

JSR B

JOURNAL OF
SCIENTIFIC REPORTS B



Kutahya Dumlupınar University Scientific Reports B
Evliya Çelebi Campus Tavşanlı Road 10 KM. 45270 Kutahya
Phone : 02740-443 19-42
E-mail : journalsb@gmail.com
jsrpb.com

Dumlupınar University Press





Sahibi

Kütahya Dumlupınar Üniversitesi adına
Prof. Dr. Süleyman KIZILTOPRAK (Rektör)
Lisansüstü Eğitim Enstitüsü adına
Doç. Dr. Eray ACAR (Enstitü Müdürü)

Owner

On Behalf of Kütahya Dumlupınar University
Prof. Dr. Süleyman KIZILTOPRAK (Rector),
On Behalf of Institute of Graduate Studies
Assoc. Prof. Dr. Eray ACAR (Director)

Yayın Kurulu / Editorial Board

| | |
|-------------------------------|--|
| Prof. Dr. Önder UYSAL | Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği |
| Prof. Dr. Cengiz YENİKAYA | Kütahya Dumlupınar Üniversitesi / Kimya |
| Prof. Dr. Cengiz KARAGÜZEL | Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği |
| Prof. Dr. Gürsel YANIK | Kütahya Dumlupınar Üniversitesi / Jeoloji Mühendisliği |
| Doç. Dr. Cemal PARLAK | Ege Üniversitesi / Fizik |
| Doç. Dr. Nevzat BEYAZIT | Ondokuz Mayıs Üniversitesi / Çevre Mühendisliği |
| Doç. Dr. Levent URTEKİN | Ahi Evran Üniversitesi / Makine Mühendisliği |
| Prof. Dr. Fatih ŞEN | Kütahya Dumlupınar Üniversitesi / Biyokimya |
| Dr. Öğr. Üyesi Ümran ERÇETİN | Kütahya Dumlupınar Üniversitesi / Makine Mühendisliği |
| Dr. Öğr. Üyesi Durmuş ÖZDEMİR | Kütahya Dumlupınar Üniversitesi / Bilgisayar Müh. |

Journal of Scientific Reports-B dergisi, yayın hayatına 2000 yılında başlayan Dumlupınar Üniversitesi Fen Bilimleri Enstitüsü Dergisinden ayrılmış olup, Haziran ve Aralık aylarında olmak üzere yılda düzenli olarak 2 kez yayımlanan ulusal hakemli bir dergidir. Derginin yazım dili Türkçe ve İngilizce'dir. Dergiye gönderilen makaleler, editör kurulu tarafından seçilen ve konusunda uzman en az iki hakem tarafından değerlendirilmektedir. Dergiye sunulan bütün makaleler çift-körleme yöntemiyle değerlendirilmektedir. Değerlendirilmek üzere dergimize gönderilen makalelerin, daha önce yayınlanmamış, yayınlanmak üzere kabul edilmemiş ve yayınlanmak için başka bir dergide değerlendirilme sürecinde olmaması gerekmektedir. Dergide yayımlanan yazıların her türlü sorumluluğu yazar(lar)ına aittir.

Dergi, fen ve mühendislik bilimlerinde ulusal ve uluslararası düzeyde yapılan bilimsel çalışmalarını bilim insanları ve kamuoyu ile paylaşmayı amaçlar. Dergiye, fen ve mühendislik bilim dallarında yapılan, özgün araştırma makaleleri, derleme makaleleri ve kısa notlar kabul edilir. Özgün araştırma makalelerinin başka dergilerde yayınlanmamış olması, teorik ve deneysel sonuçlar içermesi beklenir. Derleme makalelerinde ise belirli bir konu üzerinde bilimsel, teknolojik ve güncel gelişmelerin geniş bir kaynakça kullanılarak yansıtılması ve bunların doyurucu bir değerlendirilmesinin yapılması aranır. Kısa notlar, özgün bir çalışmanın ilk bulgularının duyurulması amacıyla yönelik hazırlanan kısa yazılar olmalıdır.

İçerik Politikası

Dergimiz açık erişim dergisi olup, makale değerlendirme süresi 1-2 aydır

Yazışma Adresi: Kütahya Dumlupınar Üniversitesi Evliya Çelebi Yerleşkesi Lisansüstü Eğitim Enstitüsü 43270 KÜTAHYA

Telefon: 0 274 443 19 42

Faks: 0 274 265 20 60

E-posta: joursrb@gmail.com

Web Sayfası: gsjsrb.com

Journal of Scientific Reports-B was separated from Journal of Science and Technology of Dumlupınar University which started its publication life in 2000 and is a national peer-reviewed journal published regularly twice a year in June and December. The language of the journal is Turkish and English. Articles submitted to the journal are evaluated by at least two referees who are experts in the subject and selected by the editorial board. All articles submitted to the journal are evaluated by the double-blind method. Articles submitted to our journal for review should not be previously published, accepted for publication and in the process of being evaluated for publication in another journal. All responsibility for the articles published in the journal belongs to the author(s).

The journal aims to share scientific studies carried out in the fields of science and engineering at national and international level with scientists and the public. Original research articles, review articles and short notes in science and engineering disciplines are accepted for the journal. Original research articles are expected to contain theoretical and experimental results and should not be published in other journals. In the review articles, it is expected that scientific, technological and current developments on a specific subject are reflected by using an extensive bibliography and made a satisfying evaluation of these. Short notes should be brief writings prepared to announce the first findings of an original study.

Editorial Policy

The journal is open access and the article evaluation period is between 1-2 months.

Correspondence Address: Kütahya Dumlupınar University Evliya Çelebi Campus Graduate School of Education 43270 KÜTAHYA

Phone: 0 274 443 19 29 - 30

Fax: 0 274 265 20 60

E-mail: joursrb@gmail.com

Webpage: gsjsrb.com

Bölüm Editörleri / Section Editors

| | |
|---|---------------------------------|
| İnşaat Mühendisliği / Civil Engineering Prof. Dr. M. Çağatay KARABÖRK | Kütahya Dumlupınar Üniversitesi |
| Makine Mühendisliği / Mechanical Engineering Prof. Dr. Ramazan KÖSE | Kütahya Dumlupınar Üniversitesi |
| Elektrik-Elektronik Mühendisliği / Electrical-Electronics Engineering Dr. Öğr. Üyesi Kadir VARDAR | Kütahya Dumlupınar Üniversitesi |
| Bilgisayar Mühendisliği / Computer Engineering Doç. Dr. Doğan AYDIN | Kütahya Dumlupınar Üniversitesi |
| Endüstri Mühendisliği / Industrial Engineering Dr. Öğr. Üyesi Kerem CİDDİ | Kütahya Dumlupınar Üniversitesi |
| Maden Mühendisliği / Mining Engineering Dr. Öğr. Üyesi Uğur DEMİR | Kütahya Dumlupınar Üniversitesi |
| Jeoloji Mühendisliği / Geology Engineering Dr. Öğr. Üyesi Muzaffer ÖZBURAN | Kütahya Dumlupınar Üniversitesi |
| Metalurji ve Malzeme Mühendisliği / Metallurgical and Materials Engineering Prof. Dr. İskender IŞIK | Kütahya Dumlupınar Üniversitesi |
| Gıda Mühendisliği / Food Engineering Prof. Dr. Muhammet DÖNMEZ | Kütahya Dumlupınar Üniversitesi |
| Çevre Mühendisliği / Environmental Engineering Doç. Dr. Nevzat BEYAZIT | Ondokuz Mayıs Üniversitesi |
| Matematik / Mathematics Dr. Öğr. Üyesi Cansu KESKİN | Kütahya Dumlupınar Üniversitesi |
| Fizik / Physics Doç. Dr. Huriye Sanem AYDOĞU | Kütahya Dumlupınar Üniversitesi |
| Kimya / Chemistry Doç. Dr. Bülent ZEYBEK | Kütahya Dumlupınar Üniversitesi |
| Biyoloji / Biology Dr. Öğr. Üyesi Nüket Akalın BİNGÖL | Kütahya Dumlupınar Üniversitesi |
| Biyokimya / Biochemistry Doç. Dr. Derya KOYUNCU ZEYBEK | Kütahya Dumlupınar Üniversitesi |
| İş Sağlığı ve Güvenliği / Occupational Health and Safety Prof. Dr. Cem ŞENSÖĞÜT | Kütahya Dumlupınar Üniversitesi |

Danışma Kurulu / Advisory Board

| | |
|----------------------------------|--|
| Prof. Dr. Sibel AKAR | Eskişehir Osmangazi Üniversitesi / Kimya |
| Prof. Dr. Abdurrahman AKTÜMSEK | Selçuk Üniversitesi / Biyoloji |
| Prof. Dr. Mustafa ALTUNOK | Gazi Üniversitesi / Ağaç İşleri Endüstri Mühendisliği |
| Prof. Dr. Uğur ARİFOĞLU | Sakarya Üniversitesi / Elektrik-Elekt. Mühendisliği |
| Prof. Dr. Oktay ARSLAN | Balıkesir Üniversitesi / Kimya |
| Prof. Dr. Şükrü ASLAN | Sivas Cumhuriyet Üniversitesi / Çevre Mühendisliği |
| Prof. Dr. Ülfet ATAV | Selçuk Üniversitesi / Fizik |
| Prof. Dr. Mustafa BAYRAKTAR | TOBB Ekonomi ve Teknoloji Üniversitesi / Matematik |
| Prof. Dr. Niyazi BİLİM | Konya Teknik Üniversitesi / Maden Mühendisliği |
| Prof. Dr. İsmail BOZTOSUN | Akdeniz Üniversitesi / Fizik |
| Prof. Dr. Erdal ÇELİK | Dokuz Eylül Üniversitesi / Metalurji Malzeme Müh. |
| Prof. Dr. Hayri DAYIOĞLU | Kütahya Dumlupınar Üniversitesi / Biyoloji |
| Prof. Dr. Muhammet DÖNMEZ | Kütahya Dumlupınar Üniversitesi / Gıda Mühendisliği |
| Prof. Dr. Mehmet Ali EBEOĞLU | Kütahya Dumlupınar Üniversitesi / Elektrik-Elekt. Müh. |
| Prof. Dr. İsmail Göktaş EDİZ | Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği |
| Prof. Dr. İsmail EKİNCİOĞLU | Kütahya Dumlupınar Üniversitesi / Matematik |
| Prof. Dr. Kaan ERARSLAN | Kütahya Dumlupınar Üniversitesi / Maden Mühendisliği |
| Prof. Dr. Zeynal Abiddin ERGÜLER | Kütahya Dumlupınar Üniversitesi / Jeoloji Mühendisliği |
| Prof. Dr. Seyhan FIRAT | Gazi Üniversitesi / İnşaat Mühendisliği |
| Prof. Dr. Remzi GÖREN | Sakarya Üniversitesi / Met. Malzeme Müh. |
| Prof. Dr. Rasim İPEK | Ege Üniversitesi / Makine Mühendisliği |
| Prof. Dr. Refail KASIMBEYLİ | Eskişehir Teknik Üniversitesi / Endüstri Mühendisliği |
| Prof. Dr. Hamdi Şükür KILIÇ | Selçuk Üniversitesi / Fizik |
| Prof. Dr. Yaşar KİBİCİ | Bilecik Şeyh Edebali Üniversitesi / Jeoloji Mühendisliği |
| Prof. Dr. İsmail KOCAÇALIŞKAN | Yıldız Teknik Üniversitesi / Moleküler Biy. ve Genetik |
| Prof. Dr. Mahmut KOÇAK | Eskişehir Osmangazi Üniversitesi / Mat.-Bilgisayar |
| Prof. Dr. Muhsin KONUK | Üsküdar Üniversitesi / Moleküler Biy. ve Genetik |
| Prof. Dr. Mustafa KURU | Başkent Üniversitesi / Moleküler Biy. ve Genetik |
| Prof. Dr. Ömer İrfan KÜFREVİOĞLU | Atatürk Üniversitesi / Biyokimya |
| Prof. Dr. Halim MUTLU | Ankara Üniversitesi / Jeoloji Mühendisliği |
| Prof. Dr. Ekrem SAVAŞ | İstanbul Ticaret Üniversitesi / Matematik |
| Prof. Dr. Murat TANIŞLI | Eskişehir Teknik Üniversitesi / Fizik |
| Prof. Dr. Ali Rehber TÜRKER | Gazi Üniversitesi / Kimya |
| Prof. Dr. Mustafa TÜRKMEN | Giresun Üniversitesi / Biyoloji |
| Prof. Dr. Abdülmecit TÜRÜT | İstanbul Medeniyet Üniversitesi / Fizik Mühendisliği |
| Prof. Dr. Eşref ÜNLÜOĞLU | Eskişehir Osmangazi Üniversitesi / İnşaat Mühendisliği |
| Prof. Dr. Nurettin YAYLI | Karadeniz Teknik Üniversitesi / Eczacılık |
| Prof. Dr. Yusuf YAYLI | Ankara Üniversitesi / Matematik |
| Prof. Dr. Elçin YUSUFOĞLU | Uşak Üniversitesi / Matematik |
| Prof. Dr. Hüseyin Serdar YÜCESU | Gazi Üniversitesi / Otomotiv Mühendisliği |
| Prof. Dr. Mehmet Tevfik ZEYREK | Orta Doğu Teknik Üniversitesi / Fizik |

JOURNAL OF SCIENTIFIC REPORTS-B

İÇİNDEKİLER / CONTENTS

DERLEME MAKALELERİ / REVIEW ARTICLES

- Bee anatomy: a comprehensive overview of bee morphology and physiology*** 1-19
Arı anatomisi: arı morfolojisi ve fizyolojisine kapsamlı bir bakış
Ebru Halvacı, Teslime Kozak, Mert Gül, Hatice Kars, Fatih ŞEN*

ARAŞTIRMA MAKALELERİ / RESEARCH ARTICLES

- Anemi hastalığının yapay sinir ağları yöntemleri kullanılarak sınıflandırılması*** 20-34
Classification of anemia disease using artificial neural networks methods
Nagihan YAĞMUR*, Hasan TEMURTAŞ, İdiris DAĞ
- Investigation of the effects of some plant varieties on tyrosinase activity and antioxidant properties*** 35-42
Classification of anemia disease using artificial neural networks methods
Bazı bitki çeşitlerinin tirozinaz aktivitesine etkileri ve antioksidan özelliklerinin incelenmesi
Duygu YAMAN, Hatice SERİN, Merve ÇALIŞ, Gulnur ARABACI*
- Beyin tümörü teşhisinde CNN-FL modeli ağ performansının aktivasyon fonksiyonlarına göre karşılaştırılması*** 43-54
Comparison of CNN-FL model network performance according to activation functions in diagnosis of brain tumor
Elif Ebru Çakı*, Tamer Aslan
- Rastgele orman regresyon algoritması ile bitcoin fiyat tahmini*** 55-64
Bitcoin price prediction with random forest regression algorithm
Sümeyye ÇELİK*, Durmuş ÖZDEMİR
- Otonom Mobil Robotlar İçin Metaheuristic Algoritmaların Çeşitli Yol Planlama Problemlerinde Performanslarının Karşılaştırılması*** 65-74
Comparison of Performances of Metaheuristic Algorithms for Autonomous Mobile Robots In Various Path Planning Problems
Esra DOĞAN*, Burhanettin DURMUŞ
- İşlerin Bölünebildiği Esnek Atölye Çizelgeme Problemi için İki Metaheuristic Algoritmanın Karşılaştırılması*** 75-90
Comparison of two metaheuristic algorithms for the flexible job-shop scheduling problem with lot-streaming
Büşra TUTUMLU*, Tuğba SARAÇ



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

DERLEME MAKALE/REVIEW ARTICLE

Geliş Tarihi(Receive Date): 02.06.2023

Kabul Tarihi(Accepted Date): 18.07.2023

Bee anatomy: a comprehensive overview of bee morphology and physiology

Ebru Halvaci¹, Teslime Kozak², Mert Gül³, Hatice Kars⁴, Fatih ŞEN^{5*}

¹Sen Research Group, Department of Biochemistry, Dumlupınar University, Kutahya, Türkiye, ORCID: 0009-0003-6062-7622

²Sen Research Group, Department of Biochemistry, Dumlupınar University, Kutahya, Türkiye, ORCID: 0009-0006-9446-8449,

³Sen Research Group, Department of Biochemistry, Dumlupınar University, Kutahya, Türkiye, ORCID: 0009-0005-7215-541X

⁴Sen Research Group, Department of Biochemistry, Dumlupınar University, Kutahya, Türkiye, ORCID: 0009-0002-1107-0605

⁵Sen Research Group, Department of Biochemistry, Dumlupınar University, Kutahya, Türkiye, ORCID: 0000-0001-6843-9026

Abstract

The species and anatomy of the bee, a member of the insect class (Insecta), have very interesting importance. Although there are many production-oriented studies on bees and beekeeping in our country, it is very important to get enough information on general morphological structures, bee anatomy, bee biochemistry, bee segments, hive systematics, etc. Bees play a major role in the production of pollinators and various food crops, which are very important for the ecosystem. Therefore, understanding the morphology of bees and accessing accurate information is vital for sustainable agriculture and food security. In addition, our country is a bridge between Asia and Europe and constitutes a very important habitat for bees. However, it is very difficult to reach sufficient resources and products, especially on bee anatomy, bee behavior, and beekeeping. For this reason, in this article, bee morphology, various bee races, division of labor in the hive, reproduction stages, and social order of bees are discussed in detail.

Keywords: *Bee Anatomy, Bee Biochemistry, Bee Segments, Hive Systematics*

Arı anatomisi: arı morfolojisi ve fizyolojisine kapsamlı bir bakış

Öz

Böcekler sınıfının (Insecta) bir üyesi olan arının türleri ve anatomisi oldukça ilgi çekici bir öneme sahiptir. Ülkemizde arılar ve arıcılık üzerine üretime yönelik birçok çalışma olmasına rağmen, arıların genel morfolojik yapıları, arı anatomisi, arı biyokimyası, arı segmentleri, kovan sistematigi vb. konularda yeterli bilgi edinilmesi oldukça önemlidir. Arılar, ekosistem için çok önemli olan tozlayıcıların ve çeşitli gıda ürünlerinin üretiminde büyük rol oynamaktadır. Bu nedenle arıların morfolojisini anlamak ve doğru bilgiye ulaşmak sürdürülebilir tarım ve gıda güvenliği için hayati önem taşımaktadır. Ayrıca ülkemiz Asya ve Avrupa arasında bir köprü konumunda olup arılar için çok önemli bir habitat oluşturmaktadır. Ancak özellikle arı anatomisi, arı davranışları ve arıcılık konularında yeterli kaynak ve ürüne ulaşmak oldukça zordur. Bu nedenle, bu makalede arı morfolojisi, çeşitli arı ırkları, kovadaki iş bölümü, üreme aşamaları ve arıların sosyal düzeni detaylı olarak ele alınmıştır.

Anahtar Kelimeler: Arı Anatomisi, Arı Biyokimyası, Arı Segmentleri, Kovan Sistematigi

Corresponding Authors:

e-mail: fatihsen1980@gmail.com

© 2023 DPU All rights reserved.

1. Introduction

Around 100,000 insect species around the world are classified in taxonomy. Bees include around 23,000 species within this class. Bees are a type of insect that has adapted in a give-and-take relationship with other living things in the ecosystem and evolved over millions of years. In a bee colony, there are three different species: queen bees, worker bees, and drones. The queen and worker bee are female individuals and are formed from fertilized eggs. Drones develop from unfertilized eggs. The queen controls important mechanisms such as creating new generations by laying eggs, preparing the bees in the colony for the honey season with the hormonal scent of pheromone, encouraging worker bees to collect pollen, and controlling the hive's water needs [1]. Under normal conditions, worker bees perform all the work in the hive with extraordinary cooperation, except for laying eggs. These include nectar and water transportation to the hive, wax secretion and comb building, royal jelly secretion, queen and brood care, hive cleaning and ventilation, and honey ripening [2]. All body parts of the bee can be categorized into three thoracic parts, six visible abdominal parts, legs, and antennae. These parts are largely covered by a layer of hair to help the bee collect pollen and regulate body temperature. The developmental stage of a bee consists of 4 different periods: egg, larva, pupa, and adult. The period inside the comb cell (the brooding period) lasts 16 days for the queen, 21 days for the worker bee, and 24 days for the drone. The queen lays unfertilized eggs in large cells and fertilized eggs in small cells according to the size of the honeycomb cell. The head is located in the front part of the bee's body, and the surface of the chitinous skeleton is covered with hairs. The head is connected to the thorax by a thin, playful neck. On the head are the eyes, sensory structures (sensilla), feeding organs, and mouthparts (figure 1) [3-7].




Fig. 1. External head muscles of *Megalopta sodalis* (Halictinae). A, *Sagittal muscle*; B, *mandibular, antennal and maxillary muscles* [8].

The eyes of the bee; consist of two types of eyes, three simple eyes (osel eye, point eye) in addition to a pair of compound eyes (comb eyes) in the form of honeycombs. compound eyes; It is used for the bee to see long distances and to distinguish between structures and colors. Simple eyes, on the other hand, enable the bee to see in low light and up close [9]. Each simple eye consists of thousands of subunits. compound eye; It consists of 4,000 simple eyes for the worker bee, 3,000 for the queen, and more than 8,000 for the drone. Each unit of the eye sees a small part of the object, and then the image becomes clear with the combination of the images, thus the vision event is provided [10]. Antennas called sensors are in a pair in the middle of the head. Antennae are covered with sensitive hairs. The antennae structures, which are short in size, are articulated and have the ability to move in all directions by the muscles (figure 2). These jointed structures consist of different numbers of knuckles in queen bees and worker bees. It consists of 12 nodes in queen bees and 13 nodes in worker bees. The task of the sensors; enables us to taste, smell, feel by touch, and estimate distance, and it does this thanks to the hairs that cover the antennae. Bees have the ability to sense wind speed and air temperature with the help of nerve endings in the antennae [11].

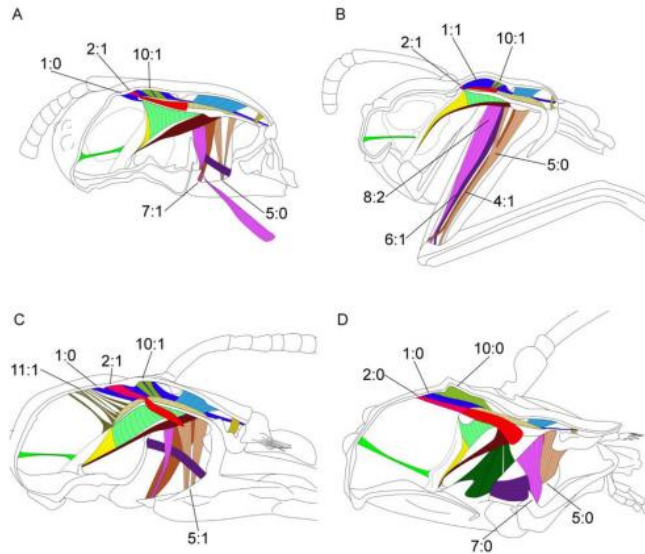


Fig. 2. Comparative morphology of Apidae female bee head exoskeleton muscles, side view. A, *Hylaeus sp.* (*Colletinae*); B, *Agapostemon semimelleus* (*Halictinae*); C, *Scaptotrigona bipunctata* (*Apinae*); D, *Trypoxylon lactitarse* (*Crabronidae*) [4].

Because bees' antennae are highly sensitive, they can easily smell honey from a distance. The mouth parts of the bees perform the sucking and chewing processes. The mouth structure of bees includes the upper lip, upper jaw, lower lip, and lower jaw parts. Thanks to the main and auxiliary jaws; honeycomb formation is provided, the enemy is neutralized and the wax is kneaded by crushing [12]. Since its jaw is straight, it does not damage the skin of the fruits and therefore does not cause any harm to agriculture. It has 80 knuckle tongues that can move in all directions. Depending on the bee breed, the tongue length varies around 6-7 mm and is very thin. In the middle part of the tongue, there is a canal covered with very small hairs. The nutrients reaching the mouth by passing through the channel are absorbed through this channel. The organ responsible for the suction task is the suction pump. This pump is a large muscular sac located in the head. The salivary secretions are responsible for moisturizing the nutrient material [13]. The taste organ, which allows the removal of jelly-like liquids that the tongue cannot grasp, is called the spoon (tassel). The tongue structure bends inwards after fulfilling its function. The thorax consists of 3 rings called segments, and these segments are called prothorax (anterior chest), mesothorax (mid-chest), and metathorax (posterior chest). The chest, which is the center of the bee's ability to move; has two pairs of wings; It consists of three pairs of legs, front, middle and rear. For this reason, they are also called six-legged in the class of insects to which bees belong. The chest area is composed of muscle tissue and is the power generation center because it contains heat and a large amount of mitochondria. All of the wings and legs are located on the thorax. The first ring structure of the abdomen is combined with the last ring structure of the thorax. These wing and leg structures found in the bee are in a pair from each segment of the three anterior segments [14]. Apart from the ability to move; one pair of forelegs do head and antennae cleaning, and a pair of middle legs provide hold. It fills the pollen into the pollen basket from the thorax and from the front legs to the hind legs; The hind legs, on the other hand, take part in transporting the pollen to the hive with the pollen basket above it. The brush and pollen sac are on the back two legs. The brush consists of many hairs located under the shin of the leg and their ends pointing downwards [15]. Pollen sac; It is a triangular-shaped bag covered with hairs in which the bee collects propolis and pollen. The Trachea located in the chest in the form of two pairs provide breathing through a transparent tube. Their two pairs of wings consist of two very thin membranes and are supported by chitinized veins [16]. The wings have four wings, one on each side, on the last two segments of the bee. The front wings are more veined and wider, and

these wings fulfill the function of flying, guiding during flight, and staying stationary in the air for a certain period [17]. Bees flap their wings 190 times per second and move at a speed of 25 km/h. The abdomen is separated from the thorax by a thin knuckle. Abdominal part including the needle, stomach, intestines, reproductive organs, nasanof (fragrance) glands, digestive organs, and wax glands; consists of sections called the abdominal segment (abdomen). The wax glands disappear as the bee ages [18]. Comparative morphological studies in bees are mostly limited to the skeleton, and the musculature of bees has not been investigated in this respect. Here we explore the head's external musculature from an evolutionary perspective. The musculature of 34 bee species belonging to six main lineages and 26 tribes and two opoid wasps were described, illustrated, and compared [19]. A standardized terminology for extrinsic musculature has been proposed and aligned with the Hymenoptera Anatomy Ontology (HAO). The abdomen is connected to each other by thin and elastic membranes, and the bee can easily move its abdomen with these elastic membranes. Thanks to these membranes, the mobility required for the digestive, respiratory, and circulatory organs in the abdomen is provided. The abdominal structure consists of these parts. The sections consist of the sternum in the lower part and the tergum in the upper part. The parts where the segments overlap are called the lower sternum. There are salivary glands, chin glands, and subpharyngeal glands in the abdomen. While the chin gland provides the production of royal jelly, which provides nutrition for the worker bee, it is the source of the chemical called pheromone in the queen bee. There are 10 abdominal segments in the larva of the honey bee, but in a mature bee, there are 9 abdominal segments as the first abdominal segment is included in the thorax. Since the last abdominal segments of the female worker bee and queen bee differentiate to form the sting, there are 6 abdominal segments and 7 abdominal segments in the drone [20]. Worker bees have wax sacs in the last four segments of the abdomen, from which wax is secreted. The scent glands that provide communication with other bees are located on the dorsal side of the abdominal segments. The needle part consists of saw-like protrusions at the end of the abdomen and is a pointed organ used for defense in queens and worker bees. The needle is attached to the venom sac. Because the sting is notched, the worker bees retract the sting after stinging the living thing. bee family; It contains three different individuals, namely queen bee, drone and worker bee [21].

1.1. Queen Bee

Although it is also known as the queen bee, there is only one in the colony outside of the main renewal time. It is like the mother of the other bees in the colony. The queen bee, consisting of a fertilized egg, has an incubation period of 16 days. She is the only female in the hive to reach sexual maturity [20]. It is selected when it is in the form of a larva by worker bees, and it is distinguished from other species because it is fed with royal jelly until it reaches a certain sexual maturity. Its role in the colony; These can be listed as encouraging the worker bees responsible for collecting pollen, providing the water requirement in the colony, ensuring the formation of new bees by laying eggs, and maintaining the continuation of the generation. This control is carried out by hormonal secretion called pheromone [17]. Queen bee; It ensures its development in a special eye of its own. 6-7 days after it leaves the room it is in, it goes on a mating flight with suitable conditions (sunny, windless weather) and secretes a chemical called pheromone and the drones follow the queen [22]. The queen, which mates with 8-10 drones during flight, takes millions of sperm cells from the drone while mating. If mating is completed, it returns to the hive and starts to lay eggs after 7 days. The queen bee, which cannot complete her mating, goes on a few more mating flights in the following days. pheromone chemical; While there is a queen in the colony, it prevents the formation of a new queen, ensures the development of the ovaries of the worker bees and is responsible for the order in the colony. If the queen bee in the colony is destroyed for some reason and the queen cannot grow, the ovaries of a few of the worker bees develop and form a false queen, and these bees are formed from infertile eggs. The queen bee provides its nutrition and cleaning with worker bees [23–25]. It cannot feed itself, worker bees feed the queen by giving royal jelly to her mouth. The queen goes out of the hive only to mate throughout her life. The lifespan of the queen bee is between 3 and 7 years, and as the age increases, the number of laying eggs decreases and the number of infertile eggs increases. Although it is the longest bee in the colony, the queen bee with a good yield can lay 1500-3000 eggs in a day. As the queen ages and her productivity decreases, it is necessary to replace the queen bee every 1-2 years. They do not have the ability to care, and raise offspring, but only fulfill the function of laying eggs [26].

1.2. Worker Bee

Although they are the smallest individual in the colony, they are female bees that are formed from fertilized eggs. In the larval stage, after the first three days, it is fed with a pollen-honey mixture of lower quality than that of the queen bee. It completes its development within 21 days and the duties of the worker bees that come out of the comb cell begin [25]. It is the most abundant bee in the colony. Each colony has 10,000-80,000 worker bees, depending on seasonal conditions, and the number of worker bees increases in summer. Worker bees that occur in the winter months have a longer lifespan, and the lifespan of the worker bees that occur in the summer months is in the range of 35-40 days due to the workload in the hive. They took on all the tasks in the colony, except for spawning. They have duties inside the hive for the first 20 days and outside the hive after 20 days. Worker bees working outside the hive are called field bees, and worker bees working inside the hive are called house bees. Taking care of and feeding the queen bee, looking after and feeding the offspring (larvae), maturing the honey by carrying propolis nectar, pollen, and water into the hive, forming a honeycomb with beeswax secretion, secreting royal jelly, guarding the hive entrance and not letting the bees inside the hive that are not in the hive. They undertake many tasks such as cleaning, and regulating the temperature and humidity of the hive by circulating air with their wings. These tasks are distributed depending on the age of the worker bees. worker bees; they have a prickly needles, and when they sting a living thing, they leave their needles on that creature and die after a while [27].

1.3. Drone

The drone, which is the largest and plumpest individual in the colony, develops from an unfertilized egg. In some cases, it can also occur from a fertilized egg and is a copy of the queen bee [28]. Drones with white eye color from fertilized eggs are killed by worker bees or thrown out of the hive when they are in the larval stage. Their lifespan is around 21-30 days and they complete their development in 24 days. Although mating with the queen bee is her main duty, they do not have stingers and therefore cannot defend themselves. The drone mates with the queen in the air, and as a result of mating, the drone dies. Since their tongues are short, they cannot take nectar or pollen from flowers. When suitable environmental conditions are provided in the colony, drones are more common after April and May, but they are also abundant during the swarming season. It is larger than the queen and worker bees and shorter in length than the queen bee [29]. It is not found in the colony during the winter months and grows in the colony during the summer months. Depending on the climatic conditions or the conditions in the colony, their number varies between 500-2000. After a while, the worker bees throw the drones out of the hive to regulate the lack of nutrients in the colony and the number of drones in the colony, and the drones are thrown out of the hive die because they starve. The most time they fly during the day is between 14.00-16:00 when the weather is warm, and they do not leave the hive before the temperature reaches 18-20°C. The drone eggs, which are 5-7 days old, can now fly and fulfill the functions of defecating by flying, recognizing the environment, and mating [30].

2. Bee Breeds

The homeland of honey bees in Europe, Africa, and Asia. It is 30-50 million years ago that bees reached their present forms and variations. Bees have attained these forms with the changing of flowering plants, which are their main food source, over time. Bees differ from other types of insects by their physiological differences. Its prominent features are its structure covered with hard hairs, the special nectar-catching structure of the mouth structures, and the presence of areas that help to carry pollen on the body and feet [13]. In the Apis community: There are honey bee species such as Apis cerana, Apis florea, Apis mellifera, Apis koschevnikovi, Apis laboriosa, Apis andreniformis, Apis dorsata. Only the homeland of Apis mellifera is the Eastern Mediterranean, Western Europe, and Africa. Others are native to South East Asia. They have lived in different ecotypes or populations within the

same race for more than 30 million years. Adaptations to different regions have occurred over this long period [31,32].

2.1. Honey bee (*Apis mellifera*) and its Taxonomy

The honey bee is a bee species in the genus *Apis* and its Latin name is *Apis mellifera*, meaning "bee carrying honey", their bodies are covered with hairs. Honey bees are indispensable creatures for herbal agriculture and ecological balance. Various products such as propolis, honey, pollen, beeswax, royal jelly, and bee venom are used in human nutrition and for the treatment of diseases [24]. Another benefit of honey bees is to ensure that plants are pollinated and that beautiful and quality plant products are obtained from those plants [33]. Honey bees; live on honeycombs made of beeswax in colonies of queen bees, drones, and worker bees. The honey bees living in this colony continue their lives in order and cooperation among themselves. There is communication between the bees in the colony for the activities that take place inside the hive and outside the hive (for example, joy and cleanliness) [34]. They provide this communication through chemicals known as pheromones secreted from their bodies and by performing various dances [35]. Honey bees vary in all regions of the world except the polar regions. It collects pollen and nectar from flowers to meet its own nutritional needs. Honey bees; To fly, to stay in the air for a certain time and at a fixed point, to adjust the direction of flight, it has two pairs of very thin membrane wings. honey bees; To ensure the continuation of its generation, to protect its food and nest, and to protect the bee colonies in the nest, it defends itself in various ways with its high sensitivity [36]. If it performs this defense process with its stingers, only drones do not have stingers in the colony. The reason for this is that the only duty of drones is to inseminate the queen and the drone dies after insemination [37]. Honey bees exhibit similar behaviors under the same environmental conditions because these creatures act instinctively. The life span of honey bees, which is 28-35 days, varies depending on the season. During the winter season, female individuals such as queen and worker bees are in the majority of the colony. Honey bees can easily perceive yellow and green colors; They cannot detect black, gray, and red color. When the life expectancy of honey bees, which is around 28-35 days, expires, they mostly die outside the hive, but they can also die inside the hive. When there is death in the hive, the worker bees carry the dead bees and throw them away. In addition to this situation, unproductive, disabled, and aged honey bees are thrown out of the hive and removed. Since honey bees are creatures with high reproductive ability, the honey bee that is born as an adult can pass to the egg-laying stage within a week. Colony productivity increases as colony strength and the number of worker bees increase [38]. Honeybees, which started their lives as eggs, go through four developmental stages because of complete metamorphosis in their lives, which are; egg, larva, pupa, and adult stages. Until the egg placed in the honeycomb cell in the hive becomes an adult bee; It takes 21 days for worker bees, 24 days for drones, and 16 days for queens. First of all, the queen lays eggs in the cells of the honeycomb, and while the drone is formed from this infertile egg, the queen and worker bee are formed from the fertile egg [21].

The egg stage lasts for a total of 3 days for all bees. Bee's egg; The ends are round and cylindrical, and the egg is positioned vertically when it is placed in the honeycomb cell in the hive [39]. The egg, which is positioned vertically, slides to the side after a while and is positioned horizontally at the base of the honeycomb after three days, and then the eggshell is torn and transformed into a larva. Honey bees secrete special secretions that break the shell. Large cells were made on the honeycomb to raise drones, and small cells were made to raise worker bees. The queen puts the fertile egg in the small chamber made on the honeycomb and the unfertilized egg in the large chamber [21].

Honey bees; In this stage of development, although the volume, shape, and color change rapidly, pore formation is observed on the rings that make up their bodies. Mouth parts that are responsible for fulfilling the nutritional function are formed. The larval stage lasts for 6 days and the cocoon stage varies for 5 days [40]. During this phase, the bees start to be fed with royal jelly for the first three days, and then they are fed according to gender. After the first three days, the queen is still fed with royal jelly, while the worker bee and drone are fed with a pollen-honey mixture. Although the amount of royal jelly varies according to the type of larva given, the highest amount and best quality royal jelly is given to the queen bee larvae. Due to the difference in quantity during feeding at this stage, different types of individuals such as queen bees or worker bees develop. Toward the end of this phase, the feeding

process ends. The comb cell is closed by the worker bees outside and the larva inside the comb, and the pupal stage begins [41]. After the queen lays her eggs, that is, at the end of the 8th day, including the egg stage, the mouth of the eyes with worker bee larvae is sealed and the larva turns into a cocoon on the 9th day with a special glandular secretion in the head. This stage, which is formed by the larva standing motionless in its cocoon on the 10th day, is called the prepupa stage, which means before the pupal stage. The prepupae turns into pupa on the 11th day, and these two stages last 12 days in total for worker bees, 7 days for queen bees and 15 days for drones. The pupa, which is described as healthy, is bright and white in color and then turns into dark brown and shades. Pupal stage closed; fry, larva and egg stages are also called open brood. After the pupal stage, the bee has become adult and comes out by opening its comb. It takes 24 days for drones, 16 days for queens, and 21 days for worker bees from the time the egg is deposited in the comb cell until it becomes an adult bee [30], [31].

2.2. African Bee (*Apis mellifera scutellata*)

This type of bee is angry, it is very difficult to catch diseases, it is a species that leaves the hive and has the ability to produce swarms. It has adapted to tropical and temperate climates. It was brought to Brazil from Africa in 1956 to increase honey production. They escaped from the quarantine zone they were in in 1957. African bees were found in South America, North America, and Texas in 1990, respectively [43]. The African bee, also known as the "killer bee", is known to cause the death of many human and animal species, thanks to the special alarm hormone it secretes. Due to the aggressive behavior of this bee species, American beekeepers had to quit their jobs for a while. The United States of America has developed many practices to prevent the entry of this species into the country. But beekeepers are quite satisfied with this species. This is because they are resistant to diseases and attract a lot of attention due to their high swarming ability. With today's developing technology, American countries have come to a position to export honey [44].

2.3. Italian Bee (*Apis mellifera ligustica*)

The Italian bee, whose hometown is Italy, has spread all over the world from Italy. It is known as the most common bee breed today. Its habitat is quite large and has managed to survive in both continental and Mediterranean climates. It has a very wide living space from Canada to China, from China to Europe, from Europe to America. It is the most researched and developed bee species. Some of its features can be listed as follows; It is a calm, yellow-colored, and long-lived bee species with a high colony formation rate [35]. Pure Italian bees do not have black rings on the abdomen. It has black dots only at the end of the last abdominal ring. Italian bees with this physiological feature are called "GOLDEN BEE". In countries such as China, Australia, and America, honey yield reaches up to 100 kg per year. Royal jelly is a product of 1-2 kg per year. They are not very prone to catching propolis. They are more prone to looting. The Italian bee was specially bred for honey and milk production. This bee species can produce honey and swarms in early spring. It is one of the species that has the ability to form a strong population. Italian bees, also known as *Apis mellifera ligustica*, are more capable of combing and wrapping honey than other bee species, which underlies a strong sense of population formation. As long as Italian bees are given honeycomb and honey, they do not attempt to swarm [45].




Fig. 3. *A. cerana* exhibits a different biogeographical distribution than *A. mellifera*, and these plants are divided into Asian species and Western species of the *Apis* genus according to their distribution [46].

Recently, both *A. cerana* and bee products *A. mellifera* have attracted great interest because of the ecological and economic value of bee products, as well as their research models for studying social behavior, neurobiology, and pesticides. In the case of natural selection, it is a species that is very prone to swarming and honeycomb production. In the Mediterranean and Aegean Regions, it is possible to divide into 8-10 hives on average per year. Although their cleaning properties are quite advanced, they are biologically resistant to European foulbrood disease. Italian bees have a low power of coming into spring by consuming the least amount of food and with the least colony and population pots. Despite this, it is preferred by beekeepers in countries such as Canada and Finland. However, it is known that if the Italian bees wake up early during the long winter periods, the offspring experience chills [23].

2.4. Carniolan Bee (*Apis mellifera carnica*)

His hometown is Yugoslavia region and Austria. It also shows distribution in Thrace and the Balkans. Carniolan bees are quite similar to Italian bees in terms of size and some behaviors. The Carniolan bee is a docile, hard-working species with high honey production. Their external appearance is dark gray and black, although rarely, it is possible to see brown spots on the 2nd and 3rd levels of the abdomen. This bee species survive the winter in small populations because of limited honey production. In the spring they progress quite rapidly, forming large populations. Carniolan bees have a very regular work division, their comb structure is beyond enormous, and their adaptability is quite good compared to other species. They wrap the honey they produce with a white glaze. They do not like to collect propolis and plunder. They have been trained in many countries, including European countries and America. The breed trained in the Americas was called the New World Carnioan. The financially very expensive New World Carni way has become quite skilled in terms of its general characteristics. The negative feature of this bee species is its high swarming tendency, but this is not a negative feature for bee farms that produce swarms. Still more natural Carniolan bees are bred in Yugoslavia and Austria. The aspirants of the bred bees come to work from European and American countries [47].

2.5. Caucasian Bee (*Apis mellifera caucasica*)

His hometown is Artvin, Ardahan, Kars, Caucasus, and Georgia. They have adapted to mountainous areas and regions with harsh climates. Physiologically, it has a dark brown color and a gray hairy structure. Brown spots can be seen in the first levels on the abdomen. Although Caucasian bees in Artvin, Ardahan, and Kars regions do not differ physiologically, Caucasian bees in transition regions may be light colored. In this bee species, which has a low propensity to swarm, the rate of plundering and propolis collection is just as high. As a result of some research, they discovered that Caucasian bees show low resistance to *Nosema* disease. Although the tendency to collect

propolis was not seen as important in ancient times, the ability of Caucasian bees to collect propolis attracts a lot of attention today, with the discovery of antimicrobial and pharmacological properties of propolis. Various countries, especially China, have started to import and breed Caucasian bees [17].

As we can see in Italian and Carniolan bee species, Caucasian bees are also very hardworking and docile bees. Honey yield is high in high areas with a harsh climate. Due to their adaptability to cold climates, their wintering abilities are also quite high. They spend the winter in small colonies. After spending the winter, they enter a rapid development process in the summer and build solid colonies. With its long tongue structure, which is one of the physical features, it provides the advantage of easily collecting pollen from even tuberos flowers. Due to their adaptability to harsh climates, they can work without interruption even at low temperatures. This bee species, which wakes up late in the spring due to its adaptation to cold climates, is not very productive in temperate climates. This causes honey yields to be low compared to other bee species. Caucasian bees are an indispensable bee species for harsh climates [48].

2.6. Anatolian Bee (*Apis mellifera anatoliaca*)

The bees living in the region excluding the Caucasus and Syria are called Anatolian bees. If we examine Anatolia geographically, it is a bridge connecting Asia to Europe. Anatolia is a region that shows a transition state not only with its topographic map but also in terms of vegetation. It also contains many endemic plants found in Asia and Europe. Anatolian geography, covering a very wide area, provides a habitat for many bee races that have adapted to the region with its high mountains and different climatic characteristics [35]. If we give an example of these bee races: The Anatolian bee, Iranian bee, Caucasian bee, and Syrian bee are some of these races. Ecotypes of Anatolian bees in the region show diversity such as the Gökçeada bee, Central Anatolian bee, Muğla bee, Black Sea Region bee, and Hatay bee. The most common bee species is the Muğla bee, which is specific to the Aegean Region. It is common in the entire Aegean region and is very similar to Carniolan and Italian bees in terms of physiological characteristics. The Anatolian bee, which is geographically distributed over a wide area, varies in color, wing structure, and morphology according to variations such as temperature, pressure, precipitation regime, and vegetation. Its color distribution varies from brown to yellow and it has a very high adaptability and wintering ability. Similar to the Italian breed, it is a productive breed with a high development rate. In the spring, honey production begins quickly. Having gained a large population at the end of the summer, the Muğla bee fills the honeycombs with pine honey in the fall and its work slows down. Muğla bees, which adapt well to a temperate and warm climate, attract more attention in the region compared to other bees [49].

3. Reproduction In Bees

To recognize the honeybees taxonomically, belong to the Apidae family of the Hymenoptera order of the Insecta class of the Arthropoda branch of the animal kingdom. This house is of the apis type. Honeybees are socially active creatures that live in groups just like us humans. Honeybees are very short creatures in terms of generation intervals, and these features have given them the ability to progress in the short term. Thanks to this ability, their efficiency can be increased. As in other living things, honeybees also rely on mate selection in their genetic changes. In order to contribute to genetic progress, drones that will mate with queens must be carefully selected. However, in natural mating practice, it is very difficult to identify drones due to the biology of queens [50]. There are no isolated parts in natural pairing, which prevents controlled coupling. This reduces targeting in selection. This situation negatively affects the rate of genetic progression. In order to avoid these negative effects, drones should mate in isolated areas or artificially mate under laboratory conditions in order to eliminate the problems arising from the mating biology of selected queens. Although natural mapping is easy in theory, it is quite difficult in practice. Bees love to fly high, but creating a controlled space is difficult because many bee populations live close together. When these conditions are collected, it is very difficult to specifically match the selected queen with the drone. Artificial mating is the most reliable way to avoid all these difficulties and uncertainties and also to increase genetic progress [51].

3.1. Reproductive Biochemistry of Honey Bees

The life of honeybees begins in the egg. When observed biologically, the bee eggs developing in the queen begin to develop in the two large ovaries of the first queen, and then the developing bee eggs are sent to the side oviduct. The eggs that pass through here travel in the middle oviduct to be sexed. Here, the sex wins. If the egg is fertilized, it creates the female bee, if the unfertilized male bee. In the middle oviduct, it provides the fertilization process with the spermatheca organ, which is connected to the canal. This organ checks whether the egg that comes with the sperm pump is fertilized or unfertilized. 5-6 million sperm, which the queen needs throughout her life, are stored in the spermatheca organ of the queen. The life of the queens depends on the number of sperm they store, their lifespan is usually 2 years [52]. Physiologically, they have a larger appearance compared to other bees. The function of queens is to mate with drones. It can produce more than 1500 eggs in 24 hours. It informs its colony that it is alive and healthy thanks to the 9-hydroxy decanoic acid it secretes [53]. At the same time, this pheromone secreted makes all the females in the colony sterile and prevents the drones from preparing other queen cells. This pheromone enables the bees included in the colony to recognize each other. If we examine the reproductive system of the queen, we can observe that it consists of a pair of ovaries, median oviducts, a pair of lateral oviducts, spermatheca, and a vagina. The task of the ovaries is to ensure the maturation of the eggs, this process is carried out by the tubes called ovarioles. There are 160-180 ovarioles in the ovaries. Ovarian maturing eggs come to the lateral oviduct, and then to the median oviduct, respectively. From here it passes into the vagina. Between the spermatheca, which is connected to the vagina with a thin channel, and the vagina entrance, there is an indentation to cover the vagina extending towards the spermatheca canal. This recess has a valve-like function. Its name is also "Valvula vaginalis". The function of this valve is to occlude the vagina after mating. This prevents the semen from flowing out and helps to press the semen toward the spermatheca. During mating, the queen opens the Valvula vaginalis with its muscles, and the semen from the drone is injected into the lateral oviduct. When the queen goes on a mating flight, she usually mates with 8-10 drones. As a result of this mating, drones inject 70 to 80 million spermatozoa. The total injected spermatozoon cannot fit into the small volume (1mm³) of the spermatheca, many of them flow out. 5-6 million spermatozoa that can fit in a small volume reach the spermatheca [54]. These injected semen remain viable as long as the queen is alive. The queen makes multiple mating to eliminate the possibility of inbreeding as a result of mating with a drone from the same bucket. If we take a look at the formation of worker bees and drones, if they are fertilized with spermatozoa released from the spermatheca just before the egg leaves the vagina, worker bee formation is observed, if not, drone formation is observed. Male bees have a haploid chromosome structure because they are formed from unfertilized eggs. It takes 24 days for them to complete their development. They reach maturity at the end of 24 days. They then reach sexual maturity in 12-14 days. The queen lays her eggs in each of the honeycombs, which have been cleaned with the help of worker bees. It sticks the egg vertically to the bottom of the eyes with its needle. When we physically examine the honeybee's egg, we see its smooth structure and white color. The sausage-shaped eggs are usually 1.5 mm in size. If the egg is not fertilized on the first day of egg development, the nucleus divides into the zygote if it is [55]. At this stage, the structure of the embryo does not become clear, but on the third day, it becomes clear. The head of the bee that will emerge is on the upper part, not attached to the bottom of the egg. Other parts are in the curved part. The first physical change of the egg takes place between 72-84 hours. In this change, the embryo contracts and tears the membrane of the egg. As a result of tearing, the liquid inside the egg begins to wrap around the outside of the embryo. Embryo contraction continues until its head touches the base of the cell. When it touches the cell base, the distinctive larval form now resembles the letter "C". Worker bees carefully feed the formed larvae with royal jelly for the first 24 hours. During the other 24 hours, they are fed with additional nutrients by the worker bees. The function of drones is to mate with the queen [56]. Unlike other bees, they are slightly larger. Their lifespan is between 21 and 32 days in spring and 90 days in summer. When we examine the reproductive organs of drones biologically, it is possible to observe that they consist of a pair of testicles, a pair of large mucous glands, a pair of large mucous glands, vasa deferens, seminal vesicles and penis. In the period when the internal organs fuse and form into an adult, spermatozoa production begins in the testicles. The ejaculation abilities of the young drones are not developed because the spermatozoa do not leave the

test. When they become adults, they will separate and ejaculation will be possible. When mating begins, the drone also sets out from the semen ejaculation line and reaches the endophallus. It is the last stop of the sperm before they pass to the queen. Then, with the suppression of the mucus released from the mucus glands, the sperm queen is transferred to the vagina, which is the reproductive organ [29]. After mating, the drones die because they leave a certain part of the Endophallus in the abdomen of the queen. If the drone has reached maturity, it is quite simple to become semen. Mature semen is found in drones older than 12 days. Its form is yellow-cream. If the semen to be taken from the drone is possible, the afternoon is the most suitable time. This is because in the afternoon when drones are most suitable for breeding. The methods of semen retrieval from drones are electrical stimulation, rubbing by hand, and the use of chemicals to stimulate drones, respectively [57]. After the drone secretes the semen, it also secretes mucus, the function of this mucus is to prevent the involuntary outflow of semen from the queens. The average amount of semen in a mature drone is 1.7 mm³ and ranges between 1.5-1.75 mm³. Drones have one of the densest spermatozoa in the animal kingdom (7.5×10^9 spermatozoa/ml). Larger drones are preferred for mating because the size of drones is directly proportional to the amount of semen [58].

The mating of bees was only elucidated at the beginning of the eighteenth century. Until it was announced by Janscha in 1775, it was thought that queens did not mate with drones and it was accepted that the eggs were fertilized in the honeycomb. Janscha, on the other hand, reveals that the queens fly to know the environment and mate with the drone in the air. It is quite difficult to observe mating in the air. Huber's work on this subject in 1792 shed light on great studies. According to Huber's studies, the queen makes a 2-5 minute flight to know the environment for 3-5 days. Then on the 5th and 6th days, it leaves the hive to mate. Flights to mate are in the range of 1-3 times. The queen bee is to reinforce the progression of sperm to the spermatheca with the flight to know the environment of 2 minutes [59]. Queen bees can fly repeatedly for a day until they reach the desired sperm saturation. According to the impressions of the explorers, about 63% of the 303 queens made a mating flight once; a second time, 6% flew to mate a third time. While each flight takes approximately 25 minutes, the time between consecutive flights is 19-120 minutes. As the time between flights increases, the next time becomes shorter and the activity of the next flights decreases [60]. In order to observe the natural mating, first of all, the queen was attached to the front of the camera with the help of support in the region where the drones come together. Then it was put at about 10 meters. The needle chamber of the queens is kept open so that mating can take place without any problems. After observing the queen, the drone approaches and clings to the queen with its 6 legs. Then the drone's abdomen is folded down and mating takes place. After this rapid mating, the drone becomes paralyzed and falls freely. After this mating, the stinger of the queen is cleaned by the worker bees and the queen becomes suitable for mating again. After mating, spermatozoa from drones are stored in the semen sac found in the queen. The spermatozoa stored here maintain their vitality as long as the queen is alive. The honeycomb diameters are measured with the 1st pair of queens' legs. Then, the queen lays fertilized worker bee and queen eggs in these cells, and unfertilized eggs in drone cells. The queen lays an average of 250,000- 300,000 eggs per year. A total of 4- 5 million spermatozoa are stored in the sperm sacs [61].

3.2. Artificial Insemination Application in Honey Bees

It is possible to obtain more qualified and larger queens by double inoculation with artificial insemination. There are some difficulties that artificial seeds bring along. Breeding drones is a seasonal event. It is always difficult to find the drones needed in the colony. Queen and drone breeding is a joint event. The natural phase is expected for the queen bee to mate. The reproductive organs and tissues of the queens, which are 6- 7 days old, have not yet reached the desired maturity. When the queens are 8- 10 days old, they start flying only to mate. In artificial insemination, mating activities begin in 8- 15 days old queens. The 15-day period is important because the tissue elasticity begins to decrease in queens past 15 days, which creates difficulties in artificial insemination. Another issue is the selection of drone bees in insemination is a very important issue. It is known that drones become adults in 24 days, and reach sexual maturity in 14 days. Considering these conditions, the breeding of drones should be started at least 40 days before. It should be close to the honeycomb where the queen bee will be reared with the help of a grid. The drone bee should be placed in specially raised cells in the honeycomb. The queen lays unfertilized

eggs in drone cells. After 24- 25 days, drones will begin to form, and the drones that are formed are marked. After 14- 15 days, drones suitable for artificial insemination are ready [62].

3.3. Queen Bee Insemination

After the drones reach sexual maturity, the thorax, of the drone is held with the index and thumb of the right hand. Then, it is compressed towards the abdomen, and ejaculation is provided. The sperm is spread on the endo phallus to form a thin layer with the mucus secreted by the drone. The obtained semen is drawn with an injector. Care should be taken that the injector does not come into contact with the mucus layer and the mucus is not drawn into the injector while the sperm is drawn with the injector. If care is not taken, the injector may become clogged. The semen extraction process continues until the total semen volume is 8-10 mm³. Then the queen is stunned with the help of CO₂. They are taken into the tube and placed with the last 5-6 segments of their abdomen outside. The tube with the queen must remain connected to the CO₂ tube because the queen must remain unconscious throughout the procedure [63].

He puts the queen under the microscope, the ventral and dorsal hooks and the sting circle of the queen are opened. Then the queen's stinger is inserted through the hole on the dorsal hook. Care must be taken when handling the injector. Starting from the vagina, the injector tip is advanced towards the vaginal valve with slow movements, when the oviduct is reached, the button of the injector is turned to the right, and semen passage is provided [58]. The injector is drawn from the queen, if there is no semen on the drawn injector, artificial insemination has been concluded correctly. The dorsal hook is removed from the sting of the queen and the queen is removed from the tube. It is waited for the queen to come to her senses and then it is placed in its colony. For rapid spawning, the queen is exposed to CO₂ in 10-minute periods. After these processes, as in natural mating, the spermatheca of the queen is approximately 5- 6 million spermatozoon and is stored here. The path followed by the sperm is very close to natural mating, the sperm that cannot reach the spermatheca comes out. From the bees of artificial insemination, the worker bees disinfect the sting circle of the queens [64].

4. Social Order Of Bees

Bees are very regular in their social life as well as in their working life. Bees, which have rules within themselves, lead a life in accordance with these rules. Although the duty of each bee in the hive is clear, they never go beyond these duties. They are not suitable for living in all areas, they live in hollows or cavities they find themselves, but they can also live in hives. Each bee has its own comb. They make these honeycombs even in their natural habitats, even if they are in a hive made by humans. All over the world, honeybees weave combs in the same way. These comb cells are both a food area and an area where they raise their young. In bee colonies, the management is in the female bees. Bees avoid polluting the area they live in, and they wait to come out of the hive. Realizing that their life will end, bees get as far away from the hive as possible. The reason for the existence of drones is only to inseminate the queen. Until the queen is old, there are not two original queens in a hive, this is because they are trying to dominate [6]. If found, they'll fight each other to the death and there's a winner. Each hive has its scent. When a bee that does not belong to the bucket wants to enter, it is recognized by its smell and is not allowed in. Bees protect their hives at the expense of their lives, and if they sting another living thing, their lives are terminated. The location of the bee hives is very important, they should not be changed, otherwise, the bees will not be able to find their hives. Each bee leaves its scent on the flowers it collects nectar and pollen so that no other bees will land on those flowers [13]. At the same time, the bees dance and share the location of the flowers they mark with other bees when they return to the hive. The life span of worker bees is a honey collection period, which takes about 40 days. Worker bees do not live long enough to eat the honey they collect in winter. Bee physiology is complex and it is important to understand it. Different technologies are also used to understand the physiology of bees. One of these technologies is nanotechnology. Nanotechnology is widely used in every field today. In the coming days, it is thought that we will encounter much more in daily life in different applications related to bees and beekeeping in the near future [65–90].

5. Conclusion

Bees are one of the most dependent populations on the ecosystem because they collect pollen and nectar and transform various raw materials into products in nature as a way of life. For this reason, bee morphology and anatomy have been a subject of great interest. The anatomy of the bee is divided into three segments: head, thorax, and abdomen. The head is the part where important secretions are made due to its internal structure. The upper jaw glands of worker bees secrete royal jelly at a young age and enzymes that break down sucrose at a later age. The thorax movement in bees consists of four segments and the first ring of the abdomen is combined with the left ring of the thorax. The sensory systems that provide the senses of smell, taste, and touch in bees are in the head. Thanks to the strong muscles and nerve endings in the sensors, they can perceive wind speed and air temperature as well as sensory organs. There are three pairs of legs and two pairs of wings, one in each of the three segments on the thorax. Although the front wings are wider and more veined than the hind wings, they both work together during flight. The wings are composed of two very thin membranes and are supported by a criticized vascular layer. In addition to the movement of the bee, the legs provide antenna cleaning, clinging to the environment, and filling the pollen basket. It is known that the morphological feature of the bee exhibits various adaptations according to climatic conditions and vegetation. There are three types of bees in the hive: queen bee, worker bee, and drone. The developmental stage of a bee goes through 4 different stages: egg, larva, pupa, and adult. The queen bee is the only species capable of laying eggs, the fertilized ones form the worker bees, and the unfertilized ones form the drones. The importance of the queen bee in the colony is the control of the bee community and the creation of an adequate brood population with a balanced division of labor. Methods such as artificial insemination and queen bee insemination are frequently used for the bee's selection ability and genetic improvement. In addition, our country has become a country where various races are raised among the countries of the world, with its geographical location and natural wealth.

Acknowledgements

There is nowhere to say thank you.

References

- [1] Van Espen, M., Williams, J.H., Alves, F., Hung, Y., de Graaf, D.C., and Verbeke, W., (2023), Beekeeping in Europe facing climate change: A mixed methods study on perceived impacts and the need to adapt according to stakeholders and beekeepers, *Science of The Total Environment*, 888, 164255.
- [2] Brazeau, M.D., (2011), Problematic character coding methods in morphology and their effects, *Biological Journal of the Linnean Society*, 104, 489–498.
- [3] Walsh, E.M., Sweet, S., Knap, A., Ing, N., and Rangel, J., (2020), Queen honey bee (*Apis mellifera*) pheromone and reproductive behavior are affected by pesticide exposure during development, *Behavioral Ecology and Sociobiology*, 74, 33.
- [4] Eeraerts, M., Vanderhaegen, R., Smagghe, G., and Meeus, I., (2020), Pollination efficiency and foraging behaviour of honey bees and non- *Apis* bees to sweet cherry, *Agricultural and Forest Entomology*, 22, 75–82.
- [5] Kekeçoğlu, M., Çaprazlı, T., and Ağan, K., (2021), Erkek Arı Larvasının Sağlık Üzerine Etkisi, *Kadirli Uygulamalı Bilimler Fakültesi Dergisi*, 1, 139–153.
- [6] Topal, E., Strant, M., Yücel, B., Köseoğlu, M., Margaoa, n, R., et al., (2018), Ana ve Erkek Arı Larvalarının Biyokimyasal Özellikleri ve Apiterapötik Kullanımı, *Hayvansal Üretim*, 59, 77–82.
- [7] Yaşan, İ., Asiye, B., and Ozan, U., (2020), Acetamipridin *Bombus* (*Bombus terrestris*) Arılarında Kuluçka Gelişimi Üzerine Etkisi, 15, 91–99.
- [8] Meira, O.M. de and Gonçalves, R.B., (2021), Comparative morphology and evolution of the cranial musculature in bees (Hymenoptera: Apoidea), *Arthropod Structure & Development*, 65, 101112.
- [9] Beutel, R.G., Krogmann, L., and Vilhelmsen, L., (2008), The larval head morphology of *Xyela* sp. (Xyelidae,

- Hymenoptera) and its phylogenetic implications, *Journal of Zoological Systematics and Evolutionary Research*, 46, 118–132.
- [10] Bernklau, E. and Arathi, H.S., (2023), Seasonal patterns of beneficial phytochemical availability in honey and stored pollen from honey bee colonies in large apiaries, *Journal of Economic Entomology*.
- [11] Amdam, G.V. and Omholt, S.W., (2002), The Regulatory Anatomy of Honeybee Lifespan, *Journal of Theoretical Biology*, 216, 209–228.
- [12] Müller, A., (1996), Convergent evolution of morphological specializations in Central European bee and honey wasp species as an adaptation to the uptake of pollen from nototribic flowers (Hymenoptera, Apoidea and Masaridae), *Biological Journal of the Linnean Society*, 57, 235–252.
- [13] Teixeira, E.W., Negri, G., Meira, R.M.S.A., Message, D., and Salatino, A., (2005), Plant origin of green propolis: Bee behavior, plant anatomy and chemistry, *Evidence-Based Complementary and Alternative Medicine*, 2, 85–92.
- [14] Evrimi, A., (n.d.), Bal Arısı Arıların Evrimi, Sistematikteki Yeri , Arı Irkları ve Tanımlama Yöntemleri Arı Ekolojisi Arıların Evrimi, Sistematikteki Yeri , Arı Irkları Ve Tanımlama Yöntemleri Bal Arısı Arıların Evrimi , Sistematikteki Yeri , Arı Irkları ve Tanımla, 1–39.
- [15] vanEngelsdorp, D. and Meixner, M.D., (2010), A historical review of managed honey bee populations in Europe and the United States and the factors that may affect them, *Journal of Invertebrate Pathology*, 103, S80–S95.
- [16] Dadant, C.P., (2018), *First Lessons in Beekeeping*, Courier Dover Publications.
- [17] Hanan, B.B., (1955), Studies of the Retrocerebral Complex in the Honey Bee: Part I: Anatomy and Histology, *Annals of the Entomological Society of America*, 48, 315–320.
- [18] Grandperrin, D. and Cassier, P., (1983), Anatomy and ultrastructure of the Koschewnikow's gland of the honey bee, *Apis mellifera* L. (Hymenoptera: Apidae), *International Journal of Insect Morphology and Embryology*, 12, 25–42.
- [19] Ronchetti, F. and Polidori, C., (2020), A sting affair: A global quantitative exploration of bee, wasp and ant hosts of velvet ants, *PLOS ONE*, 15, e0238888.
- [20] Tian, L. and Hines, H.M., (2018), Morphological characterization and staging of bumble bee pupae, *PeerJ*, 6, e6089.
- [21] Kanatl, Z., Ar, B., Ar, B., Morfoloj, A., and Anatom, V.E., (n.d.), *Apis mellifera*), 0–4.
- [22] Alaux, C., Dantec, C., Parrinello, H., and Le Conte, Y., (2011), Nutrigenomics in honey bees: digital gene expression analysis of pollen's nutritive effects on healthy and varroa-parasitized bees, *BMC Genomics*, 12, 496.
- [23] Jensen, A.B., Palmer, K.A., Boomsma, J.J., and Pedersen, B. V., (2005), Varying degrees of *Apis mellifera* ligustica introgression in protected populations of the black honeybee, *Apis mellifera mellifera*, in northwest Europe, *Molecular Ecology*, 14, 93–106.
- [24] Albeck, A., Fluss, S., and Persky, R., (1996), Peptidyl epoxides: Novel selective inactivators of cysteine proteases, *Journal of the American Chemical Society*, 118, 3591–3596.
- [25] Ament, S.A., Wang, Y., and Robinson, G.E., (2010), Nutritional regulation of division of labor in honey bees: toward a systems biology perspective, *WIREs Systems Biology and Medicine*, 2, 566–576.
- [26] Kılıç, F. and Bilgen, G., (2006), İzmir İli Bal Arısı (*Apis mellifera* L.) Populasyonlarında Enzim Polimorfizmi, *Ege Üniversitesi Ziraat Fakültesi Dergisi*, 43, 75–84.
- [27] Fünfhaus, A., Ebeling, J., and Genersch, E., (2018), Bacterial pathogens of bees, *Current Opinion in Insect Science*, 26, 89–96.
- [28] Michener, C.D., (1969), Comparative Social Behavior of Bees, *Annual Review of Entomology*, 14, 299–342.
- [29] (1994), Precise assessment of the number of patrines and of genetic relatedness in honeybee colonies, *Proceedings of the Royal Society of London. Series B: Biological Sciences*, 258, 1–7.
- [30] Üniversitesi, N., Yüksek, M., and Okulu, U., (2007), Bal Arılarında Yumurtanın Yapısı ve Embriyo Gelişim Egg Structure and Embryo Development in Honeybees (*Apis mellifera* L.) *Ethem Akyol.*
- [31] Erdoğan, A., Uçak Koç, A., Karacaoğlu, and Mete, (2017), Anadolu Arısı Ege Ekotipi (*Apis mellifera*

- anatoliaca) ve İtalyan (*Apis mellifera ligustica*) X Ege Melezi Bal Arılarının ve Farklı Yüksük Sayılarının Arı Sütü Verimleri Üzerine Etkileri, *Harran Tarım ve Gıda Bilimleri Dergisi*, 21, 91–98.
- [32] Kakhramanov, B., Isamukhamedov, S., Safarova, F., Donaev, K., and Mamadov, F., (2021), Morphological features of the Carniolan (*Apis mellifera carnica* Pollm) and Carpathian (*Apis mellifera carpatica*) breeds of honey bees, *E3S Web of Conferences*, 284, 03018.
- [33] Yalçın, M. and Turgut, C., (2016), Bal Arılarında Koloni Kaybı, Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi, 13, 151–151.
- [34] Albeck, A., Fluss, S., and Persky, R., (1996), Peptidyl epoxides: Novel selective inactivators of cysteine proteases, *Journal of the American Chemical Society*, 118, 3591–3596.
- [35] Evrimi, A., (n.d.), Bal Arısı Arıların Evrimi , Sistemattikteki Yeri , Arı Irkları ve Tanımlama Yöntemleri Arı Ekolojisi Arıların Evrimi , Sistemattikteki Yeri , Arı Irkları Ve Tanımlama Yöntemleri Bal Arısı Arıların Evrimi , Sistemattikteki Yeri , Arı Irkları ve Tanımlama Yöntemleri, 1–39.
- [36] Tomazzoli, M.M., Zeggio, A.R.S., Neto, R.D.P., Specht, L., Costa, C., Rocha, M., et al., (2020), Botanical source investigation and evaluation of the effect of seasonality on Brazilian propolis from *Apis mellifera* L., *Scientia Agricola*, 77, e20180258.
- [37] E, D.L., (1971), Adnexal Glands of the Sting Apparatus of Bees: Anatomy and Histology, I (Hymenoptera: Colletidae and Andrenidae) on Jstor, *Journal of the Kansas Entomological Society*, 44(1).
- [38] Decourtye, A., Mader, E., and Desneux, N., (2010), Landscape enhancement of floral resources for honey bees in agro-ecosystems, *Apidologie*, 41, 264–277.
- [39] Akyol, E., (2007), Bal Arılarında Yumurtanın Yapısı ve Embriyo Gelişimi, *Uludağ Arıcılık Dergisi*, 7, 135–144.
- [40] Di Pasquale, G., Salignon, M., Le Conte, Y., Belzunces, L.P., Decourtye, A., Kretzschmar, A., et al., (2013), Influence of Pollen Nutrition on Honey Bee Health: Do Pollen Quality and Diversity Matter?, *PLoS ONE*, 8, e72016.
- [41] Brodschneider, R. and Crailsheim, K., (2010), Nutrition and health in honey bees, *Apidologie*, 41, 278–294.
- [42] El-Seedi, H.R., Eid, N., Abd El-Wahed, A.A., Rateb, M.E., Afifi, H.S., Algethami, A.F., et al., (2022), Honey Bee Products: Preclinical and Clinical Studies of Their Anti-inflammatory and Immunomodulatory Properties, *Frontiers in Nutrition*, 8,.
- [43] Hepburn, H.R., Radloff, S.E., and Fuchs, S., (1998), Population structure and the interface between *Apis mellifera capensis* and *Apis mellifera scutellata*, *Apidologie*, 29, 333–346.
- [44] Barbosa, W.F., Tomé, H.V. V., Bernardes, R.C., Siqueira, M.A.L., Smaghe, G., and Guedes, R.N.C., (2015), Biopesticide-induced behavioral and morphological alterations in the stingless bee *Melipona quadrifasciata*, *Environmental Toxicology and Chemistry*, 34, 2149–2158.
- [45] Yücel, B. and Köseoğlu, M., (2009), Comparisons of Mugla Ecotype and Italian Cross Honey Bees for Some Performances in Aegean Region (Turkey), *Kafkas Üniversitesi Veteriner Fakültesi Dergisi*,.
- [46] Zhao, D., Chen, D., Su, X., Zhang, X., and Liu, Y., (2022), Transcriptome explores changes in gene expression profile contributed by *Camellia sinensis* (L.) in *Apis cerana cerana* and *Apis mellifera ligustica*, *Journal of Asia-Pacific Entomology*, 25, 101973.
- [47] Berenbaum, M.R. and Calla, B., (2021), Honey as a Functional Food for *Apis mellifera*, *Annual Review of Entomology*, 66, 185–208.
- [48] Uçak Koç, A., (2017), Farklı Mevsimlerde Yetiştirilen Kafkas (*Apis mellifera caucasica*), İtalyan (*Apis mellifera ligustica*) ırkı ve Anadolu arısı Ege Ekotipi (*Apis mellifera ataloliaca*) Ana Arıların Bazı Feromon Miktarlarının Belirlenmesi, *SAÜ Fen Bilimleri Enstitüsü Dergisi*, 21, 1–1.
- [49] Evans, J.D. and Wheeler, D.E., (1999), Differential gene expression between developing queens and workers in the honey bee, *Apis mellifera*, *Proceedings of the National Academy of Sciences*, 96, 5575–5580.
- [50] Plate, M., Bernstein, R., Hoppe, A., and Bienefeld, K., (2019), The importance of controlled mating in honeybee breeding, *Genetics Selection Evolution*, 51, 74.
- [51] Kečkeš, S., Gašić, U., Veličković, T.Ć., Milojković-Opsenica, D., Natić, M., and Tešić, Ž., (2013), The determination of phenolic profiles of Serbian unifloral honeys using ultra-high-performance liquid

- chromatography/high resolution accurate mass spectrometry, Food Chemistry, 138, 32–40.
- [52] Oxley, P.R. and Oldroyd, B.P., (2010), The Genetic Architecture of Honeybee Breeding. in: pp. 83–118.
- [53] Keller, I., Fluri, P., and Imdorf, A., (2005), Pollen nutrition and colony development in honey bees—Part II, Bee World, 86, 27–34.
- [54] Seltzer, R., Kamer, Y., Kahanov, P., Splitt, A., Bienkowska, M., Hefetz, A., et al., (2023), Breeding for hygienic behavior in honey bees (*Apis mellifera*): a strong paternal effect, Journal of Apicultural Research, 62, 419–428.
- [55] Maucourt, S., Rousseau, A., Fortin, F., Robert, C., and Giovenazzo, P., (2023), Observation of Genetic Gain with Instrumental Insemination of Honeybee Queens, Insects, 14, 301.
- [56] Gallant, A.L., Euliss, N.H., and Browning, Z., (2014), Mapping Large-Area Landscape Suitability for Honey Bees to Assess the Influence of Land-Use Change on Sustainability of National Pollination Services, PLoS ONE, 9, e99268.
- [57] Arathi, H.S. and Spivak, M., (2001), Influence of colony genotypic composition on the performance of hygienic behaviour in the honeybee, *Apis mellifera* L., Animal Behaviour, 62, 57–66.
- [58] Honkanen, A., Hensgen, R., Kannan, K., Adden, A., Warrant, E., Wcislo, W., et al., (2023), Parallel motion vision pathways in the brain of a tropical bee, Journal of Comparative Physiology A: Neuroethology, Sensory, Neural, and Behavioral Physiology, 1–29.
- [59] Boutin, S., Alburaki, M., Mercier, P.-L., Giovenazzo, P., and Derome, N., (2015), Differential gene expression between hygienic and non-hygienic honeybee (*Apis mellifera* L.) hives, BMC Genomics, 16, 500.
- [60] Naug, D., (2009), Nutritional stress due to habitat loss may explain recent honeybee colony collapses, Biological Conservation, 142, 2369–2372.
- [61] Ling, T.C., Phokasem, P., Sinpoo, C., Chantawannakul, P., Khongphinitbunjong, K., and Disayathanoowat, T., (2023), *Tropilaelaps mercedesae* Infestation Is Correlated with Injury Numbers on the Brood and the Population Size of Honey Bee *Apis mellifera*, Animals, 13, 1318.
- [62] Chen, Y.-W., Peng, C.-C., Sung, I.-H., Wu, M.-C., Nai, Y.-S., Gregorc, A., et al., (2023), Imidacloprid Pesticide Causes Unexpectedly Severe Bioelement Deficiencies and Imbalance in Honey Bees Even at Sublethal Doses, Animals 2023, Vol. 13, Page 615, 13, 615.
- [63] Crailsheim, K., Schneider, L.H.W., Hrassnigg, N., Bühlmann, G., Brosch, U., Gmeinbauer, R., et al., (1992), Pollen consumption and utilization in worker honeybees (*Apis mellifera carnica*): Dependence on individual age and function, Journal of Insect Physiology, 38, 409–419.
- [64] Ribi, W., Senden, T.J., Sakellariou, A., Limaye, A., and Zhang, S., (2008), Imaging honey bee brain anatomy with micro-X-ray-computed tomography, Journal of Neuroscience Methods, 171, 93–97.
- [65] Morse, R.A., (1991), Honeybees forever, Trends in Ecology & Evolution, 6, 337–338.
- [66] Şen, B., Aygün, A., Okyay, T.O., Şavk, A., Kartop, R., and Şen, F., (2018), Monodisperse palladium nanoparticles assembled on graphene oxide with the high catalytic activity and reusability in the dehydrogenation of dimethylamine-borane, International Journal of Hydrogen Energy, 43, 20176–20182.
- [67] Göl, F., Aygün, A., Seyrankaya, A., Gür, T., Yenikaya, C., and Şen, F., (2020), Green synthesis and characterization of *Camellia sinensis* mediated silver nanoparticles for antibacterial ceramic applications, Materials Chemistry and Physics, 250, 123037.
- [68] Şen, B., Aygün, A., Şavk, A., Akocak, S., and Şen, F., (2021), Corrigendum to “Bimetallic palladium–iridium alloy nanoparticles as highly efficient and stable catalyst for the hydrogen evolution reaction,” International Journal of Hydrogen Energy, 46, 20792.
- [69] Demirkan, B., Bozkurt, S., Cellat, K., Arıkan, K., Yılmaz, M., Şavk, A., et al., (2020), Palladium supported on polypyrrole/reduced graphene oxide nanoparticles for simultaneous biosensing application of ascorbic acid, dopamine, and uric acid, Scientific Reports, 10, 2946.
- [70] Sen, B., Kuyuldar, E., Demirkan, B., Onal Okyay, T., Şavk, A., and Sen, F., (2018), Highly efficient polymer supported monodisperse ruthenium-nickel nanocomposites for dehydrocoupling of dimethylamine borane, Journal of Colloid and Interface Science, 526, 480–486.
- [71] Arıkan, K., Burhan, H., Bayat, R., and Sen, F., (2022), Glucose nano biosensor with non-enzymatic excellent

- sensitivity prepared with nickel–cobalt nanocomposites on f-MWCNT, *Chemosphere*, 291, 132720.
- [72] Demir, E., Savk, A., Sen, B., and Sen, F., (2017), A novel monodisperse metal nanoparticles anchored graphene oxide as Counter Electrode for Dye-Sensitized Solar Cells, *Nano-Structures & Nano-Objects*, 12, 41–45.
- [73] Darabi, R., Karimi-Maleh, H., Akin, M., Arıkan, K., Zhang, Z., Bayat, R., et al., (2023), Simultaneous determination of ascorbic acid, dopamine, and uric acid with a highly selective and sensitive reduced graphene oxide/polypyrrole-platinum nanocomposite modified electrochemical sensor, *Electrochimica Acta*, 457, 142402.
- [74] Şen, F. and Gökağaç, G., (2007), Activity of Carbon-Supported Platinum Nanoparticles toward Methanol Oxidation Reaction: Role of Metal Precursor and a New Surfactant, tert -Octanethiol, *The Journal of Physical Chemistry C*, 111, 1467–1473.
- [75] Şen, F. and Gökağaç, G., (2014), Pt nanoparticles synthesized with new surfactants: improvement in C1–C3 alcohol oxidation catalytic activity, *Journal of Applied Electrochemistry*, 44, 199–207.
- [76] Askari, M.B., Salarizadeh, P., Di Bartolomeo, A., and Şen, F., (2021), Enhanced electrochemical performance of MnNi₂O₄/rGO nanocomposite as pseudocapacitor electrode material and methanol electro-oxidation catalyst, *Nanotechnology*, 32, 325707.
- [77] Ayrancı, R., Baskaya, G., Guzel, M., Bozkurt, S., Ak, M., Savk, A., et al., (2017), Enhanced optical and electrical properties of PEDOT via nanostructured carbon materials: A comparative investigation, *Nano-Structures & Nano-Objects*, 11, 13–19.
- [78] Ertan, S., Şen, F., Şen, S., and Gökağaç, G., (2012), Platinum nanocatalysts prepared with different surfactants for C1–C3 alcohol oxidations and their surface morphologies by AFM, *Journal of Nanoparticle Research*, 14, 922.
- [79] Şen, F., Şen, S., and Gökağaç, G., (2011), Efficiency enhancement of methanol/ethanol oxidation reactions on Pt nanoparticles prepared using a new surfactant, 1,1-dimethyl heptanethiol, *Phys. Chem. Chem. Phys.*, 13, 1676–1684.
- [80] Ayrancı, R., Başkaya, G., Güzel, M., Bozkurt, S., Şen, F., and Ak, M., (2017), Carbon Based Nanomaterials for High Performance Optoelectrochemical Systems, *ChemistrySelect*, 2, 1548–1555.
- [81] Şen, F., Gökağaç, G., and Şen, S., (2013), High performance Pt nanoparticles prepared by new surfactants for C1 to C3 alcohol oxidation reactions, *Journal of Nanoparticle Research*, 15, 1979.
- [82] Unal, F.A., Ok, S., Unal, M., Topal, S., Cellat, K., and Şen, F., (2020), Synthesis, characterization, and application of transition metals (Ni, Zr, and Fe) doped TiO₂ photoelectrodes for dye-sensitized solar cells, *Journal of Molecular Liquids*, 299, 112177.
- [83] Taslimi, P., Türkan, F., Cetin, A., Burhan, H., Karaman, M., Bildirici, I., et al., (2019), Pyrazole[3,4-d]pyridazine derivatives: Molecular docking and explore of acetylcholinesterase and carbonic anhydrase enzymes inhibitors as anticholinergics potentials, *Bioorganic Chemistry*, 92, 103213.
- [84] Ni, K., Wu, Y., Karimi, F., Gulbagca, F., Seyrankaya, A., Esra Altuner, E., et al., (2023), Palladium based bimetallic nanocatalysts: Synthesis, characterization and hydrogen fuel production, *Fuel*, 341, 127577.
- [85] Sen, F., Boghossian, A.A., Sen, S., Ulissi, Z.W., Zhang, J., and Strano, M.S., (2012), Observation of Oscillatory Surface Reactions of Riboflavin, Trolox, and Singlet Oxygen Using Single Carbon Nanotube Fluorescence Spectroscopy, *ACS Nano*, 6, 10632–10645.
- [86] Sen, B., Kuzu, S., Demir, E., Yıldırım, E., and Sen, F., (2017), Highly efficient catalytic dehydrogenation of dimethyl ammonia borane via monodisperse palladium–nickel alloy nanoparticles assembled on PEDOT, *International Journal of Hydrogen Energy*, 42, 23307–23314.
- [87] Goksu, H., Yıldız, Y., Çelik, B., Yazıcı, M., Kilbas, B., and Sen, F., (2016), Eco-friendly hydrogenation of aromatic aldehyde compounds by tandem dehydrogenation of dimethylamine-borane in the presence of a reduced graphene oxide furnished platinum nanocatalyst, *Catalysis Science & Technology*, 6, 2318–2324.
- [88] Sen, B., Kuzu, S., Demir, E., Onal Okyay, T., and Sen, F., (2017), Hydrogen liberation from the dehydrocoupling of dimethylamine–borane at room temperature by using novel and highly monodispersed RuPtNi nanocatalysts decorated with graphene oxide, *International Journal of Hydrogen Energy*, 42, 23299–

23306.

- [89] Sen, F., (2021), Nanomaterials for direct alcohol fuel cells : characterization, design, and electrocatalysis.
- [90] Şahin, B., Demir, E., Aygün, A., Gündüz, H., and Şen, F., (2017), Investigation of the effect of pomegranate extract and monodisperse silver nanoparticle combination on MCF-7 cell line, *Journal of Biotechnology*, 260, 79–83.



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 17.04.2023

Kabul Tarihi(Accepted Date): 09.06.2023

Anemi hastalığının yapay sinir ağları yöntemleri kullanılarak sınıflandırılması

Nagihan YAĞMUR^{1,*}, Hasan TEMURTAŞ², İdiris DAĞ³

¹ Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Eskişehir, ORCID : 0000-0002-6407-4338

² Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kütahya, ORCID: 0000-0001-6738-3024

³ Eskişehir Osmangazi Üniversitesi, Mühendislik Mimarlık Fakültesi, Eskişehir, ORCID: 0000-0002-2056-4968

Öz

Hemoglobün deęerinin belirli bir referans aralıęının altına düşmesiyle ortaya çıkan ve aynı zamanda kansızlık olarak adlandırılan anemi, teşhis ve tedavisi için birçok kan testine, radyolojik görüntüleme, tahlillere ihtiyaç duyar. Bu gibi çok fazla üretilen tıbbi verilerin yanında hastalık teşhisinin konulmasında doktor kararı gereklidir. Hastalardan alınan tıbbi veriler işlenerek yeni hasta bireyler için hastalıkların tahminleri yapılabilir ve bu tahminlerle doktorlar için karar destek mekanizmaları kurulabilmektedir. Doktorların hastalar için koyacağı teşhisteki yanılma payını azaltma konusunda oldukça önemli olan bu yöntemler sayesinde sağlık kurumlarındaki veri kayıtlarının değerlendirilmesi hasta ve hastaneler için de önem arz etmektedir. Literatürde anemi hastalığı sınıflandırma problemi için çeşitli yöntemler kullanılmış olup, veri setlerindeki hasta kayıt sayılarının deęişiklik göstermesi, kan parametrelerin sayısının ve özelliklerinin farklı olması gibi durumlardan dolayı önerilen algoritmaların performansları veri setlerine göre deęişiklik göstermektedir. Bu çalışmada Kaggle veri tabanından alınan anemi veri seti üzerinde kandaki verilere dayalı olarak anemi hastalığı sınıflandırması problemini çözmek amacıyla Yapay Sinir Ağları (YSA) yöntemleri kullanılmıştır. Öğrenmeli Vektör Kuantalama (LVQ), Rekabetçi Katman Sinir Ağı (CLNN), Örüntü Tanıma Yapay Sinir Ağı (PRNN), Kendiliğinden Organize Olan Harita (SOM) yapay sinir ağı yöntemleri kullanılarak başarı oranları hesaplanmıştır. Elde edilen sonuçların doğruluk deęerleri ve karışıklık matrisleri verilerek önerilen dört yöntem karşılaştırılmıştır. En iyi başarı performansı %100 hassasiyet ve %99,88 doğruluk, %99,86 özgülük, %99,43 kesinlik ile PRNN olduğu, onu takiben LVQ olduğu sonucuna ulaşılmıştır.

Anahtar Kelimeler: Anemi sınıflandırma, Öğrenmeli Vektör Kuantalama, Rekabetçi Katman Sinir Ağı, Örüntü Tanıma Yapay Sinir Ağı, Kendiliğinden Organize Olan Harita

Classification of anemia disease using artificial neural networks methods

Abstract

Anemia, which occurs when the hemoglobin value falls below a certain reference range and is also called anemia, needs many blood tests, radiological images and analyzes for its diagnosis and treatment. In addition to such a large amount of produced medical data, a doctor's decision is required in diagnosing the disease. By processing the medical data taken from the patients, predictions of diseases can be made for new patients and decision support mechanisms can be established for doctors with these predictions. Thanks to these methods, which are very important in reducing the margin of error in the diagnosis of doctors for patients, the evaluation of data records in health institutions is also important for patients and hospitals. Various methods have been used for the classification problem of anemia disease in the literature, and the performance of the proposed algorithms varies according to the datasets due to the changes in the number of patient records in the datasets, the number and characteristics of the blood parameters. In this study, Artificial Neural Networks (ANN) methods were used to solve the anemia disease classification problem based on blood data on the anemia dataset taken from the Kaggle database. Performance rates were calculated using the Learning Vector Quantization (LVQ), Competitive Layer Neural Network (CLNN), Pattern Recognition Artificial Neural Network (PRNN), Self-Organizing Map (SOM) methods. The four proposed methods were compared by giving the accuracy values and confusion matrix values of the obtained results. It was concluded that the best success performance was PRNN with 100% sensitivity and 99.88% accuracy, 99.86% specificity, 99.43% precision, followed by LVQ.

Keywords: Anemia classification, Learning Vector Quantization, Competitive Layer Neural Network, Pattern Recognition Artificial Neural Network, Self-Organizing Map

Corresponding Authors:

e-mail: nagihan.yagmur@dpu.edu.tr

© 2023 DPU All rights reserved.

1. Giriş

Anemi hastalığı, insan sağlığını etkileyen küresel bir sağlık sorunudur [1]. Özellikle küçük çocukları ve hamile bireyleri etkilemektedir. Dünya Sağlık Örgütü'nün tahminine göre, dünya çapında 5 yaşından küçük çocukların %42' si ve hamile kadınların %40' ı anemiktir [2]. Kansızlığın bu şekilde yaygın olması nedeniyle bu çalışmada anemi hastalığı sınıflandırması üzerine çalışılmıştır. Anemi kan testleri ile teşhisin yapılabilmesi için kan tahlillerinin, radyolojik görüntülerin vb. doktor tarafından gözlenmesi gerekmektedir. Fakat bu süreçler, özellikle gelişmemiş ülkelerde zor ve maliyetli olabilir [3].

Hastalıklar, hastalıkları erken dönemde tespit etmek, hastaya uygun ilaçları reçete etmek ve başlangıç aşamasını kısa keserek kritik aşamaya gelmemek gibi alternatif çözümlerin üretildiği birçok tıbbi veri üretir. Hastalardan elde edilen bu tıbbi veriler kullanılarak yeni hastalar için hastalık tespiti yapılabilir. Bu durum da hekimlerin hasta için yapacakları tanıdaki hata payını en aza indirmesi ve tanı koymasına yardımcı olması açısından önemlidir. Bu sebeple de, sağlık kurumlarındaki veri kayıtlarının değerlendirilmesi hastalar ve hastaneler için oldukça büyük önem arz etmektedir.

Sağlık biliminde önemli bir yere sahip olan veri madenciliğine dayalı işlemler; çok sayıdaki verileri değerlendirerek yararlı verilere dönüştürme konusunda önemlidir. Dünya sağlık örgütü, bu işlemlerin çeşitli hastalıkların tahmininde önemli bir yerinin olduğunu belirtmiştir [4]. Veri madenciliği yöntemlerinin kullanıldığı tıp alanındaki uygulamalardan biri hastalık teşhisidir. Kanseri, obezite, diyabet, tiroid, kalp hastalığı gibi hastalıklar veri madenciliği yöntemlerinin oldukça çok kullanılarak tahmin üretildiği hastalıklardır [5, 6, 7, 8, 9]. Meme kanseri hücrelerinin tahmin edilmesi için yapılan çalışmada C4.5 ve karar ağaçları kullanılmış ve C4.5 karar ağacının hastalık tanı ve teşhisinde %97.4359 doğruluk başarısı verdiği gözlemlenmiştir [6]. Kalp hastalığı teşhisi için yapılan bir çalışmada ZeroR, OneR, Naïve Bayes (NB), J48 Karar Ağacı, Rastgele Orman(RF), Çoklu Algılayıcılar,

k-NN, Lojistik Regresyon (LR), Destek Vektör Makinaları (SVM) gibi sınıflandırma algoritmaları kullanılmıştır [7]. Bu hastalıkların teşhisinde çeşitli yöntemlerin tekil kullanımının yanında hibrit yöntemleri de kullanılmaktadır [10, 11, 12, 13].

Literatürde anemi sınıflandırma probleminde kullanılan birçok veri madenciliği yöntemi mevcuttur. Bu yöntemler k-En Yakın Komşuluk (k-NN), Lojistik Regresyon, Bulanık Mantık (FL), Vektör Nicleme Sinir Ağı (LVQ) vb.dir Çalışmalarda kullanılan bu yöntemler, farklı veri kümelerindeki farklı özellikler nedeniyle iyi performans göstermeyebilir. Veri setlerindeki farklı parametre özellikleri ve sayısı, hasta kayıt sayısı değişikliği gibi farklılıklar anemi hastalığı sınıflandırma yöntemlerinin başarısını önemli ölçüde etkilemektedir. Bu nedenle de çalışılan veri setlerinin özellikleri ve parametre sayıları farklı olabileceğinden yeni tekniklerin geliştirilmesi önemlidir [14].

Yapay sinir ağları; görüntü işleme, makine öğrenimi, doğal dil işleme, biyomedikal vb. alanlarda farklı parametre ve yapılarla sahip verileri sınıflandırmak için başarıyla kullanılmıştır [15, 16, 17]. Sağlık alanında yapılan çalışmalarda yapay sinir ağları yöntemlerinin yüksek başarı gösterdiği görülmüştür [18, 19].

Bu çalışmada Kaggle veri tabanından alınan 1732 kan verisi, dört farklı yapay sinir ağı yöntemi kullanılarak incelenmiştir. Önerilen yöntemler LVQ, CLNN, PRNN ve SOM yöntemleri ile analiz edilerek veri seti anemili / sağlıklı birey olmak üzere ikili sınıflandırmaya tabii tutulmuştur. Bu çalışmanın özgün değeri çoklu Kaggle veri tabanından alınan anemi hastalığı veri setine LVQ, CLNN, PRNN ve SOM yöntemleri ile çözüm ve sonuçların karşılaştırması ilk defa yapılmıştır. Önerilen dört algoritmanın performansı anemi teşhis etmek için karşılaştırılmıştır ve ayrıca literatürde mevcut olan önceki çalışmalardan daha iyi bulunmuştur. Makalenin bir diğer amacı da önerilen dört yöntemden aneminin sınıflandırılmasında elde edilen sonuçların karşılaştırılmasıdır. Literatürde anemi hastalığı sınıflandırması ile ilgili bazı çalışmalar aşağıda sunulmuştur.

2012 yılında yapılan bir çalışmada LVQ, İleri Beslemeli Ağlar (FFN), Dağıtılmış Gecikme Ağları (DDN), Zaman Gecikmeli Ağlar (TDN), Basamaklı İleri Ağlar (CFN), Olasılıklı Sinir Ağı (PNN) gibi sinir ağı çeşitleri kullanılarak kadınlarda demir eksikliği anemisi tahmini üzerinde çalışılmıştır [3]. En yüksek başarı %99.33 doğrulukla LVQ ile sınıflandırmada olduğu sonucuna varılmıştır. YSA yardımıyla talasemi (akdeniz anemisi) hastalığının tespiti için yapılan bir çalışmada 10 farklı talasemi hastalığının sınıflandırılması için yapılan testler sonucunda ortalama %90 başarı performans elde edilmiştir [20]. Başka bir çalışmada kan merkezlerinden toplanan verilerle anemi tahmini için denetimli makine öğrenme algoritmalarından NB, RF ve Karar ağaçları (DT) kullanılmıştır [21]. Sonuç olarak NB'nin daha iyi performans gösterdiği gözlemlenmiştir. 2019 yılında yapılan başka bir çalışmada Bangladeş'te özellikle beş yaş altı çocuklar için ciddi bir halk sağlığı sorunu olan anemi hastalığını tahmin etmek için makine öğrenmesi algoritmalarından Doğrusal Diskriminant Analizi (LDA), Sınıflandırma ve Regresyon Ağaçları (CART), SVM, RF, Lineer Regresyon kullanılmıştır [22]. Çalışma sonucunda RF algoritmasının en iyi sınıflandırma doğruluğuna ulaştığını, k-NN'in en düşük doğruluğu verdiği görülmüştür. 2019 yılında yapılan başka bir çalışmada ise kan parametrelerine dayalı anemi sınıflandırması için yeni bir makine öğrenimi yöntemi (HEAC - Hemoglobin Tahmini ve Anemi Sınıflandırması) önerilmiş olup, literatürdeki diğer makine öğrenmesi metodlarıyla karşılaştırılmıştır [23]. Sonuçta önerilen yöntemin daha iyi performans gösterdiği kaydedilmiştir. 2020 yılında SVM, Ekstrem Öğrenme Makinesi (ELM), k-NN ve Düzenleştirilmiş Ekstrem Öğrenme Algoritmaları (RELM) gibi algoritmaların kullanıldığı çalışmada HGB, RBC, HCT, MCV, MCH, RDW ve MCHC gibi kan parametreleri kullanılarak beta-talasemi ile demir eksikliği anemisi hastalıklarının tanısı için karar destek sistemleri geliştirilmiş olup %95.59 oranında başarı elde edilmiştir [24]. Dört laboratuvar sonuçlarının (MCV, MCH, MCHC, RBC) temel alınarak geliştirildiği kandaki demir eksikliğinin tahmin edildiği bir çalışmada ANN ve uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS) kullanılmıştır [25]. Sonuç olarak ANN ile %96.29 ile en iyi performans elde edilmiştir. PNN, FFN, Gini algoritması, Klone seçim algoritması kullanılarak demir eksikliği anemisi sınıflandırma probleminde %98.73 başarı elde edilmiştir [26]. Başka bir çalışmada demir eksikliği anemisi için HGB, RBC, MCV, HCT kan değerleri kullanılarak çıkış olarak Anemi (+) ve Anemi (-) değerlendirmesi yapılmıştır [27]. Değerlendirmeler için ANN, CDTA, k-NN yöntemleri kullanılmış ve en yüksek başarı ANN ile %78.31 oranı ile elde edilmiştir. 2021 yılında yapılan bir doktora tezinde geliştirilen bir yapay zeka mimarisi ile 12 farklı anemi tipine teşhis koyma çalışması yapılmıştır. Tezde YSA, SVM, NB ve DT yöntemleri kullanılmıştır. Çalışma sonucunda, anemi türlerinin teşhis edilmesinde DT yöntemlerinin daha anlamlı

ve dengeli sonuçlar verdiği ortaya konulmuştur [28]. 2023 yılında yapılan bir çalışmada YSA kullanarak kan örneği görüntülerinden kaydedilen renk bilgileri kullanarak hemoglobin değerleri tahmin edilmiştir [29]. Yapılan başka bir çalışmada da anemi tespit etmek için RF, SVM ve diğer makine öğrenme teknikleri kullanılmıştır. Böyle anemi tespit etme süreci otomatikleştirilmeye çalışılmıştır [30]. 2023 yılında yapılan başka bir çalışmada ise avuç içi görüntüleri toplanarak CNN, k-NN, SVM, Naïve Bayes ve Karar ağaçları kullanılarak anemi saptama çalışması yapılmıştır [31].


Çalışmanın bölümleri şu şekilde sıralanabilir: İkinci bölümde önerilen yöntemler hakkında bilgiler verilmiş, üçüncü bölümde önerilen yöntemlerin deneysel çalışmaları sunulmuştur. Dördüncü bölümde yöntemlerin başarı karşılaştırması yapılmış ve sonuçlar vurgulanmıştır.

2. Materyal ve Yöntem

2.1. Veriseti ve Ön İşleme

Yapılan çalışmada Kaggle veri tabanından alınan 1732 adet hastaya ait kan verisi kullanılmıştır. Veri seti, 351 adet anemi hastası ve 1381 adet anemi hastası olmayan vakalardan oluşmaktadır. Her bir hasta verisinin kandaki kırmızı kan hücresi ya da alyuvar miktarı olan RBC değeri, kırmızı kan hücrelerinde depo edilen demir açısından zengin protein miktarını gösteren hemoglobin miktarı yani HBG değeri, kırmızı kan hücrelerindeki kanın hacimsel miktarı olan HCT değeri, ortalama hücre hacmi olan MCV değeri, belirli bir hacimde bulunan hemoglobin miktarının kırmızı kan hücrelerine oranı olan MCH değeri, tek bir kırmızı kan hücresinin içindeki ortalama hemoglobin miktarı olan MCHC değeri alınarak 6 farklı kan bileşeni ve buna karşılık anemi sonuç bilgisi yer almaktadır.

Şekil 1’de bu çalışmada kullanılan yapının şeması gösterilmiştir.



Şekil 1. Çalışmada kullanılan yapının şemasal gösterimi.

Çizelge 1’de verilerin maksimum ve minimum değerleri gösterilmiştir. Daha tutarlı sonuçlar elde edebilme amacıyla verilerin ön işlenmesi aşamasında kan değerleri 0.1 ile 0.9 arasına çekilerek normalizasyon işlemi yapılmıştır. Verilerin sınıflandırılması için Şekil 1’de görüldüğü gibi LVQ, CLNN, SOM, PRNN yöntemleri kullanılmıştır.

Çizelge 1. Veri setindeki özneliklerin listesi.

| Özellik Adı | Minimum | Maksimum | Ortalama |
|-------------|---------|----------|----------|
| HGB | 2 | 13.100 | 4.484 |
| RBC | 3.600 | 16.700 | 12.453 |
| MCH | 15.700 | 52.110 | 38.003 |
| WBC | 2.900 | 116 | 84.907 |
| MCHC | 13.6 | 39.54 | 27.884 |
| HCT | 22.9 | 43.7 | 32.713 |

2.2. Rekabetçi Katman Sinir Ağı

Bir grup nöronun aktif olma hakkı için rekabet ettiği bir sinir ağına rekabetçi sinir ağı denir [32]. Ekstrem durum olarak, eğer birden fazla nöron aktif olma hakkı elde etmişse, en büyük girdiye sahip düğümün aktivasyonu 1’e, diğer tüm düğümlerin aktivasyonu 0’a eşit olarak ayarlanır [33]. Bu durum “kazanan hepsini alır” mantığı olarak bilinir. Rekabetçi katmandaki nöronlar, genellikle girdi vektörlerini tanımak için kendilerini dağıtırlar [33]. Rekabetçi ağların nöronları, benzer girdi vektörlerinin gruplarını tanımayı öğrenir. Kazanan nöronun ağırlıkları Kohonen öğrenme kuralı ile ayarlanır [34]. Kohonen katmanındaki çıkış düğümleri ile ilişkili olarak bir ağırlık vektörü değerleri vardır. Rekabetçi ağların nöronları, benzer girdi vektörlerinin gruplarını tanımayı öğrenir. Çıktı sıfıra (kazanan nöron) eşit değilse, belirli bir nöron için ağırlık vektörü (w) değiştirilir. Böylece ağırlık vektörü giriş vektörüne daha yakın olan nöron daha da yakın olacak şekilde güncellenir [35]. Sonuç olarak, kazanan nöronun bir daha benzer bir vektör sunulduğunda rekabeti kazanma olasılığı daha yüksektir ve çok farklı bir girdi vektörü sunulduğunda kazanma olasılığı daha düşüktür [35].

2.3. Kendiliğinden Organize Olan Harita

Girdi alanının düşük boyutlu (genel olarak iki boyutlu), ayrıklaştırılmış bir temsilini üretmek için denetimsiz öğrenme kullanılarak eğitilen bir tür yapay sinir ağıdır. SOM ağları, 1981 yılında Teuvo Kohonen tarafından geliştirilmiş olup veri setindeki elemanları hem haritalandırır hem de kümelendirir [35, 36]. SOM ağlarının amacı çok boyutlu bir veriyi iki boyutlu bir haritaya indirgemektir [36]. Veri setindeki değişken sayısı giriş nöronlarının sayısını belirleyen SOM ağları, giriş ve çıkış nöronlarından oluşmaktadır. Giriş nöronları düğümlere ağırlık katsayısı ile bağlıdır. Çıktıdaki düğüm sayısı tercihe bağlı seçilir [35]. Çalışma kapsamında SOM analizi için Neural Network Toolbox Self Organizing Map aracı kullanılarak yapılmıştır.

2.4. Örüntü Tanıma Yapay Sinir Ağı

Örüntü tanıma, ham verileri alan ve desenin kategorisine göre bir eylem yapan bir süreçtir. Belirli koşullara dayalı olarak en uygun şekilde kalıpları çıkarır ve bir sınıfı diğerinden ayırır. Örüntü tanıma ağları, girdileri hedef sınıflara göre sınıflandırmak için eğitilebilen ileri beslemeli, örüntü tanıma tabanlı ağlardır. PRNN için hedef veriler, temsil edecekleri sınıf olan i ögesindeki 1 hariç tüm sıfır değerlerinin vektörlerinden oluşur [37].

2.5. Öğrenmeli Vektör Kuantalama Yapay Sinir Ağı

Temel prensibi belirli sayıda vektör kullanarak bir vektörü temsil etmek olup Kohonen tarafından geliştirilmiştir [34]. SOM ağlarının bir çeşididir. Bir LVQ ağı, birinci rekabetçi katmana ve ikinci bir doğrusal katmana sahiptir [38]. “Kazanan her şeyi alır” prensibinden yola çıkarak geliştirilen LVQ modelini temel felsefesi, girişleri referans vektör olarak ifade etmektir [38]. LVQ ağı; giriş katmanı, Kohonen katmanı ve çıkış katmanı olmak üzere üç katmandan oluşur [39]. Giriş katmanında veriler ağa sunulurken, Kohonen katmanında referans vektörleri bulunur ve bu katmanda gelen veriler komşulukluklarına göre yarıştırlır. Çıkış katmanında ise en yakın nöronun sınıf bilgisi yer almaktadır.

3. Deneysel Çalışma

Çalışmada anemi ve anemi olmayan/sağlıklı bireyler olarak iki sınıf ifade edilmiştir. Test ve eğitim aşamasında tüm veri seti kullanılmıştır. Çalışmada Intel Core i5 11400 F 2.6 GHz işlemci ve 16 GB DDR4 belleğe sahip bir sistem üzerinde uygulama gerçekleştirilmiştir. Çalışma kapsamında LVQ, PRNN, CLNN ve SOM kullanılarak anemi veri seti üzerinde tahmin çalışması yapılmıştır. 4 farklı algoritmanın performansını kıyaslamak için ROC analizi ölçütü kullanılmıştır. ROC analizi, çeşitli yöntemler ile elde edilen sonuçların performansını karşılaştırmak amacıyla, sonuçların Accuracy (doğruluk), Sensitivity (duyarlılık), Specificity (özgüllük), Precision (kesinlik), F1 skor olarak değerlendirilebilmesini sağlayan bir yöntemdir [40]. Veri madenciliği uygulamalarında sıklıkla kullanılmaktadır [41].

ROC analizi için temel eşitlikler Eş. 1-5 ile gösterilmiştir.

$$\text{Accuracy} = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

$$\text{Sensitivity} = \frac{TP}{TP+FN} \quad (2)$$

$$\text{Specificity} = \frac{TN}{FP+TN} \quad (3)$$

$$\text{Precision} = \frac{TP}{TP+FP} \quad (4)$$

$$\text{F1 - Score} = \frac{2 \cdot \text{Precision} \cdot \text{Sensitivity}}{\text{Precision} + \text{Sensitivity}} \quad (5)$$

ROC değerleri içerisindeki doğruluk değeri Eş. 1 ile, duyarlılık değeri Eş. 2 ile, özgüllük değeri Eş. 3, kesinlik değeri Eş. 4, F1 Skor değeri Eş. 5 ile hesaplanmaktadır. Bu hesaplamalar ile elde edilen sonuçlar, 4 farklı yöntemle karşılaştırılmıştır. ROC analizinin amacı, çeşitli metodlar ile elde edilen sonuçların performansını karşılaştırabilmek için, sonuçların duyarlılık, özgüllük ve doğruluk olarak değerlendirilebilmesini sağlayan bir metottur [40]. Analizde kullanılan ROC parametreleri TP, TN, FP ve FN'dir. TP (True Positive); hasta olarak sınıflandırılmış bir hastanın, analiz sonucunda hasta olarak tespit edilmesiyken, TN (True Negative); sağlıklı olarak sınıflandırılmış bir kayıtn, analiz sonucunda hasta olarak tespit edilmesidir. FP (False Positive); sağlıklı olarak tespit edilen bir kayıtn analiz sonucu test sonuçlarının hasta olarak tespit edilmesiyken, FN (False Negative); hasta olarak tespit edilen kayıtn analiz sonucu test sonuçlarının sağlıklı olarak tespit edilmesidir.

ROC analizi için genel konfüzyon matrisi Çizelge 2'de görülmektedir.

Çizelge 2. ROC analiz konfüzyon matrisi.

| | Tahmin Edilen | |
|---|---------------|---|
| | 0 | 1 |
| 0 | | |
| 1 | | |

| | | | |
|--------|---|----|----|
| Gerçek | 0 | TN | FP |
| | 1 | FN | TP |

Çalışmada kullanılan verisetinin ilk 10 hasta için örneği Çizelge 3'te verilmiştir. Çizelgelerde verilen S sıra, Ö öznitelik, M metot, T test değerlerinin kısaltılmış halidir. Çalışmada her bir yapay sınır ağı için 10 farklı test yapılarak her bir test için sonuçlar ve en iyi sonuçlar Çizelge 3-11'de listelenmiştir.

Çizelge 3. Veriseti kayıt örneği.

| S | Ö | | | | | | Sonuç |
|----|------|------|------|-------|-------|-------|-------|
| | RBC | HBG | HCT | MCV | MCH | MCHC | |
| 1 | 4.98 | 8.8 | 31.6 | 63.52 | 17.72 | 27.82 | 1 |
| 2 | 4.83 | 10.9 | 35.9 | 74.32 | 22.62 | 30.42 | 1 |
| 3 | 4.34 | 11 | 34.7 | 80.02 | 25.32 | 31.7 | 0 |
| 4 | 4.03 | 11.1 | 34.9 | 86.6 | 27.5 | 31.8 | 1 |
| 5 | 3.71 | 11.1 | 34.3 | 92.5 | 29.9 | 32.4 | 0 |
| 6 | 4.37 | 11.2 | 35.8 | 81.92 | 25.62 | 31.3 | 0 |
| 7 | 4.2 | 12.2 | 34.4 | 81.9 | 29 | 35.5 | 0 |
| 8 | 3.62 | 10.8 | 33.3 | 92 | 29.8 | 32.4 | 1 |
| 9 | 4.34 | 7.72 | 26.6 | 61.32 | 17.72 | 28.92 | 1 |
| 10 | 4.05 | 10.1 | 32.5 | 80.22 | 24.92 | 31.1 | 1 |

Çizelge 4. CLNN Yöntemi için ROC Analiz Sonuçları.

| T | M | | | | Accuracy | Sensitivity | Specificity | Precision | F1 |
|---------|-----|------|----|-----|----------|-------------|-------------|-----------|--------|
| | TP | TN | FP | FN | | | | | |
| Test 1 | 291 | 1026 | 60 | 355 | 0.7604 | 0.4505 | 0.9448 | 0.8291 | 0.5838 |
| Test 2 | 294 | 1028 | 57 | 353 | 0.7633 | 0.4544 | 0.9475 | 0.8376 | 0.5892 |
| Test 3 | 298 | 997 | 53 | 384 | 0.7477 | 0.4370 | 0.9495 | 0.8490 | 0.5770 |
| Test 4 | 295 | 998 | 56 | 383 | 0.7465 | 0.4351 | 0.9469 | 0.8405 | 0.5734 |
| Test 5 | 297 | 999 | 54 | 382 | 0.7483 | 0.4374 | 0.9487 | 0.8462 | 0.5767 |
| Test 6 | 299 | 983 | 52 | 398 | 0.7402 | 0.4290 | 0.9498 | 0.8519 | 0.5706 |
| Test 7 | 304 | 920 | 47 | 461 | 0.7067 | 0.3974 | 0.9514 | 0.8661 | 0.5448 |
| Test 8 | 293 | 1059 | 58 | 322 | 0.7806 | 0.4764 | 0.9481 | 0.8348 | 0.6066 |
| Test 9 | 299 | 957 | 52 | 424 | 0.7252 | 0.4136 | 0.9485 | 0.8519 | 0.5568 |
| Test 10 | 298 | 986 | 53 | 395 | 0.7413 | 0.4300 | 0.9490 | 0.8490 | 0.5709 |

Çizelge 4’te gösterildiği üzere CLNN yöntemi anemi hastalığı veriseti üzerinde 10 kere çalıştırılmıştır. Her test sonucunda TP, TN, FP, FN, Accuracy, Sensitivity, Specificity, Precision, F1-Score değerleri hesaplanmıştır. Bu hesaplamalara göre CLNN yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 5’te verilmiştir.

Çizelge 5. CLNN yöntemi için ortalama ve en iyi sonuç.

| M T | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------------------|-----------------|--------------------|--------------------|------------------|-----------|
| Ortalama | 0.7460 | 0.4361 | 0.9484 | 0.8456 | 0.5750 |
| En iyi (8.Test) | 0.7806 | 0.4764 | 0.9481 | 0.8348 | 0.6066 |

Çizelge 6. SOM yöntemi için ROC analiz sonuçları.

| M T | TP | TN | FP | FN | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------|-----------|-----------|-----------|-----------|-----------------|--------------------|--------------------|------------------|-----------|
| Test 1 | 241 | 1232 | 110 | 149 | 0.8505 | 0.6179 | 0.9180 | 0.6866 | 0.6505 |
| Test 2 | 236 | 1248 | 115 | 133 | 0.8568 | 0.6396 | 0.9156 | 0.6724 | 0.6556 |
| Test 3 | 235 | 1250 | 116 | 131 | 0.8574 | 0.6421 | 0.9151 | 0.6695 | 0.6555 |
| Test 4 | 240 | 1240 | 111 | 141 | 0.8545 | 0.6299 | 0.9178 | 0.6838 | 0.6557 |
| Test 5 | 236 | 1248 | 115 | 133 | 0.8568 | 0.6396 | 0.9156 | 0.6724 | 0.6556 |
| Test 6 | 240 | 1241 | 111 | 140 | 0.8551 | 0.6316 | 0.9179 | 0.6838 | 0.6566 |
| Test 7 | 232 | 1257 | 119 | 124 | 0.8597 | 0.6517 | 0.9135 | 0.6610 | 0.6563 |
| Test 8 | 237 | 1246 | 114 | 135 | 0.8562 | 0.6371 | 0.9162 | 0.6752 | 0.6556 |
| Test 9 | 234 | 1250 | 117 | 131 | 0.8568 | 0.6411 | 0.9144 | 0.6667 | 0.6536 |
| Test 10 | 236 | 1248 | 115 | 133 | 0.8568 | 0.6396 | 0.9156 | 0.6724 | 0.6556 |

Çizelge 6’da gösterildiği üzere SOM yöntemi ile yapılan testler verilmiştir. Bu test sonucuna göre SOM yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 7’de verilmiştir.

Çizelge 7. SOM yöntemi için ortalama ve en iyi sonuç.

| M T | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------------------|-----------------|--------------------|--------------------|------------------|-----------|
| Ortalama | 0.8561 | 0.6370 | 0.9160 | 0.6744 | 0.6551 |
| En iyi (7.Test) | 0.8597 | 0.6517 | 0.9135 | 0.6610 | 0.6563 |

Çizelge 8. PRNN yöntemi için ROC analiz sonuçları.

| M T | TP | TN | FP | FN | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------|-----------|-----------|-----------|-----------|-----------------|--------------------|--------------------|------------------|-----------|
| Test 1 | 345 | 1380 | 6 | 1 | 0.9960 | 0.9971 | 0.9957 | 0.9829 | 0.9900 |
| Test 2 | 347 | 1380 | 4 | 1 | 0.9971 | 0.9971 | 0.9971 | 0.9886 | 0.9928 |
| Test 3 | 349 | 1381 | 2 | 0 | 0.9988 | 1 | 0.9986 | 0.9943 | 0.9971 |
| Test 4 | 347 | 1380 | 4 | 1 | 0.9971 | 0.9971 | 0.9971 | 0.9886 | 0.9928 |
| Test 5 | 347 | 1380 | 4 | 1 | 0.9971 | 0.9971 | 0.9971 | 0.9886 | 0.9928 |
| Test 6 | 346 | 1380 | 5 | 1 | 0.9965 | 0.9971 | 0.9964 | 0.9858 | 0.9914 |
| Test 7 | 346 | 1380 | 5 | 1 | 0.9965 | 0.9971 | 0.9964 | 0.9858 | 0.9914 |
| Test 8 | 346 | 1380 | 5 | 1 | 0.9965 | 0.9971 | 0.9964 | 0.9858 | 0.9914 |
| Test 9 | 347 | 1380 | 4 | 1 | 0.9971 | 0.9971 | 0.9971 | 0.9886 | 0.9928 |
| Test 10 | 348 | 1380 | 3 | 1 | 0.9977 | 0.9971 | 0.9978 | 0.9915 | 0.9943 |

Çizelge 8’de gösterildiği üzere PRNN yöntemi anemi hastalığı veriseti üzerinde 10 kere çalıştırılmıştır. Her test sonucunda TP, TN, FP, FN, Accuracy, Sensitivity, Specificity, Precision, F1-Score değerleri hesaplanmıştır. Bu hesaplamalara göre PRNN yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 9’da verilmiştir.

Çizelge 9. PRNN yöntemi için ortalama ve en iyi sonuç.

| M T | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------------|-----------------|--------------------|--------------------|------------------|-----------|
| Ortalama | 0.9970 | 0.9974 | 0.9970 | 0.9881 | 0.9927 |
| En iyi (3.Test) | 0.9988 | 1 | 0.9986 | 0.9943 | 0.9971 |

Çizelge 10. LVQ yöntemi için ROC analiz sonuçları.

| M T | TP | TN | FP | FN | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------|-----------|-----------|-----------|-----------|-----------------|--------------------|--------------------|------------------|-----------|
| Test 1 | 312 | 1354 | 39 | 27 | 0.9619 | 0.9204 | 0.9720 | 0.8889 | 0.9043 |
| Test 2 | 316 | 1349 | 35 | 32 | 0.9613 | 0.9080 | 0.9747 | 0.9003 | 0.9041 |
| Test 3 | 316 | 1354 | 35 | 27 | 0.9642 | 0.9213 | 0.9748 | 0.9003 | 0.9107 |
| Test 4 | 313 | 1355 | 38 | 26 | 0.9630 | 0.9233 | 0.9727 | 0.8917 | 0.9072 |
| Test 5 | 307 | 1349 | 44 | 32 | 0.9561 | 0.9056 | 0.9684 | 0.8746 | 0.8899 |
| Test 6 | 314 | 1349 | 37 | 32 | 0.9602 | 0.9075 | 0.9773 | 0.8946 | 0.9010 |
| Test 7 | 318 | 1357 | 33 | 24 | 0.9671 | 0.9298 | 0.9763 | 0.9060 | 0.9177 |
| Test 8 | 313 | 1351 | 38 | 30 | 0.9607 | 0.9125 | 0.9726 | 0.8917 | 0.9020 |

| | | | | | | | | | |
|----------------|-----|------|----|----|--------|--------|--------|--------|--------|
| Test 9 | 311 | 1352 | 40 | 29 | 0.9602 | 0.9147 | 0.9713 | 0.8860 | 0.9001 |
| Test 10 | 303 | 1346 | 48 | 35 | 0.9521 | 0.8964 | 0.9656 | 0.8632 | 0.8795 |

Çizelge 10’da gösterildiği üzere LVQ yöntemi ile yapılan testler verilmiştir. Bu test sonucuna göre LVQ yöntemi için ortalama ve en iyi sonuç değerleri Çizelge 11’de verilmiştir.

Çizelge 11. LVQ yöntemi için ortalama ve en iyi sonuç.

| M T | Accuracy | Sensitivity | Specificity | Precision | F1 |
|----------------------------|-----------------|--------------------|--------------------|------------------|-----------|
| Ortalama | 0.9607 | 0.9140 | 0.9726 | 0.8897 | 0.9017 |
| En iyi (7.Test) | 0.9671 | 0.9298 | 0.9763 | 0.9060 | 0.9177 |

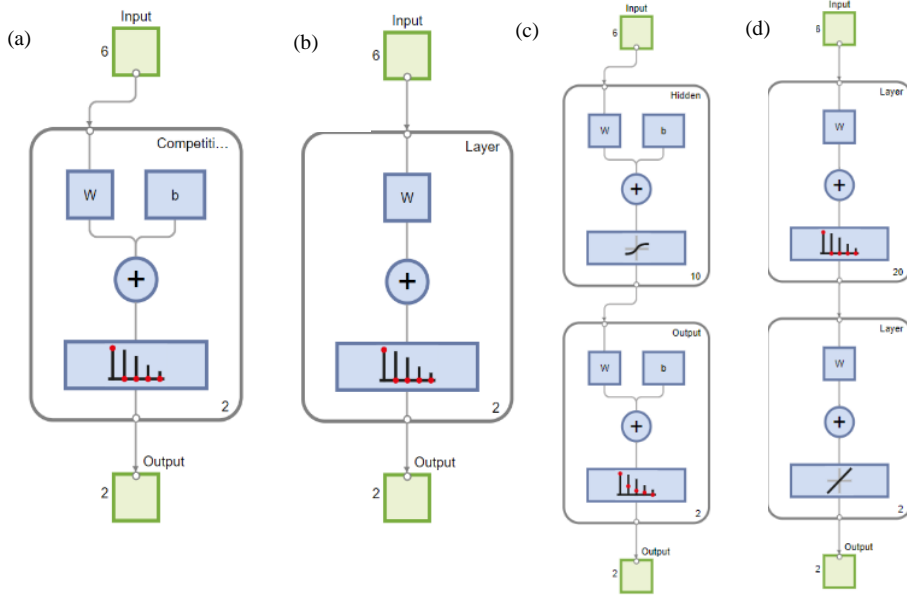
4. Sonuçlar

Bu çalışma kapsamında Kaggle veri tabanından 1732 adet hastaya ait kan verisi alınarak anemi hastalığı tahmin problemi üzerinde çalışılmıştır. Her bir hasta verisinin RBC, HBG, HCT, MCV, MCH ve MCHC kan değerlerinden olmak üzere 6 farklı kan bileşeni ve buna karşılık anemi sonuç bilgisi yer aldığı veri tabanındaki bilgilerin sınıflandırılması için yapay sinir ağları yöntemlerinden LVQ, PRNN, CLNN ve SOM ağları kullanılmıştır. MATLAB Neural Network Toolbox arayüzü kullanılarak modelleme yapılmıştır [42].

Eğitim sürecinde kullanılan adımlar Çizelge 12’de listelenmiştir. Performans fonksiyonu olarak tüm yöntemler için Ortalama Kare Hatası (Mse) kullanılmıştır. Önerilen ağların iterasyonları, hızları, hata oraları, eğitim fonksiyonları ve uyarlamalı öğrenme fonksiyonu olarak kullanılan fonksiyonlar Çizelge 12’de sunulmuştur. Çalışmada Matlab Toolbox kullanıldığı için kullanılan fonksiyonlara müdahale edilmemiştir. Eğitim sürecinde tüm veriler kullanılmış, test sürecinde yine tüm veriler test edilmiştir. RBC, HGB, HCT, MCH, MCHC ve MCV değerlerine sahip 1732 hastadan alınan kan örneğinin kan analizi 6 giriş nöronu olarak kullanılmış ve sonuç verisi çıkış olarak sisteme girilmiştir. Önerilen yöntemlerin Network Diagram’ı Şekil 2’de verilmiştir.


Çizelge 12. Ağ eğitiminin karşılaştırılması.

| | İterasyonlar | Zaman (sn) | Hata (mse) | Eğitim Fonksiyonu | Uyarlamalı Öğrenme Fonksiyonları |
|-------------|---------------------|-------------------|-------------------|-------------------------------------|---|
| CLNN | 1000 | 264 | Eğitim Yok | Trainr (Random Weight/Bias Rule) | adaptwb |
| SOM | 200 | 0 | Eğitim Yok | Trainbu (Batch Weight/Bias Rule) | adaptwb |
| PRNN | 1000 | 2 | 0.005 | Trainscg(Scaled Conjugate Gradient) | adaptwb |
| LVQ | 1000 | 925 | 0.041 | Trainr (Random Weight/Bias Rule) | adaptwb |



Şekil 2. Önerilen yöntemlerin Network Diyagramları; (a) CLNN Network Diyagram, (b) SOM Network Diyagram, (c) PRNN Network Diyagram, (d) LVQ Network Diyagram.

Şekil 2’de görüldüğü üzere önerilen dört yöntemin diyagramları açıklanmak istenirse; Şekil 2(a) ve (b)’da verilen CLNN ve SOM ağıının diyagramında transfer fonksiyonu olarak ‘compet’ kullanılmıştır. Şekil 2(c) PRNN ağıının diyagramı 1 gizli katman ve 1 çıkış katmanı olarak oluşturulmuştur. Gizli katmanda transfer fonksiyonu ‘tansig’, çıkış katmanında ‘softmax’ kullanılmıştır. Şekil 2(d) LVQ ağıının diyagramı 2 katmanla oluşturulmuştur. 1. katmanda transfer fonksiyonu olarak ‘compet’, 2. katmanda ‘purelin’ kullanılmıştır.



Şekil 3. Dört yöntem için en iyi sonuç veren testlerin konfüzyon matrisi; (a) CLNN konfüzyon matrisi, (b) SOM konfüzyon matrisi, (c) PRNN konfüzyon matrisi, (d) LVQ konfüzyon matrisi

Çizelge 13. Tüm yöntemler için en iyi sonuç.

| Yöntem | En iyi Accuracy | En iyi Sensitivity | En iyi Specificity | En iyi Precision | En iyi F1-Skor |
|--------|-----------------|--------------------|--------------------|------------------|----------------|
| CLNN | 0.7806 | 0.4764 | 0.9481 | 0.8348 | 0.6066 |
| SOM | 0.8597 | 0.6517 | 0.9135 | 0.6610 | 0.6563 |
| PRNN | 0.9988 | 1 | 0.9986 | 0.9943 | 0.9971 |
| LVQ | 0.9671 | 0.9298 | 0.9763 | 0.9060 | 0.9177 |

Şekil 3(a)'da CLNN ağı için yapılan 10 test sonucunda için en iyi sonucu veren 8.testin, Şekil 3(b)'de SOM için en iyi sonucu veren 7.testin, PRNN için en iyi sonucu veren 3.testin ve LVQ için en iyi sonucu veren 1.testin konfüzyon matrisleri verilmiştir. Çizelge 13'te tüm yöntemlerin en iyi sonuçları tek bir çizelgede gösterilmiştir.

Matrisler ve sonuçlar karşılaştırıldığında PRNN test işlemi sonucunda %100 hassasiyet ve %99,88 doğruluk, %99,86 özgüllük, %99,43 kesinlik ile anemi hastalığı tespit etmede iyi bir performans gösterdiği sonucuna ulaşılmıştır. Çizelge 14’te literatür taraması yapıldığı kadarıyla veri seti benzerliği gösteren diğer çalışmaların doğruluk performansları listelenmiştir. Çizelgede yer alan sonuçlara göre önerdiğimiz yöntem ile tıbbi veri sınıflandırmasının çok yüksek doğrulukla mümkün olduğu gösterilmiştir. PRNN’yi takiben doğruluk başarısının %96,71 ile LVQ, %85,97 ile SOM, %78,06 ile CLNN olduğu sonucuna varılmıştır. Sonuçlar değerlendirildiğinde LVQ, PRNN, CLNN ve SOM kullanılarak yapılan tahmin sürecinde 351’i anemili ve 1381’i anemisiz olmak üzere toplam 1732 vakada 6 farklı kan bileşeni kullanılarak hedeflenen çıktılara başarıyla ulaşılmıştır. Bilindiği kadarıyla bu çalışma ile Kaggle veritabanından alınan anemi hastalığı veri setine LVQ, CLNN, PRNN ve SOM yöntemleri ile çözüm ve çözümlerin karşılaştırması ilk defa yapılmıştır. Böylece bir hasta kaydının anemi olup olmadığının doğru bir şekilde teşhis edilmesi ve hekimlerin karar vermesine yardımcı olacak bir karar destek sistemi geliştirilmiştir. Bu sunulan algoritmalar için hastanın kanından alınan yaş, cinsiyet, kilo ve farklı bileşenler gibi ekstra parametreler eklenerek aneminin en iyi sınıflandırması bulunabilir. Bundan sonraki hedefimiz ise, Türkiye’deki bir hastaneden daha fazla parametreyi içeren yeni veri seti alınarak anemi tiplerini belirlemektir.

Çizelge 14. Çalışmamıza benzer ilgili çalışmalar.

| Parametre | Yöntem | Kaynak | Accuracy |
|--|---|--------|----------|
| HGB, RBC, MCH, WBC, MCHC, HCT | FFN, CFN, DDN, TDN, LVQ, PNN | [3] | %99.33 |
| MCV, RBC HGB, HCT, MCHC MCH, RDW | k-NN, LR, SVM, Ekstrem Öğrenme Makinesi ve Düzenli Ekstrem Öğrenme Makinesi | [24] | %95.59 |
| MCV MCH, MCHC, HGB, RBC | ANN ve uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS) | [25] | %96.29 |
| MCH, MCHT, MCV, RBC HGB, HCT | PNN, FFN, Gini algoritması, Klon seçim algoritması | [26] | %98.73 |
| HGB, RBC MCV, HCT | ANN, CDTA k-NN, | [27] | %78.31 |
| HGB, HCT, MCH, MCV | RF, Naïve Bayes ve CDTA | [21] | %96.09 |
| Önerdiğimiz Yöntemler için Sonuçlar | | | |
| Parametre | Yöntem | | Accuracy |
| HGB, RBC, MCH, WBC, MCHC, HCT | CLNN | | %78.06 |
| | SOM | | %85.97 |
| | PRNN | | %99.88 |
| | LVQ | | %89.67 |

Teşekkür

Yazarların özellikle teşekkür edecekleri kimse bulunmamaktadır.

Kaynakça

- [1] Baldi, A., Pasricha, S. R. (2022). Anaemia: Worldwide Prevalence and Progress in Reduction, Nutritional Anemia. Springer International Publishing, 3-17.
- [2] World Health Organization (WHO), https://www.who.int/healthtopics/anaemia#tab=tab_1
- [3] Yılmaz, Z., Bozkurt, M. R. (2012). Determination of women iron deficiency anemia using neural networks. Journal of medical systems, 36, 2941-2945.
- [4] Vijayarani, S., Sudha, S. (2013). Disease prediction in data mining technique—a survey. International Journal of Computer Applications & Information Technology, 2(1), 17-21.
- [5] Dörterler, S. (2023). Kanser Hastalığı Teşhisinde Ölüm Oyunu Optimizasyon Algoritmasının Etkisi. Mühendislik Alanında Uluslararası Araştırmalar VIII, 15.
- [6] Danacı, M., Çelik, M., Akkaya, A. E. (2010). Veri madenciliği yöntemleri kullanılarak meme kanseri hücrelerinin tahmin ve teşhisi. Akıllı Sistemlerde Yenilikler ve Uygulama Sempozyumu, 21(24), 9-12.
- [7] Taşçı, M. E., Şamlı, R. (2020). Veri madenciliği ile kalp hastalığı teşhisi. Avrupa Bilim ve Teknoloji Dergisi, 88-95.
- [8] Başer, B. Ö., Yangın, M., Sarıdaş, E. S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.
- [9] Akgül, G., Çelik, A. A., Aydın, Z. E., Öztürk, Z. K. (2020). Hipotiroidi Hastalığı Teşhisinde Sınıflandırma Algoritmalarının Kullanımı. Bilişim Teknolojileri Dergisi, 13(3), 255-268.
- [10] Yeh, W. C., Chang, W. W., Chung, Y. Y. (2009). A new hybrid approach for mining breast cancer pattern using discrete particle swarm optimization and statistical method. Expert Systems with Applications, 36(4), 8204-8211.
- [11] Devi, R. D. H., Bai, A., Nagarajan, N. (2020). A novel hybrid approach for diagnosing diabetes mellitus using farthest first and support vector machine algorithms. Obesity Medicine, 17, 100152.
- [12] Dörterler, S. (2022). Hybridization of k-means and meta-heuristics algorithms for heart disease diagnosis. NEW TRENDS IN ENGINEERING AND APPLIED NATURAL SCIENCES, 55.
- [13] Dörterler, S., Dumlu, H., Özdemir, D., & Temurtaş, H. (2022). Melezlenmiş K-means ve Diferansiyel Gelişim Algoritmaları ile Kalp Hastalığının Teşhisi. In International Conference on Engineering and Applied Natural Sciences, 1840-1844.
- [14] Kilicarslan, S., Celik, M., Sahin, Ş. (2021). Hybrid models based on genetic algorithm and deep learning algorithms for nutritional Anemia disease classification. Biomedical Signal Processing and Control, 63, 102231.
- [15] Ergezer, H., Dikmen, M., Özdemir, E. (2003). Yapay sinir ağları ve tanıma sistemleri. PiVOLKA, 2(6), 14-17.
- [16] Uğur, A., Kınacı, A. C. (2006). Yapay zeka teknikleri ve yapay sinir ağları kullanılarak web sayfalarının sınıflandırılması. XI. Türkiye'de İnternet Konferansı (inet-tr'06), Ankara, 1(4).
- [17] Akgündoğdu, A. (2003). Bulanık-yapay sinir ağları ile biyomedikal görüntü işlenmesi, Yüksek Lisans Tezi, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- [18] Gil, D., Johnsson, M., Chamizo, JMG, Paya, AS, Fernandez, DR. (2009). Yapay sinir ağlarının ürolojik fonksiyon bozukluklarının teşhisinde uygulanması. Uygulamalı uzman sistemler, 36 (3), 5754-5760.
- [19] Gönül, Y., Ulu, Ş., Bucak, A., Bilir, A. (2015). Yapay sinir ağları ve klinik araştırmalarda kullanımı. Genel Tıp Dergisi, 25(3).
- [20] Wongseeree, W., Chaiyaratana, N., Vichittumaros, K., Winichagoon, P., Fucharoen, S. (2007). Thalassaemia classification by neural networks and genetic programming. Information Sciences, 177(3), 771-786.
- [21] Jaiswal, M., Srivastava, A., Siddiqui, T. J. (2019). Machine learning algorithms for anemia disease prediction. Recent Trends in Communication, Computing, and Electronics: Select Proceedings of IC3E 2018, Springer Singapore, 463-469.

- [22] Khan, J. R., Chowdhury, S., Islam, H., Raheem, E. (2021). Machine learning algorithms to predict the childhood anemia in Bangladesh. *Journal of Data Science*, 17(1), 195-218.
- [23] El-kenawy, E. S. M. T. (2019). A Machine Learning Model for Hemoglobin Estimation and Anemia Classification. *International Journal of Computer Science and Information Security (IJCSIS)*, 17(2), 100-108.
- [24] Çil B., Ayyıldız H., Tuncer T. (2020). Discrimination of β -thalassemia and iron deficiency anemia through e treme learning machine and regularized e treme learning machine-based decision support system. *Medical Hypotheses*, 138, 1- 6, DOI: <https://doi.org/10.1016/j.mehy.2020.109611>.
- [25] Azarkhish, I., Raoufy, M. R., & Gharibzadeh, S. (2012). Artificial intelligence models for predicting iron deficiency anemia and iron serum level based on accessible laboratory data. *Journal of medical systems*, 36, 2057-2061
- [26] Çarklı Yavuz, B., Karagül Yıldız, T., Yurtay, N., Pamuk, Z. (2014). Comparison Of K Nearest Neighbours And Regression Tree Classifiers Used With Clonal Selection Algorithm to Diagnose Haematological Diseases. *AJIT-e: Online Academic Journal of Information Technology*, 5(16).
- [27] İlaslaner, T., Güven, A. (2019). Demir Eksikliği Anemisinde Biyokimya Değerlerinin Etkisinin İncelenmesi. *Tıp Teknolojileri Kongresi*.
- [28] Karagül Yıldız, T. (2021). Hematolojik hastalıkların teşhisinde yapay zeka tekniklerinin performans karşılaştırması, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü
- [29] Ghosh, A., Mukherjee, J., Chakravorty, N. (2023). A Low-Cost Test for Anemia Using an Artificial Neural Network. *Computer Methods and Programs in Biomedicine*, 229, 107251.
- [30] Dixit, A., Jha, R., Mishra, R., & Vhatkar, S. (2023). Prediction of Anemia Disease Using Machine Learning Algorithms. In *Intelligent Computing and Networking: Proceedings of IC-ICN 2022*, Singapore: Springer Nature Singapore, 229-238.
- [31] Appiahene, P., Asare, J. W., Donkoh, E. T., Dimauro, G., & Maglietta, R. (2023). Detection of iron deficiency anemia by medical images: a comparative study of machine learning algorithms. *BioData Mining*, 16(1), 1-20.
- [32] Behnke, S., Karayiannis, N. B. (1988). Competitive neural trees for pattern classification. *IEEE Transactions on Neural Networks*, 9(6), 1352-1369.
- [33] Sowmya, B., & Rani, B. S. (2011). Colour image segmentation using fuzzy clustering techniques and competitive neural network. *Applied Soft Computing*, 11(3), 3170-3178.
- [34] Kohonen, T. (2012). *Self-organization and associative memory*. Springer Science & Business Media.
- [35] Turias, I. J., Gonzalez, F. J., Martín, M. L., Galindo, P. L. (2006). A competitive neural network approach for meteorological situation clustering. *Atmospheric Environment*, 40(3), 532-541.
- [36] Kalan, O. (2009). Lejyoner hastalığının istatistiksel risk analizi, Yüksek Lisans Tezi.
- [37] Al-Allaf, O. N. A., AbdAlKader, S. A., Tamimi, A. A. (2013). Pattern recognition neural network for improving the performance of iris recognition system. *Int'l Journal of Scientific & Engineering Research*, 4(6), 661-667.
- [38] Çetin, O., & Temurtaş, F. (2018). Öğrenmeli Vektör Kuantalama ile Beyin Bilgisayar Arayüzü Üzerine Bir Çalışma. *Sakarya University Journal of Computer and Information Sciences*, 1(2), 1-7.
- [39] Er, O., Yumusak, N., Temurtas, F. (2010). Chest diseases diagnosis using artificial neural networks. *Expert Systems with Applications*, 37(12), 7648-7655.
- [40] Obuchowski, N. A. (2005). ROC analysis. *American Journal of Roentgenology*, 184(2), 364-372.
- [41] Slaby, A. (2007). ROC analysis with Matlab. 2007 29th International Conference on Information Technology Interfaces, 191-196.
- [42] Matlab, S. (2012). *Matlab. The MathWorks*, Natick, MA.



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 25.12.2022

Kabul Tarihi(Accepted Date): 04.04.2023

Investigation of the effects of some plant varieties on tyrosinase activity and antioxidant properties

Duygu YAMAN¹, Hatice SERİN², Merve ÇALIŞ³, Gulnur ARABACI^{4*}

¹Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Kimya Bölümü, Sakarya, ORCID: 0000-0002-8283-7490

²Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Biyomedikal Mühendisliği Bölümü, Sakarya, ORCID: 0000-0003-3087-8351

³Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Kimya Bölümü, Sakarya, ORCID: 0000-0003-3708-3391

⁴Sakarya Üniversitesi, Fen Fakültesi, Kimya Bölümü, Sakarya, ORCID: 0000-0002-1190-5695

Abstract

Free radicals and reactive oxygen derivatives that cause damage to cells are effectively reduced by antioxidants and converted into products with less toxicity. Antioxidants must be taken into the body continuously to maintain living health. The enzyme tyrosinase is an oxidase that catalyzes the oxidation of tyrosine in the synthesis of melanin, the pigment that gives color to the skin. Over or under-expression of the enzyme can cause various skin problems and neurodegenerative damage in living things. This study aimed to determine the antioxidant capacity of rosemary and green tea, two important plants that we consume in our daily life in meals and as herbal tea, by determining the tyrosinase enzyme inhibition effects, total phenolic substance content, and DPPH free radical scavenging activity. The natural extraction method is preferred. According to this method, green tea and rosemary plants were dried and extracted with pure water by brewing method. The rosemary plant inhibited the tyrosinase enzyme at 750 µg/ml concentrations by 75% and the green tea plant at 1000 µg/ml concentration by 77%. Total phenolic contents were determined by the Folin-Ciocalteu method. Green tea (186 mg/GAE) was found to have the highest phenolic content. Antioxidant capacities were determined by the DPPH(1,1-diphenyl-2-picryl-hydrazil) method, and their free radical scavenging effects were determined. Trolox and BHT were used as positive controls in the DPPH method. Green tea and rosemary showed the highest DPPH free radical scavenging activity at 1000 µg/ml concentration

Keywords: Tyrosinase, Antioxidant, Phenolic Substance, Rosemary, Green Tea

Bazı bitki çeşitlerinin tirozinaz aktivitesine etkileri ve antioksidan özelliklerinin incelenmesi

Öz

Hücrelerde hasar oluşturan serbest radikaller ve reaktif oksijen türevleri, antioksidanlar tarafından etkili şekilde indirgenerek daha az toksisitesi olan ürünlere dönüştürülür. Canlı sağlığının devamlılığı açısından antioksidanların sürekli olarak vücuda alınması gerekmektedir. Tirozinaz enzimi, deriye renk veren pigment olan melaninin sentezinde tirozinin oksidasyonunu katalizleyen bir oksidazdır. Enzimin çok ya da az sentezlenmesi canlılarda çeşitli cilt sorunlarına ve bazı nörodejeneratif hasarlara yol açabilmektedir. Bu çalışmada günlük hayatımızda yemeklerde ve bitki çayı olarak tükettiğimiz iki önemli bitkiden biberiye ve yeşil çayın tirozinaz enzimi inhibisyon etkilerini, içeriğindeki toplam fenolik madde miktarı ve DPPH serbest radikal giderimi aktivitesinin belirlenerek antioksidan kapasitesinin tespit edilmesi amaçlanmıştır. Doğal ekstraksiyon yöntemi tercih edilmiştir. Bu yöntemle göre biberiye and yeşil çay bitkileri kurutulularak demleme metoduyla saf su ile ekstrakte edilmiştir. Tirozinaz enzimini, biberiye bitkisi 750 µg/ml konsantrasyonda %75, yeşil çay bitkisi ise 1000 µg/ml konsantrasyonda % 77 oranında inhibe etmiştir. Toplam fenolik içerikleri Folin-Ciocalteu yöntemiyle belirlenmiştir. En yüksek fenolik içeriğe sahip olan yeşil çay (186 mg/GAE) bulunmuştur. Antioksidan kapasiteleri DPPH(1,1-difenil-2-pikril-hidrazil) metoduyla serbest radikal giderim etkileri belirlenmiştir. DPPH metodunda pozitif kontrol olarak Trolox ve BHT kullanıldı. En yüksek DPPH serbest radikal giderim aktivitesini yeşilçay ve biberiye 1000 µg/ml konsantrasyonda göstermiştir.

Anahtar kelimeler: Tirozinaz, Antioksidan, Fenolik Madde, Biberiye, Yeşil Çay

Corresponding Authors:

e-mail: garabaci@sakarya.edu.tr

© 2023 DPU All rights reserved.

1. Introduction

Toxic substances known as prooxidants, which cause oxidative stress in the structure of oils, nucleic acids and proteins, can cause various diseases and pathological conditions. Free radicals can cause DNA and cell damage by causing the structure of proteins to break down [1]. Antioxidants are known as preservatives that prevent or delay the effects of these toxic substances, prooxidants. Free radicals and reactive oxygen derivatives that cause damage to cells are effectively reduced by antioxidants and converted into products with less toxicity. Antioxidants have a very important place in our lives for a healthy life and the smooth continuity of metabolic systems [2].

Enzymes are protein-structured substances that act as a biological catalyst in a chemical reaction, accelerate the reaction, and remain unchanged after the reaction. There are various substances that increase or limit enzyme activity in a chemical reaction. Substances that increase the activity of the enzyme are called activators, and substances that have the opposite effect are called inhibitors. Inhibition of enzymes is used to treat many diseases or to control undesirable enzyme activity for various conditions in pesticides. The mechanism of action of many existing drugs is based on this. For example, most drugs used for Alzheimer's disease try to increase the amount of acetylcholine that decreases in this disease by inhibiting the acetylcholinesterase enzyme. In another example of inhibitor, It is aimed to treat diseases such as abnormal pigmentations on the skin, vitiligo and melasma, which are caused by suppression of the tyrosinase enzyme [3,4].

The tyrosinase enzyme is an oxidase that catalyzes the oxidation of tyrosine in the synthesis reaction of the substance that gives color to the skin, known as the melanin pigment in living things [5]. In the synthesis of melanin pigment, if this synthesis is more or less, various diseases and disorders may occur in living things. While skin aging, vitiligo and melasma are some of these disorders in humans, disorders in this enzyme can also cause quality problems by causing darkening in plants and foods [6]. This abnormal synthesis of melanin causes aesthetic problems for both humans and food in general [7]. In addition, the formation of neuromelanin can cause neurodegeneration, which paves the way for serious diseases such as Parkinson's. Considering all these situations, new natural compounds that will reduce melanin formation, act as a tyrosinase inhibitor and counteract the harmful effects of synthetic inhibitors are widely researched [8,9].

Rosemary (*Rosmarinus officinalis L.*) is a perennial herb that grows naturally in the Mediterranean climate and can stay green in summer and winter [10]. It is frequently used in folk medicine for therapeutic purposes and as a flavouring for meals. It has a high antioxidant effect because it contains flavonoids, phenolic acids and triterpenes.

Research on rosemary has proven its effects in treating microbial diseases and enhancing memory. In addition, the effective studies of this plant on anticancer have attracted great interest in recent years [11].

Green tea (*Camellia sinensis*) is produced from the green shoots of tea containing various polyphenolic compounds. Green tea has an important place among the popular herbal protection methods against many diseases. Due to its high antioxidant properties, regular consumption of green tea prevents many diseases. It is counted among the benefits of improving brain functions and protecting against various cancers. It has been determined that the amino acid L-theanine in green tea, which can pass the blood-brain barrier, plays a role in the prevention of serious neurodegenerative diseases such as Parkinson's and Alzheimer's [12].

Today, natural resources have begun to be preferred in cosmetic and pharmaceutical products. Therefore, the importance of herbal, medicinal and aromatic plants is gradually increasing. The use of these plants in the treatment of various diseases has been known since ancient times. The use of these medicinal plants as medicine inhibits enzymes that cause diseases. The use of synthetic inhibitors in the tyrosinase enzyme is very limited. Therefore, there is always a need for natural tyrosinase inhibitors [13,14].

This study aims to identify new natural inhibitors of tyrosinase enzyme. For this purpose, rosemary (*Rosmarinus officinalis L.*) and green tea (*Camellia sinensis*) plants were used. The inhibitory effects of these plants on the tyrosinase enzyme were investigated and the total phenol content and antioxidant properties of these plants were also determined.

2. Materials And Methods

2.1. Chemicals Used

Rosemary (*Rosmarinus officinalis L.*) and green tea (*Camellia sinensis*) plants used in the study were purchased from a local market in Sakarya. Tyrosinase (T3824-25 KU), L-DOPA, DPPH and other chemicals were obtained from Sigma-Aldrich.

2.2. Preparation of Plant Extracts

Rosemary and green tea plants were obtained from a local market in Sakarya. 2 g of the plants were weighed and 100 ml of distilled water at 100 °C was added to them and left to infuse for 10 minutes. After the infusion process was finished, it was filtered through filter paper and the supernatant part was stored at 4 °C for use in experimental studies.

2.3. Tyrosinase Enzyme Inhibition

The enzyme inhibition method was modified and applied to plant extracts as in Yang et al.(2012)'s [15]. First of all, 100 µl of 0.1M pH:6.8 phosphate buffer solution, 20 µl of 250 U/ml tyrosinase solution and 20 µl of plant extracts (0, 10, 50, 250, 500, 1000 µg/ml) were mixed and added to the 96-well plate at 25°C for 10 min. Then, 20 µL of 3 mM L-DOPA substrate was added to these mixtures and incubated at 25°C for 30 min. The reaction absorbance was measured at 492nm. All experiments were carried out in 3 repetitions. Ascorbic acid was chosen as a positive control. Percent Inhibition of plant extracts was calculated with the following formula.

$$(\%) = [(A_{\text{control}} - A_{\text{plant}}) / A_{\text{control}}] \times 100$$

Then, % relative activity was calculated and $I_{c_{50}}$ values were determined. $I_{c_{50}}$ is defined as the inhibitor concentration that halves the enzyme activity.

2.4. Determination of Total Phenolic Substance

Total phenolic content of plant samples was determined by the Folin-Ciocalteu method [11]. 125 µl of 10% Folin-Ciocalteu reagent was mixed with 300 µL of plant extract and 1825 µl of distilled water and left for 5 minutes. After adding 250 µl of 20% sodium carbonate, it was kept for 30 minutes. The absorbance of the samples was measured at 650 nm. Experiments were carried out in 3 repetitions. A standard curve was created with gallic acid prepared at concentrations of 0, 10 50, 250, 500, 750 and 1000 µg/ml prepared with ethanol. The total phenolic content of the plant extracts was determined as gallic acid equivalent per dry weight of the extract (mg GAE/g dry extract weight).

2.5. DPPH Free Radical Removal Activity Analysis

Free radical scavenging activity was performed by changing the Blois method with 1,1-diphenyl-2-picrylhydrazil (DPPH) radical [12]. 1 ml of plant extract with concentrations of 50, 250, 500, 750 and 1000 µg/µl was taken and 4 ml of 0.1 mM DPPH solution was added. 1 ml of pure water and 4 ml of DPPH solution were used as control solution. As a standard, BHT and Trolox were prepared at the concentrations determined for the plants and the same amount of DPPH solution was added. The reaction tubes were incubated for 30 min at 25°C and in the dark. The absorbance was then measured with a spectrophotometer at 517 nm. The free radical scavenging activity was calculated from the equation below.

DPPH Removal Activity :

$$(\% \text{ inhibition}) = (A_{\text{Control}} - A_{\text{sample}}) / A_{\text{Control}} \times 100$$

A_{Control} = control absorbance at 517 nm

A_{Sample} = sample absorbance at 517 nm

3. Results

3.1. Tyrosinase Enzyme Inhibition

Tyrosinase is a crucial enzyme both in the formation of melanin pigment in humans and in the browning reaction of plants. However, it causes disorders and diseases in these systems with its excessive work [18,19]. Therefore, many synthetic and natural inhibitors of the enzyme are currently in development. In this study, the inhibitory effects of infusing extracts of rosemary and green tea, which are widely used among the public, on the tyrosinase enzyme were investigated.

The results were presented in Table 1. According to the results, it was observed that rosemary plant extract inhibited the tyrosinase enzyme over 50% at 500 µg/ml and 750 µg/ml concentrations. Green tea extract inhibited the enzyme more than 50% at concentrations of 500 µg/ml, 750 µg/ml and 1000 µg/ml. Ascorbic acid used as a positive control inhibited the tyrosinase enzyme by 75% at 750 µg/ml. The inhibition rate was 77% at 1000 µg/ml, where green tea showed the highest inhibition. This rate was even higher than the highest inhibition of ascorbic acid used as a positive control. Rosemary and ascorbic acid showed 75% inhibition at 750 µg/ml concentration.

Table 1. % inhibition values of samples to tyrosinase enzyme activities

| Concentration (µg/ml) | Rosemary % inhibition | Green tea % inhibition | Ascorbic acid % inhibition |
|-----------------------|-----------------------|------------------------|----------------------------|
| | | | |

| | | | |
|------|-------|----|------|
| 10 | 25.68 | 10 | 17 |
| 50 | 32 | 15 | 22 |
| 100 | 38 | 22 | 30 |
| 250 | 44 | 35 | 42 |
| 500 | 63 | 52 | 60.7 |
| 750 | 75 | 65 | 75 |
| 1000 | - | 77 | - |

IC₅₀ value, their % relative activities were calculated first. The concentration versus % relative graph was plotted and the inhibitor concentration that halved the enzyme activity was calculated from there. The results are given in Table 2.

Table 2. IC₅₀ values of inhibitors

| | rosemary | green tea | ascorbic acid |
|---------------------------|----------|-----------|---------------|
| IC ₅₀ ((µg/ml) | 334.4 | 538.1 | 391.64 |

3.2. Determination of Total Phenolic Substance

In this study, the total phenolic content of rosemary and green tea extracts was determined. Therefore, a standard graph of gallic acid was drawn as seen in Figure 1.




Figure 1. Gallic Acid Standard Curve

According to the results obtained from the plant extracts we used and the Figure 1 equation above, green tea with the highest total phenolic content (185 mg GAE/g) was determined. The total amount of phenol in our rosemary extract was calculated as 176 mg GAE/g. Total phenolic amounts of our extracts are shown in Figure 2.




Figure 2. The average amount of phenolic compound content of extracts

3.3. DPPH Free Radical Removal Activity

One of the most widely used methods to determine the antioxidant properties of antioxidant compounds is the determination of DPPH free radical scavenging activity. In this study, DPPH free radical scavenging activities of water extracts of rosemary and green tea plants were determined. For DPPH free radical scavenging activity, samples were prepared at concentrations of 50, 250, 500, 750 and 1000 µg/µl and absorbance was measured at 517 nm. the results are given in graphic form in Figure 3 and Table 3.




Figure 3. DPPH free radical removal % inhibition results

BHT and trolox were used as standard. Trolox showed greater than 90% inhibition at all concentrations. At a concentration of 50 µg/ml, green tea showed 60.08% inhibition, an effect above standard BHT. Rosemary at a concentration of 250 µg/ml had an effect of 53.95% and green tea had an effect of 73.63% on BHT. The other

standard, Trolox, showed more inhibition of all with 90.4%. At 500 µg/ml concentration, rosemary showed more inhibition than green tea with 86.45%. rosemary and green tea showed greater inhibition of BHT. Trolox showed greater inhibition in this set as well.

Table 3. % inhibition values of DPPH free radical scavenging activity according to concentrations

| Concentration (µg/ml) | Rosemary % inhibition | Green tea % inhibition | BHT % inhibition | Trolox % inhibition |
|-----------------------|-----------------------|------------------------|------------------|---------------------|
| 50 | 12.09 | 60.08 | 34.8 | 90.3 |
| 250 | 53.95 | 73.63 | 41.5 | 90.4 |
| 500 | 86.45 | 81.30 | 51.9 | 90.5 |
| 750 | 86.85 | 87.39 | 66.9 | 90.8 |
| 1000 | 89.58 | 91.41 | 69.2 | 90.9 |

Green tea showed more effect than rosemary and BHT with 87.39% effect at 750 µg/ml concentration. Trolox showed the highest inhibition effect at this concentration with 90.8%. Rosemary showed 89.58% and green tea 91.41% inhibition effects at a concentration of 1000 µg /ml. In these two values, it showed more inhibition than BHT used as standard. Green tea, on the other hand, was the sample with the highest DPPH free radical scavenging activity by showing more effect than all the substances used in this study.

4. Conclusion

In this study, the inhibition effect of rosemary and green tea plants on tyrosinase enzyme was investigated and their antioxidant properties were determined. According to the findings, it was determined that the two selected plants, especially green tea, had higher DPPH radical scavenging activity than the synthetic standard antioxidants used. In addition, it has been determined that both plant extracts can be used as natural tyrosinase enzyme inhibitors by inhibiting the tyrosinase enzyme. Green tea and rosemary are often used in alternative medicine for their therapeutic properties. The results of our study also support this theory. It is thought that green tea and rosemary extracts, which are natural tyrosinase enzyme inhibitors, can be a positive support in the treatment of various diseases.

Acknowledgements

The authors would like to thank the Department of Chemistry at Sakarya University, Turkey for providing the necessary laboratory facilities.

References

- [1] Ulusu F., Tümer K. and Ulusu Y., (2022). Antioxidant Responses To Drought Stress In Pennyroyal (*Mentha pulegium* L.). *Journal of Scientific Reports-A.*, (051): 26-48.
- [2] Nacak, F.M., (2014). Determination of Antioxidant capacity by Electrochemical Methods and Comparison

With Classical Methods, Adnan Menderes University, Institute of Science and Technology

- [3] Bahadori, M.B., Kirkan, B., Sarikurkcu, C. and Ceylan, O., (2019). Metabolite profiling and health benefits of *Stachys cretica* subsp. *myrtinaea* as a medicinal food, *Industrial Crops and Products*, 131, 85-89.
- [4] Bahadori, M.B., Maggi, F., Zengin, G., Asghari, B. ve Eskandani, M., (2020). Essential oils of hedgenettles (*Stachys inflata*, *S. lavandulifolia*, and *S. byzantina*) have antioxidant, anti –Alzheimer, antidiabetic, and anti-obesity potential: A comparative study, *Industrial Crops and Products*, 145, 112089.
- [5] Bonesi, M., Xiao, J., Tundis, R., Aiello, F., Sicari, V., and Loizzo, M., (2019). Advances in the tyrosinase inhibitors from plant source, *Current medicinal chemistry*, 26 (18), 3279-3299.
- [6] Polatoğlu İ., (2016). Tirozinaz Enzim Aktivitesi Üzerine Reaksiyon Parametre Etkilerinin UV Spektrofotometre Ile Yerinde Analiz Edilmesi. *CBUJOS.*, 12, 2, 319-325.
- [7] Kalka, K., Mukhtar, H., Turowski-Wanke A., Merk H., (2000). Biomelanin antioxidants in cosmetics: assessment based on inhibition of lipid peroxidation, *Skin Pharmacology and Applied Skin Physiology*, 13, 143-149.
- [8] Gholamhoseinian, A. and Razmi, Z., (2012). Screening the methanolic extracts of some plants for tyrosinase inhibitory activity, *Toxicological & Environmental Chemistry*, 94 (2), 310-318.
- [9] Özer, Ö., (2006). Kozmetik renk açıcı maddeler ve değerlendirilme yöntemleri Türkiye Klinikleri, *Turkish Journal of Medical Sciences*, 2, 24-29.
- [10] Al-Sereiti M.R., Abu-Amer KM, Sen P., (1999). Pharmacology of rosemary (*Rosmarinus officinalis* Linn.) and its therapeutic potentials. *Indian J Exp Biol*, 37(2), 124-130.
- [11] Tai, J., Cheung, S., Wu, M., Hasman, D., (2012). Antiproliferation effect of Rosemary *Rosmarinus officinalis* on human ovarian cancer cell in vitro. *Phytomedicine*, 19, 436-443.
- [12] Yang, C.S. and Landau, J.M., (2000). Effects of Tea Consumption on Nutrition and Health. *American Society for Nutr. Sci.*, 130, 2409-2412.
- [13] Yapar, E.A., (2017). Overview of Skin Whiteners, *Marmara Pharmaceutical Journal*, 21, 1, 48- 53.
- [14] Kim Y J, Uyama H., (2005). Tyrosinase İnhibitors from Natural and Synthetic Sources: Structure, İnhibition Mechanism and Perspective for the Future, *Cellular and Molecular Life Sciences*, 62, 1707-1723.
- [15] Yang, Z., Wang, Y., Wang, Y., and Zhang, Y., (2012). Bioassay-guided screening and isolation of α -glucosidase and tyrosinase inhibitors from leaves of *Morus alba*, *Food chemistry*, 131, 2, 617-625.
- [16] Clarke, G., Ting, KN, Wiart, C., and Fry, J., (2013). High correlation of 2, 2-diphenyl-1- picrylhydrazyl (DPPH) radical scavenging, ferric reducing activity potential and total phenolics content indicates redundancy in use of all three assays to screen for antioxidant activity of extracts of plants from the Malaysian rainforest, *Antioxidants*, 2 (1), 1-10.
- [17] Blois M.S., (1958). Antioxidant determinations by the use of a stable free radical, *Nature*, 181, 1199–1200.
- [18] Pawelek J. M. and Körner A. M., (1982). The biosynthesis of mammalian melanin. *AMSCA* 70, 136–145.
- [19] Mayer A. M., (1987). Polyphenol oxidases in plants: recent progress. *Phytochemistry* 26: 11–20.
- 5.



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 15.11.2022

Kabul Tarihi(Accepted Date): 23.12.2022

Beyin tümörü teşhisinde CNN-FL modeli ağ performansının aktivasyon fonksiyonlarına göre karşılaştırılması

Elif Ebru Çakı^{1*}, Tamer Aslan²

¹ Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Afyonkarahisar, ORCID: 0000-0002-2225-5675

² Afyon Kocatepe Üniversitesi, Afyon Meslek Yüksekokulu, Afyonkarahisar, ORCID: 0000-0003-3068-731X

ÖZ

Beyin tümörü, hücre bölünmesinin kontrolden çıkarak hücrelerin büyüyerek kitle haline gelmesinden meydana gelmektedir. Kafatası içerisinde sınırlı bir alanda bulunan beyine baskı oluşturan tümör büyüdükçe kişinin beyinin görevlerini gerçekleştirmemesine neden olmaktadır. Her yaş grubunda meydana gelebilen ve oldukça riskli olan bu tümörün teşhisinin doğru olması kişinin hayat fonksiyonlarının da korunmasını sağlamaktadır. MR Çalışmanın nihai hedefi erken ve doğru teşhis ile kişinin yaşam fonksiyonlarına olduğu gibi devamını sağlamaktır. Hastalıkların doğru ve hızlı teşhisi için yapay zeka sistemleri kullanılmaktadır. Brain Tumor veri seti, CNN mimarisini temel alan ancak daha başarılı sonuçlar verebilen CNN-FL mimarisi ile eğitilmiştir. Literatürde yaygın kullanılan 4 aktivasyon ile eğitimler gerçekleştirilerek karşılaştırılmaları yapılmıştır. Kullanılan aktivasyon fonksiyonları ReLU, Leaky ReLU, GELU ve Swish aktivasyon fonksiyonlarıdır. En yüksek %98 sınıflandırma başarısı GELU aktivasyon fonksiyonu ile elde edilmiştir. Çalışmamızın sonunda yapay zeka kullanımı ile gerçekleştirilen model MR görüntülerinden beyin tümörü teşhisine yardımcı bir araç olabileceğini göstermektedir.

Anahtar kelimeler: CNN-FL, Beyin Tümörü, Yapay Zeka, Derin Öğrenme, Aktivasyon Fonksiyonları.

Comparison of CNN-FL model network performance according to activation functions in diagnosis of brain tumor

ABSTRACT

A brain tumor occurs when cell division goes out of control and the cells grow into a mass. As the tumor grows, it puts pressure on the brain, which is located in a limited area within the skull, causing the person's brain not to perform its functions. The correct diagnosis of this tumor, which can occur in any age group and is quite risky, ensures that the person's life functions are protected. The ultimate goal of the MR Study is to ensure that the person's life functions continue as they are with early and accurate diagnosis. Artificial intelligence systems are used for accurate and rapid diagnosis of diseases. Brain Tumor dataset is

trained with CNN-FL architecture, which is based on CNN architecture but can provide more successful results. Trainings were carried out with 4 activations commonly used in the literature and their comparisons were made. The activation functions used are ReLU, Leaky ReLU, GELU and Swish activation functions. The highest 98% classification success was achieved using the GELU activation function. At the end of our study, we show that this artificial intelligence based model can be a helpful tool for brain tumor diagnosis from MR images.

Keywords: CNN-FL, Brain Tumor, Artificial Intelligence, Deep Learning, Activation Functions.

Corresponding Authors:

e-mail: elifebrucaki@gmail.com

© 2023 DPU All rights reserved.

1. Giriş

Beyin tümörü, beyinde bulunan hücrelerin yenilenmesi esnasında hücrelerin büyümesi ve büyüyen hücrelerin kitle haline gelerek beyinde yer edinmesi ile tümörler oluşmaktadır. Her yaş grubunda oluşabilen bu tümörler kafatasında basınca neden olmaktadır. Baskıdan etkilenen beyin görevini yerine getirememektedir. Tümörün erken teşhisi tedavi sürecini hızlandırmakta ve tedaviyi kolaylaştırmaktadır. Tümörün kafatası gibi sınırlı bir alanda büyümesi de erken teşhisi önemli kılmaktadır [1].

Günümüzde görüntü işleme teknolojisi ve yapay zeka tabanlı yöntemlerin tıp alanında da oldukça yaygınlaşması ile MR görüntülerinden tümör tespiti çalışmaları yapılmaktadır. Bazı çalışmalarda sınıflandırma için öznelik çıkarma algoritmaları kullanılırken bazı çalışmalarda ise öznelik çıkarımının yanı sıra sınıflandırma için derin öğrenme yöntemleri kullanılmaktadır.

Prema ve arkadaşları [2] tarafından 2016 yılında yapılan bir çalışmada Otsu algoritması kullanılarak tümörün tespit edilmesine yönelik bir çalışma gerçekleştirilmiştir. Otsu ve Watershed yöntemleri CT(Computed Tomography) görüntülerine uygulanmıştır. Hastalığın tümörlü ve sağlıklı beyin olarak sınıflandırılmasında görüntü işleme yöntemleri kullanılmıştır. Beyin kitle segmentasyonu ve özellik çıkarıma işlemi gerçekleştirilmiştir.


Havaei ve arkadaşları [3] tarafından 2017 yılında yapılan bir başka çalışmada ise derin sinir ağı (DNN, Deep Neural Networks) kullanılmaktadır. Çalışma özgün ve yeni mimari ile gerçekleştirilmekte ve kullanılan 2013 BRATS üzerinde de başarı ile sonuçlanmıştır. Tümörün şekli, boyutu ve görüntü özelliklerinin baz alınmadığı yöntem önerilmekte ve otomatik bir yöntem geliştirdiklerini belirtmektedirler.

Çalışmamızda beyin tümörü teşhisinde MR görüntüleri üzerinden erken teşhis için tanı karar sürecinin en aza indirilerek hastalığın doğru tanısı hedeflenmektedir. Hedeflenen doğru teşhis için CNN-FL mimarisi ile farklı aktivasyon fonksiyonları karşılaştırılmaktadır.

2. Materyal Ve Method

2.1. Brain Tumor Veriseti

Bu çalışmada farklı boyut ve açılardan elde edilmiş 2.513 tane tümörlü beyin MR görüntüsü ve 2.087 tane sağlıklı beyin MR görüntüsü kullanılmaktadır. Şekil 1'de verisetinde bulunan örnek sağlıklı ve tümörlü beyin MR görüntüsü verilmiştir.

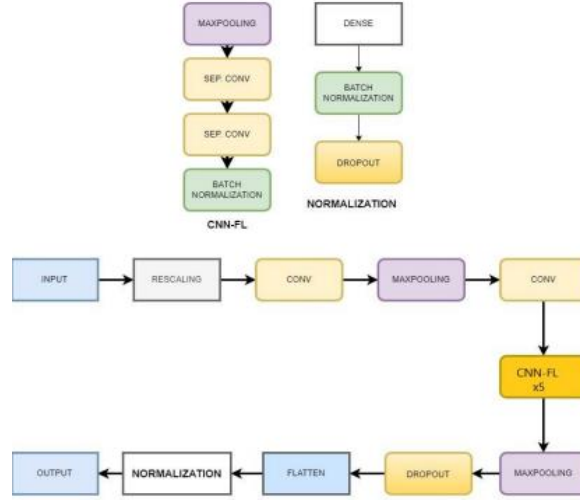


Şekil 1. Sağlıklı ve tümörlü beyin MR görüntüsü.

2.2. CNN-FL

CNN-FL (Convolutional Neural Networks- Federated Learning) başarısız ağ çıktılarının başarısızlığı ile ilişkisini öğrenerek tahmin için bir model oluşturmaktadır. Modelin oluşumunda evrişimli sinir ağını temel almaktadır [4]. Mimaride 10 adet evrişim katmanı mevcuttur. İki adet standart evrişim katmanının ardından ayrılabilir evrişim katmanları kullanılmaktadır. Eğitim için az veriye ihtiyaç duymasından dolayı ayrılabilir (Separable) evrişim kullanılmaktadır. Ayrılabilir evrişim öğrenmeyi iki adıma ayırarak çalışmaktadır. CNN-FL mimarisinde ise 8 katmanda yer almakta sonrasında ise havuzlama katmanı ile devam etmektedir [5]. Mimari modeli Şekil 2’de verilmektedir.


CNN-FL hata için evrişimli bir sinir ağı oluşturur ve ağı test durumlarıyla eğitir. Son olarak sanal bir test seti kullanarak eğitilen modeli test ederek her bir ifadenin şüpheliliğini değerlendirir. Çalışmamızdaki veri setinin sanal veri seti ile de test edilmesi ile doğru tanı oranının artması hedeflenmektedir.



Şekil 2. CNN-FL mimarisi [5].


Çalışmada MR görüntülerinin sınıflandırılarak tümörün tanımlanmasında CNN-FL mimarisi kullanılmıştır. Model 32 batch size, 0.01 öğrenme hızı, 10 epoch ile eğitim gerçekleştirilmiştir. Çalışmamızda evrişim katmanlarındaki aktivasyon fonksiyonları değiştirilmiştir. ReLU, Leaky ReLU, GELU ve Swish aktivasyon fonksiyonları kullanılarak analiz gerçekleştirilmiştir. Bu fonksiyonların karşılaştırılması yapılarak başarıları analiz edilmiştir. Analizlere ait grafikler verilmiştir.

Aktivasyon fonksiyonları, nöron içerisindeki değerlerin normalleştirilmesinde kullanılmaktadır. ReLU (Rectified Linear Unit) aktivasyon fonksiyonu en çok kullanılan aktivasyon fonksiyonlarından biridir. Bir diğer adı ile doğrultulmuş lineer birim fonksiyonudur. Bu fonksiyon nöron çıkışı 0'dan büyük olduğunda çıkış değerine, küçük olduğunda ise çıkışı 0'a eşitlemektedir [6]. Koordinat sisteminde gösterimi Şekil 3'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 1'de aşağıda verilmektedir. Şekil 4 ve Şekil 5'de eğitimin başarı ve kayıp grafikleri yer almaktadır.




Şekil 3. ReLU aktivasyon fonksiyon grafiği [7].

$$ReLU(x) = \max(0, x) = \begin{cases} x, & \text{if } x > 0 \text{ (active state)} \\ 0, & \text{if } x \leq 0 \text{ (inactive state)} \end{cases} \quad (1)$$




Şekil 4. ReLU accuracy (Doğruluk) grafiği.



Şekil 5. ReLU loss (Kayıp) grafiği.


Leaky ReLU, sızdırılan veya sızdıran ReLU olarak da bilinmektedir. Eksi sonsuza kadar giden bu aktivasyon fonksiyonu negatif değerlerin öğrenilmesinde kullanılmaktadır [8]. Koordinat sisteminde gösterimi Şekil 6 'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 2'de de aşağıda verilmektedir. Şekil 7 ve Şekil 8'de eğitimin başarı ve kayıp grafikleri verilmiştir.

Leaky ReLU




Şekil 6. Leaky ReLU aktivasyon fonksiyon grafiği[7].

$$Leaky ReLU(x) = \max(kx, x) = \begin{cases} x, & \text{if } x > 0 \\ kx, & \text{if } x \leq 0 \end{cases} \quad (2)$$

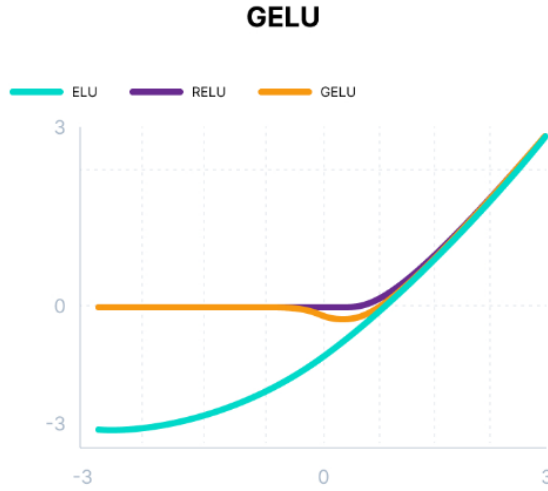


Şekil 7. Leaky ReLU accuracy (Doğruluk) grafiği.




Şekil 8. Leaky ReLU loss (Kayıp) grafiği.

Yüksek performansı ile kullanılan GELU aktivasyon fonksiyonu gauss hatasının doğrusal birimi olarak bilinmektedir. ReLU aktivasyon fonksiyonundan gelen özellikleri birleştirerek işler [9]. Koordinat sisteminde gösterimi Şekil 9’da verilmiştir. Fonksiyonun matematiksel formülü Eş. 3’de aşağıda verilmektedir. Şekil 10 ve Şekil 11’de eğitim sonundaki accuracy (başarı) ve loss (kayıp) grafikleri verilmiştir.




Şekil 9. GELU aktivasyon fonksiyon grafiği[7].

$$GELU(x) = xP(X \leq x) = x\Phi(x) = x \cdot \frac{1}{2} \left[1 + \operatorname{erf}\left(\frac{x}{\sqrt{2}}\right) \right] \quad (3)$$




Şekil 10. GELU accuracy (Doğruluk) grafiği.



Şekil 11. GELU loss (Kayıp) grafiği.

Google tarafından geliştirilmiş olan ve zor veri setlerindeki çalışma başarısı ile bilinen Swish aktivasyon fonksiyonu görüntü işleme alanlarında oldukça iyi performans göstermektedir. Fonksiyonda x negatif sonsuza yaklaşırken y sabitlenir. x sonsuza yaklaştığında ise y de sonsuza yaklaşmaktadır. ReLU'da $x=0$ anında anlık yön değişimi varken Swish aktivasyon fonksiyonunda bu yön değişimi bulunmamaktadır [10]. Koordinat sisteminde gösterimi Şekil 12'de verilmiştir. Fonksiyonun matematiksel formülü Eş. 4'de aşağıda verilmektedir. Şekil 13 ve Şekil 14'de eğitimin başarı ve kayıp grafikleri verilmiştir.


Swish




Şekil 12. Swish aktivasyon fonksiyon grafiği [7].

$$f(x) = \frac{x}{1+e^{-x}}$$

(4)



Şekil 13. Swish accuracy (doğruluk) grafiği.



Şekil 14. Swish loss (kayıp) grafiği.

Çalışmamızda CNN-FL mimarisi farklı aktivasyon fonksiyonları ile test edilerek ağırlık eğitim başarıları ve eğitim kayıpları karşılaştırıldı. Literatürde yaygın kullanılan 4 aktivasyon fonksiyonları kullanılarak gerçekleştirilen eğitimlerin performans sonuçları sonuçlar kısmında yer alan Tablo 1, Tablo 2, Tablo 3, Tablo 4 ve Tablo 5 de verilmektedir.

3. Sonuçlar

Beyin tümörünün erken ve doğru teşhisi hayati fonksiyonların devamı için oldukça önem arz etmektedir. Çalışmamızda MR görüntülerinden tümörün teşhisini farklı aktivasyon fonksiyonları ve parametreleri kullanılarak gerçekleştirildi. Literatürde yeni yer edinen CNN-FL mimarisi ile eğitim gerçekleştirilmiştir. Tablo 1, Tablo 2, Tablo 3 ve Tablo 4'de kullanılan aktivasyon fonksiyonlarının tümörlü ve sağlıklı beyinin teşhisinde elde edilen başarı sonuçları verilmektedir. Tablolardaki sonuçlar çalışmamızda tümörlü ve sağlıklı olarak doğru sınıflandırmanın gerçekleştiğini göstermektedir.

Tablo 5'de aktivasyon fonksiyonlarının performans sonuçları verilmektedir. Eğitim sırasında yalnızca aktivasyon fonksiyonlarının değişimi ile sonuçlar elde edilmiş ve %98.2608 model başarıları GELU aktivasyon fonksiyonu ile elde edilmiştir.

Sonuç tablolarından da görüldüğü üzere CNN-FL modeli ile eğitimler sonucunda doğru tanı başarıları oldukça yüksektir.

Çizelge 1. ReLU aktivasyon fonksiyonunun teşhis başarıları.

| | Kesinlik | Duyarlılık | F1-Score | Support |
|-----------------|----------|------------|----------|---------|
| Tümörlü | 0.96 | 0.99 | 0.98 | 779 |
| Sağlıklı | 0.98 | 0.95 | 0.97 | 601 |

Çizelge 2. Leaky ReLU aktivasyon fonksiyonunun teşhis başarıları.

| | Kesinlik | Duyarlılık | F1-Score | Support |
|-----------------|----------|------------|----------|---------|
| Tümörlü | 0.98 | 0.99 | 0.98 | 779 |
| Sağlıklı | 0.98 | 0.98 | 0.98 | 601 |

Çizelge 3. GELU aktivasyon fonksiyonunun teşhis başarısı.

| | Kesinlik | Duyarlılık | F1-Score | Support |
|-----------------|-----------------|-------------------|-----------------|----------------|
| Tümörlü | 0.98 | 0.99 | 0.98 | 779 |
| Sağlıklı | 0.99 | 0.97 | 0.98 | 601 |

Çizelge 4. Swish aktivasyon fonksiyonunun teşhis başarısı.

| | Kesinlik | Duyarlılık | F1-Score | Support |
|-----------------|-----------------|-------------------|-----------------|----------------|
| Tümörlü | 0.97 | 0.98 | 0.98 | 779 |
| Sağlıklı | 0.98 | 0.97 | 0.97 | 601 |

Çizelge 5. Aktivasyon fonksiyonlarının model başarısı (%).

| | Doğruluk |
|-------------------|-----------------|
| ReLU | 97.2463 |
| Leaky ReLU | 98.1884 |
| GELU | 98.2608 |
| Swish | 97.6811 |

Teşekkür

Yazarların teşekkür etmesi gereken herhangi bir kişi ya da kuruluş yoktur.

Kaynakça

- [1] Bulut, F., Kiliç, İ., and İnce, İ. F. (2018), Beyin Tümörü Tespitinde Görüntü Bölütleme Yöntemlerine Ait Başarımların Karşılaştırılması ve Analizi, *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 20(58), 173-186.
- [2] Prema, V., Sivasubramanian, M., and Meenakshi, S. (2016), Brain cancer feature extraction using Otsu's thresholding segmentation. *Brain*, 6(3).
- [3] Havaei, M., Davy, A., Warde-Farley, D., Biard, A., Courville, A., Bengio, Y., ... and Larochelle, H., (2016), Brain Tumor Segmentation with Deep Neural Networks. *Cornell University Library*, arXiv preprint arXiv:1505.03540.
- [4] Zhang, Z., Lei, Y., Mao, X., and Li, P., (2019), CNN-FL: Evrişimli sinir ağlarını kullanarak hataların yerini tespit etmek için etkili bir yaklaşım, *IEEE 26th International Conference on Software Analysis, Evolution and Reengineering (SANER)*, 445-455.
- [5] Çaki, E. E., and Bayram, F., (2022), Cnn-F1 Modeli Ile Pnömoni Tespitinin Aktivasyon Fonksiyonlarına Göre Karşılaştırılması.
- [6] Ozkaya, U., Melgani, F., Bejiga, M. B., Seyfi, L., and Donelli, M. (2020), GPR B scan image analysis with deep learning methods. *Measurement*, 165, 107770.
- [7] The AI website. [Online], (2022), Available: <https://www.v7labs.com/blog/neural-networks-activation-functions>
- [8] Xu, J., Li, Z., Du, B., Zhang, M., & Liu, J. (2020, July). Reluplex made more practical: Leaky ReLU. In *2020 IEEE Symposium on Computers and communications (ISCC)*, 1-7.

- [9] Hendrycks, D. and Gimpel, K. (2016). Gauss hata doğrusal birimleri (gelus). arXiv ön baskı arXiv:1606.08415 .
- [10] Ramachandran, P., Zoph, B. and Le, QV (2017). Aktivasyon fonksiyonları arıyor. arXiv ön baskı arXiv:1710.05941 .



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 17.05.2023

Kabul Tarihi(Accepted Date): 21.18.2023

Rastgele orman regresyon algoritması ile bitcoin fiyat tahmini

Sümeyye ÇELİK^{1*}, Durmuş ÖZDEMİR²

¹Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43000, Kütahya, ORCID: 0009-0001-1135-976X

²Kütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, 43000, Kütahya,, ORCID: 0000-0002-9543-4076

ÖZ

Günümüz teknolojilerindeki hızlı gelişmeler ile insanlar artık ödeme ve alışveriş işlemlerini dijital platformlar üzerinden gerçekleştirebilmektedir. Ancak, e-hizmetlerdeki ödeme güvenliği sorunları, insanları alternatif ödeme yöntemleri arayışına yönlendirdi. Blokzincir teknolojisi sayesinde, merkezi otoriteye bağlı olmayan ve tamamen güvenli bir şekilde ödeme yapılabilen kripto paralar geliştirildi. Bitcoin, Satoshi Nakamoto'nun 2008 yılında yayınladığı "Bitcoin: Eşler Arası Elektronik Para Sistemi" adlı makalesiyle tanıtılan, merkezi bir otoriteye veya bankaya bağlı olmayan dijital bir para birimidir. Özellikle pandemi sürecinde finans dünyasında yatırımcıların dikkatini çeken Bitcoin, yüksek volatiliteye sahip bir piyasada işlem görmektedir. Bu nedenle, ileriye yönelik fiyat tahminleri yapmak isteyenler için büyük önem taşımaktadır. Bu çalışmada Bitcoin yatırımcılarının kâr payına olumlu bir katkı sağlayacak fiyat tahmini yöntemi geliştirilmek istenmiştir. Bitcoin'e sahip veriler bir zaman serisine ait olması ve zaman serilerinin tahminlemede kullanılan bir model olan Random Forest Regresyon kullanılmıştır. Model 2020-2022 yıllarına ait iki yıllık Bitcoin verilerine göre eğitilmiştir. Modele ait istatistiksel hata metrikleri ise MSE, R2, MAE ve RMSE sırasıyla %0,031, %99,39, %31,16 ve %55,33 olarak hesaplanmıştır.

Anahtar Kelimeler: Makine öğrenmesi, Finans, Bitcoin, Rastgele Orman Regresyon, Blokzincir

Bitcoin price prediction with random forest regression algorithm

ABSTRACT

With the rapid developments in today's technologies, people can now perform their payment and shopping transactions through digital platforms. However, payment security problems in e-services have led people to seek alternative payment methods. Thanks to blockchain technology, cryptocurrencies that are not dependent on the central authority and can be paid in a completely secure way have been developed. Bitcoin is a digital currency that is not tied to a central authority or bank, introduced

in Satoshi Nakamoto's 2008 article entitled "Bitcoin: The Peer-to-Peer Electronic Money System". Bitcoin, which attracts the attention of investors in the financial world, especially during the pandemic process, is traded in a market with high volatility. For this reason, it is of great importance for those who want to make forward price predictions. In this study, it is aimed to develop a price prediction method that will contribute positively to the profit share of Bitcoin investors. With Bitcoin, the data belongs to a time series, and Random Forest Regression, a model used to predict time series, was used. The model is trained on two years of Bitcoin data for the years 2020-2022. The statistical error measures of the model were calculated as MSE, R2, MAE and RMSE as 0.031%, 99.39%, 31.16% and 55.33%, respectively.

Keywords: Machine Learning, Finance, Bitcoin, Random Forest Regression, Blockchain


Corresponding Authors:

e-mail: e sumcelik960@gmail.com

© 2023 DPU All rights reserved.

1. Giriş

Satoshi Nakamoto'nun Ekim 2008'de yayınladığı makaleyle tanıştığımız Blockchain ve Bitcoin kavramları, 2009 yılında ilk işlemi gerçekleştirerek hayata geçmiştir [2]. Blockchain teknolojisi, kripto para birimlerinin işleyiş prensibini kurarak işletmelerin çalışma şeklini devrimleştirebilmeyi iddia etmektedir. İş süreçlerinde aracılara ortadan kaldırarak zaman ve maliyetleri azaltır [31]. Geleneksel finans sistemi merkezi bir yapıya sahipken, Bitcoin'in en önemli özelliklerinden biri merkeziyetsizlik ve sadece bir grup kod yazılımcısı tarafından desteklenmesidir. Bu kripto para birimi sayesinde, işlemler ve transferler aracılar olmadan gerçekleştirilebilmektedir, böylece taraflar arasındaki güven ilişkisi artmaktadır. Bitcoin'in arkasındaki teknoloji, geleneksel finansal düzenlemelerin dışında bir alternatif sunmakta ve gelecekte finansal sistemlerin nasıl şekilleneceğine dair önemli ipuçları vermektedir. Merkeziyetsiz bir ağ üzerinde çalışıyor olması Bitcoin'i güvenli yapan unsurlardan biri olmak ile bu durum bazı sakıncalarda içerebilmektedir [3]. 2020'da pandeminin etkisiyle rekor yükseliş göstererek 63 bin dolar seviyesine ulaşan Bitcoin, kripto para madenciliğine olan ilgiyi önceki dönemlerde görülmemiş ölçüde artırdı. Günümüzde de popülerliği devam eden Bitcoin'in avantajları; dışarıdan müdahalenin oldukça maliyetli olması, basit kullanılabilirliği, güvenilirliği ve geleneksel yöntemlere nazaran hızlı ve ucuz transfer edilebilmesidir [3]. Dezavantajları ise fiyat oynaklığının yüksek ve risk oranının yatırım yapmak için yüksek olması, işlem hızı ve kapasitesinin rakiplerine göre oldukça düşük kalması, Bitcoin blokzincirinin çalışması için gereken yüksek enerji kullanımınıdır [3]. Alım satım yapan kişilerin üzerinde durması gereken bir diğer maddeler ise Bitcoin fiyatının nasıl belirlendiğidir. Teorik olarak arz ve talep ilişkisine göre belirlenmektedir. Bitcoin'in piyasadaki arz miktarı belirli olduğundan, fiyat dengesi risk iştahına ve talebe göre belirlenmektedir [5]. Genel talebi ise birçok unsur etkiler; merkez bankası faiz kararları, jeopolitik gerginlikler, global ekonomik krizler ve piyasalardaki risk iştahı gibi etkenler Bitcoin fiyatında oldukça etkilidir [3, 5].



Şekil 1. Blockchain Çalışma Mekanizması [24].

Literatürde bulunan birçok tahmin modeli arasından regresyon modeller incelenmiştir. Yapılan çalışmalara örneklerden biri olan Alex ve Benjamin (2015) [9] 3 çeşit regresyon modelini kullanarak ortalama kare hatalarını (MSE) hesaplamışlardır. Temel (Baseline) regresyon modelinde 2.02, Lineer (Linear) regresyon modelinde 1.94, Destek vektör makinesi (Support Vector Machine (SVM)) regresyon modeli ile 1.98 sonuçlarını elde etmişlerdir.

Köksal vd. [8] tarafından yapılan çalışmada Bitcoin fiyat tahmini için Lojistik Regresyon ve Naive Bayes algoritmaları kullanılarak oluşturulan modellerin başarı oranları karşılaştırılmıştır. Bu modeller, Bitcoin kelimesini içeren günlük pozitif tepkili tweet oranı ve Bitcoin günlük açılış değeri gibi verileri kullanarak Bitcoin'in kapanış değerini tahminlemektedir. Elde edilen sonuçlar göstermiştir ki, Doğrusal Regresyon modeli R^2 değeri %88,97 ile, Rastgele Orman Regresyonu modeli R^2 değeri ise %94,16 ile daha başarılı sonuçlar vermiştir.

Metin [26] tarafından yapılan çalışmada üç farklı kripto para için Çoklu Lineer Regresyon, Gradient-Boosted Trees, Polynomial Regresyon modelleri incelenmiştir. Bitcoin için modellerin R^2 değerleri Çoklu Lineer Regresyon için %99,99, Gradient-Boosted Trees için %99,97, Polynomial Regresyon modelinde ise bu oran %100 olarak hesaplanmıştır. İncelediği diğer kripto para ve modellerine göre Bitcoin'in Polynomial Regresyon modeliyle daha uyumlu olduğu görülmüştür.

Literatür de bulunan araştırmaların yanı sıra bu çalışmada kullanılan iki yıllık verinin pandemi dönemi sonlarını ve sonrasını içermektedir. Tüm dünyayı etkisi altına almış bir pandemi döneminin dijitale olan talebin artmasına neden olmuş ve bu dönem içerisinde de Bitcoin üzerinde yükseliş trendinde olduğu gözlemlenmiştir.

2. Materyal Ve Method


2.1. Veri Seti

Bir medya mülkü olan Yahoo ağının bir parçası olan Yahoo Finans [16]; piyasa özetleri, finansal raporlar, tarihsel alıntılar ve haber akışları dahil olmak üzere diğer finansal bilgileri sağladığı için bir dizi kitaplık, API veya yöntem olarak adlandırılabilir güvenilir bir borsa verileri kaynağıdır [15]. Tüm bunlar, finansal piyasalar için gerçek zamanlı veya tarihsel verilerin elde edilmesine yardımcı olur. Manuel hisse kodu belirtmektense, KAP (Kamuyu Aydınlatma Platformu)' dan aldığımız ve sürekli güncellenen hisse kodları sayesinde, yfinance

modülünden verileri otomatize ederek alınmıştır. Ulaştığım verilerde veri analizinde kullanılan başlıca komutlarla veri setinin ilk 10 verisine, boş bir veri girdisi olup olmadığı gibi temel işlemlerle kontrolü yapılmıştır. Ardından veri setinin hangi trende sahip olduğunun tespit edilebilmesi amacıyla bir grafiği çizdirilmiştir.


2.2. Veri Görselleştirilmesi ve Normalizasyonu

2 yıllık Bitcoin verisine göre fiyat oynaklığının ve 2021'in Ocak ve Nisan ayları arasında belirgin bir şekilde artış yaşadığı görülmüştür.



Şekil 2. Bitcoin Kapanış Fiyatları.

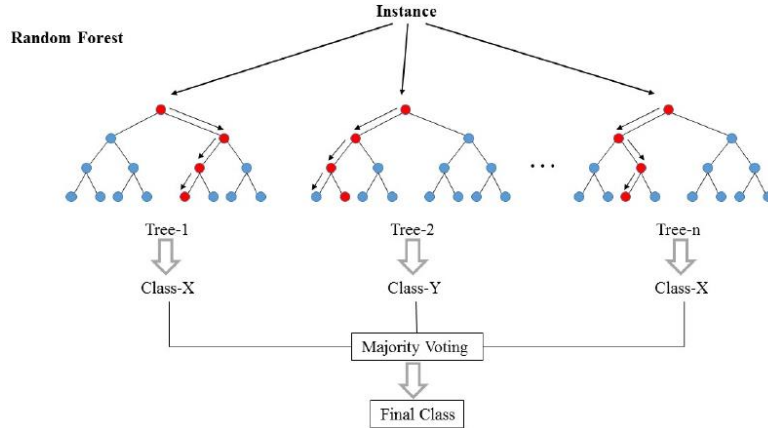
Makine öğrenmesi algoritmalarında bu oynaklık ve geniş fiyat skalası ile doğru bir tahminleme yapılamamaktadır. Tahminlemenin daha tutarlı olabilmesi adına verilerin daha dar bir skala içerisinde yer almasını sağlamak için normalizasyon işlemlerinin gerçekleştirilmelidir. Verilerin normalizasyonu için kullanılan istatistiksel ve matematik yöntemlerinden biri olan logaritma alınarak normalize edilmiştir.



Şekil 3. Normalize Edilmiş Bitcoin.

2.3. Rastgele Orman Regresyonu

Bu projede Python'un açık kaynak kodlu kütüphanelerinden scikit-learn içerisindeki makine öğrenimi modellerinden biri olan Rastgele orman modeli kullanılmıştır. Rastgele orman modeli, denetimli makine öğrenmesinin bir yöntemi olarak kullanılan bir ağaç tabanlı topluluktur [19, 20]. Bu yöntem, rastgele değişkenler topluluğuna bağlı ağaçlardan oluşmaktadır. Leo Breiman, bu yöntemi 1997'de Amit ve Geman'ın çalışmalarından esinlenerek tanıtmıştır. Rastgele orman modeli, Breiman'ın Bagging fikrinin bir uzantısıdır ve boosting yöntemine alternatif bir yöntem olarak geliştirilmiştir [21]. Bu model, sınıflandırma ve regresyon problemlerinde kullanılabilir, diğer yöntemlere göre daha hızlı eğitilmesi ve tahmin yapması, az sayıda düzenleme parametresi gerektirmesi ve çok boyutlu problemlere doğrudan uygulanabilmesi gibi özellikleri nedeniyle tercih edilmektedir. Rastgele orman, bankacılık, borsa, tıp ve e-ticaret gibi birçok farklı sektörde kullanılmaktadır [28,29,30]. Rastgele Orman Regresyonu İşleyişi Şekil 4'te sunulmuştur.



Şekil 4. Rastgele Orman Regresyonu İşleyişi [23].

3. İstatiksel Hata Metrikleri

3.1. Ortalama Kare Hata

Ortalama kare hata, özellikle regresyon modellerinde sıklıkla kullanılan bir performans metriğidir. MSE, gerçek ve tahmin edilen değerler arasındaki farkların karelerinin ortalamasıdır. Ortalama kare hata daha yüksek hataların daha fazla ağırlığına sahip olduğu bir ölçüttür. Bu nedenle, büyük hataların model performansını daha fazla düşüreceği durumlarda kullanılır. Ortalama kare hata değeri sifıra yaklaştıkça, modelin tahminleri gerçek değerlere daha yakın hale gelir ve modelin performansı artar. Ancak, ortalama kare hatanın yorumlanması için gerçek değerlerin aralığına ve veri kümesinin özelliklerine göre değerlendirme yapılması gerekmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (1)$$

3.2. Kök Ortalama Kare Hata

Ortalama kare hatanın karekökü alınarak elde edilir ve gerçek değerler ile tahmin edilen değerler arasındaki farkların büyüklüklerinin ortalamasını verir. RMSE, Ortalama kare hatadan farklı olarak büyük hataların daha fazla cezalandırılmasını sağlar. Bu özellik, özellikle büyük hataların önemli olduğu durumlarda daha uygun bir metrik haline gelmesini sağlar. Ayrıca, RMSE değeri, tahminlerin gerçek değerlere ne kadar yakın olduğunu gösterir ve farklı modellerin performanslarını karşılaştırmak için kullanılabilir.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2)$$

3.3. Ortalama Mutlak Hata

Ortalama mutlak hata (MAE), regresyon ve zaman serisi problemlerinde sıklıkla kullanılan bir performans metriğidir ve gerçek ile tahmin edilen değerler arasındaki mutlak farkların ortalamasını hesaplamaktadır. Ortalama mutlak hata, her bir veri noktasının model performansına eşit ağırlık verdiği bir ölçüttür. Bu nedenle, küçük hataların da büyük hatalar kadar önemli olduğu durumlarda kullanılmaktadır. Ortalama mutlak hata değeri sifıra yaklaştıkça, modelin tahminleri gerçek değerlere daha yakın hale gelir ve modelin performansı artar. Ortalama mutlak hata, kolay yorumlanabilir bir metrik olduğu için özellikle endüstriyel ve ticari uygulamalarda tercih edilir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |x_i - x| \quad (3)$$

3.4. Düzeltilmiş R Kare (R^2)

Düzeltilmiş R kare hata metriği, bağımsız değişkenlerin bağımlı değişkendeki varyasyon oranını ölçerek modelin doğruluğunu belirler. R^2 hata metriği, aşırı uyum sorununu göz ardı ettiği için modelin test verilerinde başarısız olma olasılığını artırabilir. Bu sorunu önlemek için, düzeltilmiş R kare hata metriği, modele eklenen ek bağımsız değişkenleri cezalandırarak aşırı uyum sorununu azaltır. R^2 değeri, deneysel verilerin doğrusal bir eğriye ne kadar iyi uydurulduğunu gösterir ve 1'e yakın olması tercih edilmektedir.

$$R^2 = 1 - \frac{SS_{Regression}}{SS_{Total}} = 1 - \frac{\sum_i (y_i - \hat{y}_i)^2}{\sum_i (y_i - \bar{y})^2} \quad (4)$$


4. Bulgular

Yahoo finanstan alınan 2 yıllık verinin seçilen model ile fiyat tahminlemesi yapılmış ve hata ölçütleri incelenmiştir. Tablo 1' de seçilen modele ait kesinlik değerleri yer almaktadır. Tahmin için rastgele orman regresyonu modeli seçilmiştir. Bu modele ait R^2 değeri 0.9939, MAE değeri 0.0031, RMSE değeri 0.0055, MSE değeri 0.000031 olarak hesaplanmıştır.

Tablo 1. Seçilen Modele Ait Hata Ölçütleri

| Hata Ölçütleri | RFR Modeli |
|----------------|------------|
| R^2 | 0.9939 |
| MAE | 0.0031 |
| RMSE | 0.0055 |
| MSE | 0.000031 |

Elde edilen bu sonuçlarla beraber tahminleme işlemimizi tamamlayabilmek adına en son logaritmasını aldığımız verilerin eksponansiyel değerine çevirerek aşına olduğumuz fiyat tahminlerini elde edilmiştir. Tahmin edilen fiyatların Şekil 5.' te mevcuttur.



Şekil 5. Tahmin Edilen Fiyatlar (BTC-USD).

5. Sonuçlar ve Tartışma

Nakamoto'nun yapmış olduğu "Bitcoin: A peer-to-peer electronic cash system," adlı çalışmasıyla gündeme gelen sanal para mekanizması olan Bitcoin, herhangi bir otorite olmadan bağımsız yapıda olan dijital para birimidir. Pandemi döneminde alış-satış faaliyetlerinin artması ile popülerliğini arttırmış olan Bitcoin yeni kriptoloji yöntemlerinin denenmesini ve gelecek fiyat tahminlerinin yapılmasını tetiklemiştir. Kripto para birimlerinin fiyatları, diğer menkul değerlerden farklı olarak bağımsız bir fiyatlandırma yapısına sahiptir. Bitcoin de dahil olmak üzere kripto varlıklarının fiyatları oldukça dalgalıdır ve farklı faktörlerin etkisiyle hızlı değişiklikler gösterebilir. Bu nedenle, kripto paraları gelecekte tahmin ederken, ülkelerin kripto para birimlerine olan tutumlarının da göz önünde bulundurulması faydalı olacaktır. Ülkelerin kripto para birimlerine olan tutumları, fiyat dalgalanmalarına neden olabilecek önemli bir faktördür.

Bu çalışmada regresyon modellerinden birini kullanarak 2020'den 2022'ye kadar olan ve pandemi sürecini de içinde barındıran veri setiyle Bitcoin için tahmin yapılmıştır. Literatürde incelenen diğer çalışmalarla karşılaştırıldığında kullanılan modelin R^2 değeri %99.39 ile oldukça yüksek bir sonuca sahip olduğu ve modelin verilerle iyi bir uyum sağladığı görülmüştür. Elde edilen bulgulardan biri olan MSE değerinin de çok düşük olması, modelin düşük hata ile tahminler yapabildiğini söyleyebiliriz [22]. Bu çalışmayla seçilen model rastgele orman regresyonu ve literatür genelinde üzerinde çalışılmış olan regresyon çeşitlerinin Bitcoin tahmin çalışmalarında başarılı olduğu ve kullanılabilir olduğu gözlemlenmiştir.

Gelecekteki çalışmalarda elde edilen bulguların güvenilirliğini garanti etmek ve modelin genel performansını daha iyi değerlendirmek için çeşitli veri kümeleri ve değerlendirme teknikleri kullanılabilir. Böylece modelin çeşitli piyasa koşullarında ve farklı zaman aralıklarında nasıl çalıştığını anlamamıza yardımcı olabilir ve tahminlerin genel geçerliliğini artırabilir. Bitcoin fiyat tahmini alanında daha derinlemesine bir bakış elde etmek için ise bir dizi regresyon modeli ve tahmin yöntemi değerlendirilmesi gerekebilir. Bu, gelecekteki araştırmalarda farklı veri setleri (borsa verileri vb.) kullanarak kıyaslamalar yapmak ve daha kapsamlı araştırmalar yapmak için çeşitli tekniklerin kullanılmasına olanak sağlayabilir. Bu çalışmanın sonuçlarını daha derinlemesine inceleyerek ve Bitcoin fiyat tahminini geliştirmek için çeşitli teknikler geliştirerek araştırmacılar, Bitcoin fiyat tahminine önemli bir katkı sağlayabilirler.

Teşekkür

Bu çalışmanın tamamlanması için tavsiyesini esirgemeyen ve emeği geçen herkese teşekkür ederiz.

Kaynakça

- [1] S. Nakamoto- Bitcoin' i Tanıtan İlk Makale. "Bitcoin: A Peer-to-Peer Electronic Cash System", 3 Ocak 2009, 28 Aralık 2022, <https://bitcoin.org/bitcoin.pdf>
- [2] BtcTurk Bilgi Platformu. "Bitcoin (BTC) Nedir?", 1 Temmuz 2013, 31 Aralık 2022, <https://www.btcturk.com/bilgi-platformu/bitcoin-btc-nedir/>
- [3] Bitlo Rehber Portalı. "Bitcoin (BTC) Nedir?", 31 Aralık 2022, <https://www.bitlo.com/rehber/bitcoin-nedir>
- [4] Khakikhouei, R. (2020). Makine Öğrenme Yöntemleriyle Bitcoin Fiyat Analizi (Yüksek Lisans Tezi, Fırat Üniversitesi, 2020), IV. Uluslararası Battalgazi Bilimsel Çalışmalar Kongresi Özet Kitabı, 25.
- [5] Böhme, R., Christin, N., Edelmann, B., Moore T., (2015) Bitcoin: Economics, Technology and Governance. *Journal of Economic Perspectives*, 29(2), 213 – 238.

- [6] Şengül, Z. (2022). Makine Öğrenmesi Algoritmalarını Kullanarak Bitcoin Fiyat Tahmini. Yayımlanmamış Yüksek Lisans Tezi, T.C. Trakya Üniversitesi Sosyal Bilimler Enstitüsü, Edirne.
- [7] Yavuz, U., Özen, Ü., Taş, K., Çağlar, B. (2020) Yapay Sinir Ağları ile Blockchain Verilerine Dayalı Bitcoin Fiyat Tahmini. *Bilişim Sistemleri ve Yönetim Araştırmaları Dergisi*, 2 (1), 1-9.
- [8] Köksal, B., Erdem, G., Türkeli, C., Öztürk, Z., K. (2021) Twitter’da Duygu Analizi Yöntemi Kullanılarak Bitcoin Değer Tahminlemesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9 (2021) 280-297.
- [9] Greaves, A., AU, B. (2015). Using the Bitcoin Transaction Graph to Predict. *CS224W: Social and Information Network Analysis*, 1-8.
- [10] Evcı, S. (2020). Bitcoin Piyasasında Haftanın Günü Anomalisi. *Alanya Akademik Bakış*, 4(1), 53-61.
- [11] Demir, A., Akilotu, B., N., Kadıroğlu, Z., Şengür, A. (2019) Bitcoin Price Prediction Using Machine Learning Methods. 2019 1st International Informatics and Software Engineering Conference (UBMYK), 1-4.
- [12] Phaladisailoed, T., Numnonda, T. (2018). Machine Learning Models Comparison for Bitcoin Price Prediction. 2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE), 506-511.
- [13] Auti, A., Patil, D., Zagade, O., Bhosale, P. (2022). Bitcoin Price Prediction Using SVM. *International Journal of Engineering Applied Sciences and Technology*, 226 – 229.
- [14] Roy, S., Nanjiba, S., Chakrabarty, A. (2018). Bitcoin Price Forecasting Using Time Series Analysis. 2018 21st International Conference of Computer and Information Technology (ICIT), 1 – 5.
- [15] Businessyield Finans ve Muhasebe Sayfası. “Yahoo Finance: Haberler, Net değer, nasıl başladıkları ve API Kılavuzu”, 5 Aralık 2022. Ocak 1, 2023. <https://businessyield.com/tr/finance-accounting/yahoo-finance/#:~:text=Yahoo%20Finance%20API%2C%20piyasa%20C3%B6zetleri,g%C3%BCvenilir%20bir%20borsa%20verileri%20kayna%C4%9F%C4%B1d%C4%B1r>.
- [16] Yahoo Finans Günlük BTC Fiyat Listesi. “Bitcoin USD”, 31 Aralık 2022. 31 Aralık 2022. <https://finance.yahoo.com/quote/BTC-USD?p=BTC-USD>.
- [17] Günel, A. (2003). Regresyon Denkleminin Başarısını Ölçmede Kullanılan Belirleme Katsayısı ve Kritiği. *Doğuş Üniversitesi Dergisi*, 133-140.
- [18] BitDegree Eğitici Yazılar Portalı. “Python Kütüphaneleri: Hangisi Ne İşe Yardımcı Olur?”, 07 Aralık 2022. 1 Ocak 2023. <https://tr.bitdegree.org/tutorial/python-kutuphaneleri/#heading-13>.
- [19] Demirezen, S., Çetin, M. (2021). Rassel Orman Regresyonu ve Destek Vektör Regresyonu ile Piyasa Takas Fiyatının Tahmini. *Nicel Bilimler Dergisi*, 3(1), 1 - 15.
- [20] Devhunter Kişisel Bloğu. “Rastgele Orman (Random Forest) Algoritması”, 20 Eylül 2018. 1 Ocak 2023. <https://devhunteryz.wordpress.com/2018/09/20/rastgele-ormanrandom-forest-algoritmasi/comment-page-1/>.
- [21] Breiman, L. (2001). Random Forests. *Machine Learning*, 45, 5–32.
- [22] Medium Buse Köseoğlu Bloğu. “Model Performansını Değerlendirmek: Regresyon.”, 11 Şubat 2011. 1 Ocak 2023. <https://medium.com/yaz%C4%B1%C4%B1m-ve-bili%C5%9Fim-kul%C3%BCb%C3%BC/model-performans%C4%B1n%C4%B1-de%C4%9Ferlendirmek-regresyon-48b4afec8664>.
- [23] Nomidl Machine Learning. “Random Forest algorithm for Machine Learning”, 25 Eylül 2022. 1 Ocak 2023. <https://www.nomidl.com/machine-learning/random-forest-algorithm-for-machine-learning/>.
- [24] Yaparimben Blog Portalı. “Blockchain İşletim Sistemi Nedir?”, 30 Ekim 2019. 31 Aralık 2022. <https://www.yaparimben.com/blockchain-isletim-sistemi-nedir/>
- [25] Gültepe, Y. (2019). Makine Öğrenmesi Algoritmaları ile Hava Kirliliği Tahmini Üzerine Karşılaştırmalı Bir Değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.
- [26] Orte, F., Mira, J., Sanchez, M., J., Solana, P. (2022). A Random Forest-Based Model For Crypto Asset Forecasts In Futures Markets With Out-Of-Sample Prediction. *Research in International Business and Finance*, Elsevier, vol. 64(C).

- [27] Metin, S. (2021). Kripto Para Fiyatlarının Regresyon Analizi Yöntemleri ile Tahmini: Bitcoin, Ethereum ve Ripple. 2. Uluslararası Sosyal Bilimler ve İnovasyon Kongresi, 591-606.
- [28] Sarı, S. S. (2021). Amerikan 10 Yıllık Tahvil Faiz Oranlarına Dayanılarak BİST 100 Endeks Tahmininde Ağaç Tabanlı Regresyon Modelleri Uygulaması. Çukurova Üniversitesi İİBF Dergisi, 25(2), 225-238.
- [29] Başer, B., Yangın, M., Sarıdaş, E., S. (2021). Makine Öğrenmesi Teknikleriyle Diyabet Hastalığının Sınıflandırılması. Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 25(1), 112-120.
- [30] Kazan, S., Karakoca, H. (2019). Makine Öğrenmesi ile Ürün Kategorisi Sınıflandırma. Sakarya University Journal Of Computer And Information Sciences, 2(1), 18 – 27.
- [31] Günek, B., Yurttakal, A., H. (2022). Bibliometric Analysis of Research Papers on Blockchain Technologies. IEEE Innovations in Intelligent Systems and Applications Conference, 1-5.



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 15.06.2023

Kabul Tarihi(Accepted Date): 04.09..2023

Otonom Mobil Robotlar İçin Metasezgisel Algoritmaların Çeşitli Yol Planlama Problemlerinde Performanslarının Karşılaştırılması

Esra DOĞAN^{1*}, Burhanettin DURMUŞ²

^{a*}Kütahya Dumlupınar Üniversitesi, Lisansüstü Eğitim Enstitüsü, Elektrik-Elektronik Mühendisliği ABD, Kütahya 43000, Türkiye, ORCID:0009-0005-9275-994X

^bKütahya Dumlupınar Üniversitesi, Mühendislik Fakültesi, Elektrik-Elektronik Mühendisliği, Kütahya 43000, Türkiye, ORCID:0000-0002-8225-3313

Özet

Otonom mobil robotların, engellerin olduğu bir ortamda engellere çarpmadan başlangıç noktasından hedef noktaya kadar olan yolu planlaması zor bir problemdir. Bu amaçla, başlangıç noktasından hedef noktaya giden yolu bulmak ve engellere çarpmamak için geliştirilen metasezgisel optimizasyon algoritmaları kullanılmaktadır. Bu çalışmada, robotun belirli bir alanda yol planlama problemini çözen bazı algoritmalar kullanılarak robotun çeşitli yol planlama problemlerindeki performansının karşılaştırılmasına değinilmiştir. Bu amaçla Farksal Gelişim Algoritması (DE), Parçacık Sürüsü Optimizasyon Algoritması (PSO), Gri Kurt Optimizasyon Algoritması (GWO) ve Karınca Aslanı (ALO) algoritmalarının aynı ve farklı engelli ortamlardaki performansları karşılaştırılmıştır. Karşılaştırma sonuçlarında bu algoritmaların engele çarpmayan uygun bir yol güzergahı planladıkları ve algoritmaların rekabetçi sonuçlar ürettikleri görülmektedir. Algoritmalar aynı ve farklı şekilli engellerin olduğu ortamlardaki performans sonuçları incelendiğinde yakın sonuçlar elde edildiği değerlendirilmiştir. Engellerin sayısının artırılması algoritmaların yol planlamada performans düşmesine neden olduğu görülmekle beraber ortalama bir tekrar sayısında (5 ve 10 tekrar arası) algoritmaların gerekli optimum performansa ulaştıkları değerlendirilmektedir.

Anahtar kelimeler: Robot Yol Planlaması, Metasezgisel Algoritmalar, Otonom Mobil Robotlar.

Comparison of Performances of Metaheuristic Algorithms for Autonomous Mobile Robots In Various Path Planning Problems

Abstract

It is a difficult problem for autonomous mobile robots to plan the path from the starting point to the target point without hitting the obstacles in an environment with obstacles. For this purpose, heuristic optimization algorithms developed to find the way from the starting point to the target point and not to hit the obstacles are used. In this study, the comparison of the robot's performance in various path planning problems is discussed by using some algorithms that solve the robot's path planning problem in a certain area. For this purpose, the performances of Differential Enhancement Algorithm (DE), Particle Swarm Optimization Algorithm (PSO), Gray Wolf Optimization Algorithm (GWO) and Ant Lion (ALO) algorithms in the same and different handicapped environments were compared. In the comparison results, it is seen that these algorithms plan a suitable road route that does not hit the obstacle and the algorithms produce competitive results. When the performance results of the algorithms in the environments with the same and different shaped obstacles are examined, it is evaluated that close results are

obtained. Although it is seen that increasing the number of obstacles causes a decrease in the performance of the algorithms in path planning, it is evaluated that the algorithms reach the required optimum performance in an average number of repetitions (between 5 and 10 repetitions).

Keywords: Robot Path Planning, Meta-heuristic Algorithms, Autonomous Mobile Robots.

* Esra DOĞAN. Tel.: +9-0507-974-71-26
E-mail address: esra.altun@ogr.dpu.edu.tr

1. Giriş

Metasezgisel algoritmalar optimizasyon problemlerinin çözümünde son yıllarda çokça kullanılmaktadır. Metasezgisel algoritmalar genel olarak doğadaki sürülerin sosyal davranışlarını ilham alır ve taklit eder [1]. Mobil robotlar için yol planlamasında metasezgisel algoritmalar ile, belirli koşullar altında ve belirli bir alanda bir başlangıç noktasından bir hedef noktasına optimal veya optimale yakın olacak şekilde engellere çarpmayan bir yol oluşturulması amaçlanmaktadır [2]. Son yıllarda özellikle engellerden kaçan yol planlaması problemi ile ilgili birçok araştırma ve çalışma yapılmıştır [3,4].

Bu çalışmalarda amaç robotun nereden nereye ve engellere çarpmadan nasıl gideceğini bulmaktır. Bu sebeple robotun engellere çarpmadan, başlangıç noktası ile hedef noktası arasında mümkün olan en kısa ve en az maliyetli yoldan hareket etmesi amaçlanmaktadır [5]. Bu çalışmada popüler sezgisel optimizasyon algoritmalarından DE [6], PSO [7], GWO [8] ve ALO [9] algoritmalarının çeşitli yol planlama senaryolarındaki performanslarının karşılaştırılmasından bahsedilmektedir. Bu algoritmaların temel ve popüler algoritmalar olmasından dolayı yol planlamasındaki performansları incelenmiştir [5-9]. Bu amaçla ele aldığımız algoritmaları birçok farklı senaryoda performanslarını karşılaştırarak hangi algoritmaların hangi yol planlama problemlerinde daha iyi sonuç verdiği değerlendirilmektedir. Farksal Gelişim Algoritması (DE), Parçacık Sürüsü Optimizasyon Algoritması (PSO), Gri Kurt Optimizasyon Algoritması (GWO) ve Karınca Aslanı Optimizasyon (ALO) algoritmaları tek tip ve farklı engellerdeki performansları ve farklı tip ve sayıdaki engellerdeki performansları karşılaştırmalı olarak sunulmaktadır.

2. Yol Planlama Problemi

Günümüz teknolojik gelişmeleri dikkate alındığında özellikle endüstride mobil robotlara daha fazla ihtiyaç duyulmakta, bu da robotlar ile ilgili çalışmaların artmasına neden olmaktadır [10]. Robot teknolojisinin, askeri, bilimsel, endüstri gibi alanlarda çokça kullanıldığı görülmektedir [11]. Robot teknolojisindeki bu ihtiyaçların giderek artması robotların yol problemini de beraberinde getirmektedir. Robotların yol problemini mümkün olan en az maliyetle çözmesi gerekmektedir. Yol planlama problemi, başlangıç noktasından hedef noktaya uygun bir yol bulmayı amaçlar. Ayrıca robotların hareketli oluşları beraberinde yüksek enerji kullanım sorununu ortaya çıkarmaktadır. Bu nedenle mobil robotlar için en kısa yol bulunması problemi daha önemli hale gelmektedir. Mobil robot için yol planlaması, engelli bir alanda bir başlangıç konumundan bir hedef konumuna engellere çarpmadan mümkün olan en kısa güzergahı bulmaktır. Literatürde yol planlaması ile ilgili metasezgisel algoritmaların tekil ve hibrit kullanılması gibi çeşitli yaklaşımlar bulunmaktadır [11,19,20]. Bu çalışmada güncel ve popüler bazı algoritmalar yardımıyla yol planlaması probleminin çözümünün karşılaştırmalı olarak incelenmesi amaçlanmaktadır. Yol planlama probleminin amaç fonksiyonu aşağıda verilmiştir:

$$J = \min_{x,y} Q(1 + \beta V) \quad (1)$$

Burada β ihlal katsayısı (100), V ihlal maliyetini belirtir, Q başlangıç ve hedef noktalar arasındaki toplam mesafeyi gösterir.

3. Metasezgisel Algoritmalar

Metasezgisel algoritmalar, bir problemi çözmek için doğal olaylardan ilham alan ve buna göre matematiksel olarak modellenen algoritmalarlardır. Bu algoritmalar kesin çözümü garanti etmezler ama yakınsama özelliğine sahip olduklarından doğruya yakın bir çözüm bulurlar. Optimizasyon kelime olarak en uygun, en iyileme anlamına gelmektedir. Bir problemin çözümü için, belirli şartlar dahilinde tüm çözümler arasından en iyi ya da en uygun çözümü elde etme işlemidir.

Birçok metasezgisel algoritma bulunmaktadır. Çalışmada DE, PSO, GWO ve ALO algoritmalarından yararlanarak yol planlama probleminin performansları karşılaştırılmıştır. DE, Price ve Storn tarafından geliştirilen, işleyiş bakımından genetik algoritmaya dayanan popülasyon temelli sezgisel bir optimizasyon tekniğidir. Algoritma, sürekli parametrelerin söz konusu olduğu durumlarda başarılı sonuçlar veren bir algoritmadır [12]. PSO, sosyolog-psikolog James Kennedy ve Russel Eberhart

tarafından geliştirilen, kuş ve balık sürü hareketlerinden ilham alarak doğrusal olmayan nümerik problemlere optimum çözümler bulmak için geliştirilmiş popülasyon tabanlı bir optimizasyon yöntemidir [13]. GWO, Seyedali Mirjalili ve arkadaşları tarafından önerilmiştir. GWO doğadaki gri kurtların liderlik hiyerarşisini ve avlanma mekanizmasını taklit eder. Liderlik hiyerarşisini simüle etmek için alfa, beta, delta ve omega gibi dört tür gri kurt kullanılır [14]. Ayrıca avlanma, av arama, avın etrafını sarma ve ava saldırma olmak üzere üç ana adım uygulanmaktadır [15]. ALO, Seyedali Mirjalili tarafından önerilen sürü zekası tabanlı bir algoritmadır. Karınca aslanlarının doğadaki avlanma mekanizmasını taklit eder [16]. Karıncaların gelişigüzel yürümesi, tuzak kurma, karıncaları tuzaklara hapsetme, av yakalama ve tuzakları yeniden kurma gibi beş ana adımı uygulamaktadır [17].

4. Metasezgisel Algoritmalar İle Yol Planlamasında Literatür Çalışmaları

Literatürde metasezgisel algoritmalar kullanılarak mobil robotlar için yol planlaması problemi ile ilgili çeşitli çalışmalar bulunmaktadır [18]. Literatürde daha önce yol planlamasında kullanılan algoritmalarından öne çıkan PSO ile yapılan yol planlamasında elde edilen sonuçlara bakıldığında en iyi sonuç üreten algoritmalarından biri olarak öne çıktığı görülmektedir [19]. Fakat PSO'nun arama ve uygulamada dengeleme güçlükleri olması ayrıca durgunluk yaşaması bazen yol planlamasını çözmedeki etkinliğini kısıtlamaktadır. Bunun üstesinden gelen ve verimli bir şekilde yol planlamasını amaçlayan farklı çalışmalar da mevcuttur. Literatürde ayrıca hibrit çalışmalar olduğu da görülmektedir. Örneğin, bahsettiğimiz PSO'nun eksiklerinin olmasından kaynaklı, Karınca Kolonisi Algoritması (ACO) ve PSO hibrit yöntemi kullanılmaktadır. Bu yöntem, robotun engelli yol boyunca karşılaştığı engellerden kaçınarak en uygun yolu bulmak için kullanılır. Bu çalışmadaki hibrit yöntem sonuçları incelendiğinde, geleneksel yöntemlere göre (ACO ve PSO) daha iyi sonuçlar sağladığı görülmektedir [20].

Yol planlamasında kullandığımız algoritmalar incelendiğinde, engel sayısı, engellerin şekli ve büyüklüğü, robotun bulunduğu alan büyüklüğü gibi değişkenler algoritmaların yol planlamasında avantaj ve dezavantajlarının olduğu görülmektedir. Bu çalışma ile elde edilen sonuçlara bakarak mobil robot yol planlamasının DE, PSO, GWO ve ALO algoritmalarının yol problemindeki performanslarının karşılaştırılması ve engel sayısı, engellerin şekli ve büyüklüğü gibi değişkenler karşısında avantaj ve dezavantajlarının ortaya çıkarılması amaçlanmaktadır. Literatürde yol planlama probleminde özellikle algoritmaların farklı tip ve sayıda engeller karşısında ve aynı tip engellerin olduğu ortamlarda nasıl bir performans gösterdikleri ile ilgili çalışmaların eksik olduğu görülmektedir. Bu çalışma ile bahsedilen algoritmaların çeşitli yol problemi simülasyonlarındaki performansları karşılaştırılmıştır.

5. Deneysel Çalışmalar

Yapılan bu çalışmada ağırlıklı olarak popüler bazı metasezgisel optimizasyon algoritmaları ile yol planlamasını yapıp, farklı yol problemlerinde bu algoritmaların performanslarını karşılaştırarak yol planlamadaki başarılarının matlab geliştirme ortamında incelenmesi sunulmuştur.

DE, PSO, GWO ve ALO metasezgisel algoritmaların kodları, Intel(R) Core(TM) i5-3230M CPU@2.60GHz RAM/8 özellikli bir bilgisayarda çalıştırılmıştır. Popülasyon büyüklüğü 50, maksimum iterasyon sayısı 100'dür. Robot yol planlama problemi için Tablo 1, Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te farklı robot yol planlaması simülasyonları için 4 sezgisel algoritmanın 1, 5, 10 ve 50 tekrar ve 100 iterasyonda 10x10 birimlik bir alandaki koşmaların karşılaştırmalı sonuçları sunulmuştur. Algoritma performanslarının karşılaştırılmasının tam olarak doğru olması için yol problemi simülasyonu oluşturulurken bütün koşullar eşit tutulmuştur.

Tablo 1. Engel şekline göre(daire, kare, üçgen, çokgen) DE, PSO, GWO ve ALO algoritmalarının performanslarının karşılaştırılması.

| Algoritma | Yol Problemi Modeli (5 engel) | Ortalama Maliyet | En İyi Maliyet | En Kötü Maliyet | Standart Sapma | Tekrar sayısı | İterasyon Sayısı |
|-----------|-------------------------------|------------------|----------------|-----------------|----------------|---------------|------------------|
| DE | Daire | 11.7491 | 11.7491 | 11.7491 | 0 | 1 | 100 |
| | Kare | 11.9309 | 11.9309 | 11.9309 | 0 | | |
| | Üçgen | 13.5295 | 13.5295 | 13.5295 | 0 | | |
| | Çokgen | 11.7733 | 11.7733 | 11.7733 | 0 | | |
| PSO | Daire | 11.6557 | 11.6557 | 11.6557 | 0 | 1 | 100 |
| | Kare | 11.6533 | 11.6533 | 11.6533 | 0 | | |
| | Üçgen | 11.6551 | 11.6551 | 11.6551 | 0 | | |
| | Çokgen | 11.4803 | 11.4803 | 11.4803 | 0 | | |
| GWO | Daire | 11.7465 | 11.7465 | 11.7465 | 0 | 1 | 100 |
| | Kare | 12.0762 | 12.0762 | 12.0762 | 0 | | |

| | | | | | | | |
|-----|--------|---------|----------------|---------|---|---|-----|
| ALO | Üçgen | 11.7221 | 11.7221 | 11.7221 | 0 | 1 | 100 |
| | Çokgen | 12.1944 | 12.1944 | 12.1944 | 0 | | |
| | Daire | 11.7202 | 11.7202 | 11.7202 | 0 | | |
| | Kare | 11.8097 | 11.8097 | 11.8097 | 0 | | |
| | Üçgen | 11.7504 | 11.7504 | 11.7504 | 0 | | |
| | Çokgen | 11.4979 | 11.4979 | 11.4979 | 0 | | |

Tablo 1 de, aynı büyüklükteki daire, kare, üçgen ve çokgen şekillerdeki engellerde 1 tekrar 100 iterasyon koşturma sonucundaki DE, PSO, GWO ve ALO optimizasyon algoritmalarının performansları sunulmuştur. Her bir algoritma için aynı sayı ve şekildeki engellerde en iyi maliyet değeri incelenmiştir. Matlab ortamında, yol planlamasında algoritmaların performanslarının incelenmesi için yapılan deneysel çalışmalarda engel şeklinin değişmesi, algoritmaların yol planlaması performansını önemli derecede etkilemediği görülmektedir. Bununla beraber DE algoritması daire, PSO algoritması çokgen, GWO algoritması üçgen ve ALO algoritmasının çokgen engellerde belirtilen koşullarda en iyi sonucu verdiği görülmektedir.

Tablo 2. 6,8 ve 10 engelli karışık şekilli engel ortamlarında DE, PSO, GWO ve ALO algoritmalarının performanslarının karşılaştırılması.

| Algoritma | Yol Problemi Modeli | Ortalama Maliyet | En İyi Maliyet | En Kötü Maliyet | Standart Sapma | Tekrar sayısı | İterasyon Sayısı |
|-----------|--------------------------------------|------------------|----------------|-----------------|----------------|---------------|------------------|
| DE | Yol Problemi 1 (6 engelli ortam) | 11.4038 | 11.4038 | 11.4038 | 0 | 1 | 100 |
| PSO | | 11.3862 | 11.3862 | 11.3862 | 0 | | |
| GWO | | 11.7381 | 11.7381 | 11.7381 | 0 | | |
| ALO | | 11.5447 | 11.5447 | 11.5447 | 0 | | |
| DE | Yol Problemi 2 (8 engelli ortam) | 12.2973 | 12.2973 | 12.2973 | 0 | 1 | 100 |
| PSO | | 11.3036 | 11.3036 | 11.3036 | 0 | | |
| GWO | | 13.4690 | 13.4690 | 13.4690 | 0 | | |
| ALO | | 11.3134 | 11.3134 | 11.3134 | 0 | | |
| DE | Yol Problemi 3 (10 engelli ortam) | 11.4425 | 11.4425 | 11.4425 | 0 | 1 | 100 |
| PSO | | 13.4220 | 13.4220 | 13.4220 | 0 | | |
| GWO | | 12.2608 | 12.2608 | 12.2608 | 0 | | |
| ALO | | 11.5349 | 11.5349 | 11.5349 | 0 | | |

Tablo 2 de, 1 tekrar 100 iterasyon koşturma sonucundaki DE, PSO, GWO ve ALO optimizasyon algoritmalarının yol problemi 1 (6 karışık şekilli engel ortam), yol problemi 2 (8 karışık şekilli engel ortam) ve yol problemi 3 (10 karışık şekilli engel ortam) için performansları sunulmuştur. Her bir algoritma için ilgili yol problemlerindeki en iyi maliyet, en kötü maliyet, ortalama maliyet ve standart sapma değerleri karşılaştırmalı olarak sunulmuştur. Tablodaki değerlere göre yol problemi 1 ve yol problemi 2'de en iyi performansı PSO, yol problemi 3'te DE algoritmasının daha iyi sonuç verdiği görülmektedir. Algoritma bazlı incelendiğinde üç yol planlama probleminde de ALO algoritmasının istikrarlı ve iyi bir performans gösterdiği diğer algoritmalarda engel sayısının değişmesi bir istikrarsızlığa neden olduğu görülmektedir.

Tablo 3. 6,8 ve 10 engelli karışık şekilli engel ortamlarında DE, PSO, GWO ve ALO algoritmalarının performanslarının karşılaştırılması.

| Algoritma | Yol Problemi Modeli | Ortalama Maliyet | En İyi Maliyet | En Kötü Maliyet | Standart Sapma | Tekrar sayısı | İterasyon Sayısı |
|-----------|--------------------------------------|------------------|----------------|-----------------|----------------|---------------|------------------|
| DE | Yol Problemi 1 (6 engelli ortam) | 11.5439 | 11.4031 | 11.6615 | 0.0933403 | 5 | 100 |
| PSO | | 11.3866 | 11.3740 | 11.3963 | 0.010638 | | |
| GWO | | 11.6042 | 11.5445 | 11.7077 | 0.0662461 | | |
| ALO | | 12.0393 | 11.6262 | 12.644 | 0.45935 | | |
| DE | Yol Problemi 2 (8 engelli ortam) | 12.6191 | 12.3179 | 13.5153 | 0.508912 | 5 | 100 |
| PSO | | 11.3016 | 11.2956 | 11.3065 | 0.0047636 | | |
| GWO | | 13.3663 | 11.5306 | 14.6062 | 1.24282 | | |
| ALO | | 13.9581 | 12.3762 | 16.0515 | 1.57479 | | |
| DE | Yol Problemi 3 (10 engelli ortam) | 12.6889 | 12.2797 | 13.5312 | 0.506424 | 5 | 100 |
| PSO | | 11.2864 | 11.2390 | 11.4667 | 0.100785 | | |
| GWO | | 15.7456 | 13.4995 | 21.7908 | 3.40753 | | |

| | | | | |
|-----|---------|---------|---------|---------|
| ALO | 12.8879 | 11.2493 | 18.2921 | 3.03608 |
|-----|---------|---------|---------|---------|

Tablo 3 de, 5 tekrar 100 iterasyon koşturma sonucundaki DE, PSO, GWO ve ALO optimizasyon algoritmalarının yol problemi 1, yol problemi 2 ve yol problemi 3 için performansları sunulmuştur. Her bir algoritma için ilgili yol problemlerindeki en iyi maliyet, en kötü maliyet, ortalama maliyet ve standart sapma değerleri karşılaştırmalı olarak sunulmuştur. Tablodaki değerlere göre yol problemi 1, yol problemi 2 ve yol problemi 3’de PSO algoritmasının en iyi performansı verdiği görülmektedir. Tablodaki tekrar ve iterasyon sayısı kadar yapılan deneyde engel sayısı arttıkça DE ve GWO algoritmalarının yol planlama performanslarının düşme eğiliminde olduğu görülmektedir.

Tablo 4: 6,8 ve 10 engelli karışık şekilli engel ortamlarında DE, PSO, GWO ve ALO algoritmalarının performanslarının karşılaştırılması

| Algoritma | Yol Problemi Modeli | Ortalama Maliyet | En İyi Maliyet | En Kötü Maliyet | Standart Sapma | Tekrar sayısı | İterasyon Sayısı |
|-----------|--------------------------------------|------------------|----------------|-----------------|----------------|---------------|------------------|
| DE | Yol Problemi 1 (6 engelli ortam) | 11.6410 | 11.3696 | 13.1618 | 0.542194 | 10 | 100 |
| PSO | | 11.4462 | 11.3627 | 11.5203 | 0.0732188 | | |
| GWO | | 12.0351 | 11.4635 | 15.819 | 1.33486 | | |
| ALO | | 11.7915 | 11.4403 | 12.3211 | 0.300045 | | |
| DE | Yol Problemi 2 (8 engelli ortam) | 12.7809 | 11.4216 | 13.5545 | 0.676772 | 10 | 100 |
| PSO | | 11.3570 | 11.2960 | 11.4607 | 0.0743957 | | |
| GWO | | 13.6809 | 11.4936 | 15.3685 | 1.39645 | | |
| ALO | | 12.2026 | 11.7823 | 13.0542 | 0.355809 | | |
| DE | Yol Problemi 3 (10 engelli ortam) | 12.9794 | 11.8444 | 14.4368 | 0.849694 | 10 | 100 |
| PSO | | 11.4073 | 11.2387 | 12.0945 | 0.263139 | | |
| GWO | | 13.7759 | 11.6774 | 19.9162 | 2.50294 | | |
| ALO | | 13.6918 | 11.2457 | 15.9837 | 1.37602 | | |

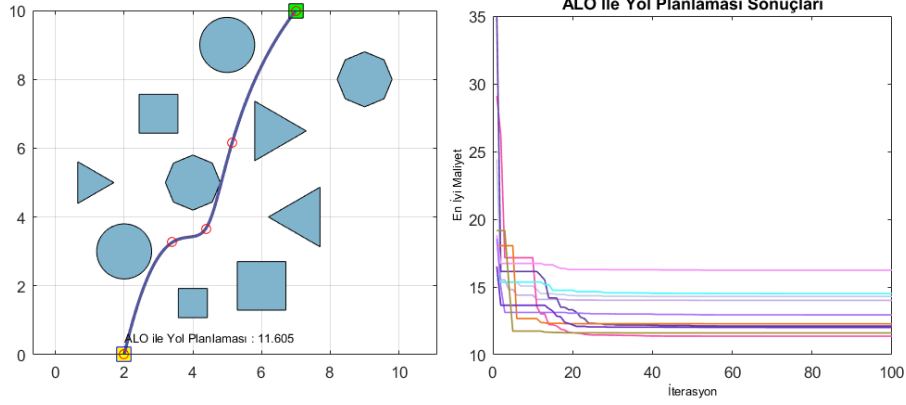
Tablo 4’de, 10 tekrar 100 iterasyon koşturma sonucundaki DE, PSO, GWO ve ALO optimizasyon algoritmalarının yol problemi 1, yol problemi 2 ve yol problemi 3 için performansları sunulmuştur. Her bir algoritma için ilgili yol problemlerindeki en iyi maliyet, en kötü maliyet, ortalama maliyet ve standart sapma değerleri karşılaştırmalı olarak sunulmuştur. Tablodaki değerlere göre yol problemi 1, yol problemi 2 ve yol problemi 3’de PSO algoritmasının en iyi performansı verdiği görülmektedir. Algoritma bazlı incelendiğinde engellerin sırayla artırıldığı üç yol planlama probleminde de DE’nin performansının düştüğü, PSO’nun önemli derecede bir performans değişimi olmadığı görülmele beraber iyi bir performans gösterdiği, GWO’nun biraz düştüğü, ALO’ nunda düşüp tekrar yükseldiği fakat iyi bir performans gösterdiği görülmektedir. Bu bölümdeki koşturmalarda genel olarak engel sayısı arttıkça algoritmaların yol planlama performanslarının iyi olduğu ve önem arz eden bir performans değişiminin olmadığı görülmektedir.

Tablo 5: 6,8 ve 10 engelli karışık şekilli engel ortamlarında DE, PSO, GWO ve ALO algoritmalarının performanslarının karşılaştırılması.

| Algoritma | Yol Problemi Modeli | Ortalama Maliyet | En İyi Maliyet | En Kötü Maliyet | Standart Sapma | Tekrar sayısı | İterasyon Sayısı |
|-----------|--------------------------------------|------------------|----------------|-----------------|----------------|---------------|------------------|
| DE | Yol Problemi 1 (6 engelli ortam) | 11.6513 | 11.3933 | 13.2039 | 0.439353 | 50 | 100 |
| PSO | | 11.4800 | 11.3888 | 11.5278 | 0.0535691 | | |
| GWO | | 12.0152 | 11.3974 | 14.1996 | 0.700801 | | |
| ALO | | 11.6846 | 11.5082 | 13.8635 | 0.370656 | | |
| DE | Yol Problemi 2 (8 engelli ortam) | 12.5751 | 11.3431 | 14.3761 | 0.875183 | 50 | 100 |
| PSO | | 11.5813 | 11.296 | 14.1676 | 0.44189 | | |
| GWO | | 13.0848 | 11.3208 | 15.0326 | 0.919037 | | |
| ALO | | 12.4175 | 11.3026 | 15.2467 | 1.43908 | | |
| DE | Yol Problemi 3 (10 engelli ortam) | 13.1812 | 11.2921 | 14.5759 | 1.01803 | 50 | 100 |
| PSO | | 12.7696 | 11.2392 | 14.3132 | 1.41997 | | |
| GWO | | 15.0386 | 11.5661 | 23.809 | 3.24936 | | |
| ALO | | 13.9134 | 11.47 | 20.0639 | 2.2204 | | |

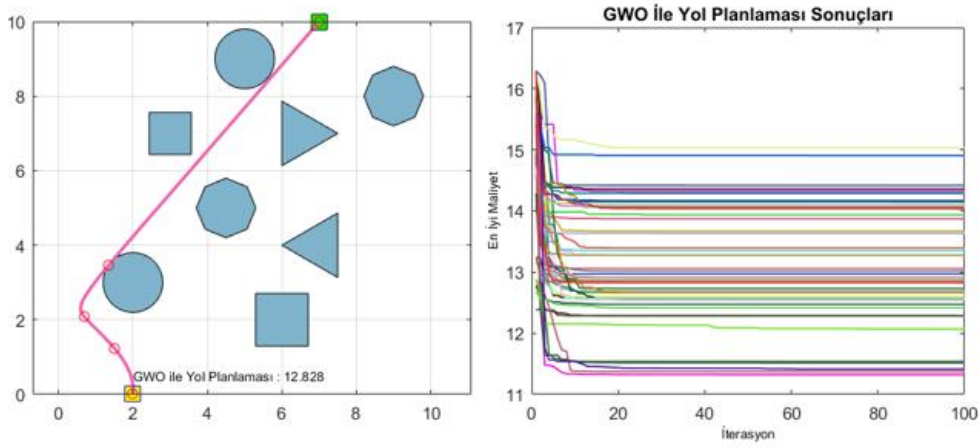
Tablo 5 de, 50 tekrar 100 iterasyon koşturma sonucundaki DE, PSO, GWO ve ALO optimizasyon algoritmalarının yol problemi 1, yol problemi 2 ve yol problemi 3 için performansları sunulmuştur. Her bir algoritma için ilgili yol problemlerindeki en iyi maliyet, en kötü maliyet, ortalama maliyet ve standart sapma değerleri karşılaştırmalı olarak sunulmuştur. Tablodaki değerlere göre yol problemi 1, yol problemi 2 ve yol problemi 3’de PSO algoritmasının en iyi performansı verdiği görülmektedir. Tabloda PSO’nun en iyi performansı gösterdiği görülmekle beraber diğer algoritmalarında yakın performans gösterdiği görülmektedir. Bu bölümde yapılan koşturmalarda genel olarak engel sayısı arttıkça algoritmaların yol planlama performanslarının iyi olduğu fakat tekrar sayısı değişimden dolayı düşük bir düşüş performansı değişiminin olduğu görülmektedir.

Şekil 1, Şekil 2, Şekil 3 ve Şekil 4 de matlab ortamında yapılan bazı deneysel çalışmalar sunulmuştur. Şekillerde algoritmanın yol planlama simülasyonu ve iterasyonlar boyunca izlediği performans grafiği gösterilmektedir. Şekillerin solunda tekrarlı çalıştırılan deneylerde, programın son tekrarda verdiği simülasyondur. Tablolarda ise bu tekrarlar içerisindeki en iyi ve en kötü değer gösterilmektedir. Ayrıca tekrar sayısına göre ortalama değer hesaplanarak ortalama maliyet olarak belirtilmektedir.



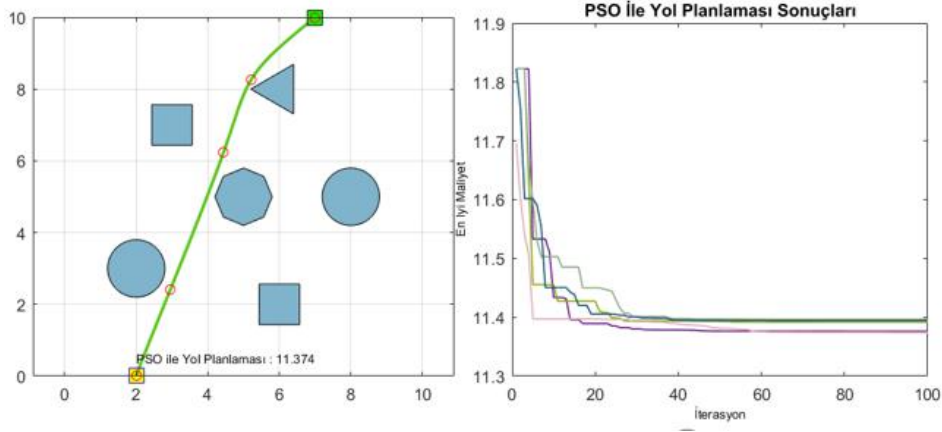
Şekil 1. ALO optimizasyon algoritmasının karışık tip 10 engelli ortamda 10 tekrar 100 iterasyon koşturmadaki performans değer ve grafiği

Şekil 1’de 10 karışık tip engelli bir alanda 10 tekrar 100 iterasyonluk koşturma sonucunda ALO’nun yol planlamasındaki performansı ve her tekrar için bir grafik olacak şekilde maliyet grafiği gösterilmektedir. Her 100 iterasyonluk tekrar için bir yol güzergahı çizilmektedir. Şekilde gösterilen yol güzergahı son tekrar olan 10’uncu tekrarı güzergahıdır.



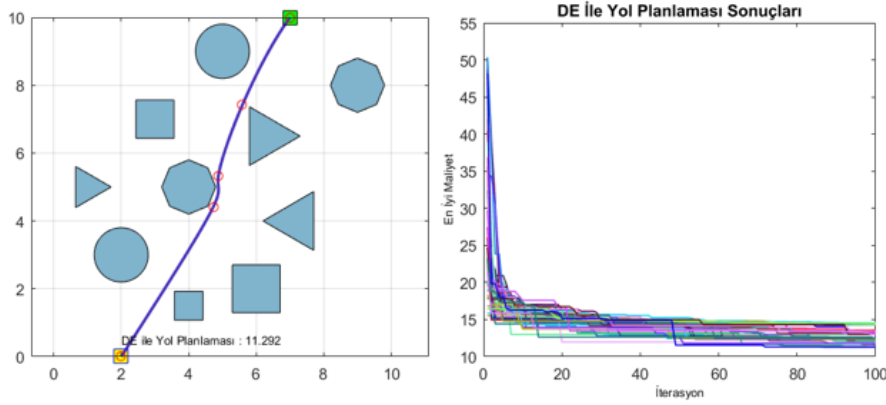
Şekil 2. GWO optimizasyon algoritmasının karışık tip 8 engelli ortamda 50 tekrar 100 iterasyon koşturmadaki performans değer ve grafiği

Şekil 2’de 8 karışık tip engelli bir alanda 50 tekrar 100 iterasyonluk koşturma sonucunda GWO’nun yol planlamasındaki performansı ve her tekrar için bir grafik olacak şekilde maliyet grafiği gösterilmektedir. Her 100 iterasyonluk tekrar için bir yol güzergahı çizilmektedir. Şekilde gösterilen yol güzergahı son tekrar olan 50’nci tekrarı güzergahıdır.




Şekil 3. PSO optimizasyon algoritmasının karışık tip 6 engelli ortamda 5 tekrar 100 iterasyon koşturmadaki performans değer ve grafiği

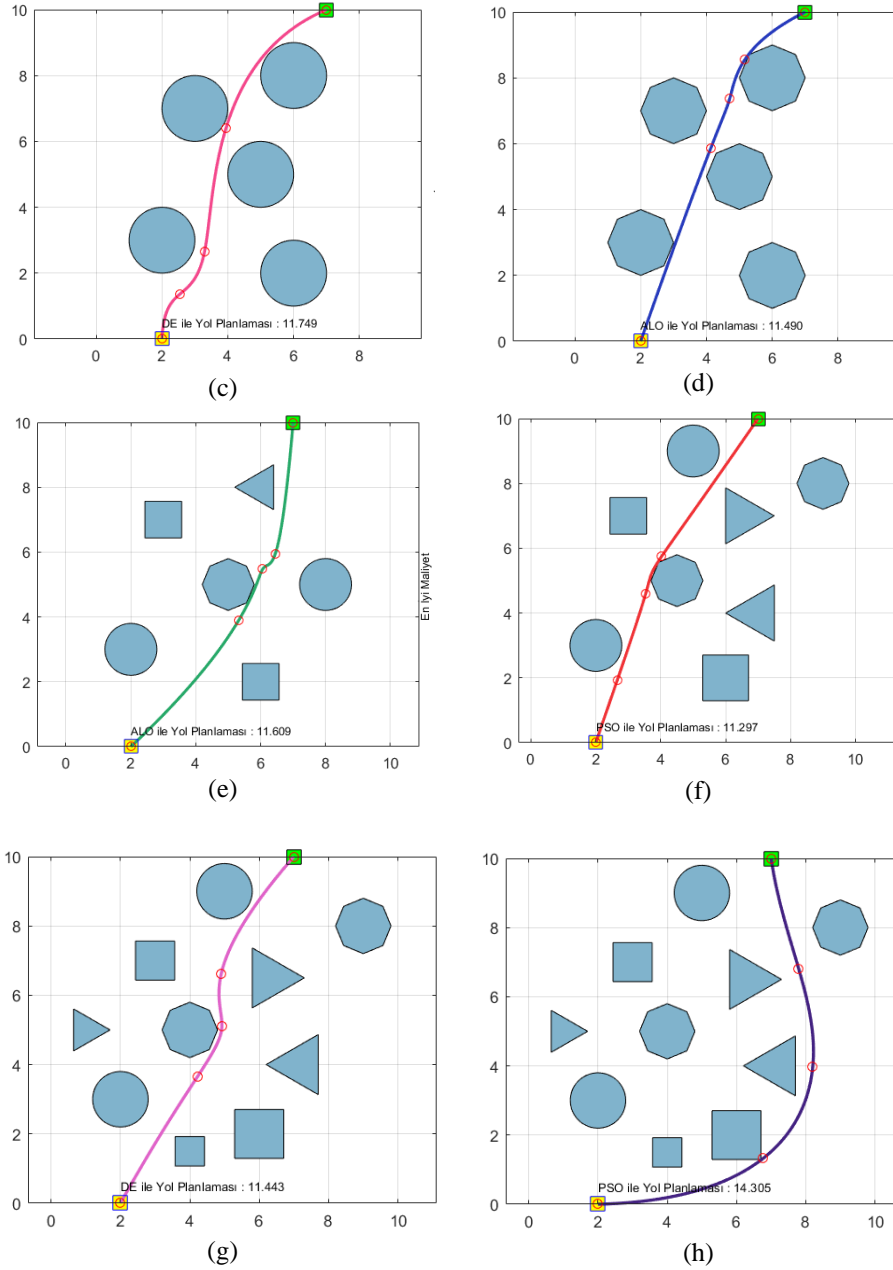
Şekil 3’de 6 karışık tip engelli bir alanda 5 tekrar 100 iterasyonluk koşturma sonucunda PSO’nun yol planlamasındaki performansı ve her tekrar için bir grafik olacak şekilde maliyet grafiği gösterilmektedir. Her 100 iterasyonluk tekrar için bir yol güzergahı çizilmektedir. Şekilde gösterilen yol güzergahı son tekrar olan 5’nci tekrarın güzergahıdır.



Şekil 4. DE optimizasyon algoritmasının karışık tip 10 engelli ortamda 50 tekrar 100 iterasyon koşturmadaki performans değer ve grafiği

Şekil 4’de 10 karışık tip engelli bir alanda 50 tekrar 100 iterasyonluk koşturma sonucunda DE’nin yol planlamasındaki performansı ve her tekrar için bir grafik olacak şekilde maliyet grafiği gösterilmektedir. Her 100 iterasyonluk tekrar için bir yol güzergahı çizilmektedir. Şekilde gösterilen yol güzergahı son tekrar olan 50’nci tekrarın güzergahıdır.





Şekil 5. (a,b,c,d,e,f,g,h), Çalışmada kullanılan yol problemleri ve sezgisel algoritmaların yol planlamadaki performansları

Şekil 5’te, çalışmada kullanılan tüm yol problemleri için bazı deneysel çalışmalar sonucunda metasezgisel algoritmaların yol planlamadaki performansları gösterilmiştir. Deneysel çalışmada çeşitli tip ve farklı sayıdaki engellerle yol planlama sonuçları örnek olarak sunulmuştur. Şekilde a, b, c, d ile gösterilen; 5 adet üçgen, kare, daire, çokgen engelin olduğu yol simülasyonunu göstermektedir. e, f, g, h ile gösterilen sırasıyla 6, 8, 10, 10 karışık tip şekilli engellerin olduğu yol simülasyonunu göstermektedir.

6. SONUÇLAR

Çalışmada 10x10 birimlik bir ortamda popüler dört metasezgisel algoritmanın yol planlama performansları karşılaştırılmıştır. Çalışmada kullanılan metasezgisel algoritmaların aynı tip ve farklı tip engellerdeki performansları incelendiğinde yakın sonuçlar elde edildiği görülmektedir. Engel sayısının artması performans düşmesine neden olduğu görülmektedir. Çalışmada 1, 5, 10 ve 50 tekrar 100 iterasyonlu koşurma sonuçları incelendiğinde özellikle 5 ile 10 arası 100 iterasyonluk koşurmaların algoritmanın yol

planlamasındaki performansının anlaşılması için yeterli olduğu görülmektedir. Ayrıca iterasyon sayısının 100 olarak belirlenmesinde yapılan deneysel çalışmalarda bu iterasyon değerinde, algoritma optimum performansı verdiği bundan sonraki iterasyon sayılarında stabil hale geldiği görülmektedir. Yapılan deneysel çalışmaların sayısal sonuçları 5. bölümde tablolarda karşılaştırmalı olarak sunulmuştur. Algoritmaların yol planlamasını kaç birim mesafe ile gerçekleştirdiği en iyi maliyetle ifade edilmiştir. Bunun yanında en kötü maliyet, ortalama maliyet, standart sapma değerleri tablolarda karşılaştırmalı olarak sunulmuştur. Tüm deneysel çalışma ve yol problemlerinde PSO algoritmasının daha iyi ve daha istikrarlı bir performans gösterdiği görülmektedir. Tekrar sayısının belirli bir norma getirilmesiyle beraber tüm algoritmalar rekabetçi bir performans göstermektedir. Daha sonra yapılacak çalışmalarda bu algoritmalarla beraber daha fazla algoritma ve farklı şekil ve sayıdaki engelli yol planlama problemlerindeki performansları karşılaştırılıp en iyi performans veren algoritmaların sonuçları karşılaştırmalı olarak sunulacaktır.

7. TARTIŞMA

Bu çalışmada robot yolu planlama problemi için DE, PSO, GWO ve ALO algoritmalarının çeşitli yol problemlerindeki performansları incelenmiştir. Algoritmaların yol planlama problemini çözme performansının değerlendirilmesi için dört tanınmış metasezgisel algoritma (DE, PSO, GWO ve ALO) kullanılmıştır. Karşılaştırma sonuçlarına bakıldığında algoritmaların iyi ve rekabetçi sonuçlar ürettikleri görülmekle beraber, PSO algoritmasının daha iyi bir performans ortaya koyduğu görülmektedir.

Teşekkür

Bu makalenin her aşamasında bilgi ve yardımını esirgemeyen, önerileriyle bana rehberlik eden değerli danışmanım Doç. Dr. Burhanettin DURMUŞ'a teşekkür ediyorum.

Kaynakça

- [1] Beheshti, Z., Shamsuddin, S. M. H. (2013). A review of population-based meta-heuristic algorithm. *International Journal of Advances in Soft Computing and its Applications*, 5(1), 1-35.
- [2] Alexopoulos, C., Griffin, P. M. (1992). Path planning for a mobile robot. *IEEE Trans. Syst. Man. Cybern.*, 22(2), 1132-1139.
- [3] Sariff, N., Buniyamin, N. (2006). "An overview of autonomous mobile robot path planning algorithms. 4th Student Conference on Research and Development, 183-188.
- [4] Hofner, C., Schmidt, G. (1995). Path planning and guidance techniques for an autonomous mobile cleaning robot. *Rob. Auton. Syst.*, 14(2-3), 199-212.
- [5] Yarpiz. "Optimal Robot Path Planning using PSO", 31 Ekim 2019, 5 Haziran 2023, <http://yarpiz.com/403/ypap115-path-planning>.
- [6] Storn, R., Price, K. (1997). Differential Evolution – A Simple and Efficient Heuristic for global Optimization over Continuous Spaces. *J. Glob. Optim.*, 11(4), 341-359.
- [7] Kennedy, J., Eberhart, R. (1995). Particle swarm optimization. *Proceedings of ICNN'95-International Conference on Neural Networks 4*, 1942-1948.
- [8] Mirjalili, S., Mirjalili, S. M., Lewis, A. (2014). Grey Wolf Optimizer. *Adv. Eng. Softw.*, 69, 46-61.
- [9] Mirjalili, S. The ant lion optimizer. *Adv. Eng. Softw.*, 83, 80-98.
- [10] Alomari, A., Phillips, W., Aslam, N., Comeau, F. (2017). Swarm intelligence optimization techniques for obstacle-avoidance mobility-assisted localization in wireless sensor networks. *IEEE*, 6, 22368-22385.
- [11] Garip, Z. (2018). Mobil robotların yol planması için metasezgisel hibrit algoritmalar geliştirilmesi ve uygulanması, Doktora Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Mekatronik Ana Bilim Dalı, Sakarya, 167s.
- [12] Price, K. V., Storn, R. M., Lampinen, J. (2005). *Differential Evolution: A Practical Approach to Global Optimization (Natural Computing Series)*. 28.
- [13] Clerc, M., Kennedy, J. (2002). The particle swarm - explosion, stability, and convergence in a multidimensional complex space. *IEEE Trans. Evol. Comput.*, 6(1), 58-73.
- [14] Mirjalili, S., Mirjalili, S. M., Lewis, A. (2014). Grey Wolf Optimizer. *Advances in Engineering Software*, 69, 46-61.
- [15] Geeksforgeeks. "Gray wolf optimization – introduction", 16 Mart 2021, 10 Nisan 2023, <https://www.geeksforgeeks.org/grey-wolf-optimization-introduction/>.
- [16] Mirjalili, S. (2015). The Ant Lion Optimizer. *Advances in Engineering Software*, 83, 80-98.
- [17] Kumar, S., Kumar, A., (2018). A brief review on antlion optimization algorithm. *International Conference on Advances in Computing, Communication Control and Networking (ICACCCN2018)*, 236-240.
- [18] Gürgüze, G., Türkoğlu, İ. (2019). Robot Sistemlerinde Kullanılan Algoritmalar. *Türk Doğa ve Fen Dergisi*, 8(1), Sayfa 17-31.

- [19] Beşkirli, M., Tefek, M. F. (2019). Parçacık Sürü Optimizasyon Algoritması Kullanılarak Optimum Robot Yolu Planlama. *European Journal of Science and Technology, (Special Issue)*, 201–213.
- [20] Gigras, Y., Choudhary, K., Gupta, K., Vandana. (2015). A hybrid ACO-PSO technique for path planning. *2nd International Conference on Computing for Sustainable Global Development (INDIACom)*, 1616-1621.



Contents lists available at *Dergipark*

Journal of Scientific Reports-B

journal homepage: <https://dergipark.org.tr/en/pub/jsrb>



E-ISSN: 2717-8625

Sayı(Number) 8, Aralık(December) 2023

ARAŞTIRMA MAKALESİ/RESEARCH ARTICLE

Geliş Tarihi(Receive Date): 13.10.2023

Kabul Tarihi(Accepted Date): 12.12.2023

İşlerin Bölünebildiği Esnek Atölye Çizelgeme Problemi için İki Matsezgisel Algoritmanın Karşılaştırılması

Büşra TUTUMLU^{1*}, Tuğba SARAÇ²

^aKütahya Dumlupınar Üniversitesi, Endüstri Mühendisliği Bölümü, Kütahya, Türkiye

^bEskişehir Osmangazi Üniversitesi, Endüstri Mühendisliği Bölümü, Eskişehir, Türkiye

Özet

Esnek atölye çizelgeme problemlerinde (EAÇP) işlerin alt partilere bölünerek farklı makinelerde gerçekleştirilmesi, işletmelerin müşteri taleplerini daha hızlı bir şekilde karşılamasını ve makinelerin de daha verimli kullanılmasını sağlamaktadır. Bu çalışmada, ele alınan problem işlerin bölünebildiği EAÇP'dir. Amaç, son işin tamamlanma zamanının enküçüklenmesidir. Problemin çözümü için hem matsezgisel tavlama benzetimi algoritması (MTB) hem de matsezgisel değişken komşuluk arama algoritması (MDKA) önerilmiştir. Ele alınan problemde işlerin hangi makinelere atanacağı, hangi sırada işleneceği ve alt parti büyüklüklerinin ne olacağını belirlemek gerekmektedir. Önerilen algoritmalarda alt parti büyüklüklerinin ne olacağı matematiksel model ile belirlenmektedir. Böylelikle sezgisel algoritmaların hızlı bir şekilde çözüm uzayında arama yapması avantajı ile matematiksel modellerin alt problemlerdeki en iyi çözümü elde etmesi avantajı bir araya getirilmiştir. Önerilen algoritmaların performansını gösterebilmek için rassal türetilen test problemleri ve literatürden alınan bir matematiksel model kullanılmıştır. Ayrıca MTB'nin ve MDKA'nın performansları da kıyaslanmıştır.

© 2023 DPU All rights reserved.

Anahtar Kelimeler: İş Bölünmesi; Esnek Atölye Çizelgeleme; Matsezgisel Algoritma; Tavlama Benzetimi; Değişken Komşuluk Arama

* Corresponding author. Tel.: +0-000-000-0000 ; fax: +0-000-000-0000 .

E-mail address: author@institute.xxx

<http://dx.doi.org/10.1016/j.cviu.2017.00.000>

Comparison of two matheuristic algorithms for the flexible job-shop scheduling problem with lot-streaming

Abstract

In flexible job-shop scheduling problems (FJSP), splitting into sub-lots of jobs and performing them on different machines enables businesses to satisfy customer demands more quickly and to use their machines more efficiently. In this study, the FJSP with lot-streaming is discussed. The objective function is to minimize the makespan. To solve the considered problem, matheuristic simulated annealing algorithm (MSA) and matheuristic variable neighborhood search algorithm (MVNS) are proposed. In the problem addressed, it is necessary to determine which machines the jobs will be assigned to, in which sequence they will be processed, and what the sub-lot sizes will be. The proposed algorithms determine the sub-lot sizes by the mathematical model. In this way, the advantage of heuristic algorithms to quickly search the solution space and the advantage of mathematical models to obtain the optimum solution in sub-problems are considered together. To show the performance of the proposed algorithms, randomly generated test problems and a mathematical model taken from the literature are used. Additionally, the performances of MSA and MVNS are compared.

© 2023 DPU All rights reserved.

Keywords: Lot- Streaming; Flexible Job Shop Scheduling; Matheuristic Algorithm; Simulated Annealing; Variable Neighborhood Search

1. Giriş

Günümüz rekabet ortamında işletmelerin en önemli hedeflerinden biri işlerin zamanında teslim edilmesidir. İşlerin makinelere bölünerek daha kısa sürelerde tamamlanabilmesi mümkündür. Fakat literatürde çizelgeleme problemlerini ele alan çalışmaların çoğunda işlerin bölünemeyeceği varsayılmaktadır. İşlerin bölünmesine izin vermek sadece işlerin tamamlanma zamanının azaltılmasını değil makinelerin de daha verimli kullanılmasını sağlamaktadır. Kısaca, işlerin bölünmesi, makineler üzerindeki malzeme akışının hızını artırmaya ve üretim süresini, döngü süresini ve süreç içi stoğu azaltmaya büyük ölçüde katkıda bulunmaktadır. Bu çalışmada, esnek atölye çizelgeleme probleminde (EAÇP) işlerin bölünmesi ele alınmıştır.

Literatürde son yıllarda işlerin bölünmesine izin verilen EAÇP ile ilgili çalışmaların sayısı artmaktadır. İncelenen literatürde iş bölünmeli çalışmalar alt partilerin sabit ve değişken olmasına göre ve alt parti sayılarının önceden bilinmesine ve bilinmemesine göre sınıflandırılabilir. Alt partilerin sabit olduğu ve alt parti sayılarının ise önceden bilindiği çalışmalara Zhang vd. [3], Lei ve Guo [4], Liu vd. [5], Xu vd. [6], Defersha, Chen [7] ve Rooyani ve Defersha [8] örnek verilebilir. Zhang vd. [3], büyük ölçekli toplu üretimi içeren eşit boyutlu parti bölmeli EAÇP problemi için bir ikili parçacık sürüsü optimizasyon algoritması önermiştir. Lei ve Guo [4], son işin tamamlanma zamanını en küçüklemek için bir yapay arı kolonisi algoritması önermişlerdir. Liu vd. [5], sabit sayıda iş bölme yaklaşımı kullanarak bu parametreyi sistematik olarak değiştirerek, sabit sayıda alt partinin parti akışının performansı üzerindeki etkisini incelemiş ve genetik algoritma (GA) tabanlı bir iş bölme yaklaşımı önermiştir. Xu vd. [6], işleri belirli sayıda partiye ayırmaya izin veren bir evrimsel algoritma önermişlerdir. Defersha ve Chen [7], çok akışlı EAÇP için bir matematiksel model önermişlerdir ve önerilen modeli çözmek için bir GA geliştirmişlerdir. Rooyani ve Defersha [8] çok amaçlı bir matematiksel model önermiştir ve iki aşamalı bir GA geliştirmiştir. Alt parti büyüklüklerinin değişken olduğu ve alt parti sayılarının önceden bilindiği çalışmalara Daneshamooz vd. [9] ve Abderrabi vd. [10] örnek verilebilir. Daneshamooz vd. [9], problemi işlerin makinelere atanması ve makinelerdeki işlerin sırasının belirlenmesi üzere iki alt probleme ayırmış ve değişken komşuluk arama algoritmasına dayalı iki algoritma önermiştir. Abderrabi vd. [10], iş bölmeli EAÇP için bir matematiksel model önermiştir.

Novas [11] çalışmasında, alt partilerin sabit olduğu ve alt parti sayılarının ise önceden bilinmediği durumu ele almıştır. Bu çalışmada, bir kısıt programlama (constraint programming) modeli önerilmiştir. Bu yöntem ile hem partilerin bölünmesi hem de işlerin çizelgelenmesi sağlanmıştır. Alt partilerin değişken olduğu ve alt parti sayılarının önceden bilinmediği çalışmalara Bozek ve Werner [12], Fan vd. [13], Li vd. [14] ve Tutumlu ve Saraç [15] örnek

verilebilir. Bozek ve Werner [12], parti akışı ve değişken alt partilerin parti boyutlandırılması ile EAÇP için iki aşamalı bir çözüm yaklaşımı önermiştir. İlk aşamada, tamamlama süresi enküçüklenmiş ve ikinci aşamada ise, alt parti büyüklükleri enbüyüklenmiştir. Alt partilerin boyutları alt ve üst değerler ile sınırlandırılmıştır. Fan vd. [13], klasik GA'nın benimsendiği bir matsezgisel değişken komşuluk arama algoritması önermiştir. Alt parti sayıları maksimum bölünebilecek parti sayısı ile sınırlandırılmıştır. Li vd. [14], hem son işin tamamlanma zamanının hem de toplam enerji tüketiminin enküçüklenmesini amaçlamıştır ve problemin çözümü için emperyalist rekabet algoritması geliştirmişlerdir. Alt partiler, alt ve üst değerler ile sınırlandırılmıştır. Tutumlu ve Saraç [15], işlerin bölünmesinde alt partilerin boyutunun ve sayısının sınırlandırılmadığı bir matematiksel model önermişlerdir. Büyük boyutlu problemlerin çözümü için parti boyutunun ve sayısının yerel arama algoritması ile belirlendiği melez bir genetik algoritma önerilmiştir.

İşlerin bölünmesine izin verilen EAÇP literatürüne bakıldığında çözüm yöntemi olarak genellikle metasezgisel yöntemlerin kullanıldığı görülmektedir. Erişilen literatürde sadece bir çalışmada [13] çözüm yöntemi olarak matsezgisel algoritma kullanılmıştır. Ele alınan problem türünde matsezgisel algoritmalar nadir kullanılmış olmasına rağmen, bu algoritmalar hem sezgisel yöntemlerin hem de matematiksel modellerin başarılı yönlerinin birleştirilmesiyle ortaya çıktığından büyük bir potansiyele sahiptir. Bu nedenle bu çalışmada, işlerin bölünmesine izin verilen EAÇP problemi için iki farklı matsezgisel algoritma geliştirilmiştir. Bu algoritmalar, matsezgisel tavlama benzetimi ve matsezgisel değişken komşuluk aramadır. Tavlama benzetimi algoritmasının tercih edilmesi, literatürde çoğu problem tipin çok sık kullanılması ve başarılı çözümler elde etmesidir. Değişken komşuluk arama algoritmasının tercih edilmesinin sebebi ise matsezgisel algoritma öneren çalışmada [13] başarıyla kullanılmasıdır. Bu algoritmaların performansının gösterilebilmesi için literatürdeki hiçbir sınırlandırma olmadan iş bölünmesini ele alan Tutumlu ve Saraç [15]'in çalışmasındaki matematiksel model kullanılmıştır. Farklı boyutta test problemleri türetilerek algoritmaların başarısı karşılaştırılmıştır.

Bu çalışmanın izleyen bölümünde ele alınan problem açıklanmış ve literatürdeki matematiksel model verilmiştir. Üçüncü bölümde önerilen matsezgisel algoritmalar tanıtılmış ve dördüncü bölümde sayısal sonuçlar verilmiştir. Son bölümde ise sonuç ve öneriler sunulmuştur.

2. Problemin Tanımlanması ve Matematiksel Model

Bu çalışmada ele alınan problemde n adet iş, m adet makinede işlem görmektedir. İşler operasyondan oluşmaktadır. Her işin operasyonları arasında öncelik sırası vardır. Bu sıra rota olarak adlandırılmaktadır ve önceden bilinmektedir. Operasyonların hangi makinede ve hangi sırada gerçekleştirileceği, işlerin rotaları göz önünde bulundurularak belirlenmelidir. Bazı operasyonlar yalnızca belirli makinelerde gerçekleştirilebilirken, bazıları aynı özelliklere sahip makinelerde bölünmeden veya farklı alt gruplar halinde bölünerek birden fazla makinede gerçekleştirilebilmektedir.

Bu çalışmada Tutumlu ve Saraç [15] tarafında önerilen matematiksel model ($Model_{TS}$) kullanılmıştır. Modelde, son işin tamamlanma zamanının en küçüklenmesi amaçlanmıştır.

Modelin varsayımları şu şekildedir:

- Planlama periyodunun başında tüm işler hazırdır.
- Bir makine aynı anda tek bir iş işleyebilir.
- İşlerin önceliği yoktur.
- İşlerin hazırlık süreleri, işlem süreleri ve rotaları önceden bilinmektedir.
- İşlerin hazırlık süreleri, sıra bağımlı değildir.
- İşler birden fazla operasyondan oluşabilir.
- İşler bölünebilir ve farklı alt parti büyüklüklerinde farklı paralel makinelere atanabilir. Alt parti büyüklükleri model tarafından belirlenmektedir.

- Her operasyonun gerçekleştirildiği her makinede hazırlık süresine ihtiyaç vardır. Hazırlık süreleri her makinede farklıdır. Eğer bir iş alt partilere bölünüyorsa, her biri için hazırlık süresi gerekmektedir.

$Model_{TS}$ 'in indisleri, parametreleri, karar değişkenleri, amaç fonksiyonu ve kısıtları aşağıda verilmiştir.

indisler:

i, k : iş indisi
 j, l : operasyon indisi
 r, a : makine indisi
 q, b : sıra indisi

parametreler:

g_i : i . işin parti büyüklüğü
 o_i : i . işin operasyon sayısı
 t_{ijr} : r . makededeki i . işin j . operasyonunun birim işlem süresi
 s_{ijr} : r . makededeki i . işin j . operasyonunun hazırlık süresi
 u_{ijr} : r . makedede i . işin j . operasyonu işlem görüyorsa 1, işlem görmüyorsa 0.
 M : yeterince büyük bir pozitif sayı
 e : alt parti büyüklüğü için en küçük değer (Bu değer sıfıra eşit olduğunda, alt parti boyutu için bir sınır yoktur.)

karar değişkenleri:

x_{ijrq} : eğer r . makinenin q . sırasında i . işin j . operasyonu işleniyorsa 1, işlenmiyorsa 0.
 C_{ijr} : r . makedede i . işin j . operasyonunun tamamlanma zamanı
 α_{ijr} : r . makedede i . işin j . operasyonunun alt parti büyüklüğü
 C_{enb} : son işin tamamlanma zamanı

amaç fonksiyonu:

$$enk f = C_{enb} \quad (1)$$

kısıtlar:

$$\sum_r \alpha_{ijr} = g_i \quad \forall_{i,j : j \leq o_i} \quad (2)$$

$$\alpha_{ijr} \leq g_i \sum_q x_{ijrq} \quad \forall_{i,j,r : j \leq o_i} \quad (3)$$

$$\alpha_{ijr} \geq e \sum_q x_{ijrq} \quad \forall_{i,j,r : j \leq o_i} \quad (4)$$

$$\sum_q x_{ijrq} \leq 1 \quad \forall_{i,j,r : j \leq o_i} \quad (5)$$

$$\sum_i \sum_{j : j \leq o_i} x_{ijrq} \leq 1 \quad \forall_{r,q} \quad (6)$$

$$x_{ijrq} \leq u_{ijr} \quad \forall_{i,j,r,q : j \leq o_i} \quad (7)$$

$$q - b \geq 1 - M(2 - x_{ijrq} - x_{ilrb}) \quad \forall_{i,j,l,r,q,b : j \neq l, j \leq o_i, q \neq b} \quad (8)$$

$$\sum_i \sum_{j: j \leq o_i} x_{ijrq} - \sum_k \sum_{l: l \leq o_k} x_{klr(q-1)} \leq 0 \quad \forall_{r,q: q>1} \quad (9)$$

$$C_{ijr} + M(1 - x_{ijrq}) \geq s_{ijr} + t_{ijr} \alpha_{ijr} \quad \forall_{i,j,r,q: q=1, j=1} \quad (10)$$

$$C_{ijr} + M(2 - x_{ijrq} - x_{klr(q-1)}) \geq C_{klr} + s_{ijr} + t_{ijr} \alpha_{ijr} \quad \forall_{i,j,k,l,r,q: q>1, j=1, i \neq k} \quad (11)$$

$$C_{ijr} + M(2 - x_{ijrq} - x_{i(j-1)ab}) \geq C_{i(j-1)a} + s_{ijr} + t_{ijr} \alpha_{ijr} \quad \forall_{i,j,r,a,q,b: q=1, j>1, r \neq a} \quad (12)$$

$$C_{ijr} + M(2 - x_{ijrq} - x_{klr(q-1)}) \geq C_{klr} + s_{ijr} + t_{ijr} \alpha_{ijr} \quad \forall_{i,j,k,l,r,q: q>1, k \neq i, j \leq o_i, l \leq o_k} \quad (13)$$

$$C_{ijr} + M(2 - x_{ijrq} - x_{i(j-1)ab}) \geq C_{i(j-1)a} + s_{ijr} + t_{ijr} \alpha_{ijr} \quad \forall_{i,j,r,q,a,b: j>1, j \leq o_i} \quad (14)$$

$$C_{enb} \geq C_{ijr} \quad \forall_{i,j,r} \quad (15)$$

$$C_{ijr} \geq 0 \quad \forall_{i,j,r} \quad (16)$$

$$C_{enb} \geq 0 \quad (17)$$

$$x_{ijrq} \in \{0,1\} \quad \forall_{i,j,r,q} \quad (18)$$

$$\alpha_{ijr} \geq 0 \text{ ve tamsayı} \quad \forall_{i,j,r} \quad (19)$$

Amaç (Eş. (1)), C_{enb} değerinin enküçüklenmesidir. Eş. (2), i . işin alt parti büyüklüklerinin toplamının g_i 'ye eşit olmasını sağlamaktadır. Eş. (3) ve (4), α_{ijr} ve x_{ijrq} karar değişkenleri için ilişki kısıtlarıdır. Eş. (5) bir işin bir operasyonunun sadece bir makineye atanmasını sağlamaktadır. Eş. (6), bir makinenin bir sırasına en fazla bir işin atanmasını sağlamaktadır. Eş. (7), i . işin j . operasyonu r . makinede gerçekleştirilemiyorsa ilgili operasyonun r . makineye atanmamasını sağlamaktadır. Eş. (8) ve (9), makinelerde işlerin operasyonlarının sıra atlamaksızın işlem görmesini sağlamaktadır. Eş. (10), işlerin ilk operasyonları ilk sırada gerçekleştirildiğinde tamamlanma zamanını hesaplamaktadır. Eş. (11), işlerin ilk operasyonu ikinci ve sonraki sırada gerçekleştiğinde tamamlanma zamanını hesaplamaktadır. Eş. (12), işlerin ikinci ve sonraki operasyonları ilk sırada gerçekleştiğinde tamamlanma zamanını hesaplamaktadır. Eş. (13), işlerin ilk sıra dışındaki operasyonların tamamlanma zamanını hesaplamaktadır. Eş. (14) işlerin ikinci ve sonraki operasyonlarının tamamlanma zamanını hesaplamaktadır. Eş. (15), C_{enb} değerini hesaplayan kısıttır. Eş. (16)-(19) işaret kısıtlarıdır.

3. Önerilen Matsezgisel Algoritmalar

Bu çalışmada, Matsezgisel Tavlama Benzetimi ve Matsezgisel Değişken Komşuluk Arama algoritmaları önerilmiştir. Bu algoritmalarda işlerin bölündükleri makinelerdeki alt parti büyüklüğünün ne olacağı kararı matematiksel model ($Model_{APB}$) ile belirlenmektedir. İzleyen alt bölümlerde algoritmalarda kullanılan çözüm gösterimi, $Model_{APB}$, kontrol işlemi ve algoritmalar detaylı olarak açıklanmıştır.

3.1. Algoritmalar da Kullanılan Çözüm Gösterimi

Bu çalışmada ele alınan problemin kısıtlarına uygun üç satırlı bir çözüm gösterimi yapısı önerilmiştir. Önerilen bu yapı, her işin hangi makineye atandığı ve atandığı makinelerdeki sırası ve parti büyüklüğü bilgilerini göstermektedir. Şekil 1’de önerilen çözüm gösterimine örnek verilmiştir. Gösterimin uzunluğu, her işin operasyonlarının işlenebileceği makine sayısının toplamıdır.

| | O_{31} | O_{21} | O_{11} | O_{21} | O_{12} | O_{22} | O_{22} | O_{12} | O_{32} | O_{32} |
|-----------------|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| İş | 3 | 2 | 1 | 2 | 1 | 2 | 2 | 1 | 3 | 3 |
| Makine | 2 | 1 | 2 | 2 | 1 | 2 | 1 | 2 | 1 | 2 |
| Parti Büyüklüğü | 100 | 13 | 100 | 87 | 70 | 100 | 0 | 30 | 100 | 0 |

Şekil 1. Önerilen çözüm gösterimi.

Şekil 1’de verilen örnekte 2 makine, 3 iş ve her işin 2 operasyonu bulunmaktadır. O_{ij} , i . işin j . operasyonunu temsil etmektedir. O_{11} ve O_{31} sadece M2 makinesine, diğer operasyonlar her iki makineye de atanabilmektedir. Gösterimin uzunluğu 10’dur. İlk satır işleri göstermektedir. Bu satıra göre işlerin operasyonları belirlenmektedir. Örneğin ilk sütunda 3. iş bulunmaktadır. İlk defa 3. iş olması sebebiyle O_{31} operasyonunu temsil eder. O_{31} operasyonu tek makinede gerçekleştirildiği için ikinci defa tekrarlanan 3. iş O_{32} operasyonunu temsil eder. Bu nedenle dokuzuncu sütundaki 3. iş ise O_{32} operasyonunu ifade etmektedir. İkinci satır, işlerin operasyonlarının hangi makinede işlendiğini göstermektedir. Üçüncü satır, işlerin bölünüp bölünmediğini hem de bölündüyse atandığı makinede işlenmesi gereken parti büyüklüğünü (100 br.) göstermektedir. Şekil 1’de O_{22} ve O_{32} operasyonları iki makinede de işlem görebilecekler işler bölünmemiş tek bir makinede parti büyüklüğü kadar işlenmektedirler. O_{12} ve O_{21} operasyonları iki makineye bölünerek işlenmektedir. O_{12} , M1’de 70 br. ve M2’de 30 br. işlenmektedir. O_{21} ise M1’de 13 br. ve M2’de 87 br. işlenmektedir.

3.2. Algoritmalar da Başlangıç Çözümün Oluşturulması

Algoritmaların adımlarını gerçekleştirebilmek için uygun bir çözüm ile başlanması gerekir. Bu çalışmada aşağıdaki adımlar izlenerek başlangıç çözümü oluşturulmuştur.

Adım 1: Satır sayısı 3 olan sütun sayısı ise tüm işlerin operasyonlarının işlenebileceği makine sayısının toplamı ($\sum_i \sum_j MS_{ij}$) olan bir matris oluşturulur. (MS_{ij} : i . işin j . operasyonunun işlenebileceği makine sayısı)

Adım 2: Matrisin ilk satırı işleri gösterdiğinden her iş numarasının $\sum_j MS_{ij}$ kadar tekrar ettiği bir karışık liste oluşturulur. Bu liste matrisin ilk satırıdır.

Adım 3: Matrisin ikinci satırı makineleri göstermektedir. Bu satırı oluşturabilmek için matrisin ilk satırındaki bilgi kullanılarak hangi işin hangi operasyonu olduğu belirlenir ve bu operasyonun gerçekleştirilebileceği makinelerden biri seçilir. Bu şekilde ikinci satırdaki tüm hücreler tamamlanır.

Adım 4: Matrisin üçüncü satırı işlerin operasyonlarının kaçta bölündüğünü ve alt parti büyüklüklerini göstermektedir. Başlangıç çözüm için bu adımda sadece kaçta bölündüğü bilgisi belirlenir. Daha sonra algoritmalar da matematiksel model ile alt parti büyüklüğü belirlenir. Bu yüzden bu adımda ilk iki satırın bilgileri kullanılır. Eğer operasyon tek makinede işlem görüyorsa ilgili hücreye 1 değeri atanır. Eğer birden fazla makinede işlem görebiliyorsa bir makineye mutlaka atanmasını sağlamak için rassal olarak atanabileceği herhangi bir makineye 1 değeri atanır. Bu işlem bu satır tamamlanıncaya kadar gerçekleştirilir.

3.3. Önerilen $Model_{APB}$

İşlerin bölünmesine izin verilen çalışmalarda arama uzayı çok büyük olması nedeniyle klasik algoritmaların adımları ile alt parti büyüklüklerini belirlemek çok zordur. Bu nedenle bu çalışmada matsezigisel algoritmaların avantajı kullanarak ele alınan problemde işlerin makinelerdeki alt parti büyüklükleri bir doğrusal model ($Model_{APB}$) ile belirlenmektedir. Ayrıca bu model ile çözümün amaç fonksiyonu değeri de hesaplanmaktadır. Önerilen $Model_{APB}$, $Model_{TS}$ temel alınarak geliştirilmiştir. $Model_{TS}$ 'deki x_{ijkl} karar değişkeni, $Model_{APB}$ 'de parametredir. x_{ijrq} değerleri çözüm gösteriminden belirlenir. Çözüm gösteriminin ilk iki satırından i . işin j . operasyonunun r . makinede q . sırada işlem gördüğü bilgisi elde edilir ve üçüncü satırdan da o makineye atanıp atanmadığı belirlenir. Yani satırdaki ilgili hücrenin değeri sıfırdan büyük ise x_{ijrq} 1 değerini almaktadır. Sıfır olduğunda ise x_{ijrq} 0 değerini almaktadır.

$Model_{APB}$ 'nin amaç fonksiyonu ve kısıtları aşağıda verilmiştir.

$Model_{APB}$

amaç fonksiyonu:

$$enk f = C_{enb}$$

kısıtlar:

Eş. (2-4)

Eş. (10-17)

Eş. (19)

3.4. Kontrol işlemi

Ele alınan problemde işlerin kaç alt partiye bölüneceğine algoritma ile alt parti büyüklüklerine ise $Model_{APB}$ ile karar verilmektedir. Modeldeki n parametresi işler bölünüyorsa alt parti büyüklüğünün olabilecek en küçük değeridir. Bu değer sıfır alınabileceği gibi farklı değerlerde alınabilmektedir. Gerçek hayat problemlerinde bir birim parti büyüklüğüne sahip işin farklı makinede işlem görmesi çokta mantıklı değildir. Bu nedenle gerçek hayat problemlerine uygun olması için e parametresinin değeri sıfır alınmamıştır. Ayrıca bu çalışmada bir iş en küçük parti büyüklüğü kadar bölünmüş ise bölünmediği durum da değerlendirilmiş ve hangi durumun amaç fonksiyonu değeri daha başarılı ise o durum dikkate alınmıştır.

Kontrol işleminin adımları aşağıda verilmiştir.

Adım 1: Eldeki çözümün α_{ijr} değerlerini kaydet.

Adım 2: Eğer $\alpha_{ijr} = e$ ise $\sum_q x_{ijrq} = 0$ olarak güncelle.

Adım 3: $Model_{APB}$ çöz.

Adım 4: Eldeki çözümden daha iyi bir çözüm bulduysa eldeki çözümü güncelle.

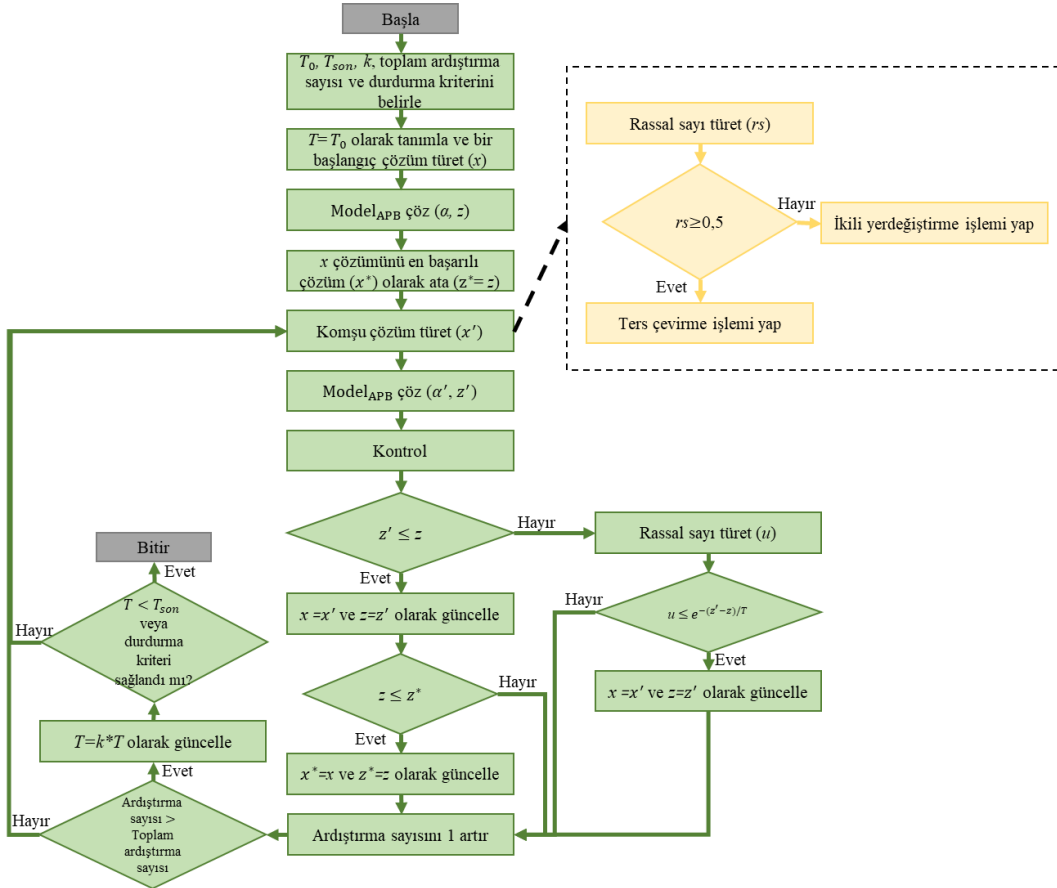
Adım 5: Her α_{ijr} için *Adım 2*, *Adım 3* ve *Adım 4*'ü tekrarla.

3.5. Matsezigisel tavlama benzetimi

Tavlama Benzetimi (TB), ilk kez Kirkpatrick vd. tarafından 1983 yılında tanıtılmıştır [16]. Bu algoritmada katıların fiziksel tavlama süreçlerinden ilham alınmıştır. Bu nedenle doğal süreçlerden ilham alınan ilk algoritmadır. TB, birçok problem türünde uygulanabildiği için yaygın olarak kullanılmaktadır. Yerel en iyiden

kaçmak için kötü çözümlerin kabul etmesi ve yakınsama özelliği ile kısa sürede büyük boyutlu problemlere çözüm bulabilmektedir. Bir başlangıç sıcaklığı ile başlanır ve her adımda belli bir oranda bu sıcaklık düşürülür. Sıcaklık değeri yüksek iken yeni çözümlerin çoğu kabul edilirken sıcaklık düştükçe yeni çözümlerin kabulü azalarak yakınsama sağlanır. TB'nin parametreleri, başlangıç sıcaklığı (T_0), son sıcaklık değeri (T_{son}), sıcaklığı azaltma oranı (k), her sıcaklıktaki artırma sayısı ve durdurma kriteridir.

Bu çalışmada, önerilen $Model_{APB}$ 'i TB algoritmasına entegre edilmiştir. Böylelikle $Model_{TS}$ 'nin belirlenen süre limitleri içerisinde çözüm bulamadığı büyük boyutlu problemler için çözüm bulunmuştur. Ayrıca işlerin makinelerdeki alt parti büyüklükleri model tarafından belirlendiği için başarılı çözümler elde edilmiştir. Önerilen matsezigisel tavlama benzetimi (MTB) algoritmasının adımları akış şeması ile gösterilmiştir. Akış şeması Şekil 2'de verilmiştir. Akış şemasındaki z , amaç fonksiyonun değeri ve α ise işlerin operasyonlarının alt parti büyüklüklerini ifade etmektedir.



Şekil 2. Önerilen matsezigisel tavlama benzetimi algoritmasının akış şeması.

Bu algorithmada komşu çözüm üretmek için çözüm gösterimindeki iş satırı için ikili yer deđiştirme veya ters çevirme operatörleri kullanılmıştır. Şekil 3 ve 4'de operatörlerin uygulaması verilmiştir.

| | | | | | | | | | | |
|----|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | O_{31} | O_{21} | O_{11} | O_{21} | O_{12} | O_{22} | O_{22} | O_{12} | O_{32} | O_{32} |
| İş | 3 | 2 | 1 | 2 | 1 | 2 | 2 | 1 | 3 | 3 |

| | | | | | | | | | | |
|----|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | O_{31} | O_{32} | O_{11} | O_{21} | O_{12} | O_{21} | O_{22} | O_{12} | O_{22} | O_{32} |
| İş | 3 | 3 | 1 | 2 | 1 | 2 | 2 | 1 | 2 | 3 |

Şekil 3. İkili yerdeğiştirme operatörü.

| | | | | | | | | | | |
|----|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | O_{31} | O_{21} | O_{11} | O_{21} | O_{12} | O_{22} | O_{22} | O_{12} | O_{32} | O_{32} |
| İş | 3 | 2 | 1 | 2 | 1 | 2 | 2 | 1 | 3 | 3 |

| | | | | | | | | | | |
|----|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| | O_{31} | O_{21} | O_{11} | O_{32} | O_{12} | O_{21} | O_{22} | O_{12} | O_{22} | O_{32} |
| İş | 3 | 2 | 1 | 3 | 1 | 2 | 2 | 1 | 2 | 3 |

Şekil 4. Ters çevirme operatörü.

Görüldüğü gibi, Şekil 3'te gösterilen ikili yer değiştirme operatörü için rastgele iki konum seçilir ve bu konumlardaki değerler birbirleriyle değiştirilir. Ters çevirme operatörü için rastgele iki konum seçilir ve bu iki konum arasındaki hücrelerdeki değerler ters çevrilir. Çözüm gösteriminin makine satırı yani ikinci satır ilk satırdaki değişiklikten dolayı tekrar düzenlenir. Üçüncü satır için rastgele $[1, PMO/3]$ aralığından bir sayı seçilir. PMO , tüm işlerin paralel makinelerde işlem görebilen operasyonlarının toplamıdır. Bu sayı kadar paralel makinelerde işlenebilen işlerin operasyonları seçilir ve her operasyonun işlenebileceği tüm makineler için rassal sayı türetilir. Rassal sayı 0,5'ten büyük ise 1, küçük ise 0 değeri atanır. Diğer işlerin operasyonlarının değerlerinde herhangi bir değişiklik yapılmaz.

3.6. Matsezigisel değişken komşuluk arama

Değişken komşuluk arama algoritması ilk kez Mladenovic ve Hansen [17] tarafından 1997'de geliştirilmiştir. Tavlama benzetimi gibi tek çözüm tabanlı bir algoritmadır. Diğer sezgisel algoritmalara kıyasla bu algoritma, basit yapısı, farklı çözüm teknikleriyle entegre edilebilmesi ve çok az parametre gerektirmesi nedeniyle diğer algoritmalara göre önemli avantajlar sunmaktadır [18]. Tek bir komşuluk yapısı yerine birden fazla komşuluk yapısı kullanılmaktadır. Bu çalışmada, değişken komşuluk arama algoritmasına da önerilen $Model_{APB}$ entegre edilerek matsezigisel değişken komşuluk arama (MDKA) algoritması önerilmiştir. 5 farklı komşuluk yapısı kullanılmıştır. Bu yapılar aşağıda verilmiştir.

Komşuluk 1 (İkili Yer Değiştirme Operatörü): Çözüm gösterimindeki alt parti sayılarını değiştirmeden işlerin sıralarının değiştirilmesi sağlanmaktadır.

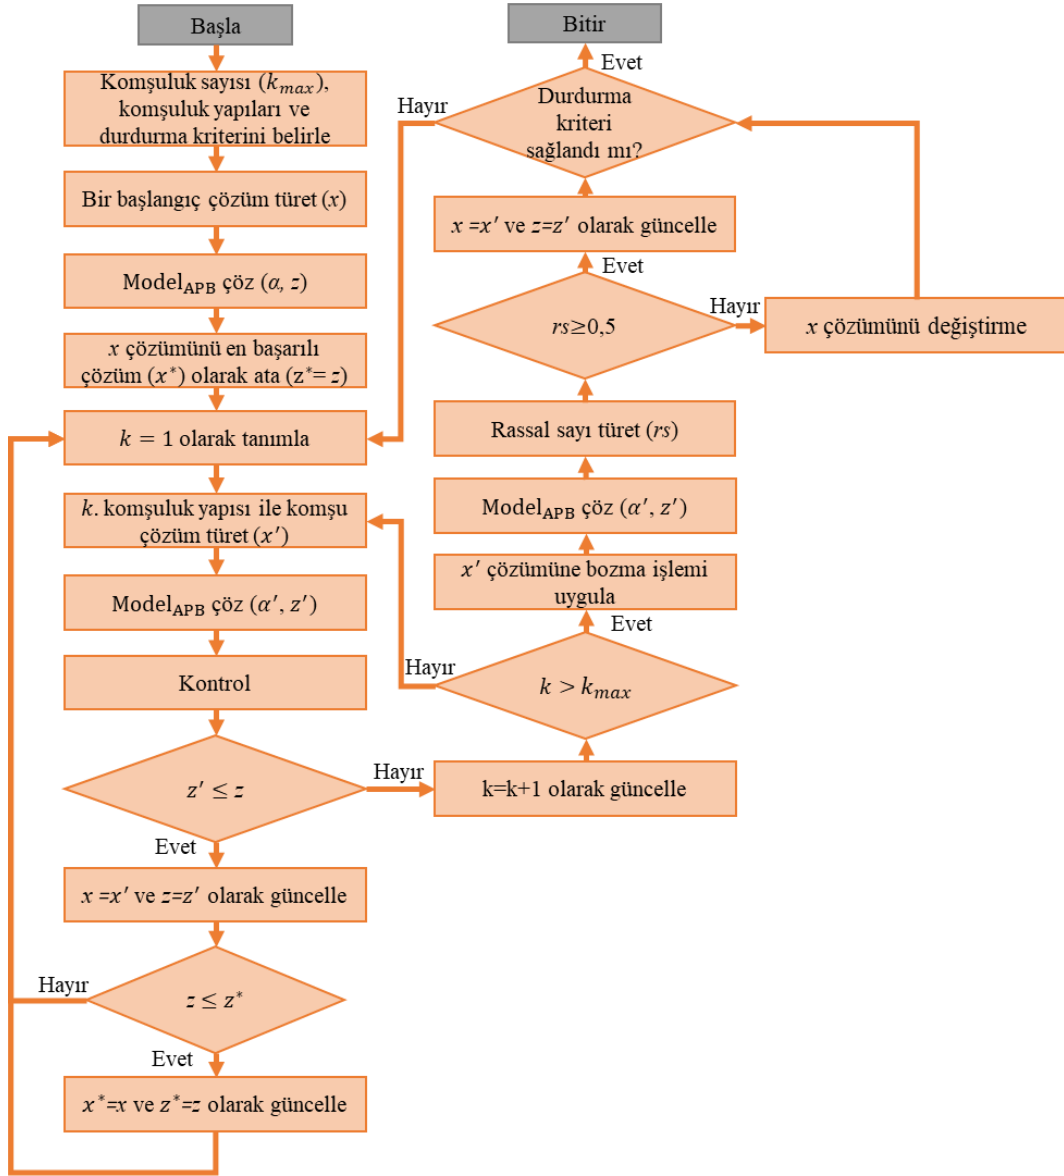
Komşuluk 2 (Ters Çevirme Operatörü): Komşuluk 1'deki gibi çözüm gösterimindeki alt parti sayılarını değiştirmeden işlerin sıralarının değiştirilmesi sağlanmaktadır. Fakat komşuluk 1'e göre bu komşuluk yapısı daha büyük değişikliklere neden olmaktadır.

Komşuluk 3 (Alt Parti Sayısının Değiştirilmesi): Rastgele $[1, PMO/3]$ aralığından bir sayı seçilir. Bu sayı kadar paralel makinelerde işlenebilen işlerin operasyonları seçilir ve her operasyonun işlenebileceği tüm makineler için rassal sayı türetilir. Rassal sayı 0,5'ten büyük ise 1, küçük ise 0 değeri atanır.

Komşuluk 4 (İkili Yer Değiştirme Operatörü + Alt Parti Sayısının Değiştirilmesi): Hem Komşuluk 1 hem de Komşuluk 3 yapısındaki değişiklikler birlikte yapılmaktadır.

Komşuluk 5 (Ters Çevirme Operatörü + Alt Parti Sayısının Değiştirilmesi): Hem Komşuluk 2 hem de Komşuluk 3 yapısındaki değişiklikler birlikte yapılmaktadır.

Önerilen MDKA'nın adımları akış şeması ile gösterilmiştir. Akış şeması Şekil 5'de verilmiştir.




Şekil 5. Önerilen değişken komşuluk arama algoritmasının akış şeması.

Şekil 5'ten de görülebileceği gibi, değişken komşuluk arama algoritmasında komşu çözüme bozma işlemi uygulanmaktadır. Bu işlem, yerel eniyiye takılmamak ve aramayı etkili bir şekilde çeşitlendirmek için gerçekleştirilmektedir. Bu çalışmada bozma işlemi için aşağıdaki adımlar uygulanmaktadır.

Adım 1: Bozma işlemi uygulanacak komşu çözümün ilk satırından rastgele bir konum seçilir. Bu konumdan sonraki işler karıştırılır. Şekil 6'da bu işlemin nasıl gerçekleştirildiği gösterilmiştir.

Adım 2: İkinci satıra tekrar makine atamaları yapılır.

Adım 3: Çözümün bozulmadığı durumdaki işlerin operasyonlarının alt parti sayıları ve büyüklüklerine göre üçüncü satır düzenlenir.



Şekil 6. Çözümün ilk satırını bozma işlemi.

4. Sayısal Sonuçlar

Bu bölümde, önerilen MTB ve MDKA algoritmalarını karşılaştırabilmek için farklı boyutta test problemleri türetilmiştir. Türetilen test problemler önerilen algoritmalar ile Python 3.9.7 ve Gurobi 9.5.0 kullanılarak çözülmüştür. Ayrıca algoritmaların performansını değerlendirebilmek içinde türetilen test problemleri literatürdeki $Model_{TS}$ ile de GAMS 23.7'nin CPLEX çözücüsü kullanılarak çözülmüştür. Tüm test problemleri, 2.40 GHz Intel Core i5 ve 8 GB RAM'e sahip bir bilgisayarda çözülmüştür.

4.1. Test problemlerinin türetilmesi

Önerilen MTB ve MDKA algoritmalarının performansı, rastgele oluşturulmuş küçük, orta ve büyük boyutta problemler çözdürülerek test edilmiştir. Problemlerin özellikleri Tutumlu ve Saraç [15]'in çalışmasındaki gibi ele alınmıştır. Küçük, orta ve büyük boyutlu problemlerin özellikleri; iş sayısı 4, 6 ve 10, işlerin operasyon sayısı 3, 4 ve 5 ve makine sayısı 5, 8 ve 11'dir. Operasyonların gerçekleştirebileceği alternatif makine sayısı küçük boyutlu problemde 2 iken diğer boyuttaki problemlerde 3'tür. Ayrıca test problemlerinin t_{ijr} $[1/g_i, 99/g_i]$ ve s_{ijr} $[1,30]$ aralığında düzgün dağılıma uygun türetilmiştir. e ve g_i sırasıyla 10 ve 100 olarak tanımlanmıştır.

4.2. Önerilen algoritmaların parametreleri

Algoritmaların uygulanabilmesi için bazı parametre değerlerinin belirlenmesi gerekmektedir. MTB için başlangıç sıcaklığı (T_0), son sıcaklık değeri (T_{son}), sıcaklığı azaltma oranı (k), her sıcaklıktaki artırma sayısı ve durdurma kriterine karar verilmesi gerekmektedir. MDKA algoritması için ise komşuluk sayısı ve durdurma kriterine karar verilmesi gerekmektedir. İki algoritmada da durdurma kriteri olarak iterasyon sayısı uygulanmıştır. Tablo 1'de önerilen algoritmaların parametre değerleri verilmiştir.

Tablo 1. Önerilen algoritmaların parametre değerleri.

| MTB | | MDKA | |
|-----------|--------|------------------|--------|
| Parametre | Değeri | Parametre | Değeri |
| T_0 | 100 | Komşuluk sayısı | 5 |
| T_{son} | 10 | İterasyon sayısı | 10000 |

| | |
|-------------------|------|
| k | 0,90 |
| Ardıştırma sayısı | 5 |
| İterasyon sayısı | 500 |

Tablo 1'den de görülebileceği gibi MTB'de birden fazla parametre değerine karar verilmesi gerekirken, MDKA'da ise daha az sayıda parametre değerine karar verilmesi gerekmektedir. MDKA, sezgisel yöntemler arasında en az parametreye sahip algoritmalarından biridir. İki algoritmanın birbiri ile kıyaslanabilmesi için araştırdıkları çözüm sayılarının dengeli olması gerekir. Parametre değerleri belirlenirken bu durum dikkate alınmıştır. İki algortmada da yaklaşık 50000 tane komşu çözüm araştırılmaktadır.

4.3. Oyuncak problem

İş sayısının 4, işlerin operasyon sayısının 2, makine sayısının 3 ve operasyonların gerçekleştirebileceği alternatif makine sayısının 2 olduğu bir oyuncak problem türetilmiştir. Problemden işlerin operasyonlarının gerçekleştirilebileceği makinelerdeki ($u_{ijr}=1$) t_{ijr} ve s_{ijr} süreleri Tablo 2'de verilmiştir.

Tablo 2. Toy problemin t_{ijr} ve s_{ijr} parametre değerleri.


| i | j | r | t_{ijr} | s_{ijr} |
|-----|-----|-----|-----------|-----------|
| 1 | 1 | 1 | 0,13 | 19 |
| 1 | 1 | 3 | 0,17 | 15 |
| 1 | 2 | 3 | 0,38 | 14 |
| 2 | 1 | 2 | 0,09 | 10 |
| 2 | 1 | 3 | 0,20 | 18 |
| 2 | 2 | 1 | 0,11 | 14 |
| 2 | 2 | 2 | 0,15 | 17 |
| 3 | 1 | 2 | 0,12 | 15 |
| 3 | 1 | 3 | 0,85 | 28 |
| 3 | 2 | 1 | 0,47 | 17 |
| 4 | 1 | 1 | 0,13 | 14 |
| 4 | 1 | 3 | 0,32 | 28 |
| 4 | 2 | 2 | 0,39 | 7 |
| 4 | 2 | 3 | 0,45 | 24 |

Oyuncak problem $Model_{TS}$, MTB ve MDKA ile çözümlenerek Tablo 3'de sunulan C_{enb} ve çözüm süreleri elde edilmiştir.

Tablo 3. C_{enb} değerleri ve çözüm süreleri.

| Yöntem | C_{enb} | Süre (sn.) |
|--------------|-----------|------------|
| $Model_{TS}$ | 111,31 | 13,23 |
| MTB | 111,31 | 29,83 |
| MDKA | 111,31 | 75,23 |

Tablo 3'ten de görülebileceği gibi oyuncak problemin en iyi amaç fonksiyonu değeri olan 111,31 hem MTB hem de MDKA ile bulunmuştur. Böylelikle iki algoritmanın da eniyi çözüme ulaşabildiği gösterilmiştir. Şekil 7'de oyuncak problemin Gantt Şeması verilmiştir.



Şekil 7. Oyuncak problemin Gantt Şeması.

Şekil 7 incelendiğinde hem O_{21} hem de O_{22} operasyonları iki alt partiye bölünmüştür. O_{21} operasyonu makine 2'de 54 br. ve makine 3'te 46 br. ve O_{22} operasyonu da makine 1'de 57 br. ve makine 2'de 43 br. işlenmektedir. Ayrıca işlerin alt partilere bölünmesinin makine kullanımlarını da dengelediği görülmektedir.

4.4. Test sonuçları

Rastgele türetilen test problemleri literatürden alınan [15] matematiksel model ($Model_{TS}$) ve melez genetik algoritma (MGA_{TS}) ve önerilen MTB ve MDKA algoritmaları ile çözülmüştür. Çözüm süreleri 7200 saniye ile sınırlıdır. Farklı boyuttaki test problemleri için elde edilen sonuçlar ve çözüm süreleri Tablo 4'de verilmiştir. Tablo 4'de verilen MTB ve MDKA için C_{enb} değerleri 5 kez çalıştırma sonucunda elde edilen en başarılı sonuçlardır.

Tablo 4. Elde edilen sonuçlar ve çözüm süreleri.

| Test Problemleri | $Model_{TS}$ | | MGA_{TS} | | MTB | | MDKA | |
|------------------|--------------|------------|------------|------------|-----------|------------|-----------|------------|
| | C_{enb} | Süre (sn.) | C_{enb} | Süre (sn.) | C_{enb} | Süre (sn.) | C_{enb} | Süre (sn.) |
| Küçük | 195,78 | 483,13 | 195,78 | 234,97 | 195,78 | 311,12 | 195,78 | 413,62 |
| Orta | 515,2 | 7200 | 285 | 520,93 | 283 | 1635,51 | 284,96 | 3015,92 |
| Büyük | - | - | 481,04 | 1486,71 | 461,72 | 1718,63 | 473 | 5307,41 |

Tablo 4 incelendiğinde, literatürdeki $Model_{TS}$ ile küçük boyutlu problemde en iyi çözüm ve orta boyutlu problemde süre limiti içerisinde bir uygun çözüm elde edilmiştir. Fakat büyük boyutlu problemde süre limiti içerisinde bir çözüm elde edilememiştir. MGA_{TS} , MTB ve MDKA algoritmaları ile tüm boyutlardaki problemler için bir çözüm bulunmuştur. Hatta küçük boyutlu problemin en iyi çözümüne tüm algoritmalar ile kısa sürede ulaşılmıştır. Önerilen algoritmalar çözüm süreleri açısından karşılaştırıldığında küçük, orta ve büyük boyutlu problemlerde sırasıyla %24,78, %45,77 ve %67,62 oranında MTB, MDKA'dan daha kısa sürede çözüm bulmuştur.

Literatürden alınan ve önerilen çözüm yöntemlerinin başarısı kıyaslanarak iyileştirme yüzdeleri Tablo 5'te verilmiştir. İyileştirme yüzdeleri Denklem (20)'de verilen formül ile hesaplanmıştır. Burada iyileştirme yüzdesi, kıyaslama yapılan ikinci yöntemin amaç fonksiyonunun (z_2) ilk yöntemine (z_1) kıyasla yüzdesel olarak ne kadar başarılı olduğu anlamına gelmektedir.

$$\text{İyileştirme (\%)} = \frac{(z_1 - z_2)}{z_1} 100 \quad (20)$$

Tablo 5. İyileştirme yüzdeleri.

| Test Problemleri | İyileştirme (%) | | | | |
|------------------|------------------|-------------------|----------------|-----------------|------------|
| | $Model_{TS-MTB}$ | $Model_{TS-MDKA}$ | MGA_{TS-MTB} | $MGA_{TS-MDKA}$ | $MDKA-MTB$ |
| Küçük | 0 | 0 | 0 | 0 | 0 |
| Orta | 45,07 | 44,69 | 0,70 | 0,01 | 0,69 |
| Büyük | - | - | 4,02 | 1,67 | 2,38 |

Tablo 5'ten de görülebileceği gibi, küçük boyutlu problemin tüm yöntemler ile eniyi çözümüne ulaşılmıştır. Orta boyutlu test probleminde MTB ve MDKA sırasıyla $Model_{TS}$ 'den %45,07 ve %44,69 daha başarılı sonuç bulmuşlardır. MGA_{TS} 'nin amaç fonksiyonu değeri ise sırasıyla %0,7 ve %0,01 oranında iyileştirilmiştir. Orta boyutlu problemde MTB ve MDKA çok yakın sonuçlar elde etmişlerdir. Büyük boyutlu problemde MTB ve MDKA algoritmaları ile sırasıyla MGA_{TS} 'den %4,02 ve %1,67 daha başarılı amaç fonksiyonu değeri elde edilmiştir. Ayrıca MTB, MDKA'ya göre %2,38 daha başarılı çözüm bulmuştur.

Kısaca özetlersek, MTB ve MDKA'nın küçük boyutlu problemde $Model_{TS}$ ile aynı sonucu yani en iyi çözümü bulduğu gösterilmiştir. Önerilen iki algoritma kıyaslandığında ise MTB, MDKA'dan daha kısa süre de daha başarılı çözümler bulmuştur.

5. Sonuçlar ve Öneriler

Bu çalışmada, işlerin bölünebildiği esnek atölye çizelgeleme problemi ele alınmıştır. Bu problemde işlerin kaç alt partiye bölüneceği ve alt parti büyüklüklerinin ne olacağını belirlemek kolay değildir. Bu nedenle genellikle literatürdeki çalışmalarda alt parti büyüklükleri bir sayının katı olarak ele alınmaktadır veya alt ve üst sınırlar ile sınırlandırılmaktadır. Tutumlu ve Saraç [15] hiçbir sınırlandırma olmadan ele alınan problem için bir matematiksel model ve melez bir GA önermişlerdir. Önerilen sezgisel yöntemde alt parti büyüklüklerinin ne olacağını belirlerken mevcut çözümdeki alt parti büyüklükleri artırılarak veya azaltılarak belirlenmektedir. Bu işlem ile geniş arama uzayında kısa sürelerde başarılı çözümler bulmak zor olabilir. Oysaki son yıllarda hem matematiksel modellerin hem de sezgisel yöntemlerin birlikte kullanıldığı matsezgisel algoritmaların kullanımı artmıştır. Matsezgisel algoritmalar sayesinde alt parti büyüklükleri matematiksel model ile belirlenebilmektedir. Böylelikle sezgisel algoritmanın türettiği komşu çözümlerin en iyi alt parti büyüklükleri bulunmaktadır. Bu çalışmada ele alınan problem için hem MTB hem de MDKA algoritmaları önerilmiştir, her iki algortmada da literatürden farklı olarak işlerin alt parti büyüklükleri, matematiksel model ile bulunarak hem alt problemin eniyi çözümü hem de sezgisel algoritmanın arama yapacağı çözüm uzayı daraltılmıştır. Algoritmaların performansı farklı boyutlarda rastgele türetilen test problemleri ve literatürden alınan matematiksel model kullanılarak gösterilmiştir. Ayrıca önerilen algoritmalarla elde edilen sonuçlar kıyaslanmıştır. Elde edilen sonuçlara göre MTB, MDKA'ya göre kısa sürelerde daha başarılı çözümler elde etmektedir.

Gelecek çalışmalarda, problem çok amaçlı olarak ele alınıp, çok amaçlı matsezgisel yöntemler geliştirilebilir.

Teşekkür

Teşekkür edeceğimiz herhangi bir kişi veya kuruluş bulunmamaktadır.

Kaynaklar

- [1] J. W. Stevenson, *Production/Operations Management*, Irwin, 1996.
- [2] H. Liu, A. Abraham ve Z. Wang, "A multi-swarm approach to multi-objective flexible job-shop scheduling problems", *Fundamenta Informaticae*, cilt 95, sayı 4, s. 465-489, 2009, doi: 10.3233/FI-2009-160.
- [3] H. P. Zhang, J. H. Ye, X. P. Yang, N. W. Muruve ve J. T. Wang, "Modified binary particle swarm optimization algorithm in lot-splitting scheduling involving multiple techniques", *International Journal of Simulation Modelling*, cilt 17, sayı 3, s. 534-542, Eylül 2018, doi: 10.2507/IJSIMM17(3)CO13.
- [4] D. Lei ve X. Guo, "Scheduling job shop with lot streaming and transportation through a modified artificial bee colony", *International Journal of Production Research*, cilt 51, sayı 16, s. 4930-4941, Ağustos 2013, doi: 10.1080/00207543.2013.784404.
- [5] C. H. Liu, L. S. Chen ve P. S. Lin, "Lot streaming multiple jobs with values exponentially deteriorating over time in a job-shop environment", *International Journal of Production Research*, cilt 51, sayı 1, s. 202-214, 2013, doi: 10.1080/00207543.2012.657255.
- [6] X. L. Xu, L. Li, L. X. Fan, J. Zhang, X. H. Yang ve W. L. Wang, "Hybrid discrete differential evolution algorithm for lot splitting with capacity constraints in flexible job scheduling", *Mathematical Problems in Engineering*, 2013, doi: 10.1155/2013/986218.
- [7] F. Defersha ve M. Chen, "Jobshop lot streaming with routing flexibility, sequence-dependent setups, machine release dates and lag time", *International Journal of Production Research*, cilt 50, sayı 8, s. 2331-2352, 2012, doi: 10.1080/00207543.2011.574952.
- [8] D. Rooyani ve F. Defersha, "A two-stage multi-objective genetic algorithm for a flexible job shop scheduling problem with lot streaming", *Algorithms*, cilt 15, sayı 7, Temmuz 2022, doi: 10.3390/a15070246.
- [9] F. Daneshamooz, P. Fattahi ve S. M. H. Hosseini, "Scheduling in a flexible job shop followed by some parallel assembly stations considering lot streaming", *Engineering Optimization*, cilt 54, sayı 4, s. 614-633, Nisan 2022, doi: 10.1080/0305215X.2021.1887168.
- [10] F. Abderrabi vd., "Flexible job shop scheduling problem with sequence dependent setup time and job splitting: Hospital catering case study", *Applied Sciences-Basel*, cilt 11, sayı 4, Şubat 2021, doi: 10.3390/app11041504.
- [11] J. M. Novas, "Production scheduling and lot streaming at flexible job-shops environments using constraint programming", *Computers & Industrial Engineering*, cilt 136, s. 252-264, Ekim 2019, doi: 10.1016/j.cie.2019.07.011.
- [12] A. Bozek ve F. Werner, "Flexible job shop scheduling with lot streaming and subplot size optimisation", *International Journal of Production Research*, cilt 56, sayı 19, s. 6391-6411, Ekim 2017, doi: 10.1080/00207543.2017.1346322.
- [13] J. X. Fan, C. J. Zhang, W. M. Shen ve L. Gao, "A matheuristic for flexible job shop scheduling problem with lot-streaming and machine reconfigurations", *International Journal Of Production Research*, cilt 61, sayı 19, s. 6565-6588, Ekim 2022, doi: 10.1080/00207543.2022.2135629.
- [14] Y. B. Li, Z. P. Yang, L. Wang, H. T. Tang, L. B. Sun ve S. S. Guo, "A hybrid imperialist competitive algorithm for energy-efficient flexible job shop scheduling problem with variable-size sublots", *Computers & Industrial Engineering*, cilt 172, Ekim 2022, doi: 10.1016/j.cie.2022.108641.
- [15] B. Tutumlu ve T. Saraç, "A MIP model and a hybrid genetic algorithm for flexible job-shop scheduling problem with job-splitting", *Computers and Operations Research*, cilt 155, Temmuz 2023, doi: 10.1016/j.cor.2023.106222.
- [16] W. H. T. Meira vd., "Scheduling of a single-source multiproduct pipeline system by a matheuristic approach: Combining simulated annealing and MILP", *Computers & Chemical Engineering*, cilt 136, Mayıs 2020, doi: 10.1016/j.compchemeng.2020.106784.
- [17] N. Mladenovic ve P. Hansen, "Variable neighborhood search", *Pergamon*, cilt 24, sayı 11, s. 1097-1100, Kasım 1997, doi: 10.1016/S0305-0548(97)00031-2.
- [18] P. Hansen ve N. Mladenovic, "J-Means: a new local search heuristic for minimum sum of squares clustering", *Pattern Recognition*, cilt 34, sayı 2, s. 405-413, Şubat 2001, doi: 10.1016/S0031-3203(99)00216-2.