

# FEN BİLİMLERİ VE MATEMATİK

Alanında Uluslararası Çalışmalar

Mart 2025

## EDİTÖRLER

PROF. DR. HASAN HÜSEYİN DOĞAN  
PROF. DR. ALPARSLAN DAYANGAÇ

 SERÜVEN  
YAYINEVİ

**Genel Yayın Yönetmeni / Editor in Chief • Eda Altunel**

**Kapak & İç Tasarım / Cover & Interior Design • Serüven Yayınevi**

**Birinci Basım / First Edition • © Mart 2025**

**ISBN • 978-625-5552-75-4**

**© copyright**

Bu kitabın yayın hakkı Serüven Yayınevi'ne aittir.

Kaynak gösterilmeden alıntı yapılamaz, izin almadan hiçbir yolla çoğaltılamaz. The right to publish this book belongs to Serüven Publishing. Citation can not be shown without the source, reproduced in any way without permission.

**Serüven Yayınevi / Serüven Publishing**

**Türkiye Adres / Turkey Address:** Kızılay Mah. Fevzi Çakmak 1. Sokak

Ümit Apt No: 22/A Çankaya/ANKARA

**Telefon / Phone:** 05437675765

**web:** www.seruvenyayinevi.com

**e-mail:** seruvenyayinevi@gmail.com

**Baskı & Cilt / Printing & Volume**

Sertifika / Certificate No: 42488

FEN BİLİMLERİ  
*ve*  
MATEMATİK

ALANINDA ULUSLARARASI ÇALIŞMALAR

**EDİTÖR**

**PROF. DR. HASAN HÜSEYİN DOĞAN**  
**PROF. DR. ALPARSLAN DAYANGAÇ**



## İÇİNDEKİLER

### Bölüm 1

#### MAKİNE ÖĞRENME ALGORİTMALARINA GENEL BAKIŞ

*Bahdiyar YAVUZ, Pelin KASAP—1*

### Bölüm 2

#### PARÇACIK FİZİĞİNE YÖN VEREN ALGIÇLAR

*Çağın KAMIŞCIOĞLU—19*

### Bölüm 3

#### BİYOKÜTLE KAYNAKLI AKTİF KARBONLAR: SENTEZ, AKTİVASYON VE UYGULAMALARI

*Hilal ÇELİK KAZICI—43*





## MAKİNE ÖĞRENME ALGORİTMALARINA GENEL BAKIŞ

*Bahdiyar YAVUZ<sup>1</sup>, Pelin KASAP<sup>2</sup>*

---

1 Yüksek Lisans Öğrencisi, Ondokuz Mayıs Üniversitesi, Fen Fakültesi, İstatistik Bölümü, Samsun, Türkiye, bahdiaryavuz147@gmail.com ORCID: 0009-0000-0095-6457

2 Prof. Dr., Ondokuz Mayıs Üniversitesi, Fen Fakültesi, İstatistik Bölümü, Samsun, Türkiye, ORCID:0000-0002-1106-710X

## GİRİŞ

Makine öğrenimi, 1959'da yapay zeka ile ortaya çıkan numerik öğrenme ve model tanıma çalışmalarıyla şekillenen bilgisayar bilimi alanıdır. Bu alan, verilerden yola çıkarak tahminler yapabilen algoritmalar geliştirmeye odaklanır. Geleneksel yöntemlerdeki sabit programlama kurallarına bağlı kalmak yerine, makine öğrenimi algoritmaları örnek verilerden öğrenerek modeller oluşturur ve bu modelleri kullanarak tahminlerde bulunur ya da kararlar alır (Zilyas ve Yılmaz, 2023).

Makine öğrenme yöntemleri, temel olarak denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme olmak üzere üç ana gruba ayrılır. Makine öğrenmesinin asıl amacı modellerden maksimum performansı elde etmektir. Denetimli öğrenme türünde girdiler ve çıktılar arasında eşleme yapan fonksiyon regresyon veya sınıflandırma yöntemleriyle oluşturulur. Eğitim verileri hem girdileri hem de çıktıları içerir. Denetimsiz öğrenme yönteminde bilinmeyen bir yapı tahmin edilir. Giriş verisinin sınıfı belirsizdir. Takviyeli öğrenme şekli girdilerin etrafıyla etkileşerek ödül denilen geri bildirimlerini en iyi duruma ulaştırıp en uygun sonucu elde etmeyi hedefler, böylece diğer makine öğrenim çeşitlerinden farklıdır (Arslankaya ve Toprak, 2021).

Makine Öğrenme yöntemlerinin uygulama adımları aşağıda verilmiştir:

*Veri Toplama:* Makine öğrenme süreçlerinin temelini veri oluşturur. Verilerin çeşitliliği ve miktarının artması, makine öğrenimi modellerinin daha tutarlı ve doğru sonuçlar üretmesine olanak tanır. Bununla birlikte, güvenilir ve doğru verilere dayanmak, elde edilen sonuçların doğruluğu açısından kritik bir öneme sahiptir.

*Verilerin Hazırlanması:* Analitik işlemlerin başarısı, kullanılan verilerin kalitesine doğrudan bağlıdır. Verilerin kalitesini değerlendirmek ve artırmak için eksik verilerin tamamlanması, aykırı değerlerin düzeltilmesi gibi işlemlerin gerçekleştirilmesi gerekir (Çolakoğlu, 2020). Normalizasyon, makine öğreniminde sıklıkla veri hazırlık sürecinin bir parçası olarak uygulanan bir yöntemdir. Bu işlem, veri kümesindeki sayısal sütunların değerlerini, aralıklardaki farklılıkları bozmadan belirli bir ölçüğe uyarlamayı amaçlar. Ancak, her veri kümesi için normalizasyon gerekli olmayabilir. Normalizasyon, genellikle veri boyutunu küçültmek, işlemleri belirli aralıklarla gerçekleştirmek ve daha anlamlı, yorumlanabilir sonuçlar elde etmek için tercih edilir (Gültepe, 2019).

*Bir Modelin Eğitimi:* Bu aşamada, uygun algoritma seçimi yapılır ve veriler model oluşturma sürecine hazırlanır. Temizlenen veriler, belirli



bir oran doğrultusunda eğitim ve test olmak üzere iki bölümdür. Eğitim kısmı, modelin geliştirilmesinde kullanılırken, test verileri modelin performansını değerlendirmek ve doğrulamak amacıyla referans olarak kullanılır.

*Model Değerlendirme:* Modelin doğruluğunu değerlendirmede, verilerin ikinci bölümü olan test verileri kullanılır. Bu adım, algoritma seçiminde daha kesin bir karar alınmasını sağlar. Modelin performansını daha iyi değerlendirebilmek için, test işlemi model oluşturma sürecinde hiç kullanılmamış veriler üzerinde gerçekleştirilir. Bu yaklaşım, modelin genelleme yeteneğini ve gerçek dünya verilerine uyumunu ölçmeyi amaçlar.

*Performans İyileştirme:* Elde edilen sonuçlar doğrultusunda, modelin verimliliğini iyileştirmek veya alternatif olacak model seçmek gerekebilir. Bu nedenle, özellikle veri toplama ve hazırlama süreçleri büyük önem taşır ve genellikle bu aşamalara ciddi bir zaman ayrılması gerekir. (Çolakoğlu, 2020).

## DENETİMLİ MAKİNE ÖĞRENME ALGORİTMALARI

### 1. Lojistik Regresyon

Lojistik regresyon analizi, veri setindeki gözlemleri belirli gruplara atamak için kullanılan yöntemlerden biridir. Bu yöntemle, mevcut verilere dayanarak bir sınıflandırma modeli oluşturulur ve bu model sayesinde yeni eklenen gözlemler uygun sınıflara atanabilir.

Lojistik regresyon, bağımlı değişkenin iki veya daha fazla kategoriye sahip olduğu durumlarda, bağımsız değişkenlerle arasındaki neden-sonuç ilişkisini analiz etmek için de tercih edilen bir yöntemdir. Lojistik regresyon finans ve ekonomi alanında sıkça kullanılan bir yöntemdir (Başer ve ark., 2021).

Lojistik regresyon yöntemi, bağımlı değişkenler ile bağımsız değişken arasındaki ilişkinin anlamlı olup olmadığını değerlendiren bir yöntemdir. Bu analizde, ilgilenilen değişkenin modele dahil edilmesi durumunda elde edilen tahmin değerleri gözlenen değerlerle karşılaştırılır. Eğer bu değişkenin eklenmesiyle daha doğru ve tutarlı tahminler yapılabiliyorsa, söz konusu değişkenin model için önemli olduğu sonucuna varılır. Araştırmacılar, bağımlı değişken üzerinde birden fazla etkenin etkisini ayrı ayrı incelemekle birlikte, bu etkenlerin bir arada bağımlı değişken üzerindeki toplam etkisini analiz etmek istediklerinde de lojistik regresyon yöntemine başvururlar (Başer ve ark., 2021).

## 2. Karar Ağaçları

Karar ağaçları yöntemi, çoğunlukla sınıflandırmada kullanılan yöntemlerden biridir. Veri madenciliğinde, hem sınıflandırma hem de regresyon analizlerinde karar ağaçları yaygın şekilde tercih edilir. Düşük maliyeti, kolay anlaşılabilir ve yorumlanabilir yapısı, yüksek güvenilirliği ve veri tabanlarıyla sorunsuz entegrasyonu, bu yöntemi en popüler sınıflandırma tekniklerinden biri haline getirmektedir (Yangın, 2019).

Karar ağaçları, denetimli öğrenme için kullanılan ve veri dağılımından bağımsız bir öğrenme yöntemi olarak bilinir. Yapısal olarak kök düğüm, dallar ve yapraklardan oluşur. Yapraklarda elde edilen sonuçlar, çıktı olarak adlandırılır; eğer problem bir sınıflandırma problemi ise sınıf etiketi, bir regresyon problemi ise sayısal bir değer olarak ifade edilir. Ayrıca, veri setinin karmaşıklığı, ağacın yapısını doğrudan etkiler; karmaşık veri setlerinde karar ağacı daha fazla dallanarak büyüyebilir (Başer ve ark., 2021).

Karar ağacını meydana getirebilmek için eğitim kümesinde örnekleri en iyi şekilde açıklayan değişken bulunur. Seçilen dalın üzerindeki örneklerden yeni bir değişken bulunur ve yeni dallar meydana çıkar. Örnekleri ayırt edecek başka bir ayırtaç kalmadığında yeni dallanma bitmiş olur. Ayırt edici olacak, ağaç kökü hesaplamasıyla elde edilir. Değişkenlerden hangi nitelik en fazla dala sahip ise değişken kök olarak nitelik belirlenir (Akbulut, 2022).


## 3. Yapay Sinir Ağları Algoritması

Yapay Sinir Ağları algoritması, tıpkı insan beynindeki sinir hücrelerinin çalışma prensibine göre hareket eder ve bu konuyu anlamaya yönelik araştırmalardan doğmuştur. Buradan elde edilen bilgiler, bilgisayar sistemlerine aktarılarak ilk yapay sinir ağlarının geliştirilmesi sağlanmıştır. Yapay sinir ağları, keşfedildiği zamandan bu yana sürekli olarak gelişmiş ve bilinen bilgisayar algoritmalarından ayrı bir yapıya kavuşmuştur.

Genellikle yapay sinir ağları, ağırlıklı bağlantılarla bir araya gelen ve hepsi kendi hafızasına sahip olan bileşenlerden bir araya gelen, paralel ve dağıtılmış bir bilgi işleme sistemi olarak tanımlanır. Bu özellikleri sayesinde, doğrusal olmayan birçok karmaşık probleme etkili çözümler sunar. Günümüzde yapay sinir ağları; endüstri, ulaştırma, havacılık, iletişim, tıp ve finans gibi birçok farklı alanda yaygın olarak kullanılmaktadır (Ustalı ve ark., 2021).


Yapay sinir ağları, bağlanma yönlerine ve ağırlıklarına göre ileri ve geri beslemeli olmak üzere ikiye ayrılır. İleri

beslemeli ağlarda, işlem elemanları genellikle katmanlar halinde düzenlenir ve sinyaller yalnızca giriş katmanından çıkış katmanına doğru tek yönlü olarak iletilir. Bu tür ağlarda, giriş katmanı dış ortamdan aldığı bilgileri değişiklik yapmadan gizli katmana aktarır. Gizli katman ve çıkış katmanlarında ise bilgi işlenerek nihai sonuç üretilir (Ataseven, 2013). Şekil 2’de ileri beslemeli ağın yapısı verilmiştir.



Şekil 2. İleri Beslemeli Yapay Sinir Ağı

Geri beslemeli ağ mimarileri, çoğunlukla denetimsiz öğrenme yöntemlerinin kullanıldığı ağlardır. Bu tür ağlarda, en az bir hücrenin çıkışı ya kendi girişine ya da diğer hücrelere geri besleme olarak iletilir; bu geri besleme genellikle bir geciktirme elemanı aracılığıyla gerçekleştirilir. Geri besleme, sadece bir katmandaki hücreler arasında değil, aynı zamanda katmanlar arasındaki hücreler arasında da olabilir. Bu özellik, geri beslemeli yapay sinir ağlarının doğrusal olmayan, dinamik bir davranış sergilemesini sağlar. Geri beslemeli ağlara örnek olarak, Hopfield, Elman ve Jordan ağları gösterilebilir (Ataseven, 2013). Aşağıda Şekil 3’de geri beslemeli yapay sinir ağı verilmiştir.



Şekil 3. Geri Beslemeli Sinir Ağı (Yavuz ve ark., 2012).


#### 4. Destek Vektör Makineleri Algoritması

Bu algoritma, istatistiki öğrenme çerçevesinde meydana gelen bir öğrenme yöntemidir. Bu yöntem, sınıflandırma işlemlerinde örnekler arasına bir sınır çizerek veriyi iki gruba ayırır. Bu sınır, her iki grubun üyelerinden en uzak noktayı belirleyecek şekilde konumlandırılır. Sınır çizgisi, iki grubun üyelerine paralel ve yakın olan iki çizginin birbirine yaklaştırılmasıyla elde edilir. Destek vektör makineleri, veriyi ayırmak için en uygun fonksiyonu tahmin etme prensibine dayanır (Karakoyun ve Hacıbeyoğlu, 2014).

Destek vektör makineleri, basit yapısı ve pratik uygulamalarda sağladığı yüksek performans ile oldukça kullanışlıdır. Bu yöntem için örnek sayısının çok olması önemli değildir. Eğitim aşamasında, daha önce görülmemiş verileri de doğru şekilde sınıflandırabilme yeteneği göstererek, genelleme yapabilme kabiliyeti sergiler. Bu genelleştirme yeteneği, destek vektör makinelerinin diğer teknikler karşısında güçlü bir alternatif olmasını sağlar. Destek vektör makineleri sınıflandırmanın yanı sıra regresyon problemleri için de kullanılır (Karakoyun ve Hacıbeyoğlu, 2014).

Destek vektörleri, hiperdüzleme en yakın olan veri noktalarıdır. Bu noktalar, ayırıcı çizgiyi ve marjinleri hesaplayarak sınıflandırma sürecini daha doğru bir şekilde gösterir. Hiperdüzlem, farklı sınıflara ait öğeleri ayıran karar düzlemidir (Ayhan ve Erdoğmuş, 2014).

Şekil 4’de düzlem üzerinde destek vektörleri verilmiştir.



Şekil 4. Destek Vektör makinesi

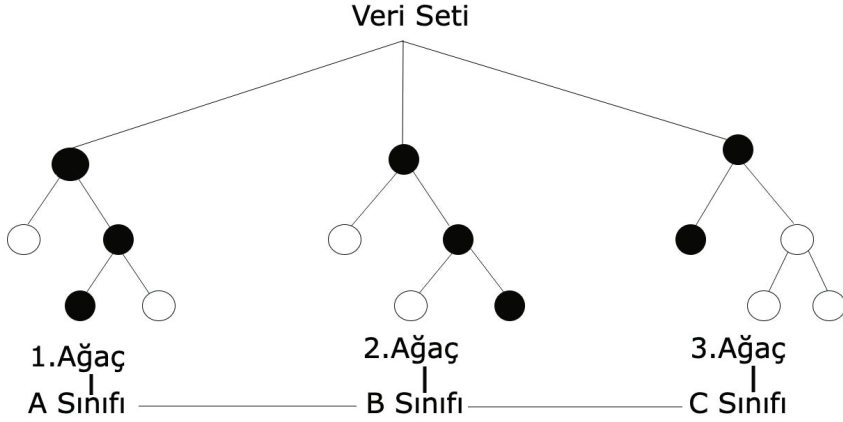
## 5. Rastgele Orman Algoritması

Bu algoritma, karar ağaçları ve düğümlerden oluşur. Kullanılan alanlar regresyon ve sınıflandırma analizleridir. Algoritmaya göre, her bir düğümdeki rastgele seçilen değerlerden en uygunu belirlenir ve oluşturulan karar ağaçlarına belirli ağırlıklar atanır. Bu ağırlıklar, her karar ağacının iç hatalarına göre belirlenir; en düşük hataya sahip olan ağaç en yüksek ağırlığı alırken, en yüksek hataya sahip olan ağaç en düşük ağırlığı alır. Bu ağırlıklar, sınıf tahminlerinde oy verme işlemi için kullanılır ve tüm oylar toplandıktan sonra nihai karar verilir (Ustalı ve ark., 2021).

Rastgele Orman algoritmasının en önemli avantajlarından biri, her öz niteliğin sınıf tahminindeki etkisini öğrenme yeteneğidir. Bu sayede, öz niteliklerin önem dereceleri ölçülerek, hangi öz niteliklerin sınıflandırma üzerinde daha etkili olduğu belirlenebilir. Ancak, yüksek boyutlu problemlerle karşılaşıldığında, öz nitelik sayısının çok fazla olması bu süreci zorlaştırabilir. Bu durum, öz niteliklerin önem puanlarını manuel olarak araştırmayı ve en uygun öz nitelikleri seçmeyi karmaşık hale getirir.

Bu nedenle, önem puanlarına dayalı otomatik öz nitelik seçim prosedürleri, ilgili ve ayırt edici öz nitelikleri daha verimli bir şekilde seçmeyi sağlar. Rastgele Orman, rastgele seçilen karar ağaçlarına dayanan bir topluluk öğrenme yöntemidir ve her bir ağaç, orijinal eğitim verisinin rastgele bir örneğinden, veriyi değiştirecek şekilde oluşturulur (Bilen ve Özer, 2022).

Rastgele orman algoritmasının aşamaları ilk olarak bir veri kümesinden rastgele olarak örnekler seçilir. Sonrasında her örnek için bir karar ağacı oluşturulur ve her bir karar ağacından bir tahmin sonucu alınır. Tahmin edilen sonuca göre seçim yapılır. Sonuç olarak son tahmin en çok oy kullanılarak seçim yapılır ve karar verilir (Kazan ve Karakoca, 2019). Şekil 5'de rastgele orman yönteminin yapısı verilmiştir.



Şekil 5. Rastgele Orman Algoritması

## 6. Naive Bayes Yöntemi

Naive Bayes yöntemi, Bayes teoremi temel alınarak geliştirilen bir tahminsel sınıflandırma yöntemidir. Bu yöntem, mevcut sınıflara ait örnek veriler kullanarak, yeni bir verinin hangi sınıfa ait olma olasılığını hesaplamak için kullanılır (Karakoyun ve Hacıbeyoğlu, 2014).

Naive Bayes'in avantajları arasında uygulama kolaylığı ve genellikle iyi sonuçlar elde etmesi yer alırken, dezavantajı ise belirli bir özelliğin değerinin, sınıf değişkeni göz önüne alındığında, başka herhangi bir özelliğin değerinden bağımsız olduğu varsayımına dayanmasıdır. Bu algoritma, olayların birbirinden bağımsız olduğu varsayımını kabul eder ve olasılık değerlerini hesaplayarak çalışır (Başer ve ark., 2021).

Naive Bayes sınıflandırıcısında her bir örnek, eşit derecede önemlidir. Bir niteliğin değeri, diğer bir niteliğin değeri ile ilgili herhangi bir bilgi içermez. Örneğin, nitelikleri içeren ve  $m$  sınıftan birine ait olan bir veri seti üzerinde çalıştığımızda, yeni bir  $X$  örneğinin hangi sınıfa ait olduğunu belirlemek için aşağıdaki eşitlik kullanılır. Bu eşitlik, her sınıf için örneğin o sınıfa ait olma olasılığını hesaplar ve en yüksek olasılığa sahip sınıf, örneğin ait olduğu sınıf olarak kabul edilir (Karakoyun ve Hacıbeyoğlu, 2014).


$$P(S_i|X) = \frac{P(X|S_i) \cdot P(S_i)}{P(X)} \quad (1)$$

Burada  $P(S_i|X)$ ,  $X$  olayı gerçekleştiğinde  $S_i$  olayının gerçekleşme olasılığını;  $P(X|S_i)$ ,  $S_i$  olayı gerçekleştiğinde  $X$  olayının gerçekleşme olasılığını;  $P(S_i)$ ,  $S_i$  olayının önsel olasılığını ve  $P(X)$  ise  $X$  olayının önsel olasılığını gösterir.

## 7. K-En Yakın Komşu Algoritması

K-en yakın komşu yöntemi, temel örnek tabanlı öğrenme algoritmalarından biridir. Bu tür algoritmalarda, öğrenme süreci eğitim verileri üzerinde yapılır ve yeni bir örnek, eğitim verileriyle olan benzerliğine göre sınıflandırılır. KNN algoritmasında, her eğitim örneği  $n$  boyutlu sayısal özelliklerle temsil edilir. Eğitim verilerindeki her örnek,  $n$  boyutlu bir uzayda bir nokta olarak yer alır. Bilinmeyen bir örnek karşılaşıldığında, eğitim setindeki en yakın  $K$  komşu örnek belirlenir ve bu komşuların sınıf etiketlerinin çoğunluk oyu alınarak yeni örneğin sınıfı belirlenir (Taşcı ve Onan, 2016).

K-en yakın komşu yöntemi, sınıf etiketleri bilinen eğitim verilerini kullanarak örnekler arasındaki uzaklık ölçülerine dayanarak sınıflandırma yapan bir yöntemdir. Bu uzaklık ölçüsü Öklid uzaklığı yöntemi ile hesaplanır. Başka bir örneğin hangi sınıfa ait olduğunu bulabilmek için, bu örnek ile eğitim veri setindeki tüm noktalar arasındaki uzaklıklar hesaplanır ve bu uzaklıklar küçükten büyüğe sıralanır. Ardından, önceden belirlenen  $K$  komşu sayısı dikkate alınarak en yakın  $K$  noktası seçilir. Bu  $K$  komşunun sınıf etiketlerine dayanarak yeni örneğin sınıfı belirlenir. Genellikle, sınıf tahmini için çoğunluk oylaması ya da ağırlıklı oylama yöntemleri kullanılır. Çoğunluk oylaması yönteminde,  $K$  komşu arasında en fazla tekrarlanan sınıf, yeni örneğin sınıfı olarak atanır. Ağırlıklı seçim yönteminde ise, yeni örneğe daha yakın olan komşuların sınıflandırmaya daha fazla etkisi olması sağlanır, yani yakın komşuların oyu daha fazla dikkate alınır (Kemalbay ve Alkış, 2020). Şekil 6' da basit bir şekilde  $K$  en yakın komşu yöntemi verilmiştir.



Şekil 6. K- En Yakın Komşu Algoritması

## 8. Aşırı Gradyan Artırma (XGBboost)

Aşırı Gradyan Artırma yöntemi, genellikle karar ağaçlarından oluşan bir modeli birleştirerek son bir model oluşturmayı amaçlayan bir grup öğrenme algoritmasıdır. Sınır ağlarının ağırlıklarının optimum duruma getirmek için de kullanılabilir. Aşırı gradyan artırma yöntemi, gradyan yükseltmenin daha ayrıntılı bir versiyonudur ve en iyi modelin seçilmesinde daha hassas bir yaklaşım benimser. Bu algoritma, modelin maliyetini minimize eder, aşırı uyum (overfitting) riskini azaltır ve genel model performansını iyileştirir. Ayrıca, aşırı gradyan artırma yöntemi hızlı bir şekilde yorumlanabilir ve etkin bir şekilde çalışabilir. Veri madenciliği alanındaki başarısı düşünüldüğünde, aşırı gradyan artırma algoritması tavsiye edilen çözüm olarak tercih edilmektedir (Altan ve Demirci, 2022).

Aşırı gradyan artırma modeli geliştirilirken, verimli sonuçlar bulmanın önemli bir unsuru parametre ayarlarının doğru yapılmasıdır. Bu süreç, iki aşamadan oluşur: İlk olarak, aşırı gradyan artırmanın genel performansını değerlendirmek amacıyla temel bir model oluşturulur. Ardından, ikinci aşamada parametre ayarlamaları yapılarak daha gelişmiş bir model geliştirilir ve bu model, temel modelle karşılaştırılarak test edilir. Parametre ayarlama süreci, genel olarak Gradient Boosting Makinesi yaklaşımına benzer şekilde ilerler.

İlk adımda, eğitim sürecini hızlandırmak için yüksek bir öğrenme oranı kullanılır. Sonrasında, ağaca özgü parametreler ayarlanır. Son olarak, öğrenme oranı düşürülür ve model, en uygun sınıflandırıcı sayısına



ulaşana kadar eğitilir ve işlem tamamlanır (Yangın, 2019). Aşırı gradyan artırma yönteminin avantajları Şekil 7’de verilmiştir.



Şekil 7. Aşırı Gradyan Yöntemi (Yangın, 2019).

Aşırı gradyan artırma algoritması son yıllarda sağlık, biyoloji, finans ve çevre gibi birçok alanda yaygın olarak kullanılmaktadır. Literatürde yapılan bu tür çalışmalarda, Aşırı gradyan artırmanın performansı benzer yöntemlerle karşılaştırılarak değerlendirilmiştir. Örneğin, Ji ve arkadaşları (2019), gerçekleştirdikleri araştırmada, aşırı gradyan artırma metodunun sinerjik ve antagonistik ilaç kombinasyonlarını sınıflandırma potansiyelini incelemişlerdir. Çalışmalarında, model geliştirmek için kimyasal yapı bilgisi, insan fenotipik verileri, biyolojik yollar, protein hedefleri ve protein-protein etkileşimleri gibi beş farklı veri profili kullanılmıştır. Aşırı gradyan artırma modelinin performansı, özelliklerin önemi, performans ölçütleri ve fazla öğrenme derecesi gibi faktörlerle detaylı bir şekilde değerlendirilmiştir.

Ayrıca, bu model, rastgele orman, lojistik regresyon, Naive Bayes (NB) ve derin öğrenme algoritmalarıyla karşılaştırılmıştır. Sonuçlar, Aşırı gradyan artırma modelinin terapötik kategoriler arasında sıralama yaparak en yüksek doğruluk oranı olan %86'yı sağladığını göstermiştir (Yangın, 2019).

## DENETİMSİZ MAKİNE ÖĞRENME ALGORİTMALARI

### 1. K – Ortalamalar Algoritması

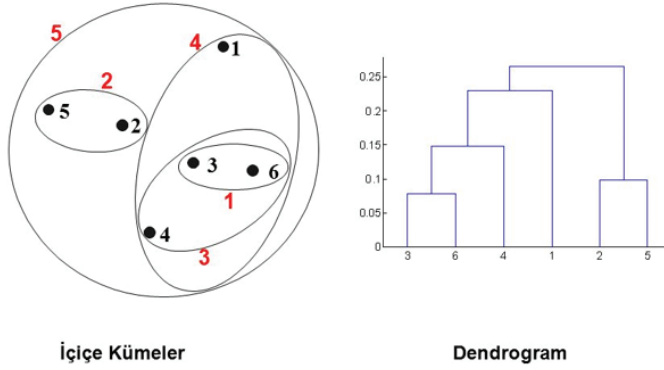
Denetimsiz öğrenme tekniklerinden en yaygınlarından biri olan K ortalamalar algoritması, her verinin yalnızca bir kümeyle ait olmasına izin vererek keskin bir kümeleme süreci gerçekleştirir.

Bu nedenle, K ortalamalar algoritması, sınıflandırma ve ayırım yapma konusunda net bir yaklaşım sergileyen bir algoritmadır. Temel olarak, algoritma,  $n$  adet veri noktasından oluşan bir veri kümesini, kullanıcı tarafından belirlenen K sayıda kümeyle ayırmayı amaçlar. Buradaki hedef, her bir küme içindeki benzerliği mümkün olduğunca artırırken, kümeler arasındaki benzerliği ise minimumda tutmaktır (Sarıman, 2011). K ortalamalar algoritmasında ilk olarak küme içerisinde rastgele K adet ağırlık merkezi oluşturulur. Sonra bu kümenin her bir elemanı, en yakın küme merkezine göre, ilgili kümeyle yerleştirilerek K tane küme oluşturulur. Bulunan her küme için kümelemenin yeni ağırlık merkezi hesaplanır. Bu kümeleme işlemlerini ağırlık merkezleri değişmeye kadar tekrarlanarak sonuca varılır.

### 2. Hiyerarşik Kümeleme Algoritması

Hiyerarşik kümeleme teknikleri, kümelerin başlangıçta bir ana küme olarak kabul edilip, sonra adım adım alt kümelere ayrılması veya ayrı kümelerin birleştirilerek tek bir küme oluşturulması prensibine dayanır. Bu yöntemler birleştirici hiyerarşik kümeleme ve ayrıştırıcı hiyerarşik kümeleme olmak üzere iki ana kategoriye ayrılır (Yeşilbudak ve ark, 2011).

Birleştirici hiyerarşik kümeleme yönteminde, başlangıçta her bir veri noktası bağımsız bir küme olarak kabul edilir ve ardından bu kümeler, çeşitli algoritmalarla birleştirilerek daha büyük kümeler oluşturulur. Diğer taraftan, ayrıştırıcı kümeleme yönteminde ise tüm veri noktaları başlangıçta tek bir küme kabul edilir ve bu küme, ayrıştırma algoritmaları kullanılarak alt kümelere bölünür (Uzun ve ark, 2016). Şekil 9' da hiyerarşik kümeleme algoritması iç içe kümeler ve dendrogram grafiği ile gösterilmiştir.



Şekil 9. Hiyerarşik Kümeleme Algoritması

### 3. Temel Bileşen Analizi Algoritması

Temel bileşen analizi (PCA), veri setini daha az sayıda değişkenle temsil ederek veriyi sadeleştirme ve yorumlama amacı güder. Bu yöntem, çok sayıda değişkeni, bilgi kaybı olmadan daha az sayıda bileşene indirger ve böylece veriye dair anlamlı yorumlar yapmayı kolaylaştırır. Temel bileşen analizi doğrusal bir analiz tekniği olarak çalışır (Tezbaşaran ve Gelbal, 2018). Bu yöntemle, karşılıklı bağımlılığa sahip  $p$  değişken, doğrusal ve birbirinden bağımsız (ortogonal)  $k$  yeni bileşene dönüştürülür. Temel bileşen analizi, verinin içindeki en belirgin örüntüyü keşfetmeye çalışır, bu nedenle örüntü tanıma amacıyla kullanılabilir. Verinin çeşitliliği, genellikle daha küçük bir boyut seti ile etkili bir şekilde temsil edilebilir. Bu sayede, boyut küçültme işlemi sonucu daha küçük veri setleri elde edilir, bu nedenle fazla boyutlu verilere uymayan algoritmalar yeni daha düşük boyutlu veri üstünde daha verimli çalışabilir (Yıldız ve ark., 2010).

Boyut indirgeme, verideki gürültüyü azaltmak için özniteliklerin ön işlenmesinde kullanılır. Bu yaklaşım, verilerin çoğunun bilgi kaybolmadan daha düşük boyutlu bir alana sıkıştırılmasını sağlar ve böylece algoritmaların tahmin performansının düşmesini engeller. (Tütüncü, 2022).

Algoritmanın çalışması için ilk olarak tüm veri kümesi alınır ve boyutların ortalaması hesaplanır. Sonra veri kümesinin kovaryans matrisi hesaplanır. Öz vektörleri ve bunlara karşılık gelen öz değerleri hesaplanır. Elde edilen tabloda öz değerlerden temel bileşenlerin toplam varyansı açıklama oranları bulunur. Son olarak öz vektör matrisi kullanılarak örnekler yeni alt uzaylara dönüştürülür.

Varyans, verinin yayılımını gösteren bir diğer ölçüttür. Temel bileşen analizinde, yüksek boyutlu verideki en büyük varyansları belirleyip, bu verileri orijinal verinin boyutunu aşmadan ya da eşit bir boyuttaki yeni bir alt uzaya yansıtarak analiz eder. Bu süreçte, alt uzayın varyansının mümkün olduğunca yüksek, boyutunun ise mümkün olan en düşük seviyede olması hedeflenir (Kılıçarslan ve ark., 2019).

## TAKVİYELİ MAKİNE ÖĞRENMESİ

Takviyeli (pekiştirmeli) öğrenmede kullanan algoritmalar öğrenme başarısını artırmak için çevre ile etkileşim kuran bir sisteme dayanmaktadır. Bu öğrenme yöntemi veri setindeki mevcut bilgiyi kullanma ve deneme yanılma yoluyla keşfetme arasında bir denge kurmaya çalışır. Canlıların öğrenme yöntemlerini taklit eden bir yol izleyerek algoritmaların öğrenmesini sağlar (Türkmen ve Özen, 2023).

Az sayıda etiketli verinin bulunduğu ancak çok sayıda etiketlenmemiş verinin mevcut olduğu durumlarda, geleneksel denetimli veya denetimsiz öğrenme yöntemleri yetersiz kalabilir. Bu tür durumlarda en etkili yöntem, sınırlı sayıda etiketli veriyi kullanarak etiketlenmemiş veriler hakkında bilgi edinmek ve onları doğru bir şekilde sınıflandırmaktır. Bu yaklaşım, yarı denetimli öğrenme veya takviyeli makine öğrenmesi olarak adlandırılır. Denetimli öğrenme, etiketli veri kümesinin büyük olduğu ve sınıflandırılması gereken veri sayısının az olduğu bir durumda işlerken, takviyeli öğrenme tam tersine, etiketlenmiş verilerin sınırlı olduğu bir ortamda kullanılır (Akbulut, 2022).

Takviyeli makine öğrenme, makine öğrenmesinin önemli bir türü olan denetimli öğrenmeden farklıdır. Denetimli öğrenme, dışarıdan bir denetçi tarafından sağlanan etiketli verilerle öğrenme sürecini yürütür. Bu yaklaşımda her bir örnek, belirli bir durumu ve bu duruma karşılık gelen doğru eylemi içerir. Denetimli öğrenmenin amacı, sistemin öğrendiği davranışları genelleyerek eğitim kümesinde bulunmayan durumlar için de doğru kararlar almasını sağlamaktır. Ancak etkileşim yoluyla öğrenme açısından bu tek başına yeterli değildir.

Etkileşimli problemler için, her durumu ve bu durumlara karşılık gelen doğru davranışları kapsayan etiketli örnekleri elde etmek pratikte zordur. Bu sebeple, yeni ve keşfedilmemiş alanlarda, bir temsilcinin kendi deneyimlerinden öğrenmesi, takviyeli öğrenmenin en faydalı olduğu durumdur (Çevik ve Kayakuş, 2020).

## SONUÇ

Makine öğrenmesi algoritmaları, veriden öğrenme ve tahmin yapma kabiliyetleri ile günümüz teknolojik dünyasında hızla önem kazanan araçlar haline gelmiştir. Bu çalışma kapsamında denetimli öğrenme, denetimsiz öğrenme ve takviyeli öğrenme gibi temel algoritmalar incelenmiştir. Denetimli öğrenme algoritmaları etiketli veri ile eğitilerek sınıflandırma ve regresyon gibi görevlerde yüksek doğruluk sunmaktadır. Diğer yandan, denetimsiz öğrenme algoritmaları etiketlenmemiş veri üzerinde yapı keşfi yapmak ve ilişkileri anlamak için kullanılırken, takviyeli makine öğrenme ise özellikle oyun, robotik ve otomatik karar sistemlerinde ödül tabanlı öğrenme süreçlerinde tercih edilmektedir.

Bu algoritmalar sağlıktan finansa, e-ticaretten güvenliğe birçok sektörde etkili çözümler sunmaktadır. Sağlık alanında hastalık teşhisi ve kişiselleştirilmiş tedavi gibi uygulamalarda yapay sinir ağları ve destek vektör makineleri gibi yöntemler öne çıkarken; finans sektöründe dolandırıcılık tespiti ve risk analizi için karar ağaçları ve lojistik regresyon yaygın olarak kullanılmaktadır. E-ticaret ve dijital pazarlama alanlarında, müşteri davranışlarını anlamak için kümeleme algoritmaları ve öneri sistemleri tercih edilmektedir. Bunun yanı sıra, görüntü ve ses işleme gibi alanlarda derin öğrenme modelleri, gelişmiş nesne tanıma ve yüz tanıma uygulamalarıyla güvenlik ve medya sektörlerinde değer yaratmaktadır.

Makine öğrenmesi algoritmalarının başarıları veri kalitesi, hiperparametre optimizasyonu ve model değerlendirme süreçlerine bağlıdır. Gelecekte daha açıklanabilir, dayanıklı ve kullanıcı dostu modellerin geliştirilmesi, makine öğrenmesi uygulamalarının daha geniş kitlelere erişimini sağlayacaktır. Büyük veri ve yapay zekadaki gelişmeler sayesinde, çok boyutlu ve karmaşık veri kümeleri üzerinde daha hızlı ve doğru tahminler yapılabilecektir. Sonuç olarak, makine öğrenmesi algoritmaları, birçok sektörde karar verme ve otomasyon süreçlerini iyileştiren yenilikçi çözümler sunmaktadır.

## Kaynakça

- Akbulut, S. (2022). *Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak b1st100 endeksi ile emtia, döviz fiyatları ve gelişmekte olan ülkelerin borsa endeksleri arasındaki ilişkinin incelenmesi*, Aksaray Üniversitesi Sosyal Bilimler Enstitüsü Yüksek Lisans Tezi, Aksaray.
- Altan, G. ve Demirci, S. (2022). Makine öğrenmesi ile nakit akış tablosu üzerinden kredi skorlaması: XGBoost yaklaşımı. *Journal of Economic Policy Researches*, 9(2), 397-424.
- Arslankaya, S. ve Toprak, Ş. (2021). Makine öğrenmesi ve derin öğrenme algoritmalarını kullanarak hisse senedi fiyat tahmini. *International Journal of Engineering Research and Development*, 13(1), 178-192.
- Asan, M. E., Taşkın, H., Alemdar, M. ve Capoglu, R. (2023). Tiroit kanseri hastalık tanısında lojistik regresyon kullanımı. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(3), 1509-1524.
- Ataseven, B. (2013). Yapay sinir ağları ile öngörü modellemesi. *Öneri Dergisi*, 10(39), 101-115.
- Ayhan, S. ve Erdoğan, Ş. (2014). Destek vektör makineleriyle sınıflandırma problemlerinin çözümü için çekirdek fonksiyonu seçimi. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 9(1), 175-201.
- Başer, B. Ö., Yangın, M. ve Sarıdaş, E.S. (2021). Makine öğrenmesi teknikleriyle diyabet hastalığının sınıflandırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 25(1), 112-120.
- Bilen, A. ve Özer, A.B. (2022). Siber Saldırıları için Rastgele Orman Algoritması Kullanılarak Öznitelik Seçimi. *Fırat Üniversitesi Fen Bilimleri Dergisi*, 34(1), 31-37.
- Çevik, K. K., ve Kayakuş, M. (2020). Bilişim Teknolojileri Departmanında Kullanıcıların Taleplerine Cevap Verme Süresinin Makine Öğrenmesi ile Tahmin Edilmesi. *Mühendislik Bilimleri ve Tasarım Dergisi*, 8(3), 728-739.
- Çolakoğlu, A.A. (2020). *Makine öğrenmesi algoritmaları ile Avrupa havalimanları analizi*, Pamukkale Üniversitesi Sosyal Bilimleri Enstitüsü, Yüksek Lisans Tezi, Denizli.
- Gültepe, Y. (2019). Makine öğrenmesi algoritmaları ile hava kirliliği tahmini üzerine karşılaştırmalı bir değerlendirme. *Avrupa Bilim ve Teknoloji Dergisi*, (16), 8-15.
- Ji, C., Zou, X., Hu, Y., Liu, S., Lyu, L. ve Zheng, X. (2019). XG-SF: An XGBoost Classifier Based on Shapelet Features for Time Series Classification. IIKI 2018: International Conference on Identification, Information and Knowledge in the Internet of Things for 2018 (s. 24-28). Elsevier B.V.
- Karakoyun, M. ve Hacıbeyoğlu, M. (2014). Biyomedikal Veri Kümeleri İle Makine Öğrenmesi Sınıflandırma Algoritmalarının İstatistiksel Olarak Karşılaştırılması. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 16(48), 30-42.

- Kazan, S. ve Karakoca, H. (2019). Makine öğrenmesi ile ürün kategorisi sınıflandırma. *Sakarya University Journal of Computer and Information Sciences*, 2(1), 18-27.
- Kemalbay, G. ve Alkış, B.N. (2020). Borsa endeks hareket yönünün çoklu lojistik regresyon ve k-en yakın komşu algoritması ile tahmini. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 27(4), 556-569.
- Kılıçarslan, S., Adem, K. ve Cömert, O. (2019). Parçacık sürü optimizasyonu kullanılarak boyutu azaltılmış mikrodizi verileri üzerinde makine öğrenmesi yöntemleri ile prostat kanseri teşhisi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 7(1), 769-777.
- Sarıman, G. (2011). Veri madenciliğinde kümeleme teknikleri üzerine bir çalışma: k-means ve k-medoids kümeleme algoritmalarının karşılaştırılması. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(3), 192-202.
- Taşar, B., Üneş, F., Demirci, M. ve Kaya, Y.Z. (2018). Yapay sinir ağları yöntemi kullanılarak buharlaşma miktarı tahmini. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 9(1), 543-551.
- Taşcı, E. ve Onan, A. (2016). K-en yakın komşu algoritması parametrelerinin sınıflandırma performansı üzerine etkisinin incelenmesi. *Akademik Bilişim*, 1(1), 4-18.
- Tezbaşaran, E. ve Gelbal, S. (2018). Temel bileşenler analizi ve yapay sinir ağı modellerinin ölçek geliştirme sürecinde kullanılabilirliğinin incelenmesi. *Mersin Üniversitesi Eğitim Fakültesi Dergisi*, 14(1), 225-252.
- Türkmen, V. ve Özen, D. (2023). Makine Öğrenmesinde Regresyon Algoritmalarının Veteriner Hekimliği Alanında Uygulamaları. *Veteriner Farmakoloji ve Toksikoloji Derneği Bülteni*, 14(3), 118-132.
- Tütüncü, T.E. (2022). *Makine öğrenmesi algoritmaları ile kredi temerrüt riskini tahmin etme*, Bursa Uludağ Üniversitesi, Yüksek Lisans Tezi, Bursa.
- Ustalı, N. K., Tosun, N. ve Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 16(1), 1-16.
- Uzun, E., Erdoğan, C. ve Saygılı, A. (2016). Hiyerarşik Kümeleme Modeli Kullanan Web Tabanlı Bir Ödev Değerlendirme Sistemi. *Ejovoc (Electronic Journal of Vocational Colleges)*, 6(3), 87-98.
- Yangın, G. (2019). *XGboost ve Karar Ağacı tabanlı algoritmaların diyabet veri setleri üzerine uygulaması*, Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Yavuz, S. ve Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağın performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (40), 167-187.
- Yeşilbudak, M., Kahraman, H. ve Karacan, H. (2011). Veri madenciliğinde nesne yönelimli birleştirici hiyerarşik kümeleme modeli. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 26(1).

- Yıldız, K., Çamurcu, Y. ve Dođan, B. (2010). Veri madenciliđinde temel bileşenler analizi ve Negatifsiz matris çarpanlarına ayırma tekniklerinin karşılaştırmalı analizi. *Akademik Bilişim*, 10, 248.
- Yücelen, A.M. ve Baykal, A. (2021). K-ortalamar kümeleme yöntemi için çift k başlatma algoritması. *Avrupa Bilim ve Teknoloji Dergisi*, (23), 280-287.
- Zilyas, D. ve Yılmaz, A. (2023). Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 14(3), 437-447.





## PARÇACIK FİZİĞİNE YÖN VEREN ALGIÇLAR

*Çağın KAMIŞCIOĞLU<sup>1</sup>*

---

<sup>1</sup> Doç.Dr. Ankara Üniversitesi, Mühendislik Fakültesi, Fizik Mühendisliği Bölümü , Ankara, Türkiye. [gunes@ankara.edu.tr](mailto:gunes@ankara.edu.tr) ORCID:0000-0003-2610-6447

## 1.Giriş

Bilim dünyası 1930'lu yılların başında atomun sadece proton, nötron ve elektrondan oluştuğunu düşünüyordu. Çok geçmeden beta bozunumundaki enerji taşıyıcı "hayalet" parçacık olan adlandırılan nötrinonun varlığı öne sürüldü. Ardından müon gibi pion parçacıklarının keşfi gerçekleştirildi. Maddenin temel yapı taşlarını anlama serüvenimizde yeni keşifler için parçacıkları yüksek hızda çarpıştıran hızlandırıcılar üretilmeye başlandı. Böylece atom altı parçacık dünyasının gizemleri biraz daha aydınlatılmış oldu. Günümüzde yüzlerce atom altı parçacık bu tarihsel serüvende detaylı araştırmalar ve deneyler sonucu keşfedilmiş oldu.

Temel parçacık fiziği, maddenin nihai bileşenlerinin ve bunların etkileşimlerinin araştırılması ve incelenmesiyle ilgilenir. Yaygın kullanımda, temel parçacık terimi, maddenin temel bileşenleri olarak kabul edilir. Bu özel fizik alanındaki ilk bilim insanları, temel parçacık adını gerçekte daha fazla bölünemeyeceğine dair büyük bir inançla: atom (Yunanca *bölünemez* anlamına gelir) demişlerdir. Demokritus tarafından M.Ö 400'lerde ortaya atılan bu fikir aslında çağının çok ötesindeydi. Deneysel bilginin artmasıyla, temel parçacığın gerçek tanımı bir evrim geçirmesi kaçınılmazdı. On dokuzuncu yüzyılın sonlarına doğru, "atom" yani bölünemez kelimesi aslında oldukça bölünebilir nesnelere atfedildi. Günümüzde biliyoruz ki atom aslında bölünebilir olduğundan, temel parçacıkların en büyük kısmı (örneğin protonlar) da gerçekten temel değildir.

Nesneleri gözle gördüğümüzde algıladığımızı düşünürüz. Örneğin metre boyutundaki gözlemleri çıplak gözle yapabiliriz. Boyut büyüdükçe gezegenler, yıldızlar uzak galaksiler oldukça büyük boyutlarda ( $\sim 10^{22}$ m) olması sebebiyle gözlemimiz ancak teleskop veya

uydu gibi sistemlerle mümkün olur. Aksi yönde çeşitli mikroorganizmaları oldukça küçük olmaları sebebiyle ( $\sim 10^{-6}$ m) Şekil 1'de de gösterildiği üzere çıplak gözle görmek mümkün değildir. Bu amaçla elektron mikroskobu gözün görme sınırlarını genişletici bir rol oynar. Bu noktada atom altı parçacıkların da algılanması hatta özelliklerinin tanımlanması gerekir. Parçacıkları algılamak, maddenin temel yapı taşları olan atom altı parçacıkların varlığını tanımlamak ve ölçmek için kullanılan yöntemlere ve teknolojilere atıfta bulunur. Bu özellikleri ölçmek için algıçlara ihtiyaç duyulmaktadır. Algıç veya dedektörler oldukça hassas olup bir parçacığın varlığını algılayabilen, izi, kütlesi, enerjisi, momentumu, spinini, elektrik yükü gibi özelliklerini saptayabilen bir araçtır (Encyclopedia Universalis, 2025). Parçacık algıçlarında parçacıklar dolaylı olarak görülür. Nasıl ki rüzgarın varlığını doğada bıraktığı etkisinden anlıyorsak, algıçlarda parçacıkların bıraktıkları bir takım izler ve özelliklerden parçacıkları algılamaktayız.



Şekil 1. Kozmik ölçekten - elektrona.

Parçacık fiziğinin tarihi, parçacık algıçlarının gelişimiyle yakından ilgilidir. Bu cihazlar genellikle belirli fizik olaylarını anlamak ve atom altı parçacıkları keşfetmek için icat edildiğinden temel hedefleri parçacığa ait bütün ipuçlarını toplamaktır. Var olan ipuçları atom altı ölçekte gizlendiğinden bu ölçekteki verilere ulaşmak ancak teknolojik ilerlemelerde paralel olmuştur. Tıpkı avcılarının avlarını çamurda veya karda bıraktıkları izlerden tanımaları gibi fizikçiler de atom altı parçacıkları algıçlarda bıraktıkları izlerden tanımaya çalışmışlardır (CERN, 2025). Önceleri bulut odası, köpük odası gibi parçacıkların izini sürebilen ve onları görünür hale getiren algıçlar üretilmiştir. Gelişimsel

olarak bakıldığında her bir algıç döneminde önemli çalışmaların yapılmasına olanak sağlamış ve parçacık fiziğinin gelişimine katkı sağlamıştır. Bu sayede günümüzde CERN’ de kullanılan parçacık hızlandırıcılarının gelişimine temel olmuştur.

Günümüzde CERN'deki hızlandırıcılar parçacık demetlerini yüksek enerjilere çıkararak çarpıtmakta, algıçlar bu çarpışmalarda ortaya çıkan parçacıklar hakkında hız, kütle ve yük gibi çeşitli veriler toplamaktadır. Bu veriler incelenerek fizikçilerin atom altı parçacıkları keşfetmelerine yardımcı olmaktadır. Ancak bu gelişmelerin temeli parçacık fiziği alanında kullanılan ilk algıçlara, onlardan edinilen bilgilere ve deney sonuçlarına dayanmaktadır. Bu anlayıştan hareketle parçacık fiziğinin gelişimine katkı sağlayan algıçların araştırılmasına ihtiyaç duyulmuştur. Bu araştırmada “*Parçacık fiziğine yön veren algıçlar nelerdir?*” sorusuna cevap aranmıştır. Bu amaçla tarihsel süreç içerisinde kullanılan önemli algıçlar incelenmiş, özellik ve türleri, güçlü ve zayıf yönleri saptanmış, benzer ve farklılıkları karşılaştırılmıştır.

## 2.Yöntem

Atom altı parçacıkları keşfetmek için 1900 ‘lı yıllardan günümüze kadar tarihsel süreç içerisinde çok sayıda algıç üretilmiştir. Araştırmada atom altı parçacıkların keşfine katkı sağlayan ve sonraki gelişmelere yön veren üç temel algıç ele alınmıştır. Bunlar Bulut Odası, Köpük Odası ve Tel Odası Algıçları olarak sıralanmıştır. Bu algıçları incelemek için nitel araştırma yöntemi benimsenmiştir. Bilindiği gibi nitel araştırmalar görüşme, gözlem veya dokümanlar yoluyla nitel veri toplanarak gerçekleştirilmektedir (Yıldırım ve Şimşek, 2008). Bu yöntem doğrultusunda alandaki resmi ve yazılı dokümanlardan nitel veriler toplanmıştır. Çalışma materyali olarak elektronik ve basılı kaynaklar,

resmi belgeler, raporlar ve bilimsel kitaplar ele alınmıştır. Ulaşılabilen bütün kaynaklardan elde edilen veriler karşılaştırmalı olarak incelenmiş, algıçların benzer ve farklı yönleri çıkarılmıştır. Her algıya ilişkin elde edilen bulgular yorumlanmıştır.

### **3.Bulgular ve Yorumlar**


Araştırmada elde edilen bulgular algıçların tarihsel sürecine, tür ve özelliklerine, benzer ve farklılıklarına göre sıralanmıştır. Bulguların verilmesinde araştırma soru sırası izlenmiştir. Bulgular Wilson Bulut Odası Algıcı, Glaser Köpük Odası Algıcı, Charpak Tel Odası Algıcı, Algıçların Temel Özellikleri, Güçlü ve Zayıf Yönleri, Benzer ve Farklı Yönleri” gibi başlıklar altında toplanmıştır.

#### **3.1.Wilson Bulut Odası Algıcı**

Alandaki kaynaklarda “Bulut Odası, Sis Odası ya da Wilson Odası” olarak bilinmektedir. İskoç fizikçi Charles T.R. Wilson (1869-1059) tarafından keşfedilmiştir. Atomaltı parçacıkları keşfetmek için kullanılan ilk dedektör/algıçtır. Charles T.R. Wilson bu algıcı, nemli bir havada bulut oluşumu ve optik olayları incelerken tesadüfen keşfetmiştir. İlk algıcı 1911 yılında yapmış ve bunu çeşitli deneylerle 1912 yılına kadar geliştirmiştir. Bulut Odası Algıcı laboratuvar ortamında yüklü taneciklerin izlerini görünür hale getiren bir aygıttır. Bir başka ifadeyle parçacıkların izini sürebilen ilk aygıttır. Aygıtın üzerinde kapalı bir ortam olan “oda” denilen silindir bir cam bölme bulunmakta, burada bulut ya da sis oluşturularak parçacık izleri gözlenmektedir. Ayrıca oluşan izlerin fotoğrafı da çekilebilmektedir. Bu algıç Wilson’a 1927 yılında Nobel ödülü kazandırmıştır (Woithe, 2016).

Wilson önceleri meteoroloji ile ilgileniyordu. İskoçya'da Ben Nevis dağının zirvesine yaptığı bir gezi sırasında gördüğü gökkuşağı halesinden çok etkilendi. 1894 yılında Ben Nevis gözlemevinde bulut oluşumları üzerinde çalışmalar yaptı. Ardından Cambridge'te Cavendish laboratuvarında bulut üretme çalışmalarına başladı. Buhar içeren havayı kapalı bir ortamda genişleterek deneyler yapıyordu. Bu deneylerde küçük su damlacıklarının toz ya da iyonlaşmış hava moleküllerinde çok hızlı bulut oluşturduğunu fark etti (Barron,1952). Havada ilerleyen yüklü tanecik, hava moleküllerinden elektron alarak, iyonlaşmış moleküller oluşturduğuna göre, bulut oluşumu için gerekli koşullar sağlanırsa, taneciğin geçtiği yolda bir dizi damlacığın kalması sağlanabilirdi. Bu gözlemlerden atomların bir hedefle çarpışması ile oluşan parçacıkların izlediği yolun belirginleştirilebileceğini yani "bulut odası" ilkesini çıkardı. Resim 1'de Cambridge Müzesi'ndeki Wilson Bulut Odası Algıcının orijinal resmi verilmektedir.

Wilson Bulut Odası Algıcı, parçacık fiziğine yön veren ilk algıcılardan biridir. Bu alanda çok sayıda keşfin yapılmasına katkı sağlamıştır. Bu algıç, 1920-1950 yılları arasında yapılan deney ve gözlemlerde kullanılmış, aynı zamanda Glaser Köpük Odası Algıcına öncülük etmiştir. Bu algıç aşırı doymuş alkol buharı içeren kapalı bir ortam ya da küçük bir odadır. Odadan içeri giren yüklü parçacıklar, izledikleri yol boyunca enerji bırakarak alkol buharını yoğunlaştırır ve bulut gibi izler bırakır. Bu parçacıklar (müonlar, elektronlar ve helyum çekirdekleri) odanın içinden geçerken alkol moleküllerini iyonlaştırır(Woithe, 2016). İyonlaşan bu moleküller odanın merkezinde sıvı alkolden oluşmuş çizgiler gibi görünürler. Her parçacık farklı bir iz bırakır. Bu izler, parçacıklar için ayırt edicidir.




*Resim 1. Wilson Bulut Odası Algıcının resmi (Cloudylabs, 2025).*

Örneğin bir alfa parçacığının izi geniş ve düz iken bir elektron, ince ve çarpışmalarda sapması daha belirgin bir iz bırakır. Farklı izler farklı parçacıkların var olduğunu gösterir (Barron,1952). Oluşan izlerin fotoğrafları çekilerek daha sonra incelemek üzere kaydedilir. Eğer parçacık demetinin odaya giriş yönüne dik olarak bir manyetik alan uygulanırsa, ortaya çıkan Lorentz kuvveti, parçacıkların yönünün değişmesine neden olur. Böylece yay şeklinde iz bırakan parçacıkların yükü ve momentumu ölçülebilir (Woithe, 2016).

Wilson Bulut Odası Algıcı üzerinde daire şeklinde cam bir oda bulunur (Resim 1,Şekil 2). Bu silindirik cam odanın (A) çapı 16,5 cm ve genişleme derinliği (yüksekliği) 3,4 cm'dir. Bu odada alkol buharı yoğunlaştırılır, bulut gibi görüntüler oluşturularak parçacık izleri gözlemlenir. Oda, pistonun içindeki ve dışındaki basınç farkına göre sabit bir dış silindir içinde yukarı veya aşağı hareket eden içi boş bir piston içerir. Pistonun hareket edebilmesi için odanın içinde 2 cm'lik su birikintisi bulunur.

Yuvarlak cam hazneye (C) uygun bir pompa ile vakum uygulanır ve vakum haznesine (C) giden vana (B) açılarak hazne içindeki havanın (bölge A) hızla genişmesi sağlanır. Vakum, içi boş pistondan havayı emerek aşağı doğru hareket etmesini sağlar ve böylece pistonun üstündeki genişleme boşluğu olan bulut odasındaki (A) nemli havayı hızla genişletir. Bulut odasının tabanı (I), boşaltılan odaya (C) açılan vana (B) ile aniden düşer ve piston kauçuk kaplı tabana (H) çarptığında aniden durur. Odanın genişlemesi, parçacık izi oluşumu için gerekli olan aşırı nem doygunluğunu sağlarken aynı zamanda kameranın flaşını da harekete geçirir (Barron,1952; Roy, Van de Leemput & Étienne, 1954).



Şekil 2. Wilson Bulut Odası Algıç diyagramı (Linda Hall Library, 2025).


Resim 1 ve Şekil 2 'de görüldüğü gibi algıcın altındaki kauçuk boru bağlantılarındaki (F) ve (G) sıkıştırma muslukları, bulut odasındaki havayı kontrol etmek ve pistonun, istenen başlangıç hacmini ( $v_1$ ) odanın son hacmine ( $v_2 = 750$  mL) ayarlayarak atmosferle iletişimin açılmasını sağlar. İç pistonun içinde içi boş bir ahşap silindir (D) bulunur. Bu silindir her genişmede bağlantı borularından geçen havanın hacmini azaltır. Bulut odasının üstü (L), duvarları (K) ve tabanı (I) camdan



yapılmıştır. Bulut Odasındaki yüklü parçacık izlerinin kolay görüntülenmesi ve fotoğraflanması için genleşme odasının tabanı siyaha boyanmış ve duvarları jelatinle kaplanarak koyu arka plan oluşturulmuştur (Cloudylabs, 2025).

Özetlemek gerekirse, Bulut Odası Algıcında radyoaktif bir kaynaktan gelen parçacıklar içinde hava ve su buharı bulunan bir cam bölmeden geçerler. Cam bölmede parçacıklar havadaki atomlara çarparak elektron koparırlar ve artı yüklü iyonlar oluştururlar. Cam bölmedeki basınç aniden düşürülünce su buharı iyonların üzerinde yoğunlaşarak minik damla izleri oluşturur. Bulut Odasındaki su damlacıklarının izleri, elektronların ve pozitronların (artı yüklü elektron) izlediği yolları gösterir. Zıt elektrik yükleri nedeniyle parçacıklar odanın manyetik alanında farklı yönlerde bükülerek eğri yörüngeler çizerler. Bu çalışma prensibi aşağıdaki Şekil 3-4'te gösterilmiştir.

Parçacık izlerinin rahat görüntülenmesi için Bulut Odası Algıcın, 1924 yılında Blackett tarafından her 15 saniyede 1 fotoğraf çekecek şekilde otomatik bir makineye dönüştürüldü. Böylece binlerce fotoğraf çekilebiliyor ve nadir nükleer olaylar gözlenebiliyordu. Yaklaşık 23.000 fotoğraftan 8'i aranan olayı gösteriyordu. Ancak özellikle kozmik ışınları incelemek için rastgele zamanlarda fotoğraf çekmek, ilginç olayları elde etmek için son derece verimsizdi. Bu problemi Blackett 1933 yılında sayaç kontrollü Bulut Odaları kullanarak çözmüştür (Cloudylabs, 2025).



Şekil 3. a) Odaanın altında basıncı azaltan bir piston vardır. b) Odaya radyoaktif bir kaynak sokulur. Alfa parçacıkları yayar (şekil yazar tarafından düzenlenmiştir).




Şekil 4. c) Alfa parçacıkları havayı iyonlaştırır. Bir elektron bir atomdan ayrılarak diğerine geçer, katyon bırakıp anyon üretir. d) Basınç aniden düşürülünce sıcaklık düşer. İyonların etrafında alkol ve su damlacıkları yoğunlaşır, iyonlaştırıcı parçacıkların yörüngesini gösterir (şekil yazar tarafından düzenlenmiştir).

ABD'li fizikçi Carl David Anderson (1905-1991) ise daha duyarlı bir sis bulutu oluşturmak için alkol yerine su kullanmış ve odaya güçlü bir manyetik alan uygulamıştır. Resim 2-3'de de verildiği üzere Bulut Odası Algıcını kullanarak 1932'de pozitronu ve 1936'da müonu keşfetmiş ve 1936 yılında Nobel Ödülü almıştır (Anderson, 1933). Yine 1947 yılında Kaonun keşfi de Bulut Odaları kullanılarak yapılmıştır.



*Resim 2. Bulut Odası Algıcında görülen parçacıkların izi (Woithe, 2016).*



*Resim 3. Bulut Odası Algıcında görülen parçacıkların izi (Anderson, 1933).*

### **3.2. Glaser Köpük Odası Algıcı**

Bu algıç alandaki kaynaklarda “Köpük Odası, Kabarcık Odası ya da Glaser Odası” olarak bilinmektedir. Donald Arthur Glaser tarafından 1952 yılında keşfedilmiştir. Tarihsel süreçte atom altı parçacıkları saptamak için kullanılan ikinci önemli algıçtır (Goulette, 2013). Bu algıç hakkında Kaliforniya Üniversitesi parçacık fiziği uzmanı profesör Herbert Steiner önemli açıklamalar yapmıştır. Herbert Steiner’e göre “Köpük odası çok sayıda yeni parçacığın bulunmasını sağlayan büyük bir keşiftir. Bu cihaz, 1960 yılından 1970’li yıllara kadar baskın parçacık algıcı olarak kullanılmış ve parçacık fiziği alanına çok büyük katkılar sağlamıştır” (University of California, 2013).



Donald Arthur Glaser, 1949 yılında Michigan Üniversitesi fizik bölümünde ders veriyordu. Burada temel parçacıkları görselleştirmek için difüzyon bulut odaları ile çeşitli deneysel teknikleri inceliyordu. O zamanlar sadece Wilson Bulut Odası Algıcı kullanılıyordu. Bulut Odası Algıcının çalışmalarına uygun olmadığını fark eden Glaser, atom altı parçacıkların yollarını öğrenmek için köpük odası yapma fikrine kapıldı (Britannica, 2025). Aşırı ısıtılmış sıvıları cam bir muhafaza içerisinde kullanarak, bir parçacığın geçişiyle oluşan kabarcıkların fotoğrafını

çekme düşüncesi vardı. Önce eterle, sonra hidrojenle çalışacaktı. Kendi deyimiyle "*pencereli bir düdüklü tencere*" yapacaktı. Bunun ilk örneğini 1952 yılında gerçekleştirdi.

Glaser başlangıçta, sadece 3 cl dietil eter içeren küçük bir cam şişe olan minik bir gösteri cihazı yaptı. Bir başka ifadeyle ilk köpük odası bir inç (2.54 cm) büyüklüğünde çok küçük ve hassas bir cihazdı. Bu cihaz, radyoaktif bir kaynaktan yayılan kozmik ışınlar veya parçacıklar geçtiğinde kalan izleri gösteriyordu. Bu projeyi geliştirmek için ABD Atom Enerjisi Komisyonu ile Ulusal Bilim Vakfından finansal destek istedi. Ancak projesi çok basit bulundu ve isteği reddedildi. Ardından 1953 yılında Washington'daki Amerikan Fizik Topluluğu toplantısına katıldı. Orada Luis Alvarez ile tanıştı ve projesini anlattı. Alvarez, Glaser'in fikrini önemli bularak destekledi ve 1959 yılında Kaliforniya Üniversitesine gelmesine yardımcı oldu. Çok geçmeden Alvarez'in ekibi, Glaser'in minik köpük cihazını iki metre uzunluğunda, sıvı hidrojenle doldurulmuş, metalden yapılmış ve atomaltı parçacıkların izlerinin fotoğraflayan, cam pencereleri olan büyük bir versiyonunu yaptı (University of California, 2013).

Köpük Odası yüklü tanecikleri belirlemek için kullanılan bir algıdır. Güçlü bir manyetik alana yerleştirilmiş içi sıvı hidrojen dolu bir silindir veya küre şeklindedir. Çalışma prensibi Bulut Odası Algıcına çok benzer. Ancak Köpük Odası Algıcı, buhar yerine kaynama noktasına çok yakın bir sıcaklığa kadar ısıtılmış bir sıvı ile doludur. Yani içerdeki sıvı belli bir basınçtaki kaynama sıcaklığının hemen altında tutulur. Ayrıca parçacıklar kaynama noktasındaki aşırı ısıtılmış bir sıvıda buhar yerine kabarcık izi bırakır (Marleau,2007). Köpük Odası Algıcında parçacık demeti odaya girer girmez, sıvıya basınç uygulayan piston yükselerek basıncı düşürür. Böylece sıvı, yüklü parçacıkların parçalanacağı kadar aşırı düzeyde ısınmış olur. Yüklü parçacıklar sıvının içinden geçerken iyonlaşma

yoluyla enerji kaybederler. Bu durum sıvının buharlaşmasını ve küçük kabarcık veya baloncuklar oluşmasını sağlar. Kabarcıklar giderek büyür ve hemen fotoğrafları çekilir ya da birden fazla kamera ile görüntüleri alınır. Fotoğraflar parçacık yörüngesinin üç boyutlu görünümünü verir (Futura Sciences, 2025). Aşağıda Şekil 5’de Köpük Odası Algıcının diyagramı ile Resim 4’te parçacık izinin görüntüsü verilmiştir.



*Şekil 5. Glaser Köpük Odası Algıcı diyagramı (şekil yazar tarafından düzenlenmiştir).*

*Resim 4. Köpük Odası Algıcı ile saptanan parçacıkların izleri (Goulette, 2013).*

Köpük Odası Algıcı, Bulut Odasına göre bazı üstünlüklere sahiptir. Bunların başında daha büyük hacimli olması ve daha yoğun sıvı içerdiğinden daha yüksek enerjili parçacıkları algılayabilmesi gelmektedir. Köpük Odası sıvısının Bulut Odasını dolduran buharın aksine daha yüksek yoğunluklu olması nedeniyle nadir reaksiyonlar üreten çarpışmalar daha sık ve daha ince ayrıntılarla gözlenebiliyordu. Köpük Odası Algıcı, parçacık hızlandırıcılarından gelen yüksek hızlı parçacık patlamalarına maruz bırakıldığında her birkaç saniyede bir yeni çarpışmalar kaydedilebiliyordu (Britannica, 2025). Köpük Odası Algıcını kullanarak fizikçiler bir dizi yeni parçacığın, özellikle de kuarkların

varlığını keşfettiler. Böylece Glaser, 1960 yılında 34 yaşında iken Nobel Ödülü alan en genç bilim insanı oldu (Goulette, 2013).

Köpük Odası Algıcı 1960'lı yıllarda yürütülen deneylerin çoğunda kullanılıyordu. Ancak 1970'li yıllarda yerini Çok Telli Oda (MWPC) ve Sürüklenme Odası (TPC) gibi elektronik olarak okunan yeni algıçlara bırakmıştır. Günümüzde hala nostaljik bir uygulama olarak bazı araştırma ve deneylerde kullanılmaktadır. Bu ilke ile çalışan en bilinen algıçlar BEBC ve Gargamelle olarak karşımıza çıkmaktadır. CERN'deki ünlü kabarcık odası Gargamelle, 1973 yılında zayıf nötr akımların keşfedilmesinde önemli bir rol oynamıştır. Bu keşif, bu akımların varlığını öngören ve zayıf kuvvet ile elektromanyetik kuvveti aynı etkileşimin iki yüzü olarak kabul eden elektro zayıf teorisinin hipotezini doğrulamıştır.



*Resim 5. Fermilab binası dışında sergilenen Odası Köpük Odası Algıcı (Wikipedia 2025).*



*Resim 6. CERN Gargamelle (BEBC) Köpük Algıcı (CERN 2025).*

Sonuç olarak Köpük Odasında Algıcında parçacık oluşumu için aşırı doymuş gaz yerine aşırı ısıtılmış bir sıvı kullanılmıştır. Bu nedenle daha fazla kararlılık sağlanmış ve arka plan sinyali azaltan kolay sıfırlamalara ve tetiklemelere izin vermiştir. Bulut Odası Algıcının

aksine, Kabarcık Odası Algıcı tetiklenemiyor, yani parçacık içeri girdiğinde kabarcık odasının zaten aşırı ısınmış durumda olması gerekiyordu. Bu nedenle Kozmik Işın Fiziği için kullanışlı değildi. Ancak 1950'li yıllarda parçacık fiziğinin hızlandırıcılara geçmesiyle, ışının varışıyla oda sıkıştırmasının senkronize edilmesi mümkün olmuştur.

### *3.3. Charpak Tel Odası Algıcı*

Bu algıç alandaki kaynaklarda “Tel Odası, Çok Telli Oransal Oda ya da Charpak Odası” olarak bilinmektedir. Georges Charpak tarafından 1968 yılında keşfedilmiştir. Tarihsel süreçte atom altı parçacıkları saptamak için kullanılan üçüncü önemli algıçtır (Goulette,2013). Yüksek enerjili parçacık fiziği deneylerinde, parçacığın yolunu gözlemlemek çok değerlidir. Bu amaçla uzun süre Köpük Odası Algıcı kullanılmıştır. Ancak 1960'lu yıllarda elektronik araçlar geliştikçe, hızlı elektronik okuma özelliğine sahip algıçlara olan talep arttı. Bu süreçte Charpak'ın orantılı bir odadaki izole bir telin yüz binlerce bağımsız tel ile nasıl değiştirileceğini keşfetmesi devrim niteliğindedeydi (The Guardian,2025).

Georges Charpak, savaş sonrası Paris'teki Frédéric Joliot Curie laboratuvarında araştırmalara başladı ve kısa sürede parçacık algıçlarına olan tutkusu onu yakaladı. Bu tutku yaşamı boyunca onu asla terk etmedi. Amerikalı fizikçi Leon Lederman tarafından Cenevre'deki Avrupa Nükleer Araştırma Merkezi'ne (CERN) davet edilmesiyle, kariyerinin büyük bölümünü burada ateşli bir fizikçi ve ilham verici bir deneysel araştırmacı olarak geçirdi. Hızlandırıcılar tarafından oluşturulan parçacıkları elektronik olarak izlemek için Köpük Odası Algıçlarının yerini alan “Çok Telli Oransal Oda Algıcımı” geliştirdi. Bu çalışma ona 1992'de Nobel Fizik Ödülü'nü kazandırdı.


Charpak Tel Odası Algıcı, yüksek voltajlı bir dizi telin topraklanmış iletken duvarlar arasından geçtiği bir ortamdır. Oda argon

ve metan gibi gazlarla doldurulur. Odadan geçen parçacıklar gaz atomlarını iyonize ederler. Elektron ve iyonlar elektrik alanda hızlanırlar. Anoda ulaşan elektron sinyalleri okunur. Parçacıkların algılanmasından doğan elektronik sinyaller bilgisayarlar aracılığıyla incelenir. Etkili ve verimli bir algıdır. Köpük Odası Algıcında parçacık algılama oranı:  $\sim 1$  Hz iken Tel Odası Algıcında parçacık algılama oranı:  $\sim 10^3$  Hz dir. (Goulette,2013; Marleau,2007).


Bu algıta parçacıkların yollarını saptıran manyetik alanlar oldukça güçlüdür. Bu konuda CERN'de unutulmayan bir hikâye anlatılır. Charpak ve ekibi, Çok Telli Oda Algıç (MWPC) üzerinde çalışıyordu. Binlerce ince teli algıca dikkatlice bağlamak için aylarca zaman harcamışlardı. Çalışmanın sonuna doğru bir gün Charpak metal bir sandalyeye oturdu ve o sırada manyetik alana çok yaklaştı. Mıknatıs, Charpak'ın altındaki metal sandalyeyi hızla çekti. Metal sandalye Tel Odası Algıcına çarptı, aylardır bağlanan bütün ince telleri kopardı ve algıç zarara uğradı (Yakın,2025).

Charpak Tel Odası Algıcında, hangi tellerin elektrik akımı darbeleri aldığını kaydederek parçacığın yolunu görebilir. Ayrıca eğrilerin yönü parçacıkların nasıl yüklendiğini gösterir. Charpak bunu enerjiyi belirlemek için orantılı sayaç fikriyle birleştirdi. Bu işlem, veri toplama hızını önceki tekniklere göre 1.000 kat artırdı ve hızla parçacık fiziğinde standart bir araç haline geldi. Tel Odası Algıcı, parçacıkların 1 mm'den daha iyi bir hassasiyetle izlenmesine izin verdi. Bu çalışmaların sonucunda tau-lepton ve egzotik kuark çeşitleri gibi birkaç yeni geçici atom altı parçacık keşfedildi. Günümüzde halen Charpak Tel Odası Algıcı CERN'de yer alan Büyük Hadron Çarpıştırıcısı'ndaki deneylerde temel bileşenler olarak kullanılmaktadır (The Guardian,2025). Aşağıda Resim 7 ve Şekil 6'da Charpak Tel Odası Algıcının resmi ile diyagramı verilmiştir.





Resim 7. Charpak Tel Odası Algıcı (Goulette, 2013).



Şekil 6. Charpak Tel Odası Algıcı diyagramı (Marleau, 2007).

Tel Odası Algıcı, argon gibi bir soy gazla dolu bir odacık şeklindedir. İçerisinde çok sayıda telin paralel olarak dizilmesiyle oluşan birkaç ızgara bulunmaktadır. Tüm şebekeler enerjilendirilmiş, katot ve anotlar dönüşümlü olarak dizilmiştir. Yüklü bir parçacık odaya girdiğinde gazı iyonize ederek atomları negatif yüklü elektronlara ve pozitif yüklü iyonlara ayırır. Ardından elektronlar anotlara, iyonlar ise katotlara çekilir. Daha sonra parçacığın varlığı anot tellerine uygulanan elektriksel darbe ile tespit edilir. O dönem için ilginç ve yeni algıçtı. Charpak "Birçok algıç üzerinde çalıştım. Bazıları çok zarif ve işe yaramazdı" diyordu. Ancak algıç işe yaramaz olmaktan çok uzaktı. Geiger sayacında olduğu gibi, orantılı bir sayaç, duvarları toprak potansiyelinde tutulan gazla dolu bir metal muhafazadan geçen yüksek gerilimli bir tel kullanır. Elektrikle yüklü bir parçacık tüpten geçerse, yakın çevresindeki gaz atomlarını iyonlaştırır. Ortaya çıkan iyonlar ve elektronlar, telin etrafındaki elektrik alanı tarafından hızlandırılır ve telde toplanan ve orijinal parçacığın enerjisiyle orantılı bir elektrik akımı veren bir iyonizasyon kaskadı oluşturur. Bu durum deney yapan fizikçinin

parçacıkları saymasını ve enerjilerini belirlemesini sağlar (Barti & Regler,1992).

Bu algıç ile birlikte parçacık fiziği yeni bir çağa girmiştir. Çok telli odanın hızı ve hassasiyeti bu alanda devrim yaratmıştır. Parçacık fizikçileri aradıkları parçacıkların bir veya iki örneğini bulmak için genellikle milyonlarca izi taramak zorunda kalıyor, bu yüzden hızlı algıçlara ihtiyaç duyuyorlardı. Charpak Tel Odası Algıcının (MWPC) keşfi, çok daha yüksek parçacık çarpışma oranlarında deneyler yapmanın, nadir olayların ve yeni büyük parçacıkların üretimini öngören teorileri test etmenin yolunu açmıştır. CERN'deki W ve Z bozonlarının, SLAC ve Brookhaven'daki çekicilik kuarkının ve Fermilab'daki üst kuarkın keşifleri bu tür bir algıç olmadan mümkün olmazdı. Halen parçacık fiziğindeki mevcut araştırmalar bu cihazlara bağlı olarak devam etmektedir (CERN 2004). Bu algıç biyoloji, radyoloji ve nükleer tıp gibi birçok başka alanda da kullanılmaktadır.

### ***3.4. Temel Özellikleri***

Araştırmada Wilson Bulut Odası Algıcı, Glaser Köpük Odası Algıcı ve Charpak Tel Odası Algıcının temel özellikleri Tablo 1'de verilmiştir.

Tablo 1'de de görüldüğü gibi parçacık fiziğine yön veren algıçların temel özellikleri kolay karşılaştırma yapılabilmesi amacıyla tablo halinde verilmiştir. Bunlardan ilk ikisi yani Bulut ve Köpük Odası Algıçları görselleştirme algıcısıdır. Bu algıçlar iyonlaştırıcı parçacıkların yörüngelerini izlemeyi ve bunların fotoğrafını çekmeyi mümkün kılar. Ardından elde edilen sonuçların görsel incelemesi yapılır. Yalnızca yüklü parçacıklar iyonlaştırıcıdır ve bu nedenle yörüngeleri doğrudan gözlemlenebilir. Nötr parçacıklar ya birkaç yüklü parçacığa bölündüklerinde ya da algıcın kendi içinde etkileşime girerek yüklü parçacıkların emisyonuna yol açtığında, yalnızca dolaylı olarak tespit

edilir. Görselleştirme algıçların en önemli özelliklerinden biri yavaş olmalarıdır. Bunların çalışma şekli, etkileşimlerin ardışık kayıtları arasında nispeten uzun bir gecikmeye neden olur. Ek olarak, görsel teknikler her etkileşimin ayrıntılı bir şekilde incelenmesine izin vermesine rağmen, sonuçların oldukça yavaş kullanılmasına yol açar ve bu nedenle elde edilen verilerin istatistiksel olarak sınırlandırılmasından zarar görür. Görselleştirme algıçları parçacık fiziğinde nadir görülen olayları incelerken hayati bir rol oynamıştır.

*Tablo 1. Algıçların Temel Özellikleri*

<b>Algıç adı</b>	<b>Wilson Bulut Odası</b>	<b>Glaser Köpük Odası</b>	<b>Charpak Tel Odası</b>
<b>Keşif tarihi</b>	1911 yılında Charles T.R. Wilson	1952 yılında Donald A. Glaser	1968 yılında Georges Charpak
<b>Süresi</b>	1920-1950 yılları	1950-1970 yılları	1970-1990 yılları
<b>Algıç türü</b>	Görselleştirme Algıçı	Görselleştirme Algıçı	Elektronik Algıç
<b>Malzemesi</b>	Su ve alkol buharı	Sıvı hidrojen	Argon gazı
<b>Algıç yapısı</b>	Silindirik cam oda ve piston	Silindirik cam oda ve piston	Cam oda ve yüksek voltajlı bir dizi ince tel
<b>Parçacık işareti</b>	İzleri gözlemeleme	İzleri gözlemeleme	Bilgisayarla okuma
<b>Keşfedilen parçacıklar</b>	1932'de Pozitron 1936'da Müon 1947'de Kaon	Kuarkların varlığı ile bir dizi yeni atom altı parçacık	W ve Z bozonları, Tau-lepton, egzotik kuark ve üst kuarklar
<b>Alınan ödül</b>	1927 yılında Nobel Fizik Ödülü	1960 yılında Nobel Fizik Ödülü	1992 yılında Nobel Fizik Ödülü

Tablo 1'de verilen Charpak Tel Odası Algıçı ise elektronik algıçtır. Bu algıç bir parçacığın geçişini elektrik darbesine dönüştürür. Büyük miktardaki bilginin hızlı bir şekilde işlenmesine olanak sağlar. Bu tür algıçlar parçacıkları saymak, ortalama akışlarını, enerjilerini, uzaysal

konumlarını ölçmek veya doğalarını belirlemek için kullanılır. Genel bir kural olarak, nihai elektrik darbesi, parçacıkların algıç ortamından geçişine bağlı olarak radyasyonun elektromanyetik etkileşimi tarafından kontrol edilir.

### 3.5. Güçlü ve Zayıf Yönleri

Araştırmada Wilson Bulut Odası Algıç, Glaser Köpük Odası Algıç ve Charpak Tel Odası Algıcının güçlü ve zayıf yönleri de incelenmiştir.

*Algıçların güçlü yönleri;* genel olarak basit ve kolay uygulanabilir olması, kullanılan malzemelerin kolay bulunması ve laboratuvar ortamında uygulanması karşımıza çıkmaktadır. Charpak Tel Odası Algıcının güçlü yönü ise elektronik algıç olması, bilgisayar kullanılması, çok miktardaki bilginin hızlı bir şekilde işlenmesine olanak sağlamasıdır.

*Algıçların zayıf yönleri;* Wilson Bulut Odası ve Glaser Köpük Odası Algıcının görselleştirme algıç olması, fotoğraflara dayalı yöntemler kullanılması, sürekli fotoğraf çekilmesi, resimlerin incelenmesi ve gereksizlerin ayıklanmasının uzun sürmesi,

- Wilson Bulut Odası ve Glaser Köpük Odası Algıcının günümüzde artık kullanılmaması,
- Parçacık izlerinin hassas bir şekilde ölçülememesi ( Puzo, 2017),
- İlginç olayları bulmak için fotoğrafları görsel olarak incelemenin zaman alması,
- Parçacık türünü ayırt etmenin ve nötr parçacıkları gözlemlemenin zorluğu,
- Veriyi kayıt altına alacak sistem ve saklama ortamının olmaması,
- Manyetik alan altında çalışmanın güçlüğü, gibi sıralanabilir.

### 3.6. Benzer ve Farklı Yönleri

Araştırmada Wilson Bulut Odası Algıcı, Glaser Köpük Odası Algıcı ve Charpak Tel Odası Algıcının benzer ve farklı yönleri de incelenmiştir. Sonuçlar Tablo 2’de verilmiştir.

Tablo 2. Algıçların Benzer ve Farklı Yönleri

Benzer Yönler	Farklılıklar
Hepsi laboratuvar ortamında kullanılan algıçlardır.	Bulut Odası Algıcında su ve alkol buharı, Köpük Odası Algıcında sıvı hidrojen, Tel Odası Algıcında argon gazı ve yüksek voltajlı bir dizi tel kullanılmıştır.
Hepsinde cam bölmeden bir oda vardır.	Bulut ve Köpük Odası Algıcı görselleştirme algıdır. Tel Odası Algıcı elektronik algıdır.
Hepsi aşamalı olarak geliştirilmiştir.	Bulut Odası ve Köpük Odası Algıcında parçacık izleri görsellerden incelenir. Tel Odası Algıcında elektronik okuma yapılır.
Hepsi Nobel Fizik Ödülü almıştır.	Bulut ve Köpük Odası Algıcı işlevsel değildir. Tel Odası Algıcı işlevselliğini halen korumaktadır.
Hepsi sonraki deneylere ışık tutmuş, parçacık fiziğine yön vermiştir.	Bulut Odası ve Köpük Odası Algıcında parçacık izlerini incelemek yavaş ve zordur. Tel Odası Algıcında hızlı ve kolaydır.

Tablo 2’de görüldüğü gibi algıçların hepsi laboratuvar ortamında kullanılmış, aşamalı olarak geliştirilmiş, Nobel ödülü almış ve parçacık fiziğinin geleceğine yön vermiştir. Algıçların farklı yönleri olarak kullanılan malzeme, parçacık izlerini incelemenin kolaylık ve zorluğu ile işlevsel olup olmaması karşımıza çıkmaktadır.

#### 4. Sonuç


Atom altı parçacıklar çıplak gözle direk görme şansımızın olmadığı ancak dolaylı olarak bazı ipuçlarından hareketle özellikleri saptanabilen parçacıklardır. Bilim insanları onları keşfetmek için çok hassas araçlar tasarlamakta ve kullanmaktadırlar. Bunlara algıç denilmektedir. Tarihsel süreç içerisinde çok sayıda algıç üretilmiştir. Bu araştırmada parçacık fiziğinin geleceğine yön veren Wilson Bulut Odası Algıç, Glaser Köpük Odası Algıç ve Charpak Tel Odası Algıç incelenmiş, temel özellikleri, güçlü ve zayıf yönleri, benzer ve farklı yönleri ortaya çıkarılmıştır. Bu algıçlarla birlikte parçacık fiziği yeni bir çağa girmiştir. Bulut Odası Algıçıyla 1932'de Pozitron, 1936'da Müon, 1947'de Kaon keşfedilmiştir. Köpük Odası Algıç ile kuarkların varlığı ile bir dizi yeni atom altı parçacık bulunmuştur. Charpak Tel Odası Algıç, çok daha yüksek parçacık çarpışma oranlarında deneyler yapmanın, nadir olayların ve yeni büyük parçacıkların keşfini öngören teorileri test etmenin yolunu açmıştır. Ardından CERN'deki W ve Z bozonları, SLAC ve Brookhaven'daki çekicilik kuarkı ve Fermilab'daki üst kuarkın keşifleri gerçekleştirilmiştir. Günümüz parçacık fiziğindeki araştırmaların çoğu bu algıçlara dayalı olarak devam etmektedir. Geçmişte bir kıvılcım ile başlatılan süreç günümüzde daha gelişmiş sistemlerle, daha yüksek enerjilerde çalışma olanağı sunmaktadır. Sonuç olarak algıçlar geçmişten günümüze parçacık fiziğinin kalbi konumundadır, olmaya da devam edecektir.

**KAYNAKLAR**

- Anderson, C. D. (1933). The Positive Electron. *Physical Review* 43, 491–494. doi:10.1103/PhysRev.43.491
- Barron, S.L. (1952). C.T.R Wilson and The Cloud Chamber, Cambridge Monograph No.4. CERN Libraries, Geneva.
- Barti, W. & Regler, M. (1992). 1992 Nobel Prize for Physics. Wire Chambers for Exploring the Elementary Constituents of Matter, *Europhysics News* Vol. 23, No. 10, pp. 184–186.
- Britannica (2025). Biography/Donald-A-Glaser, <https://www.britannica.com.translate.googleusercontent.com/translate/g/biography/Donald-A-Glaser>.
- CERN (2004). CERN70: An electronic revolution, *Infinitely CERN*, published to celebrate CERN's 50th anniversary.
- CERN (2025). Mode d'emploi d'un détecteur, <https://home.cern/science> adresinden 08.01.2025 tarihinde erişilmiştir.
- Cloudylabs (2025). Une trace pour chaque particule, <https://www.cloudylabs.fr> ... adresinden 13.01.2025 tarihinde erişilmiştir.
- Encyclopedia Universalis (2025). Détecteurs de particules, <https://www.universalis.fr> adresinden 16.01.2025 tarihinde erişilmiştir.
- Futura Sciences (2025). Donald Glaser, l'inventeur de la chambre à bulles, est décédé <https://www.futura-sciences.com> adresinden 11.01.2025 tarihinde erişilmiştir.
- Goulette, M. (2013). Les détecteurs en physique des particules, CERN.
- Linda Hall Library (2025). C. T. R. Wilson, scientist of the day, <https://www.lindahall.org/about/news/scientist-of-the-day/c-t-r-wilson/> adresinden 25.01.2025 tarihinde erişilmiştir.
- Marleau, L. (2007). Introduction a la physique des particules. Departement de physique Université Laval, Quebec, Canada.
- Puzo, P. (2017). Conception de détecteurs pour la physique des hautes énergies, Ecole IN2P3, De la physique au détecteur, Bénodet.
- Roy R. R., Van de Leemput, Étienne M. (1954). Description d'une chambre de Wilson. In: *Bulletin de la Classe des sciences*, tome 40, 1954. pp. 625-629; doi : <https://doi.org/10.3406/barb.1954.69103> .

- The Guardian (2025). Georges Charpak obituary | Physics, <https://www.theguardian.com>. adresinden 16.01.2025 tarihinde erişilmiştir.
- University of California (2013). İn Memoriam Donald Arthur Glaser, 1926-2013, [https://senate-universityofcalifornia-edu.translate.google.com/files/inmemoriam/DonaldArthurGlaser.html?\\_x\\_tr\\_sl=en&\\_x\\_tr\\_tl=tr&\\_x\\_tr\\_hl=tr&\\_x\\_tr\\_pto=sc](https://senate-universityofcalifornia-edu.translate.google.com/files/inmemoriam/DonaldArthurGlaser.html?_x_tr_sl=en&_x_tr_tl=tr&_x_tr_hl=tr&_x_tr_pto=sc)
- Wikipedia, (2025). [https://en.wikipedia.org/wiki/Bubble\\_chamber](https://en.wikipedia.org/wiki/Bubble_chamber). adresinden 17.01.2025 tarihinde erişilmiştir.
- Wilson, C. T. R. (1912). On an Expansion Apparatus for Making Visible the Tracks of Ionising Particles in Gases and Some Results Obtained by Its Use. Proceedings of the Royal Society of London. Series A, Containing Papers of a Mathematical and Physical Character, 87(595), 277–292. <http://www.jstor.org/stable/93225>.
- Woithe, J. (2016). Cloud Chamber. Do-it-yourself manual, Brought to you by the S’Cool LAB team, <http://cern.ch/s-cool-la>.
- Yakın, F. (2010). Georges Charpak, [https://www-theguardian-com.translate.google.com/science/2010/oct/07/georgescharpakobituary?\\_x\\_tr\\_sl=en&\\_x\\_tr\\_tl=tr&\\_x\\_tr\\_hl=tr&\\_x\\_tr\\_pto=sc](https://www-theguardian-com.translate.google.com/science/2010/oct/07/georgescharpakobituary?_x_tr_sl=en&_x_tr_tl=tr&_x_tr_hl=tr&_x_tr_pto=sc) adresinden 17.01.2025 tarihinde erişilmiştir.
- Yıldırım, A., & Şimşek, H. (2008). Sosyal Bilimlerde Nitel Araştırma Yöntemleri. Ankara: Seçkin Yayınları.





**BIYOKÜTLE KAYNAKLI AKTİF KARBONLAR:  
SENTEZ, AKTİVASYON VE UYGULAMALARI**

*Hilal ÇELİK KAZICI<sup>1</sup>*

---

<sup>1</sup> Doç. Dr., Van Yüzüncü Yıl Üniversitesi, Fen Fakültesi, Kimya Bölümü 0000-0003-4603-6917

## 1. GİRİŞ

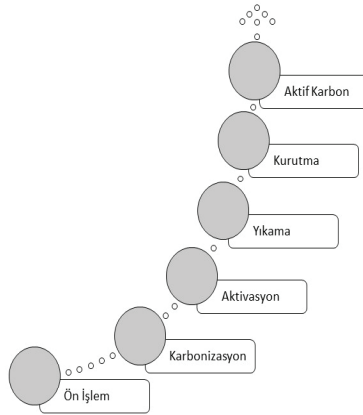
Biyokütle kaynaklı karbon malzemeleri, geniş bir kaynak yelpazesi ve düşük maliyetleri ile dikkat çekmektedir. Bu malzemeler, bol miktarda heteroatom içerir. Karbonizasyon işleminden sonra, heteroatom doping yapısının korunması, karbon malzemelerinin elektronik yapısını ayarlayarak hidrojenin adsorpsiyon ve desorpsiyonunu optimize ederken yüksek iletkenlik sağlar. Karbon iskelet yapısının korunması, kendi kendine destekleyen elektrotların inşa edilmesini mümkün kılar ve film oluşturma ajanlarının kullanımına gerek kalmadan mükemmel bir elektron transfer hızı elde edilir. Aynı zamanda, biyokütle malzemelerinin doğal gözenekli yapısı ve zengin fonksiyonel grupları, yüksek özgül yüzey alanı ve hidrofiliklik özellikleri sağlar. Bu, sıvıların adsorpsiyonu ve gazların desorpsiyonu üzerinde doğrudan etkili olup, biyokütle kaynaklı karbon malzemelerini katalizör materyali olarak büyük bir avantaja dönüştürür. Karbon, grafit, elmas gibi allotroplara sahip olup, nanoskalada fullerene, karbon nanotüpleri (CNT) ve grafen gibi farklı formlarda bulunur. Karbon bazlı malzemeler arasında, Biyokütle Türevli Aktif Karbon (BTAC), kolay bulunabilirliği ve diğer karbon kaynaklarına kıyasla düşük maliyetli üretimi ve yüksek verimi nedeniyle ticari uygulamalar için önemli kabul edilmektedir. Diğer karbon kaynaklarıyla karşılaştırıldığında, BTAC'nin üretiminde daha fazla verim elde edilebilir.

Çeşitli biyokütle türevlerinden veya kaynaklarından elde edilen BTAC, yüksek yüzey alanı, ayarlanabilir gözeneklilik, kimyasal stabilite, iyi elektriksel iletkenlik, çevre dostu özellikler ve mükemmel döngüsel stabilite gibi üstün fizikokimyasal özellikleri nedeniyle sürdürülebilir enerji depolama uygulamaları için yaygın olarak incelenmiştir. Biyokütle kaynaklı aktif karbon üretimi, karbonizasyon ve aktivasyon olmak üzere iki temel aşamadan oluşur. Karbonizasyon işlemi, biyokütlenin oksijensiz ortamda yüksek sıcaklıklara maruz bırakılarak karbon içeriğinin yoğunlaştırılmasıyla gerçekleştirilir. Ardından aktivasyon süreci, karbon malzemesinin gözeneklilik ve yüzey alanı özelliklerini iyileştirmek için uygulanır. Bu süreçler, aktif karbonun spesifik uygulamalar için optimize edilmesini sağlar. Bu bölümde, biyokütle kaynaklı aktif karbonların üretim süreçleri, aktivasyon yöntemleri ve çeşitli uygulamalarına dair bir inceleme sunulacaktır.

## 2. BİYOKÜTLE KAYNAKLI AKTİF KARBON ÜRETİMİ

Biyokütleyi aktif karbona dönüştürmek, ham biyokütleyi yüksek gözenekliliğe ve reaktif özelliklere sahip karbon malzemelerine dönüştüren bir dizi önemli süreçten oluşur. Bu süreçte, karbonizasyon ve aktivasyon sıcaklıkları, ısıtma hızı, işlem süresi, aktif ajanlar, emdirme oranı, em-

dirme süresi ve heteroatom dopantları gibi parametreleri değiştirmek için farklı alt süreçler kullanılır. Şekil 1, BTAC sentezinde yer alan önemli süreçler ve alt süreç değişikliklerini göstermektedir (Yang ve ark., 2020). Bu malzemeler, karbonizasyon ve aktivasyon işlemleri uygulanarak yüksek gözenekliliğe sahip aktif karbonlara dönüştürülür.



Şekil 1. BTAC sentezinde yer alan önemli süreçler

**Tek Adımlı Kimyasal Aktivasyon:** Karbonizasyon (piroliz) ve aktivasyon adımlarını birleştiren tek adımlı kimyasal aktivasyon sürecinde, biyokütle prekürsörü doğrudan kimyasal aktivasyon ajanları ile emdirilir. Bu işlem sırasında aril-etir bağlarının çözülmesi ve karbon iskeletinde gözenekler bırakan uçucu yan ürünlerin salınımı gerçekleşir. Daha yüksek aktivasyon sıcaklıkları, yüksek yüzey alanları ve gözenek hacimleri elde edilmesini sağlasa da belirli bir sıcaklık limitinin aşılması gözenek çökmesine yol açabilir. Bu durum, yüksek sıcaklıklarda karbonun parçalanması ve gözenek yapısının bir parçası olan uçucu moleküllerin hızla salınması nedeniyle gerçekleşir. Gözenek çökmesinin bir diğer önemli nedeni de yüksek ısıtma hızlarıdır; daha düşük hızlar, uçucu gazların daha kontrollü bir şekilde salınmasını sağlar ve gözenek çökmesini azaltabilir (Yan ve ark., 2023).

**Tek Adımlı Aktivasyon ile Sentez:** Tek adımlı aktivasyon ile sentezlenen BTAC, genellikle düşük paket yoğunluğuna ve verime sahiptir (bu durum, aktivasyon protokollerinde doğru deoksijenasyon sağlanarak hafifletilebilir). Elektrot paket yoğunluğu, aşağıdaki denklemle hesaplanabilir:

$$p = \frac{m}{\pi r^2 h} \quad (1)$$

Burada  $p$ , elektrot paket yoğunluğunu;  $m$ , aktif elektrot malzemesinin kütlesini;  $h$ , elektrotun kalınlığını ve  $r$ , elektrotun çapını ifade eder (Li ve ark., 2021).

*Çift Adımlı Aktivasyon:* Karbonizasyon ve ardından aktivasyon işlemiyle gerçekleştirilen çift adımlı aktivasyon, karbon içeriğini artırır ve oksijen ile karbon arasındaki oranı düşürür. Aktivasyon adımında, daha az oksitleyici gazın karbon yapısından kaçması sağlanır, bu da kontrollü bir gözenek ağının oluşmasına yol açar. Bu süreç, BTAC'ın daha verimli ve özellikleri optimize edilmiş bir şekilde üretilmesini sağlar (Altwater & Mokaya, 2020). Karbonizasyon süreci, biyokütlenin inert bir atmosferde 400–900°C sıcaklıklara kadar ısıtılmasıyla gerçekleştirilir. Bu işlem sırasında, biyokütlenin içeriğindeki uçucu bileşenler uzaklaştırılarak karbon oranı arttırılır. Karbonizasyonun etkinliği, kullanılan biyokütle türüne ve işlem parametrelerine bağlı olarak değişiklik gösterebilir. Daha yüksek sıcaklıklarda yapılan karbonizasyon, karbon verimini artırırken aşırı sıcaklık, gözenek yapısını bozarak adsorpsiyon kapasitesini olumsuz etkileyebilir (Raut, Bedmohata, & Chaudhari, 2023).

### 3. AKTİVASYON YÖNTEMLERİ

Biyokütle karbon malzemeleri, safsızlıkları gidermek ve iyi iletkenliğe sahip katalizörler veya matris malzemeleri hazırlamak için yüksek sıcaklıkta doğrudan pirolize edilebilir. Ancak, genel olarak biyokütle karbon bazlı malzemeler, katalizör malzemeleri hazırlama sürecinde yüzey alanını genişletmek ve yüzey fonksiyonel gruplarını modifiye etmek amacıyla aktivasyon edilmesi gerekir. Bu süreçte, kristalin yapısı iyileştirilir ve gözenekli bir yapı oluşur. Biyokütle karbon bazlı malzemelerin aktivasyon yöntemleri genellikle fiziksel aktivasyon ve kimyasal aktivasyon olarak sınıflandırılır. Ayrıca, şablon aktivasyonu, mikrodalga veya ultrasonik destekli aktivasyon, vakumlu aktivasyon gibi bazı diğer yöntemler de mevcuttur (Zhao ve ark., 2014).

#### 3.1 BTAC Sentezinde Kritik Faktörler

##### 3.1.1 Ön İşlem

İlk karbonizasyon aşamasından önce biyokütle kaynağının hazırlanması birçok yönden faydalı olabilir. Hidrotermal bazlı ve etanol ile ıslatma ön işlemlerinden geçirilerek kimyasal/fiziksel aktivasyon uygulanmış şeker kamışı bagasından elde edilen hiyerarşik gözenekli aktif karbon (HPAC), ön işlem uygulanmadan hazırlanan diğer BTAC elektrotlarına

kıyasla daha yüksek mikrogözeneklilik, kapasite (Cs) ve hız performansı göstermiştir (Nezafat ve ark., 2024). Biyokütle selülozunun şişme destekli sentezi, HPAC üretmek için kullanılan başka bir stratejidir. Bu ön işlemden pamuk, NaOH/üre çözeltisine batırılarak şişmesi sağlanır. Daha sonra uygulanan karbonizasyon süreci, selülozun şişmesine neden olarak, moleküller arası ve molekül içi hidrojen bağlarının önemli ölçüde bozulmasına yol açar. Bu da polimerleşme derecesini azaltarak ortaya çıkan HPAC'nin yüzey alanını artırır (Liu ve ark., 2016). Selüloz bozunma mekanizmasını detaylandıran çalışmalara göre, bu süreç birkaç faktörle açıklanabilir:

- Na<sup>+</sup> iyonlarının düşük iyonik yarıçapı ve yüksek yük yoğunluğu sayesinde selüloza kolayca nüfuz edebilmesi,
- Üre hidratlarının, çözünme sürecinde oluşarak selüloz zincirlerinin birbirine yaklaşmasını engellemesi ve böylece dağınık halde kalmalarını sağlaması,
- Elektron çiftlerinin, çözücü iyon değişim etkileşimlerini kolaylaştırması.

Bununla birlikte, selülozun yanı sıra lignin oranı yüksek olan biyokütle öncüllerinde, H<sub>3</sub>PO<sub>4</sub> en uygun moleküldür. Çünkü pirofosfatlar oluşturarak biyokütleyi etkili bir şekilde bozundurulur. Bu bileşikler son derece aşındırıcı ve oksitleyici özellik göstererek maksimum gözenek oluşumunu sağlar (Cai & Na, 2005).

### 3.1.2 Farklı Aktivatörlerin Mekanizması

Karbonizasyon sonrası, biyokütle bazlı karbon malzemeleri, öncüllerinin morfolojisine bağlı olarak çok sayıda heteroatom içeren karbon yapıları oluşturur. Katalizör malzemelerinin gereksinimlerini karşılayabilmesi için, elde edilen karbon malzemelerinin özgül yüzey alanının ve aktif bölge sayısının artırılması genellikle kimyasal aktivasyon ile sağlanır. Kimyasal aktivasyon sürecinde, karbon malzemelerinin gözenek oluşumu ve gözenek genişlemesi üç temel mekanizma ile gerçekleşir:

1. Aktif metal iyonları, yüksek sıcaklıkta karbon atomlarıyla tepkimeye girerek karbonatlar oluşturur. Daha sonra bu karbonatlar bozunarak gözeneklerin oluşmasını sağlar.
2. Aktivatördeki güçlü polar iyonlar, karbon iskeleti üzerinde belirli bir derecede aşındırma (etching) etkisi yaratır.
3. Biyokütle öncül malzemesinde aktivatör tarafından oluşturulan şişme etkisi, malzeme içinde boşluklar meydana getirir.

Diğer aktivasyon yöntemleriyle karşılaştırıldığında, kimyasal aktivasyonun belirgin özellikleri şunlardır (Wang & Kaskel, 2012):

- Düşük aktivasyon sıcaklığı,
- Kısa aktivasyon süresi,
- Yüksek karbon verimi,
- Geniş özgül yüzey alanı,
- Zengin ve gelişmiş gözenek yapısı.

Farklı aktivatör türlerine bağlı olarak biyokütle karbon malzemeleri üzerindeki aktivasyon mekanizmaları detaylı olarak ele alınacaktır.

### 3.1.3 Aktive Edici Maddeler

Kimyasal aktivasyonun mekanizması ve elde edilen ürünün özellikleri, büyük ölçüde kullanılan aktivatörün türüne bağlıdır. Bu reaksiyon, karbon atomlarının ayrılmasına ve gazların salınmasına yol açarak, aktif karbon iskeletinde bol miktarda gözenek yapısının oluşmasına neden olur. Aktivator, öncelikle hammaddenin dehidrate olmasına veya erozyona uğramasına neden olarak, ardından karbon yapısında gözeneklerin oluşmasını sağlar. Genel olarak, kimyasal aktive edici maddeler şu şekilde sınıflandırılabilir:

- Alkaliler: KOH (Potasyum hidroksit), NaOH (Sodyum hidroksit)
- Asitler: H<sub>2</sub>SO<sub>4</sub> (Sülfürik asit), H<sub>3</sub>PO<sub>4</sub> (Fosforik asit)
- Oksitleyiciler: H<sub>2</sub>O<sub>2</sub> (Hidrojen peroksit), KMnO<sub>4</sub> (Potasyum permanganat), K<sub>2</sub>FeO<sub>4</sub> (Potasyum ferrat)
- Tuzlar: K<sub>2</sub>CO<sub>3</sub> (Potasyum karbonat), FeCl<sub>3</sub> (Demir(III) klorür), FeCl<sub>2</sub> (Demir(II) klorür), KHCO<sub>3</sub> (Potasyum bikarbonat), ZnCl<sub>2</sub> (Çinko klorür)

Bu aktivatörler, karbon malzemelerinin gözenek yapısını geliştirmek, yüzey alanını artırmak ve katalitik özelliklerini optimize etmek amacıyla kullanılmaktadır (Rajesh ve ark., 2020).

### 3.1.4 Emprenye Oranının Önemi

Emprenye oranı, BTAC üretiminde kritik bir parametredir. Bu oran, aktifleyici ajan (örneğin, KOH, H<sub>3</sub>PO<sub>4</sub>, ZnCl<sub>2</sub>) ile biyokütle öncüsü arasındaki kütle oranı olarak tanımlanır. Emprenye oranı, gözenek oluşumu, yüzey kimyası ve nihai karbon malzemesinin dokusal özellikleri üzerinde

önemli bir etkiye sahiptir. Emprenye oranının dikkatlice optimize edilmesi, süperkapasitörler, piller, adsorpsiyon ve kataliz gibi alanlarda özelleştirilmiş aktif karbon malzemeleri tasarlamayı mümkün kılar (Balasubramanian et al., 2020). Literatür incelendiğinde; yer fıstığı kabuklarının NaOH bazlı BTAC sentezi sırasında kullanılan 1:2 ile 1:3 arasındaki farklı emprenye oranları ile, özgül yüzey alanının  $584 \text{ m}^2 \text{ g}^{-1}$  den  $826 \text{ m}^2 \text{ g}^{-1}$  e ve gözenek boyutunun  $1.8 \text{ nm}$ 'den  $2.1 \text{ nm}$ 'ye arttığı rapor edilmiştir. Bu artış, daha yüksek emprenye oranlarının daha fazla dehidrasyona yol açması, bunun sonucunda daha fazla iyonun karbon iskeletine yerleşerek gözenek genişlemesini teşvik etmesiyle ilişkilendirilmiştir (Pandey et al., 2021).

(Ergun & Bulbul, 2022) çalışmasında, kavak ağacının artıklarından kimyasal aktivasyon yöntemiyle aktif karbon üretmiştir. NaOH,  $\text{K}_2\text{CO}_3$  ve  $\text{Na}_2\text{CO}_3$  kimyasal maddeleri kullanılarak, emdirme oranları 1/1, 2/1 ve 3/1 olarak belirlenmiş olan çalışmada aktivasyon sıcaklıkları NaOH ile 600, 700, 800 °C;  $\text{K}_2\text{CO}_3$  ve  $\text{Na}_2\text{CO}_3$  ile ise 800 ve 900 °C olarak uygulanmıştır. En yüksek yüzey alanının ise NaOH ile 3/1 emdirme oranında ve 800 °C'de  $973 \text{ m}^2\text{g}^{-1}$ ,  $\text{K}_2\text{CO}_3$  ile  $1596 \text{ m}^2\text{g}^{-1}$  ve  $\text{Na}_2\text{CO}_3$  ile  $1579 \text{ m}^2\text{g}^{-1}$  elde edildiği belirtilmiştir. (Angın, 2014) tarafından yapılan bir çalışmada, vişne çekirdeklerinden elde edilen aktif karbonun sulu çözeltiden Yellow 18 tekstil boyasının giderilmesinde, farklı temas süreleri, pH değerleri ve çözelti sıcaklıklarının etkisi incelenmiştir. Vişne çekirdekleri, kimyasal aktivasyon için  $\text{ZnCl}_2$  ile 3:1 ( $\text{ZnCl}_2$ : vişne çekirdeği) emdirme oranında karıştırılmış ve 700 °C'de iki saatlik karbonizasyon işlemi uygulanmıştır. Elde edilen aktif karbonun yüzey alanı  $1704 \text{ m}^2\text{g}^{-1}$ , gözenek hacmi ise  $0,984 \text{ cm}^3\text{g}^{-1}$  olarak belirlenmiştir. Sun ve ark. çalışmasında, çam fıstığı kabuklarının aktivasyonu için melamin ve KOH birlikte kullanılmıştır. Melamin, g- $\text{C}_3\text{N}_4$  bileşiğine dönüşerek  $\text{NH}_3$ ,  $\text{C}_2\text{N}_2^+$ ,  $\text{C}_3\text{N}_2^+$  gibi yüksek aktiviteye sahip bileşenlere ayrışır ve bu bileşenler, karbonun stabil kısmını etkili bir şekilde aşındırır. Melaminin ortak aktivasyonu, azot atomu doygunluğu sağlar ve piridin ile grafit azotları, iyon transferini hızlandırarak elektro kimyasal performansı artırır. Özellikle piridin ve pirrol azotu içeriği yüksek olup, bu azotlar alkalın çözeltilerde ek bir Faraday kapasitansı sunar. Çalışmada, çam fıstığı kabuğu, KOH ve melaminin 1:3:1 kütle oranında kullanılmasıyla elde edilen karbon malzemesinin özgül yüzey alanı  $1847 \text{ m}^2/\text{g}$  olarak belirlenmiş, bu değer piridin ve pirrol azotu içeriği sayesinde elektro kimyasal performans açısından en iyi sonuçları sağladığı raporlanmıştır (Sun ve ark., 2020).

#### 4. AKTİF KARBONUN UYGULAMALARI

Aktif karbon, benzersiz yüzey özellikleri, yüksek adsorpsiyon kapasitesi ve geniş gözenek yapısıyla çeşitli endüstriyel ve çevresel uygulamalarda yaygın olarak kullanılmaktadır. Kimyasal aktivasyon ve fiziksel akti-

vasyon yöntemleriyle üretilen bu malzeme, özellikle kirletici maddelerin giderilmesinde, gaz ve sıvı filtrasyonunda, enerji depolama sistemlerinde ve tıbbi alanda önemli roller üstlenmektedir. Bu raporda, aktif karbonun farklı uygulama alanlarına dair detaylı bir inceleme ve örnekler verilecektir.

### *Çevresel Uygulamalar: Su ve Hava Temizliği*

Aktif karbonun en bilinen uygulamalarından biri su ve hava temizliğidir. Aktivasyonu sayesinde yüksek yüzey alanı elde eden bu malzeme, özellikle su arıtma sistemlerinde organik kirleticilerin ve ağır metallerin adsorpsiyonunda etkili bir şekilde kullanılır. Örneğin, aktif karbon, içme suyundaki klorlu bileşenleri ve pestisitleri etkin bir şekilde temizleyebilir. Endüstriyel atık sularından toksik bileşenlerin, deterjanların, solventlerin ve renk maddelerinin giderilmesinde aktif karbon, ekonomik ve verimli bir çözüm sunmaktadır. Bir başka örnek, aktif karbonun hava temizliğinde kullanımınıdır. Özellikle, gıda işleme tesislerinde ve kimyasal üretim tesislerinde salınan zararlı gazlar, aktif karbonla filtrelenerek hava kalitesinin korunmasına yardımcı olur. Ayrıca, hava arıtma sistemlerinde aktif karbon, özellikle amonyak ve metan gibi gazların adsorpsiyonunda kullanılır (Njewa & Shikuku, 2023).

### *Enerji Depolama ve Elektriksel Uygulamalar*

Aktif karbon, son yıllarda enerji depolama sistemlerinde de önemli bir malzeme olarak karşımıza çıkmaktadır. Özellikle süperkapasitörler ve pillerde enerji depolama kapasitesini artırmak amacıyla kullanılır. Aktif karbonun büyük yüzey alanı ve yüksek gözenek yapısı, elektrik yüklerinin depolanmasını ve hızlı salınımını sağlar. Örneğin, elektrikli araçlarda kullanılan süperkapasitörler, aktif karbon kullanılarak enerji depolama kapasitesinin artırılmasını sağlar. Bir araştırmada, aktif karbonla yapılan süperkapasitörlerin enerji yoğunluğu 10.000 döngü sonrasında %90'a varan bir kapasite kaybı göstermemektedir. Ayrıca, aktif karbonun, yenilenebilir enerji sistemlerinde enerji depolamak için kullanıldığına dair örnekler de mevcuttur (Sevilla & Mokaya, 2013). Güneş ve rüzgar enerjisi gibi yenilenebilir enerji kaynakları, değişken enerji üretim profilleri gösterdiğinden, aktif karbon bazlı enerji depolama sistemleri, enerjinin daha verimli bir şekilde depolanmasını ve kullanımı sağlamak için önemli bir çözüm sunar.

### *Kimyasal ve Farmasötik Uygulamalar*

Aktif karbon, tıbbi ve kimyasal alanlarda da geniş bir uygulama yelpazesinde kullanılmaktadır. Tıbbi alanda, zehirlenme vakalarında, ilaçların vücutta aşırı birikmesi sonucu oluşan toksik etkilerin giderilme-



sinde kullanılır. Örneğin, aktif karbon, bazı ilaç zehirlenmeleri ve alkol zehirlenmelerinde vücutta biriken toksinleri adsorbe ederek vücuttan atılmasına yardımcı olur. Ayrıca, aktif karbon, kozmetik sektöründe de aktif bir bileşen olarak kullanılır; cilt temizliği ve sivilce tedavisinde etkili olmasının yanı sıra, toksinleri vücuttan atmada yardımcı olur. Kimyasal endüstride ise, aktif karbon, çeşitli reaksiyonlarda katalizör taşıyıcı olarak işlev görebilir. Örneğin, sentetik reaksiyonlar ve katalitik işlemler için kullanılan aktif karbon, endüstriyel kimya süreçlerinde önemli bir rol oynar (Joshi ve ark., 2023).

### *Petrokimya ve Endüstriyel Uygulamalar*

Aktif karbon, petrokimya ve endüstriyel süreçlerde de önemli bir rol oynamaktadır. Petrokimya endüstrisinde, aktif karbon özellikle gazların ayrıştırılması, sıvıların rafinasyonu ve bazı kimyasal maddelerin saflaştırılması işlemlerinde kullanılır. Örneğin, petrol rafinerilerinde aktif karbon, hidrokarbonların ayrıştırılması ve kükürt bileşenlerinin arıtılması için kullanılır. Ayrıca, aktif karbon, doğal gaz işleme tesislerinde de gazların saflaştırılmasında önemli bir bileşendir. Endüstriyel uygulamalarda, aktif karbon, çeşitli çözücüler ve maddeler arasında yapılan distilasyon ve ekstraksiyon işlemlerinde de faydalanılır. Özellikle, organik çözücülerdeki istenmeyen bileşenlerin adsorpsiyonu için kullanılan aktif karbon, üretim verimliliğini artırarak proseslerin daha temiz ve ekonomik olmasına yardımcı olur (Przepiórski, 2006).

### *BTAC'nin Hidrojen Evrim Reaksiyonu (HER) Katalizörlerinin Performansına Etkisi*

Farklı öncü malzemeler, karbonizasyon şemaları ve aktivasyon yöntemleriyle hazırlanan hidrojen evrim reaksiyonu (HER) katalizörlerinin performansı, biyokütle kaynaklı aktif karbon üretimi ve uygulama alanlarında önemli bir rol oynamaktadır. Biyokütle, yenilenebilir ve çevre dostu bir kaynak olarak, enerji üretimi, çevresel temizleme ve çeşitli endüstriyel uygulamalarda kullanılabilir yüksek kaliteli aktif karbon üretimi için potansiyel sunmaktadır. HER katalizörleri, suyun elektriksel ayrışması ile hidrojen üretiminde önemli bir adım olan reaksiyonu hızlandırma kapasitesine sahip materyallerdir ve biyokütle kaynaklı aktif karbonların kullanımı, bu alandaki verimliliği artırabilir. Aktif karbon üretimi için biyokütle kaynaklı malzemeler kullanıldığında, karbonizasyon süreci büyük önem taşır. Karbonizasyon, organik bileşiklerin ısı ile ayrıştırılması işlemi olup, biyokütle malzemesinin karbon yapısına dönüşmesini sağlar. Bu süreçte, kullanılan sıcaklık, atmosfer koşulları ve işlem süresi, elde edilen aktif karbonun fiziksel özelliklerini doğrudan etkiler. Örneğin, lignosülfonat gibi biyokütle kaynakları, yüksek sıcak-

lıklarda karbonizasyon işlemi sonrasında daha yoğun ve stabil karbon yapılarına dönüşür, bu da yüksek yüzey alanı ve mikroporozite sağlar. Bu tür özellikler, aktif karbonun HER katalizörü olarak etkinliğini artırır, çünkü yüksek yüzey alanı iyon adsorpsiyonunu ve elektron iletimini optimize eder (He, Zhang, Li, & Wang, 2021).

Aktivasyon yöntemleri de biyokütle kaynaklı aktif karbon üretiminde kritik bir rol oynamaktadır. Kimyasal aktivasyon yöntemleri, biyokütle malzemelerine genellikle KOH, NaOH,  $ZnCl_2$  gibi reaktif kimyasalların uygulanmasını içerir. Bu kimyasal maddeler, biyokütlenin yapısal bozulmasını ve porozitesinin artmasını sağlayarak, karbon malzemelerinin HER için uygun hale gelmesini destekler. Örneğin, KOH ile yapılan aktivasyon, karbon malzemesinin porozitesini artırarak, protonların ve elektronların geçişini kolaylaştırarak, HER katalizörlerinin verimliliğini artırır. Diğer taraftan,  $ZnCl_2$  ile yapılan aktivasyon, özellikle selüloz bazlı biyokütle malzemelerinde yüksek özgül yüzey alanı elde edilmesini sağlar ve böylece HER performansını artırır (Sahoo ve ark., 2016). Birçok çalışmada, biyokütle kaynaklı aktif karbonların HER performansı farklı öncü malzemelerle karşılaştırılmıştır. (Jiang, 2021) lignosülfonat ile yapılan çalışmada, karbonizasyon sıcaklığının artmasını katalizörün etkinliğini nasıl etkilediğini göstermiştir.  $800\text{ }^\circ\text{C}$ 'de karbonize edilen malzeme,  $Co_3S_4$  varlığı ile verimli bir yük transferi sağlarken, düşük aşırı voltaj değerleri göstererek HER katalizörü olarak başarılı bir performans sergilemiştir. Benzer şekilde, (Atchudanve ark., 2019), magnolia bitkisi ve tioüreyi kullanarak yapılan bir çalışmada, N ve S dopajının karbon yapısındaki düzensizliği artırarak, elektrot materyallerinin iyon adsorpsiyonunu ve elektron iletimini iyileştirdiğini gözlemlemişlerdir. Bu tür çalışmalar, biyokütle kaynaklı aktif karbonların, özellikle düşük maliyetli ve sürdürülebilir hidrojen üretimi için ideal bir seçenek sunduğunu kanıtlamaktadır.

Tablo 1, farklı biyokütle temelli katalizörlerin karbonizasyon, aktivasyon yöntemleri ve bu yöntemlerin hidrojen gelişim reaksiyonu (HER) performansları üzerindeki etkilerini kapsamlı bir şekilde sunmaktadır. Tablo, her bir biyokütle kaynağının karbonizasyon sıcaklıkları, karbonizasyon süreleri, kullanılan atmosfer koşulları ve aktif karbon elde etmek için uygulanan aktivasyon yöntemlerini içermektedir. Ayrıca, her bir katalizörün spesifik yüzey alanı (S), gözenek hacmi (V) ve HER performansını belirleyen önemli elektro-kimyasal parametreler de sunulmaktadır. Bu parametreler arasında,  $10\text{ mAcm}^{-2}$  akım yoğunluğunda aşırı potansiyel ( $\eta_{10}$ ) ve Tafel eğimi (Tafel  $\text{mVdec}^{-1}$ ) yer almaktadır. Çeşitli biyokütle kaynaklarından elde edilen aktif karbonların HER performansları, kullanılan aktivasyon yöntemlerine ve karışıma bağlı olarak farklılık göstermektedir. Örneğin, melamin ve KOH kombinasyonu kullanılarak aktive

edilen çam fıstığı kabuğu, yüksek bir yüzey alanı ( $201.7 \text{ m}^2\text{g}^{-1}$ ) ve elektro-kimyasal performans ( $171 \text{ mV}$  Tafel eğimi,  $0.5 \text{ M H}_2\text{SO}_4$  çözeltisinde) sergilemiştir. Diğer bir örnek ise, çam iğnelerinin KOH ile aktive edilmesiyle elde edilen karbon malzemenin  $1931 \text{ m}^2/\text{g}$  yüzey alanına ulaşmış olmasıdır, ancak bu örnek daha düşük Tafel eğimi ve aşırı potansiyel değerlerine sahiptir. Bunun yanında, mısır sapı ve fıstık kök nodülleri gibi diğer biyokütle kaynakları da, HER performansları açısından dikkate değerdir, ancak her birinin spesifik yüzey alanları ve performansları farklılıklar göstermektedir.

Tablo ayrıca, metal tuzları gibi alternatif aktivatörlerin de biyokütle temelli katalizörlerin etkinliğini artırmada kullanıldığını göstermektedir. Özellikle  $\text{ZnCl}_2$  ile aktive edilen üzüm asmalarından elde edilen karbon malzemeleri,  $224 \text{ mV}$  Tafel eğimi ve  $144 \text{ mV}$   $\eta_{10}$  değerine ulaşmıştır, bu da bu tür aktivasyon yöntemlerinin HER performansı üzerinde belirgin bir iyileşme sağladığını göstermektedir. Diğer yandan, protein ağırlıklı karbon malzemeleri, örneğin ipekböceği kozası gibi, aktivasyon için daha etkili bir reaktan olarak KCl kullanmaktadır.  $\text{ZnCl}_2$ , selülozda benzersiz şişme özelliği sayesinde yüksek özgül yüzey alanına sahip karbon malzemelerinin elde edilmesinde tercih edilen bir aktivatördür.  $\text{H}_3\text{PO}_4$  ile yapılan aktivasyon ise, hidrofilik grupların korunmasına olanak tanır, bu da katalizörün ara yüzey reaksiyonlarını iyileştirmeye yardımcı olur. Ayrıca,  $\text{H}_3\text{PO}_4$ , bazı metal iyonlarının karbon iskeletine fosfat formunda doğrudan entegre olmasına olanak tanır. Bu bağlamda, araştırmacıların, seçilen öncü malzemelere ve karbürleştirme şemalarına dayalı olarak uygun aktivasyon yöntemlerini belirlemeleri gerektiği gibi, enerji tüketimi ve maliyet gibi faktörler de göz önünde bulundurulmalıdır.

Sonuç olarak, biyokütle kaynaklı aktif karbonların HER uygulamalarındaki performansı, kullanılan öncü malzeme, karbonizasyon koşulları ve aktivasyon yöntemlerine bağlı olarak büyük değişiklikler göstermektedir. Bu alandaki araştırmalar, biyokütle temelli aktif karbonların sürdürülebilir hidrojen üretimi için potansiyelini daha da artırmaktadır. Biyokütle kaynaklarının daha verimli bir şekilde işlenmesi ve uygun aktivasyon tekniklerinin geliştirilmesi, HER katalizörlerinin performansını optimize ederek, bu alandaki ticari uygulamalar için önemli bir adım olacaktır.

*Tablo 1: Farklı Biyokütle Tabanlı Katalizörlerin Karbonizasyon, Aktivasyon Yöntemleri ve HER Performansı*

Öncül Malzeme	Geçiş Metali	Karbonizasyon Sıcaklığı (°C)	Süre (h)	Atm	Elektrolit	S (m <sup>2</sup> /g)	V (cm <sup>3</sup> /g)	HER Performansı (η <sub>10</sub> mV, Tafel mV dec <sup>-1</sup> )
Karbon kumaş	-	800	1	H <sub>2</sub> , Ar, CH <sub>4</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	-	-	290, 121 (Li ve ark., 2021)
Sodyum Karbonat	Co	800	1	N <sub>2</sub>	1.0 M KOH	150.7	0.22	262, 96 (Yusuf ve ark., 2021)
Melamin Formaldehit Reçinesi	Co	800	2	Ar	0.5 M H <sub>2</sub> SO <sub>4</sub>	201.7	0.28	171, 81.9 (Sun ve ark., 2018)
Kitosan	Co	600	3	H <sub>2</sub> , Ar	0.5 M H <sub>2</sub> SO <sub>4</sub>	796	-	175.3, 82.1 (Lu ve ark., 2017)
2-metilimidazol	Co, Fe	800	2	N <sub>2</sub>	1.0 M KOH	53.49	0.1	182, 157.8 (Tan ve ark., 2021)
Greyfurt Kabuğu	Ni	700	3	N <sub>2</sub>	1.0 M KOH	43	-	165, 198 (He ve ark., 2021)
Fasulye Filizi	-	800	2	N <sub>2</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	397.15	1.1	413, 98 (Cao ve ark., 2021)
Demirhindi Meyve Kabukları	-	800	2.5	Ar	1.0 M KOH	-	-	221, 204 (Thirumal ve ark., 2022)
Saz Başakları	-	800	2	N <sub>2</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	765	-	248, 135 (Han ve ark., 2019)
Çam İğneleri	-	800	1	N <sub>2</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	1931	-	62, 45.9 (Zhu ve ark., 2017)
Ceviz Kabuğu	-	600	-	-	1.0 M KOH	1037.31	0.51	170, 69.76 (Fu ve ark., 2020)
İpek Fibroin	-	900	4	N <sub>2</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	29.69	-	310.86, 95.93 (He ve ark., 2022)
Koza	Co, W	900	-	N <sub>2</sub>	0.5 M H <sub>2</sub> SO <sub>4</sub>	326.01	-	138.42, 77.47 (He ve ark., 2021)
Glukoz	Co	900	-	-	0.5 M H <sub>2</sub> SO <sub>4</sub>	545.6	0.56	54, 52.8 (Yu ve ark., 2020)
Asma Sürgünleri	Pd	700	2	CO <sub>2</sub>	8 M KOH	1689	0.84	224, 144 (Cardoso ve ark., 2018)
Fıstık Kök Nodu	-	800	2	Ar	0.5 M H <sub>2</sub> SO <sub>4</sub>	-	-	116, 67.8 (Zhou ve ark., 2015)
Biyokütle Lignosülfonat	Co, Al	800	2	N <sub>2</sub>	1.0 M KOH	113.61	0.23	267, 22.93 (Jiang 2021)
Magnolia Liliiflora Çiçekleri	-	450	4	Hava	0.5 M H <sub>2</sub> SO <sub>4</sub>	56	-	75, 73 (Atchudan ve ark., 2019)
Guanin, Karbonhidrat	-	1000	2	N <sub>2</sub>	1.0 M KOH	974	0.84	350, 108 (Huang ve ark., 2017)

## SONUÇ VE PERSPEKTİF

Bu çalışmada, biyokütle kaynaklı aktif karbonların üretimi, aktivasyon yöntemleri ve çeşitli uygulamaları detaylı bir şekilde ele alınmıştır. Biyokütle türevli aktif karbonlar, düşük maliyetleri ve çevre dostu özellikleri ile dikkat çekmekte, aynı zamanda yüksek yüzey alanı, geniş gözenek yapısı ve yüksek iletkenlik gibi avantajlar sunmaktadır. Karbonizasyon ve aktivasyon işlemleri, biyokütle kaynaklı bu karbon malzemelerinin fizikokimyasal özelliklerini optimize etmek için temel süreçlerdir. Özellikle, tek ve çift adımlı aktivasyon yöntemleri, aktif karbonun yüzey alanını arttırarak daha verimli bir katalizör ve enerji depolama malzemesi olarak kullanılmasına olanak tanımaktadır. Biyokütle kaynaklı aktif karbonların üretiminde, kimyasal aktivasyon, fiziksel aktivasyona göre daha verimli sonuçlar verebilmekte ve farklı aktivatörlerin kullanımı ile malzemelerin özellikleri üzerinde hassas ayarlamalar yapılabilmektedir. Ayrıca, empenye oranı ve karbonizasyon sıcaklığı gibi parametrelerin, elde edilen aktif karbonun verimliliği üzerinde büyük etkisi olduğu gözlemlenmiştir. Bu parametrelerin optimize edilmesi, özellikle enerji depolama ve çevresel uygulamalar gibi alanlarda performansı arttırmaktadır.

Biyokütle kaynaklı aktif karbonların en önemli uygulama alanları arasında çevresel uygulamalar, enerji depolama sistemleri ve kimyasal uygulamalar yer almaktadır. Su ve hava temizliği gibi çevresel alanlarda, aktif karbonun yüksek adsorpsiyon kapasitesi ve geniş yüzey alanı, kirleticilerin etkin bir şekilde giderilmesine olanak sağlamaktadır. Aynı şekilde, aktif karbon malzemeleri, süperkapasitörler ve piller gibi enerji depolama sistemlerinde de kullanılarak, yenilenebilir enerji kaynaklarının depolanmasında önemli bir çözüm sunmaktadır.

Sonuç olarak, biyokütle kaynaklı aktif karbonların üretimi ve kullanımını, sürdürülebilir enerji sistemleri ve çevresel temizlik gibi kritik alanlarda büyük bir potansiyele sahiptir. Gelecekte, bu malzemelerin daha verimli ve çevre dostu şekilde üretilebilmesi için yeni yöntemlerin ve optimize edilmiş süreçlerin geliştirilmesi önemlidir.

**REFERANSLAR**

- [1] Yang, X., Kang, K., Qiu, L., Zhao, L., & Sun, R. (2020). Effects of carbonization conditions on the yield and fixed carbon content of biochar from pruned apple tree branches. *Renewable Energy*, 146, 1691–1699. <https://doi.org/10.1016/j.renene.2019.07.148>
- [2] Manimekala, T., Sivasubramanian, R., Dar, M. A., & Dharmalingam, G. (2025). Crafting the architecture of biomass-derived activated carbon via electrochemical insights for supercapacitors: A review. *RSC Advances*, 15(4), 2490–2522. <https://doi.org/10.1039/D4RA07682F>
- [3] Li, Y., Sun, Z., Zhang, L., Zou, Y., Yao, N., Lei, W., Jiang, T., Chen, Y., & Chen, G. Z. (2021). High yield and packing density activated carbon by one-step molecular level activation of hydrophilic pomelo peel for supercapacitors. *Journal of The Electrochemical Society*, 168(6), 060521. <https://doi.org/10.1149/1945-7111/ac0762>
- [4] Zhang, J., Li, Y., Ma, Y., Wang, H., & Zhang, L. (2020). High-performance and sustainable supercapacitor electrodes from carbonized biomass waste via one-step activation. *Energy & Environmental Science*, 13(9), 2719–2728. <https://doi.org/10.1039/D0EE01340D>
- [5] Bedmohata, M. A., Chaudhari, A. R., Singh, S. P., & Choudhary, M. D. (2015). Adsorption capacity of activated carbon prepared by chemical activation of lignin for the removal of methylene blue dye. *International Journal of Advanced Research in Chemical Science (IJARCS)*, 2(8), 1-13. ISSN 2349-039X (Print) & ISSN 2349-0403 (Online).
- [6] Zhao, Y., Zhao, F., Wang, X., Xu, C., Zhang, Z., Shi, G., & et al. (2014). Graphitic carbon nitride nanoribbons: Graphene-assisted formation and synergic function for highly efficient hydrogen evolution. *Angewandte Chemie International Edition*, 53(51), 13934-13939. <https://doi.org/10.1002/anie.201409080>
- [7] Nezafat, Z., Dong, Y., Nasrollahzadeh, M., Shafiei, N., Gharoubi, H., & Javanshir, S. (2024). Recent progress in energy conversion and storage of agricultural waste-derived (carbon/nano)materials: A review. *Green Chemistry*, 26(19), 10687-10717. <https://doi.org/10.1039/D3GC04332K>
- [8] Liu, Y., Shi, Z., Gao, Y., An, W., Cao, Z., & Liu, J. (2016). Graphene-assisted formation of graphitic carbon nitride nanoribbons for highly efficient hydrogen evolution. *ACS Applied Materials & Interfaces*, 8(42), 28283–28290. <https://doi.org/10.1021/acsami.5b11558>
- [9] Cai, J., & Na, N. (2005). Rapid dissolution of cellulose in LiOH/Urea and NaOH/Urea aqueous solutions. *Macromolecular Bioscience*, 5(6), 539-548. <https://doi.org/10.1002/mabi.200400222>
- [10] Wang, J., & Kaskel, S. (2012). KOH activation of carbon-based materials for energy storage. *Journal of Materials Chemistry*, 22(42), 23710–23725. <https://doi.org/10.1039/C2JM34066F>
- [11] Rajesh, M., Manikandan, R., Park, S., Kim, B. C., Cho, W.-J., Yu, K. H., & Raj, C. J. (2020). Pinecone biomass-derived activated carbon: The potential

- electrode material for the development of symmetric and asymmetric supercapacitors. *International Journal of Energy Research*, 44(12), 10268-10282. <https://doi.org/10.1002/er.5548>
- [12] Balasubramanian, M. M., Subramani, M., Murugan, D., & Ponnusamy, S. (2020). Groundnut shell-derived porous carbon-based supercapacitor with high areal mass loading using carbon cloth as current collector. *Ionics*, 26(12), 6297–6308. <https://doi.org/10.1007/s11581-020-03754-8>
- [13] Pandey, L., Sarkar, S., Arya, A., Sharma, A. L., Panwar, A., Kotnala, R. K., & Gaur, A. (2021). Fabrication of activated carbon electrodes derived from peanut shell for high-performance supercapacitors. *Biomass Conversion and Biorefinery*, 13(8), 6737–6746. <https://doi.org/10.1007/s13399-021-01701-9>
- [14] Ergun, A., & Bulbul, R. (2022). Production and characterization of activated carbon from Black Poplar (*Populus nigra*) wood waste with different chemical activation methods. *International Advanced Researches and Engineering Journal*, 6(3), 167–175.
- [15] Angın, D. (2014). Utilization of activated carbon produced from fruit juice industry solid waste for the adsorption of Yellow 18 from aqueous solutions. *Bioresource Technology*, 168, 259–266.
- [16] Sun, Y., Xue, J., Dong, S., et al. (2020). Biomass-derived porous carbon electrodes for high-performance supercapacitors. *Journal of Materials Science*, 55, 5166–5176. <https://doi.org/10.1007/s10853-019-04343-5>
- [17] Njewa, J. B., & Shikuku, V. O. (2023). Recent advances and issues in the application of activated carbon for water treatment in Africa: A systematic review (2007–2022). *Applied Surface Science Advances*, 18, 100501. <https://doi.org/10.1016/j.apsadv.2023.100501>
- [18] Sevilla, M., & Mokaya, R. (2013). Energy storage applications of activated carbons: Supercapacitors and hydrogen storage. *Energy & Environmental Science*, 6(5), 1385-1392. <https://doi.org/10.1039/C3EE43525C>
- [19] Joshi, P. B., Chavali, M., Tripathi, G. K., & Tondwalkar, S. (2023). Medical applications of activated carbon. In *Activated Carbon: Progress and Applications* (1st ed., pp. 42–54). Royal Society of Chemistry. <https://doi.org/10.1039/BK9781839169861-00042>
- [20] Przepiórski, J. (2006). Activated carbon filters and their industrial applications. In *Activated carbon: Progress and applications* (pp. 1-12). Elsevier. [https://doi.org/10.1016/S1573-4285\(06\)80018-9](https://doi.org/10.1016/S1573-4285(06)80018-9)
- [21] He, H., Zhang, Y., Li, Y., & Wang, P. (2021). Recent innovations of silk-derived electrocatalysts for hydrogen evolution reaction, oxygen evolution reaction, and oxygen reduction reaction. *International Journal of Hydrogen Energy*, 46(12), 7848-7865. <https://doi.org/10.1016/j.ijhydene.2020.11.265>
- [22] Sahoo, K., Hawkins, G. L., Yao, X. A., Samples, K., & Mani, S. (2016). GIS-based biomass assessment and supply logistics system for a sustainable biorefinery: A case study with cotton stalks in the Southeastern US. *Applied Energy*, 182, 260-273.

- [23] Jiang, C. (2021). A novel flower-like architecture comprised of 3D interconnected Co-Al-Ox/Sy decorated lignosulfonate-derived carbon nanosheets for flexible supercapacitors and electrocatalytic water splitting. *Carbon*, 184, 386-399. <https://doi.org/10.1016/j.carbon.2021.08.044>
- [24] Atchudan, R., Edison, T. N. J. I., Perumal, S., Parveen, A. S., & Lee, Y. R. (2019). Electrocatalytic and energy storage performance of bioderived sulphur-nitrogen-doped carbon. *Journal of Electroanalytical Chemistry*, 833, 357-369. <https://doi.org/10.1016/j.jelechem.2018.12.007>
- [25] Li, Y., Ai, C., Deng, S., Wang, Y., Tong, X., Wang, X., et al. (2021). Nitrogen-doped vertical graphene as metal-free electrocatalyst for hydrogen evolution reaction. *Materials Research Bulletin*, 134, 111094. <https://doi.org/10.1016/j.materresbull.2020.111094>
- [26] Yusuf, B. A., Xie, M., Yaseen, W., Xie, J., & Xu, Y. (2021). Simultaneous fabrication of cobalt-based graphene with rich N dopant for hydrogen evolution reaction in basic medium. *International Journal of Energy Research*, 45, 14010-14020. <https://doi.org/10.1002/er.6722>
- [27] Sun, X., Zhang, W., Tang, D., Qiao, Z. A., Liu, Y., Liang, D., et al. (2018). Co-entrapped, N-doped mesoporous carbons prepared from melamine formaldehyde resins with  $\text{CoCl}_2$  as template for hydrogen evolution. *Journal of Colloid and Interface Science*, 516, 416-422. <https://doi.org/10.1016/j.jcis.2018.01.091>
- [28] Lu, Z., Wang, J., Huang, S., Hou, Y., Li, Y., Zhao, Y., et al. (2017). N, B-codoped defect-rich graphitic carbon nanocages as high-performance multifunctional electrocatalysts. *Nano Energy*, 42, 334-340. <https://doi.org/10.1016/j.nanoen.2017.11.004>
- [29] Tan, W., Xie, S., Yang, J., Lv, J., Yin, J., Zhang, C., et al. (2021). Effect of carbonization temperature on electrocatalytic water splitting of Fe-Co anchored on N-doped porous carbon. *Journal of Solid State Chemistry*, 302, 122435. <https://doi.org/10.1016/j.jssc.2021.122435>
- [30] He, F., Wang, Y., Zhong, M., Feng, X., Su, B., & Lei, Z. (2021). Construction of nickel nanoparticles embedded in nitrogen self-doped graphene-like carbon derived from waste grapefruit peel for multifunctional OER, HER, and magnetism investigations. *Journal of Environmental Chemical Engineering*, 9, 106894. <https://doi.org/10.1016/j.jece.2021.106894>
- [31] Cao, X., Li, Z., Chen, H., Zhang, C., Zhang, Y., Gu, C., et al. (2021). Synthesis of biomass porous carbon materials from bean sprouts for hydrogen evolution reaction electrocatalysis and supercapacitor electrode. *International Journal of Hydrogen Energy*, 46, 18887-18897. <https://doi.org/10.1016/j.ijhydene.2021.03.038>
- [32] Thirumal, V., Yuvakkumar, R., Saravanakumar, B., Ravi, G., Isacfranklin, M., Shobana, M., et al. (2022). Carbonization and optimization of biomass waste for HER application. *Fuel*, 324, 124466. <https://doi.org/10.1016/j.fuel.2022.124466>
- [33] Han, G., Hu, M., Liu, Y., Gao, J., Han, L., Lu, S., et al. (2019). Efficient carbon-based catalyst derived from natural cattail fiber for hydrogen evolution



- reaction. *Journal of Solid State Chemistry*, 274, 207–214. <https://doi.org/10.1016/j.jssc.2019.03.027>
- [34] Zhu, G., Ma, L., Lv, H., Hu, Y., Chen, T., Chen, R., et al. (2017). Pine needle-derived microporous nitrogen-doped carbon frameworks exhibit high performances in electrocatalytic hydrogen evolution reaction and supercapacitors. *Nanoscale*, 9(4), 1237–1243. <https://doi.org/10.1039/C6NR08139H>
- [35] Fu, H., Chen, L., Gao, H., Yu, X., Hou, J., Wang, G., et al. (2020). Walnut shell-derived hierarchical porous carbon with high performances for electrocatalytic hydrogen evolution and symmetry supercapacitors. *International Journal of Hydrogen Energy*, 45(1), 443–451. <https://doi.org/10.1016/j.ijhydene.2019.10.159>
- [36] He, H., Zhang, Y., Zhang, W., Li, Y., Zhu, X., Wang, P., et al. (2022). Porous carbon nanofibers derived from silk fibroin through electrospinning as N-doped metal-free catalysts for hydrogen evolution reaction in acidic and alkaline solutions. *ACS Applied Materials & Interfaces*, 14, 834–849. <https://doi.org/10.1021/acsami.1c19334>
- [37] He, H., Zhang, Y., Zhang, W., Li, Y., Wang, Y., Wang, P., et al. (2021). Dual metal-loaded porous carbon materials derived from silk fibroin as bifunctional electrocatalysts for hydrogen evolution reaction and oxygen evolution reaction. *ACS Applied Materials & Interfaces*, 13, 30678–30692. <https://doi.org/10.1021/acsami.1c07058>
- [38] Yu, H., Sun, X., Tang, D., Huang, Y., Zhang, W., Miao, S., et al. (2020). Molten salt strategy to synthesize alkali metal-doped Co<sub>9</sub>S<sub>8</sub> nanoparticles embedded, N, S co-doped mesoporous carbon as hydrogen evolution electrocatalyst. *International Journal of Hydrogen Energy*, 45, 6006–6014. <https://doi.org/10.1016/j.ijhydene.2019.12.115>
- [39] Cardoso, J. A. S. B., Sljukić, B., Erdem, M., Sequeira, C. A. C., & Santos, D. M. F. (2018). Vine shoots and grape stalks as carbon sources for hydrogen evolution reaction electrocatalyst supports. *Catalysts*, 8(2), 50. <https://doi.org/10.3390/catal8020050>
- [40] Zhou, Y., Leng, Y., Zhou, W., Huang, J., Zhao, M., Zhan, J., et al. (2015). Sulfur and nitrogen self-doped carbon nanosheets derived from peanut root nodules as high-efficiency non-metal electrocatalyst for hydrogen evolution reaction. *Nano Energy*, 16, 357–366. <https://doi.org/10.1016/j.nanoen.2015.07.008>
- [41] Jiang, C. (2021). A novel flower-like architecture comprised of 3D interconnected Co-Al-Ox/Sy decorated lignosulfonate-derived carbon nanosheets for flexible supercapacitors and electrocatalytic water splitting. *Carbon*, 184, 386–399. <https://doi.org/10.1016/j.carbon.2021.08.044>
- [43] Huang, B., Liu, Y., & Xie, Z. (2017). Biomass-derived 2D carbons via a hydrothermal carbonization method as efficient bifunctional ORR/HER electrocatalysts. *Journal of Materials Chemistry A*, 5, 23481–23488. <https://doi.org/10.1039/C7TA08052B>

