sayıda yerel çözüme sahip olduğu için deterministik algoritmalar genellikle tercih edilmemektedir. Metasezgisel algoritmalar, stokastik operatörlere sahip algoritma ailesini ifade etmektedir. Rastgelelik, stokastik algoritmaların temel özelliğidir. Bu, arama alanlarında global optimumu ararken rastgele operatörler kullandıkları anlamına gelmektedir. Bu tür tekniklerin rastgele doğası, her çalışmada benzer bir çözüm elde etmede onları güvenilir hale getirirse de yerel çözümlerden deterministik algoritmalarla göre çok daha kolay kaçınabilmektedirler. Stokastik davranış ayrıca her çalışmada belirli bir problem için farklı çözümler elde edilmesiyle sonuçlanmaktadır. Bu tür yaklaşımlar, sorunları kara kutular olarak ele alır ve en uygun tasarımlara yaklaşmaktadırlar. Stokastik algoritmalarda optimizasyon süreci, belirli bir problem için bir dizi rastgele aday çözümle başlamakta ve bunları, önceden tanımlanmış adımlarla geliştirmektedir. Meta sezgisel algoritmalar birkaç kez çalıştırıldığında daha iyi bir çözüm elde etme olasılığı artmakta ve global optimuma yaklaşmaktadır [36].

Meta sezgisel algoritmalar bireysel tabanlı algoritmalar ve popülasyona dayalı algoritmalar olarak ikiye ayrılır. Bireysel tabanlı algoritmalarda optimizasyon süreci tek bir rastgele çözümle başlar ve yinelemeler üzerinden devam eder. Bireysel tabanlı algoritmaların işlev değerlendirmesi ve hesaplama maliyeti, popülasyon tabanlı algoritmalarla göre daha düşüktür. Bununla birlikte erken yakınsama en büyük dezavantaj olarak karşımıza çıkmaktadır. Erken yakınsama ile algoritma yerel optimuma takılarak global optimumun elde edilmesini zorlaştırır. Popülasyon tabanlı algoritmalar, erken yakınsama sorununun üstesinden daha kolayca gelmektedir. Ayrıca aday çözümlerin arama alanlarındaki farklı zorlukların üstesinden gelmelerine yardımcı olan bilgiler arasında bilgi alışverişi yapabilir. Genetik algoritma en popüler popülasyon tabanlı optimizasyon algoritmalarından biridir. Bununla beraber No Free Lunch [37] teoremine dayanarak her yıl literatüre onlarca yeni algoritma eklenmektedir. Bu teoreme göre herhangi bir algoritma tüm optimizasyon problemlerinde üstün performans sağlamayı garanti etmemektedir [38].

Ekstraksiyon koşullarının öneminin bilinmesiyle ekstraksiyon parametrelerinin optimizasyonu ile ilgili çalışmalar her geçen gün artmaktadır. Bu çalışmanın amacı *Pleurotus* türleri arasında önemli bir yeri olan *Pleurotus cornucopiae* var. *citrinopileatus* mantarının ekstraksiyon koşullarının yapay zeka teknikleri kullanılarak optimize edilmesidir. Bunun için gerekli veriler, daha önce gerçekleştirilmiş deneysel bir çalışmadan elde edilmiş veriler önce YSA ile modellenmiş ve en iyi ağ seçilmiştir. Daha sonra popülasyon tabanlı güncel bir algoritma olan Güve-Alev Optimizasyon (GAO) algoritması kullanılarak optimizasyon işlemi gerçekleştirilmiştir.

II. MATERİYAL VE YÖNTEM

A. VERİ SETİ

Çalışmanın veri setini, daha önce yapılan bir çalışmanın deneysel verilerinin bir kısmı oluşturmaktadır. Bu çalışmaya konu olan verilerin elde edilişi kısaca şu şekilde özetlenebilir. Lee vd. [37] nin yaptığı bir çalışmada *Pleurotus cornucopiae* Rolland var. *citrinopileatus* mantarının antioksidan aktivitelerine farklı ekstraksiyon şartlarının etkilerini araştırılmıştır. Çalışmada mantar kuru halde satın alınmış ve bir karıştırıcı ile toz haline getirilmiştir. Ekstraksiyon ise bir mikrodalga ekstraksiyon cihazı kullanılarak gerçekleştirilmiştir. Kuru mantar ağırlığın solvante oranı 1:50 ve ekstraksiyon solventinin konsantrasyonu su, %30, %60 ve %90 etanol olacak şekilde ekstraktlar hazırlanmıştır. Mikrodalga ekstraksiyon koşulları, 90 watt'lık enerji kapasitesi ve 5 dakikalık ekstraksiyon süresi ile aynı koşullar altında ekstrakte edilmiştir. Ayrıca her ekstraktın 1, 2 ve 4 mg/mL konsantrasyondaki ekstraktları hazırlanmıştır ve farklı pH koşulları altında (1,2, 3,0, 4,2 ve 6,0) antioksidan aktiviteleri araştırılmıştır. Antioksidan aktivite olarak elde edilen ekstraktların nitrit süpürme aktivitesi Gray ve Dugan [38] metoduna göre ölçülmüştür ve sonuçlar yüzde (%) cinsinden rapor edilmiştir.

B. YAPAY SİNİR AĞLARI

Basit bilgi işlem birimlerine sahip bir yapay sinir ağı, edinilen bir bilgiyi depolayarak daha sonra kullanıma sunan ve büyük ölçüde paralel dağıtılmış bir işlemci olarak nitelendirilmektedir. Dolayısıyla bir YSA, insan beyni ile iki açıdan paralellik göstermektedir [39];

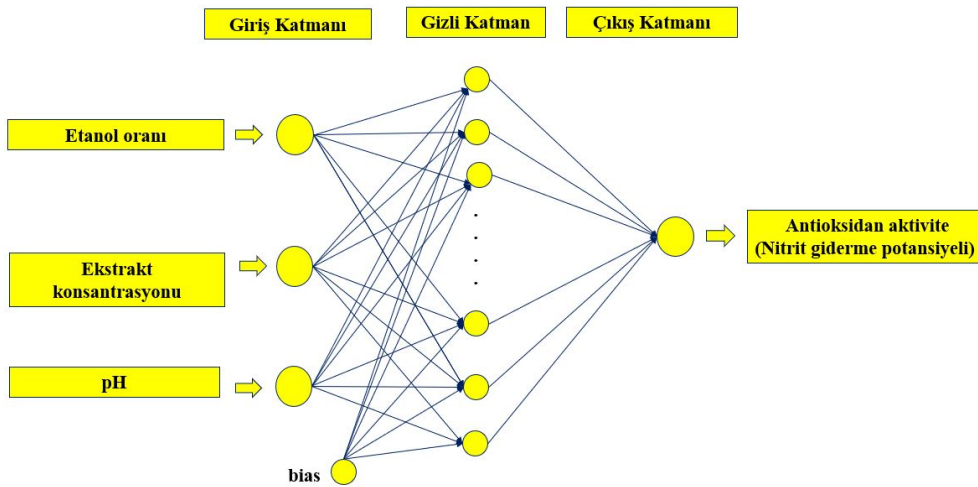
- Bilginin dış ortamdan elde edilmesinde öğrenme süreci devreye girmektedir
- Nöron bağlantı kuvvetleri, edinilen bilgiyi depolamak için kullanılmaktadır.

YSA, girdi, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı olmak üzere beş temel elemandan oluşmaktadır. Çevreden veya başka bir hücreden alınan bilgiler, girdi olarak tanımlanmaktadır. Ağırlıklar, mevcut bilginin hücre üzerindeki etkisini gösteren elmanlardır. Hücreye gelen bütün girdileri işleyerek net girdiyi hesaplamak için toplama fonksiyonu kullanılmaktadır. Toplama fonksiyonu için toplam, çarpım, maksimum ve minimum gibi fonksiyonlar bulunmakla beraber literatürde en yaygın olan Denklem 1’de gösterilen toplam fonksiyonudur.

$$Net = \sum_{i=1}^n X_i * W_i \quad (1)$$

burada X girdi değerini, W ilgili girdinin ağırlık değerini ve n girdi sayısını göstermektedir. Girdiler, ilgili ağırlıklar ile çarpılır ve tüm değerler toplanarak net girdi hesaplanır. Toplama fonksiyonundan gelen net girdi, aktivasyon fonksiyonunda işlenerek hücrenin bu girdiye karşılık üreteceği çıktı belirlenmektedir. Toplama fonksiyonunda olduğu gibi aktivasyon fonksiyonu için de farklı alternatifler bulunmaktadır. YSA’nın son elmanı olan çıktı, aktivasyon fonksiyonu tarafından üretilen nihai çıktı değeridir. Üretilen çıktı ya dış dünyaya ya da başka bir hücreye girdi olarak gönderilebilmektedir.

YSA temel olarak girdi, gizli ve çıktı katmanı olmak üzere 3 katmandan oluşmaktadır. Bununla beraber yalnızca doğrusal problemleri çözebilen, girdi ve çıktı katmanında oluşan basit YSA modelleri de bulunmaktadır. Fakat bu basit YSA türleri günümüz mühendislik problemlerini çözmek için yetersiz kalmaktadır. Dolayısıyla bir veya daha fazla gizli katmana sahip karmaşık YSA modelleri kullanılmaktadır. Bu çalışmanın girdilerini etanol oranı, ekstrakt konsantrasyonu ve pH değerleri oluştururken, çıktısını antioksidan aktivite (nitrit giderme potansiyeli) oluşturmaktadır. Çalışmadaki YSA modelinin katmanları Şekil 1’de gösterilmiştir.



Şekil 1. YSA modelinin katmanları.

YSA ile modelleme işlemi MATLAB programında yapılmıştır. Problemin yapısına uygun olarak tek bir gizli katman kullanılarak oluşturulan modellerin eğitim sürecinde Levenberg-Marquardt algoritması öğrenme algoritması olarak belirlenmiştir. Yapılan çalışmalarda 20 farklı (1:20) gizli nöron sayısı denenerek en uygun nöron sayısı belirlenmeye çalışılmıştır. Öğrenme katsayısı ve momentum katsayısı 0,5, maksimum iterasyon sayısı 100, doğrulama kontrol sayısı 50 ve hata değeri 1×10^{-6} olarak seçilmiştir. Ayrıca her bir nöron sayısında 1000 farklı model oluşturularak en uygun ağ elde edilmiştir. Deneysel çalışmadan alınan verilerin %80'i eğitim, %10'u doğrulama ve %10'u test için kullanılmıştır. YSA ile modelleme sürecinde kullanılan parametreler Tablo 1'de gösterilmiştir.

Tablo 1. YSA modellerinde kullanılan parametreler.

Parametre	Değer
Eğitim algoritması	Levenberg–Marquardt
Performans fonksiyonu	Ortalama hata karesi
Gizli katman aktivasyon fonksiyonu	Lojistik sigmoid fonksiyon
Çıktı katman aktivasyon fonksiyonu	Doğrusal fonksiyon
Gizli katman sayısı	1
Gizli katman nöron sayısı	1:20
Maksimum doğrulama sayısı	50
Maksimum hata oranı	1×10^{-6}
Maksimum iterasyon sayısı	100
Toplam çalıştırma sayısı	1000
Veri setinin bölünmesi	%80 eğitim; %10 doğrulama; %10 test

Ağın eğitimi sürecindeki performans fonksiyonu olarak Denklem 2'de gösterilen hata karelerinin ortalaması (MSE) kullanılmıştır. Ayrıca modelin tahmin yeteneğini ortaya koyan yüzde ortalama mutlak hata (MAPE) değerleri de Denklem 3'te gösterildiği gibi hesaplanmıştır.

$$MSE = \frac{1}{n} \sum (T_i - D_i)^2 \quad (2)$$

$$MAPE = \frac{1}{n} \sum \left| \frac{D_i - T_i}{D_i} \right| * 100 \quad (3)$$

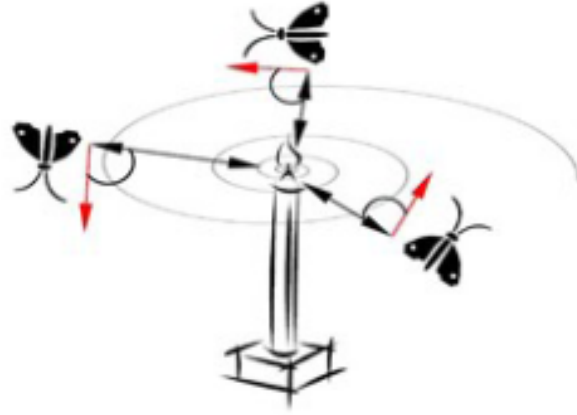
Burada T ve D sırasıyla YSA tarafından sunulan tahmin ve deneysel sonuçları göstermektedir. Eğitimi tamamlanmış YSA modellerinin performansını ölçmek için R değerleri de hesaplanmıştır.

C. GÜVE-ALEV OPTİMİZASYON ALGORİTMASI

Bu çalışmada, optimizasyon sürecinde güncel algoritmalarından biri olan [40] ve Seyedali Mirjalili tarafından geliştirilen GAO algoritması kullanılmıştır [41]. Doğada enine yönelim olarak bilinen güvelerin uçuş mekanizması, bu algoritmanın ana ilham kaynağı olmuştur.

Güveler geceleri uçmak için ay ışığını kullanmaktadırlar. Uçuş için kullandıkları mekanizmada, bir güve aya göre sabit açıyı koruyarak düz bir yolda uzun mesafeler uçabilirler. Güve ile ay arasındaki mesafenin oldukça fazla olması güvelerin düz bir yolda ilerlemesini sağlamaktadır. Enine yönelim etkinliğine rağmen, genellikle güvelerin ışıklar etrafında spiral olarak uçtuğu gözlemlenir. Güveler yapay bir ışık kaynağında da aynı mekanizmayı kullanarak düz bir çizgide uçmaya çalışırlar. Böylesi bir ışık ay ile

karşılaştırıldığında son derece yakın olduğu için ışık kaynağına benzer bir açı sağlamak, güvelerin yollarından çıkmasına sebep olmaktadır. Yapay bir ışık kaynağının varlığında güvelerin hareketi Şekil 2’deki olmaktadır.



Şekil 2. Güverlerin spiral uçuş yolu.

GAO algoritmasında aday çözümler güveler tarafından temsil edilirken, problem değişkenleri güvelerin uzaydaki konumu olmaktadır. Bu yüzden, güveler konum vektörlerini değiştirerek problem boyutundaki bir uzayda uçabilirler. Popülasyon tabanlı bir algoritma olan GAO algoritmasında güveler kümesi aşağıdaki gibi bir matrisle ifade edilmektedir.

$$G = \begin{bmatrix} g_{1,1} & g_{1,2} & g_{1,3} & \dots & g_{1,d} \\ g_{2,1} & g_{2,2} & g_{2,3} & \dots & g_{2,d} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ g_{n,1} & g_{n,2} & g_{n,3} & \dots & g_{n,d} \end{bmatrix} \quad (4)$$

burada, G güveleri, n güvelerin sayısını d ise değişkenlerin sayısını ifade etmektedir. Güvelerin konumuna karşılık gelen uygunluk fonksiyonu değerleri dizisi aşağıdaki gibi bir matrisle temsil etmektedir.

$$G = \begin{bmatrix} OG_1 \\ OG_2 \\ \cdot \\ \cdot \\ \cdot \\ OG_n \end{bmatrix} \quad (5)$$

Bu algoritmadaki bir diğer önemli bileşen alevlerdir ve güve matrisine benzer bir matris ile aşağıdaki gibi gösterilmektedir.

$$A = \begin{bmatrix} a_{1,1} & a_{1,2} & a_{1,3} & \dots & a_{1,d} \\ a_{2,1} & a_{2,2} & a_{2,3} & \dots & a_{2,d} \\ \cdot & \cdot & \cdot & \dots & \cdot \\ \cdot & \cdot & \cdot & \dots & \cdot \\ a_{n,1} & a_{n,2} & a_{n,3} & \dots & a_{n,d} \end{bmatrix} \quad (6)$$

burada, A alevleri, n güvelerin sayısını d ise değişkenlerin sayısını ifade etmektedir. Alevlerin konumuna karşılık gelen uygunluk fonksiyonu değerleri dizisi ise aşağıdaki gibi bir matrisle temsil etmektedir.

$$A = \begin{bmatrix} OA_1 \\ OA_2 \\ \vdots \\ OA_n \end{bmatrix} \quad (7)$$

Bu algoritmada, hem güveler hem de alevler çözümleri temsil etmekte olup aralarındaki tek fark, her iterasyonda bunların işleme biçimi ve güncellenmesidir. Güveler arama uzayında spiral uçuş mekanizmasına göre dolaşan temel arama elemanları iken alevler ilgili iterasyona kadar elde edilen güvelerin en iyi pozisyonlarını ifade etmektedir. Diğer bir deyişle, alevler arama uzayında güvelerin bıraktığı bayraklar olarak düşünülebilir. Böylece her bir güve iterasyonlar boyunca bir bayrak arar ve daha iyi bir çözüm bulması durumunda ise mevcut bayrağı günceller. Bu sayede herhangi bir güve, en iyi çözümü asla kaybetmez.

GAO algoritmasının matematiksel gösterimi aşağıdaki gibi ifade edilebilir.

$$GAO = (I, P, T) \quad (8)$$

burada; I , rastgele bir güveler topluluğu ve karşılık gelen uygunluk değerlerini üreten bir fonksiyondur. P , ana fonksiyondur ve güveleri arama alanının etrafına taşır, T ise fonksiyonun sonlandırma kriteridir.

Yukarıda belirtildiği gibi bu algoritmanın ilham kaynağı enine yönelimdir. Bu davranışı matematiksel olarak modellemek için her bir güvenin konumu aşağıdaki denklem kullanılarak bir aleve göre güncellenir.

$$G_i = S(A_i, G_j) \quad (9)$$

Denklemde, G_i , i . güveyi, S , spiral fonksiyonu, A_i , i . alevi, G_j ise j . güveyi temsil etmektedir.

Bu algoritmada, güvelerin ana güncelleme mekanizması olarak bir logaritmik spiral kullanılmaktadır ve matematiksel gösterimi aşağıdaki gibidir.

$$S(G_i, A_j) = D_i \cdot e^{bt} \cdot \cos(2\pi t) + A_j \quad (10)$$

Denklemde, b , logaritmik bir spiralin şeklini tanımlamak için bir sabittir. t , -1 ve 1 arasında rastgele bir sayıdır. D_i , j . alev için i . güvenin mesafesini temsil etmektedir ve aşağıdaki gibi hesaplanır.

$$D_i = |A_j - G_i| \quad (11)$$

Denklemde A_j , j . alevi, G_i , i . güveyi temsil etmektedir. GAO algoritmasının sözde kodu Şekil 3'te verilmiştir.

1	Başlama
2	Güvelerin pozisyonlarını rastgele oluştur
3	while (t<mak. iterasyon)
4	Alev sayısını güncelle
5	OG=UygunlukFonksiyonu(G)
6	if iterasyon==1
7	A=sırala(G);
8	OA=sırala(OG)
9	else
10	A=sırala(G _{t-1} , G _t);
11	OA=sırala(OG _{t-1} , OG _t)
12	end
13	for i=1:n
14	for j=1:d
15	r ve t'yi güncelle
16	İlgili güvenin konumuna göre D'yi hesapla
17	İlgili güvenin konumuna göre G(i,j)'yi güncelle
18	end
19	end
20	end
21	Bitiş

Şekil 3. GAO algoritmasının sözde kodu.

Bu çalışmada mantar ekstraktlarının antioksidan aktivitesini maksimum veren ekstraksiyon koşullarını belirlemek için GAO algoritması kullanılmıştır. Çalışmanın amaç fonksiyonu Denklem 12'de verilmiş ve çalışmanın kısıtları Tablo 2'de gösterilmiştir.

$$\text{Amaç fonksiyonu} = \text{Mak}(\text{Antioksidan aktivite}) \quad (12)$$

Tablo 2. Çalışmanın kısıtları.

Kısıtlar	Alt limit	Üst limit
Etanol oranı (%)	0	90
Ekstrakt konsantrasyonu (mg/mL)	1	4
pH	1,2	6

Çalışmada popülasyon sayısı 30, iterasyon sayısı ise 60 olarak seçilmiştir. Global optimuma yaklaşmak için çalıştırma sayısı 10 olarak belirlenmiştir. Çalışmada kullanılan GAO algoritmasında kullanılan parametreler Tablo 3'te özetlenmiştir.

Tablo 3. GAO algoritmasında kullanılan parametreler.

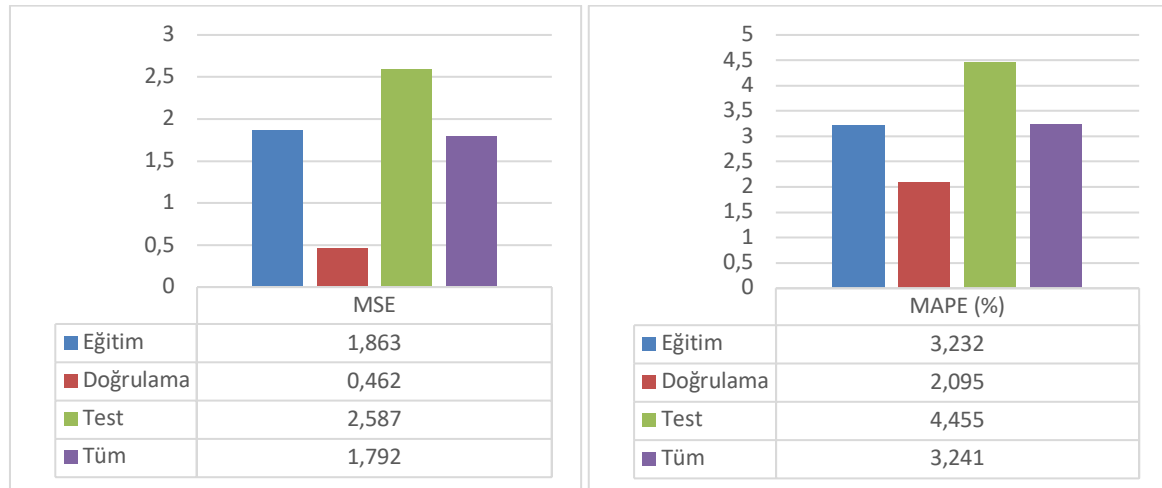
Parametre	Sayı
Popülasyon sayısı	30
İterasyon sayısı	60
Çalıştırma sayısı	10

III. ARAŞTIRMA BULGULARI

A. YSA İLE MODELLEME

Mantar ekstraktlarının antioksidan aktivitesini tahmin eden model YSA metodu ile elde edilmiştir. En iyi tahmin modelini bulmak için gizli nöron sayıları 1 ile 20 arasında denenmiş ve nihai model, aday modellerin performans değerlerine bakılarak seçilmiştir. YSA ile modelleme işleminde veriler eğitim, doğrulama ve test olarak üçe ayrılmıştır. Bu bölümlerden eğitim seti ağı öğrenme faaliyeti için, doğrulama seti ise modelin ezberlemesini engelleyici bir durdurma kriteri olarak kullanılmıştır. Son olarak test veri seti, eğitimi tamamlanmış ağı istenen performansını belirlemek için kullanılmıştır. Eğitim sonunda kurulan tahmin modelin performans değerleri eğitim, doğrulama, test ve tüm veri seti için ayrı ayrı elde edilmiştir.

Kurulan tahmin modelleri arasından 3-5-1 yapısındaki ağ en iyi tahmin modeli olarak seçilmiştir. 3-5-1 yapısı, 3 girdisi, 5 gizli nöronu ve 1 çıktısı olan ağı ifade etmektedir. YSA modelinin gizli nöronu her probleme özeldir ve uygun sayıda gizli nöron bulunması modelin tahmin yeteneği için önemli bir faktördür. Çok fazla gizli nöron, eğitim yerine verilerin ezberlenmesine neden olabilir ve ağı karmaşıklığını artırırken, çok az gizli nöron modelin genelleme yeteneğini azaltabilir. Seçilen en iyi modelin MSE ve MAPE değerleri Şekil 4'te verilmiştir.



Şekil 4. Ağın MSE ve MAPE değerleri.

Şekil 4'ten görüldüğü üzere modelin MSE değerleri eğitim, doğrulama, test ve tüm değerler için sırasıyla 1,863, 0,462, 2,587 ve 1,792 olarak bulunmuştur. MAPE değeri, modelin tahmin yeteneği ile ilgili bilgi veren bir çıktıdır. Bu çalışmada seçilen modelin MAPE değerleri eğitim, doğrulama, test ve tüm değerler için sırasıyla %3,232, %2,095, %4,455 ve %3,241 olarak bulunmuştur. Bu değerler elde edilen modelin, makul hatayla antioksidan aktivite değerlerini tahmin ettiğini göstermektedir.

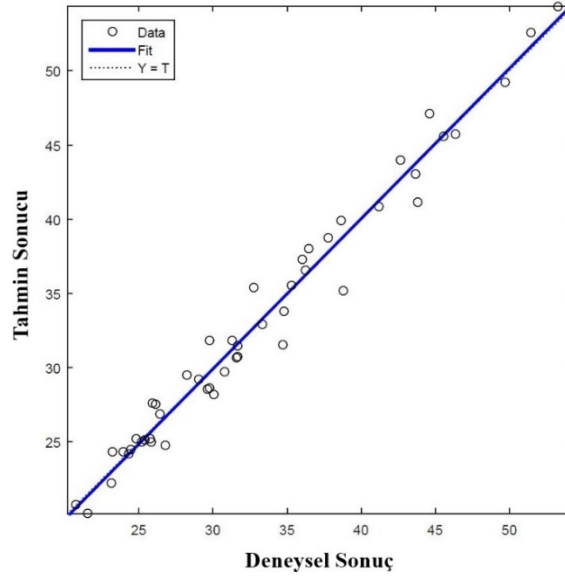
DeneySEL çalışmalardan elde edilen gerçek değerler ile YSA modelinin tahmin değerleri Tablo 4'te karşılaştırmalı olarak gösterilmiştir.

Tablo 4. Gerçek değerler ile YSA modelinin tahmin değerleri.

Etanol oranı (%)	Ekstrakt konsant.(mg/mL)	pH	Gerçek değerler	Tahmin değerleri	Mutlak Hata
0	1	1,2	31,86	29,75	2,11
0	2	1,2	31,52	34,71	-3,19
0	4	1,2	47,11	44,62	2,49
30	1	1,2	24,98	25,86	-0,88
30	2	1,2	30,66	31,61	-0,95
30	4	1,2	43,07	43,63	-0,56
60	1	1,2	24,18	24,27	-0,09
60	2	1,2	31,86	31,30	0,56
60	4	1,2	45,62	45,55	0,07
90	1	1,2	22,26	23,13	-0,87
90	2	1,2	28,61	29,73	-1,12
90	4	1,2	41,18	43,78	-2,6
0	1	3	29,75	30,79	-1,04
0	2	3	38,04	36,45	1,59
0	4	3	45,76	46,32	-0,56
30	1	3	35,39	32,77	2,62
30	2	3	35,19	38,77	-3,58
30	4	3	49,22	49,67	-0,45
60	1	3	36,56	36,26	0,3
60	2	3	43,98	42,60	1,38
60	4	3	54,35	53,29	1,06
90	1	3	35,55	35,31	0,24
90	2	3	40,88	41,17	-0,29
90	4	3	52,54	51,40	1,14
0	1	4,2	29,24	29,05	0,19
0	2	4,2	31,45	31,67	-0,22
0	4	4,2	37,32	36,01	1,31
30	1	4,2	29,49	28,26	1,23
30	2	4,2	30,71	31,63	-0,92
30	4	4,2	38,71	37,75	0,96
60	1	4,2	28,56	29,58	-1,02
60	2	4,2	32,96	33,29	-0,33
60	4	4,2	39,93	38,60	1,33
90	1	4,2	27,55	26,09	1,46
90	2	4,2	28,2	30,05	-1,85
90	4	4,2	33,81	34,75	-0,94
0	1	6	25,23	24,82	0,41
0	2	6	25,23	25,78	-0,55
0	4	6	25,11	25,38	-0,27
30	1	6	24,48	24,43	0,05
30	2	6	26,88	26,38	0,5
30	4	6	27,63	25,89	1,74
60	1	6	25,02	25,20	-0,18
60	2	6	24,78	26,80	-2,02
60	4	6	24,31	23,94	0,37
90	1	6	20,16	21,56	-1,4
90	2	6	24,33	23,20	1,13
90	4	6	20,75	20,73	0,02

Tablo 4 incelendiğinde YSA modelinin oluşturduğu tahmin değerlerinin gerçek değerlere oldukça yakın olduğu görülmektedir.

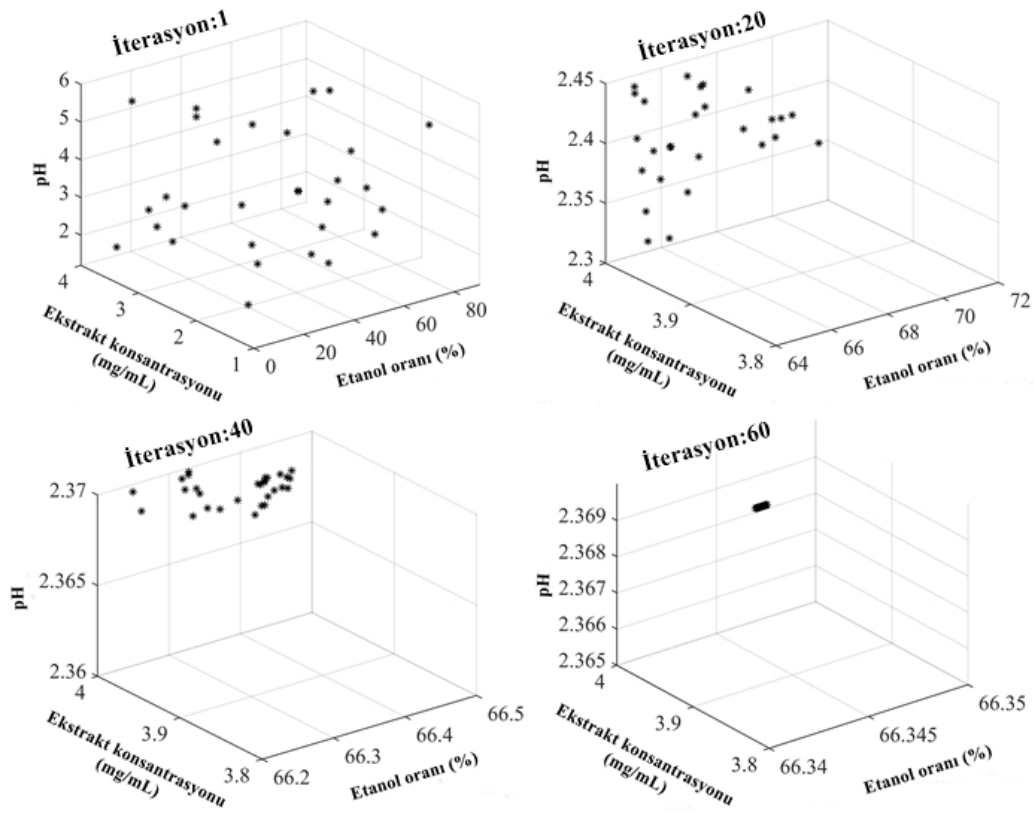
Diğer bir performans göstergesi olan, korelasyon katsayıları (R) değeri, model tarafından tahmin edilen değerler ile gerçek değerler arasındaki ilişki hakkında bilgi verir. R değeri ne kadar yüksek ve 1'e yakınsa, modelin tahmin edilen değerleri gerçek değerlere o kadar yakın demektir. Bu çalışmada seçilen tahmin modelinin R değerleri eğitim, doğrulama, test ve tüm veri seti için sırasıyla 0,985, 0,991, 0,991 ve 0,987 olarak bulunmuştur ve tüm veri seti için korelasyon grafiği değeri Şekil 5'te verilmiştir.



Şekil 5. Tahmin modelinin korelasyon grafiği.


B. GAO İLE OPTİMİZASYON

Kurulan YSA modelleri arasından en iyi model seçildikten sonra, bu model optimizasyon sürecinde amaç fonksiyonunu temsil etmek için kullanılmıştır. Bu çalışmadaki amaç, farklı ekstraksiyon koşulları altında ekstrakte edilmiş mantar ekstraktlarının antioksidan aktivitesinin maksimizasyonudur. GAO algoritması kullanılarak yapılan optimizasyon çalışmasında farklı iterasyon sayıları denenmiş ve 60 iterasyonun yeterli olduğu belirlenmiştir. İterasyonlar boyunca algoritmanın ürettiği aday çözümler yani karar değişkenlerinin değerleri aşamalı olarak Şekil 6'da gösterilmiştir.



Şekil 6. İterasyonlar boyunca algoritmanın aday çözümleri.

Şekil 6 incelendiğinde, ilk iterasyonda aday çözümler rastgele dağılmıştır. 20. iterasyonda aday çözümlerin uygunluk değerlerine göre kötü aday çözümleri elenmiş ve iyi aday çözümleri saklanmaya devam ederek sürekli iyileştirme yapılmıştır. 40. iterasyonda en uygun aday bulunmuş olsa da komşuluk araması devam etmektedir. 60. iterasyonda ise en iyi amaç fonksiyonu değerini veren nihai çözüm bulunmuştur. Algoritmanın yakınsama eğrisi Şekil 7’de verilmiştir.



Şekil 7. Algoritmanın yakınsama eğrisi

Şekil 7 incelendiğinde, birinci iterasyonda en iyi amaç fonksiyonu değeri %51,95 olarak bulunmuş ve iterasyonlar boyunca iyileştirmeler yapılarak belirli bir iterasyonda amaç fonksiyonu değeri %56,76’ya ulaşmış ve sabit kalmıştır. Ayrıca Şekil 7, iterasyon sayısının arama işlemini tamamlamak için yeterli olduğunu göstermektedir.

Sonuç olarak optimizasyon işlemi sonrası en iyi amaç fonksiyonu değeri %56,76 olarak bulunmuş ve bu değeri sağlayan optimum ekstraksiyon parametreleri (karar değişkenleri) Tablo 5'te verilmiştir.

Tablo 5. Optimum ekstraksiyon parametreleri.

Parametre	Optimum Değer
Etanol oranı (%)	66,34
Ekstrakt konsantrasyonu (mg/mL)	4
pH	2,36

Tablo 5'ten görüldüğü gibi optimizasyon işlemi sonrasında, Güve-Alev Optimizasyon algoritmasının sunduğu optimum ekstraksiyon parametreleri şu şekildedir: %66,34 etanol oranı, 4 mg/mL ekstrakt konsantrasyonu ve 2,36 pH değeri.

IV. SONUÇ

Bu çalışmada *Pleurotus cornucopiae* var. *citrinopileatus* mantarının antioksidan aktivite değerini maksimum yapan ekstraksiyon koşullarının belirlenmesi yapay zekâ teknikleri kullanılarak gerçekleştirilmiştir. Gerekli veriler daha önce gerçekleştirilmiş deneysel bir çalışmadan elde edilmiştir. Verilerin modellenmesi YSA metodu ile yapılmış ve bir tahmin modeli oluşturulmuştur. Seçilen en iyi model güncel algoritmalarından birisi olan GAO algoritması kullanılarak optimizasyon işleminde kullanılmıştır. Modelleme ve optimizasyon işlemleri sonrası görülmüştür ki YSA-GAO entegrasyonu bu tarz optimizasyon işlemlerinde rahatlıkla ve yüksek güvenilirlikte kullanabilmektedir. Özellikle kimya tabanlı bu tarz çalışmaların modellenmesi ile çalışılan sınırlar içindeki parametrelerle, çalışılmayan diğer parametrelerdeki çıktıları tahmin etmek mümkün olmaktadır. Böylece, kimyasal malzeme, maliyet, zaman ve emek tasarrufu sağlanmaktadır. Optimizasyon süreci sonrası ekstraksiyon parametrelerinin belirlenmesi ile de ekstraktlardan elde edilen verim, hedeflenen amaca göre maksimum seviyeye çıkarılmıştır.

Gelecek çalışmalarda farklı amaç fonksiyonlarının kullanıldığı optimizasyon çalışmaları gerçekleştirilebilir. Bunun yanında her yıl literatüre kazandırılan farklı optimizasyon teknikleri kullanılarak algoritma performans analizleri yapılabilir.

V. KAYNAKLAR

- [1] S.P. Wasser and A.L. Weis, "Medicinal properties of substances occurring in higher basidiomycetes mushrooms: current perspectives". *International Journal of Medicinal Mushrooms*, vol. 19, no.1, pp. 31-62, 1999.
- [2] M.E. Valverde, T. Hernández-Pérez, and O. Paredes-López, "Edible mushrooms: improving human health and promoting quality life". *International Journal of Microbiology*, vol. 2015, pp. 1-14, 2015.
- [3] Y. Liu, X.X. Xie, S.A. Ibrahim, S.G. Khaskheli, H. Yang, Y.F. Wang, and W. Huang, "Characterization of *Lactobacillus pentosus* as a starter culture for the fermentation of edible oyster mushrooms (*Pleurotus* spp.)". *LWT-Food Science Technology*, vol. 68, pp. 21-26, 2016.
- [4] L. Pathmashini, V. Arulnandhy, and R. Wijeratnam, "Efficacy of different spawn types on sawdust media". *Tropical Agricultural Research Extension*, vol. 11, pp. 55-59, 2010.
- [5] M. Ritota and P. Manzi, "Pleurotus spp. cultivation on different agri-food by-products:

Example of biotechnological application". *Sustainability*, vol. 11, no.18, pp. 5049, 2019.

[6] J. Raman, K.Y. Jang, Y.L. Oh, M. Oh, J.H. Im, H. Lakshmanan, and V. Sabaratnam, "Cultivation and nutritional value of prominent *Pleurotus* spp.: An overview". *Mycobiology*, vol. 49, no.1, pp. 1-14, 2021.

[7] P. Kalač, "Chemical composition and nutritional value of European species of wild growing mushrooms: A review". *Food chemistry*, vol. 113, no.1, pp. 9-16, 2009.

[8] G. Cardwell, J.F. Bornman, A.P. James, and L.J. Black, "A review of mushrooms as a potential source of dietary vitamin D". *Nutrients*, vol. 10, no.10, pp. 1498, 2018.

[9] H.J.M.H.J. Masri, P.M.P. Maftoun, R. Abd Malek, A.Z. Boumehira, A. Pareek, S.Z. Hanapi, O.M. Ling, and H. El Enshasy, "The edible mushroom *Pleurotus* spp.: II. Medicinal values". *International Journal of Biotechnology for Wellness Industries*, vol. 6, no.1, pp. 1-11, 2017.

[10] G. Chilanti, K. Todescatto, L.B. Andrade, C.S. Branco, M. Salvador, M. Camassola, R.C. Fontana, and A.J. Dillon, "Polyphenolic Content and Antioxidant Activity of Mycelia and Basidiomes of Oyster Mushrooms *Pleurotus* spp.(Agaricomycetes) from Brazil". *International Journal of Medicinal Mushrooms*, vol. 23, no.6, pp. 13-23, 2021.

[11] D. Roy, S. Ansari, A. Chatterjee, A. Lukanini, S. Ghosh, and N. Chakraborty, "In Vitro Search for Antiviral Activity against Human Cytomegalovirus from Medicinal Mushrooms *Pleurotus* sp. and *Lentinus* sp". *Journal of Antivirals & Antiretrovirals* vol. 12, no.3, pp. 1-12, 2020.

[12] M. Özdal, Ö. Gülmez, Ö.G. Özdal, and Ö.F. Algur, "Antibacterial and antioxidant activity of mycelial extracts of different *Pleurotus* species". *Food Health*, vol. 5, no.1, pp. 12-18, 2019.

[13] V. Mishra, S. Tomar, P. Yadav, and M. Singh, "Promising anticancer activity of polysaccharides and other macromolecules derived from oyster mushroom (*Pleurotus* sp.): An updated review". *International Journal of Biological Macromolecules*, vol. 182, pp. 1628-1637, 2021.

[14] I. Golak-Siwulska, A. Kałużewicz, T. Spizewski, M. Siwulski, and K. Sobieralski, "Bioactive compounds and medicinal properties of Oyster mushrooms (*Pleurotus* sp.)". *Folia Horticulturae*, vol. 30, no.2, pp. 191-201, 2018.

[15] N. Doğan, and C. Doğan, "İstiridyeye Mantarının (*Pleurotus ostreatus*) Farklı Flaş Zamanlarına Göre Antioksidan Aktivitesinin ve Hiperglisemide Anahtar Enzim Rolü Olan α -amilaz ve α -glukozidaz İnhibisyon Potansiyelinin Belirlenmesi". *Kahramanmaraş Sütçü İmam Üniversitesi Tarım ve Doğa Dergisi*, vol. 24, no.6, pp. 1177-1186, 2021.

[16] S.J. Wang, L. Bao, J.J. Han, Q.X. Wang, X.L. Yang, H.A. Wen, L.D. Guo, S.J. Li, F. Zhao, and H.W. Liu, "Pleurospiroketals A–E, Perhydrobenzannulated 5, 5-Spiroketal Sesquiterpenes from the edible mushroom *Pleurotus cornucopia* e". *Journal of Natural Products*, vol. 76, no.1, pp. 45-50, 2013.

[17] S.N. Um, G.E. Jin, K.W. Park, Y.B. Yu, and K.M. Park, "Physiological activity and nutritional composition of *Pleurotus* species". *Korean Journal of Food Science Technology*, vol. 42, no.1, pp. 90-96, 2010.

[18] J. Dai and R.J. Mumper, "Plant phenolics: extraction, analysis and their antioxidant and anticancer properties". *Molecules*, vol. 15, no.10, pp. 7313-7352, 2010.

[19] P. Garcia-Salas, A. Morales-Soto, A. Segura-Carretero, and A. Fernández-Gutiérrez, "Phenolic-compound-extraction systems for fruit and vegetable samples". *Molecules*, vol. 15, no.12,

pp. 8813-8826, 2010.

[20] S. Jiang, S. Liu, and M. Qin, "Effects of extraction conditions on crude polysaccharides and antioxidant activities of the lion's mane medicinal mushroom, *Hericium erinaceus* (Agaricomycetes)". *International Journal of Medicinal Mushrooms*, vol. 21, no.10, pp. 1007-1018, 2019.

[21] H.S. Yim, F.Y. Chye, S.M. Koo, P. Matanjun, S.E. How, and C.W. Ho, "Optimization of extraction time and temperature for antioxidant activity of edible wild mushroom, *Pleurotus porrigens*". *Food Bioproducts Processing*, vol. 90, no.2, pp. 235-242, 2012.

[22] J.A. Michiels, C. Kevers, J. Pincemail, J.O. Defraigne, and J. Dommès, "Extraction conditions can greatly influence antioxidant capacity assays in plant food matrices". *Food Chemistry*, vol. 130, no.4, pp. 986-993, 2012.

[23] G. Nguyen and T. Nguyen, "Effect of extraction conditions (temperature, pH and time) by cellulase on chemical properties of dried oyster mushroom (*Pleurotus sajor-caju*) extract". *Food Research*, vol. 5, no.3, pp. 351-358, 2021.

[24] N. Doğan, C. Doğan and Atila, F. "Parts from life-cycle of *H. erinaceus*: response surface methodology approach to optimize extraction conditions and determination of its antioxidant, antidiabetic and antimicrobial effect". *Journal of Microbiology, Biotechnology and Food Sciences*, vol. 10, no.6, pp. e3703-e3703, 2021.

[25] J.H. Maeng, H. Muhammad Shahbaz, K. Ameer, Y. Jo, and J.H. Kwon, "Optimization of microwave-assisted extraction of bioactive compounds from *Coriolus versicolor* mushroom using response surface methodology". *Journal of Food Process Engineering*, vol. 40, no.2, pp. e12421, 2017.

[26] J.Y. Cho, N.B. Sadiq, J.C. Kim, B. Lee, M. Hamayun, T.S. Lee, H.S. Kim, S.H. Park, C.W. Nho, and H.-Y. Kim, "Optimization of antioxidant, anti-diabetic, and anti-inflammatory activities and ganoderic acid content of differentially dried *Ganoderma lucidum* using response surface methodology". *Food Chemistry*, vol. 335, pp. 127645, 2021.

[27] B. Abbasi and H. Mahlooji, "Improving response surface methodology by using artificial neural network and simulated annealing". *Expert Systems with Applications*, vol. 39, no.3, pp. 3461-3468, 2012.

[28] P. Poonnoy, A. Tansakul, and M. Chinnan, "Estimation of moisture ratio of a mushroom undergoing microwave-vacuum drying using artificial neural network and regression models". *Chemical Product Process Modeling*, vol. 2, no.3, pp. 2007.

[29] A. Tarafdar, N.C. Shahi, and A. Singh, "Freeze-drying behaviour prediction of button mushrooms using artificial neural network and comparison with semi-empirical models". *Neural Computing Applications*, vol. 31, no.11, pp. 7257-7268, 2019.

[30] V.M. Šimić, K.M. Rajković, S.S. Stojičević, D.T. Veličković, N.Č. Nikolić, M.L. Lazić and I.T. Karabegović, "Optimization of microwave-assisted extraction of total polyphenolic compounds from chokeberries by response surface methodology and artificial neural network". *Separation and Purification Technology*, vol. 160, pp. 89-97, 2016

[31] K.M. Rajković, J.M. Avramović, P.S. Milić, O.S. Stamenković and V.B. Veljković, "Optimization of ultrasound-assisted base-catalyzed methanolysis of sunflower oil using response surface and artificial neural network methodologies". *Chemical Engineering Journal*, vol. 215, pp. 82-89, 2013.

- [32] E. Betiku and S.O. Ajala, "Modeling and optimization of *Thevetia peruviana* (yellow oleander) oil biodiesel synthesis via *Musa paradisiacal* (plantain) peels as heterogeneous base catalyst: A case of artificial neural network vs. response surface methodology". *Industrial Crops and Products*, vol. 53, pp. 314-322, 2014.
- [33] M. Rebollo-Hernanz, S. Cañas, D. Taladrid, V. Benítez, B. Bartolomé, Y. Aguilera, and M.A. Martín-Cabrejas, "Revalorization of Coffee Husk: Modeling and Optimizing the Green Sustainable Extraction of Phenolic Compounds". *Foods*, vol. 10, no.3, pp. 653, 2021.
- [34] S. Mirjalili, "The ant lion optimizer". *Advances in Engineering Software*, vol. 83, pp. 80-98, 2015.
- [35] D.H. Wolpert and W.G. Macready, "No free lunch theorems for optimization", *IEEE Transactions on Evolutionary Computation*, vol. 1, no.1, pp. 67-82, 1997.
- [36] S. Mirjalili, S.M. Mirjalili, and A. Lewis, "Grey wolf optimizer". *Advances in Engineering Software*, vol. 69, pp. 46-61, 2014.
- [37] H.J. Lee, J.R. Do, M.Y. Chung, and H.K. Kim, "Antioxidant activities of *Pleurotus cornucopiae* extracts by extraction conditions". *Journal of the Korean Society of Food Science Nutrition*, vol. 43, no.6, pp. 836-841, 2014.
- [38] J. Gray and L. Dugan Jr, "Inhibition of n-nitrosamine formation in model food systems". *Journal of Food Science*, vol. 40, no.5, pp. 981-984, 1975.
- [39] S. Haykin, *Neural Networks: A Comprehensive Foundation*, New York: Macmillan, 1994.
- [40] M. Karakoyun, and A. Özkış, "Transfer Fonksiyonları Kullanarak İkili Güve-Alev Optimizasyonu Algoritmalarının Geliştirilmesi ve Performanslarının Karşılaştırılması". *Necmettin Erbakan Üniversitesi Fen ve Mühendislik Bilimleri Dergisi*, vol. 3, no.2, pp. 1-10, 2021.
- [41] S. Mirjalili, "Moth-flame optimization algorithm: A novel nature-inspired heuristic paradigm". *Knowledge-based systems*, vol. 89, pp. 228-249, 2015.