

# İLERİ ROBOTİK SİSTEMLERİ, MAKİNE ÖĞRENMESİ VE YAPAY ZEKA MÜHENDİSLİĞİ

EDITÖR:

DOÇ. DR. ALİ YİĞİT KUTLUCA



**BİDGE Yayınları**

**İleri Robotik Sistemleri, Makine Öğrenmesi ve Yapay Zeka  
Mühendisliği**

**Editör: DOÇ. DR. ALİ YİĞİT KUTLUCA**

**ISBN: 978-625-8821-53-6**

1. Baskı

Sayfa Düzeni: Gözde YÜCEL

Yayınlama Tarihi: 2026-08-02

BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374

Yayın hakları © BİDGE Yayınları

[www.bidgeyayinlari.com.tr](http://www.bidgeyayinlari.com.tr) - [bidgeyayinlari@gmail.com](mailto:bidgeyayinlari@gmail.com)

Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.

Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya /  
Ankara





# İÇİNDEKİLER

|                                                                                    |   |
|------------------------------------------------------------------------------------|---|
| Sürü Robotiğinde Makine Öğrenmesi Yaklaşımları ve Değerlendirme Protokolleri ..... | 1 |
|------------------------------------------------------------------------------------|---|

*FIRAT KARABOĞA, HATİCE ZEYNEP AKDUMAN*

|                                                                                                                                    |    |
|------------------------------------------------------------------------------------------------------------------------------------|----|
| Makine Öğrenmesi Algoritmaları ile Konut Tipi Binaların Enerji Verimliliği Sınıflarının Kestirimi ve Karşılaştırmalı Analizi ..... | 30 |
|------------------------------------------------------------------------------------------------------------------------------------|----|

*HATİCE ZEYNEP AKDUMAN, FIRAT KARABOĞA*

|                                                                                             |    |
|---------------------------------------------------------------------------------------------|----|
| Sürü Robotiğinde Merkeziyetsiz Kontrol, Matematiksel Modeller ve Gelecek Uygulamaları ..... | 48 |
|---------------------------------------------------------------------------------------------|----|

*HATİCE ZEYNEP AKDUMAN*

# BÖLÜM 1

## SÜRÜ ROBOTİĞİNDE MAKİNE ÖĞRENMESİ YAKLAŞIMLARI VE DEĞERLENDİRME PROTOKOLLERİ

**Fırat KARABOĞA<sup>1</sup>**

**Hatice Zeynep AKDUMAN<sup>2</sup>**

### Giriş

Sürü robotiği, sınırlı algılama ve iletişim yeteneğine sahip çok sayıda basit robotun merkezî bir denetleyici olmaksızın eşgüdümlü davranış üretmesini inceleyen alandır. Alanın kavramsal kökeni, karınca kolonilerinin yiyecek arama düzeneklerinden bal arılarının yuva seçimine kadar uzanan biyolojik özörgütlenme çalışmalarına dayanır (Garnier vd., 2007). Bu düzeneklerde eşgüdüm doğrudan iletişimle değil, ortamda bırakılan izler aracılığıyla dolaylı biçimde kurulmakta olup, söz konusu mekanizma yazında stigmerji adıyla incelenmiştir (Theraulaz ve Bonabeau, 1999). Aynı biyolojik esin robotikten önce en iyileme alanında karşılık bulmuş, karınca kolonilerinin iz bırakma davranışı karınca sistemi algoritmasına (Dorigo vd., 1996), kuş ve balık

---

<sup>1</sup>[ Prof. Dr.], [BAİBÜ], [Tıbbi Hizmetler ve Teknikler Bölümü], ORCID: [0000-0001-8168-3242]

<sup>2</sup>[Öğretim Görelisi], [BAİBÜ], [Bilgisayar Programcılığı Programı], ORCID: [0000-0003-4946-8301]

sürülerinin ortak hareketi ise parçacık sürüsü eniyilemesine (Kennedy ve Eberhart, 1995) kaynaklık etmiştir. Robotik bağlamda alanın çerçevesi Şahin (2005) tarafından çizilmiş, izleyen yıllarda sürü mühendisliği bakış açısıyla sistemleştirilmiştir (Brambilla vd., 2013). Bugün gelinen noktada bin robotluk fiziksel sürülerin özbirleşim gerçekleştirebildiği (Rubenstein vd., 2014) ve otonom hava araçlarından oluşan sürülerin dış mekânda kararlı sürü hareketi sergileyebildiği (Vásárhelyi vd., 2018) gösterilmiştir.

Bütün bu ilerlemeye karşın alanın merkezî güçlüğü yerinde durmaktadır, çünkü tasarımcının elinde yalnızca bireysel robotun yerel davranış kuralları bulunurken istenen sonuç sürünün tümünde beliren kolektif örüntüdür. Yerel kuraldan küresel davranışa giden bu eşleme doğrusal olmadığı gibi, çözümlemeli yoldan türetilmesi de çoğu durumda olanaksızdır (Hamann, 2018). Makine öğrenmesinin alana sunduğu olanak tam olarak burada belirir, çünkü yerel kuralları elle tasarlamak yerine bunları ya gözlem verisinden ya da doğrudan bir başarımlı ölçütünden öğrenmek mümkün hâle gelmektedir.


Bu bölüm birbirini tamamlayan iki amaç gütmektedir. Bunlardan ilki, sürü robotiğinde kullanılan makine öğrenmesi yaklaşımlarını düzenli bir çerçeve içinde tanıtmaktır. Bölümün asıl katkısını oluşturan ikinci amaç ise, kamuya açık gerçek bir veri seti üzerinde yürütülen bir vaka çalışması aracılığıyla, sürü verisinde değerlendirme protokolü seçiminin ulaşılan sonuçları ne ölçüde kökten değiştirebildiğini göstermektir. Vaka çalışmasında UCI Machine Learning Repository üzerinden erişilebilen Swarm Behaviour veri seti kullanılmış olup (Swarm Behaviour, 2020), elde edilen bulgular yaygın biçimde uygulanan rastgele k katlı çapraz doğrulamanın bu tür verilerde belirgin biçimde iyimser başarımlı ürettiğini ortaya koymaktadır.

## Sürü Robotiğinin Temel Kavramları

### Merkezî Olmayan Denetim

Sürü robotiğini çok robotlu sistemlerin genelinden ayıran ölçüt merkezî olmayan denetimdir. Merkezî bir düzenekte tek bir denetleyici tüm robotların durumunu toplar ve eylemlerini belirler. Bu yapı küçük ölçekte verimlidir, ancak robot sayısı arttıkça iletişim yükü ve tek noktadan çökme riski hızla artar. Dağıtık yapıda ise her robot yalnızca kendi algıladığı yerel bilgiye ve komşularıyla kurduğu kısa menzilli etkileşime dayanarak karar vermekte olup, iki mimarının karşılaştırması Şekil 1'de sunulmaktadır.

*Şekil 1. Merkezî ve Dağıtık Denetim Mimarilerinin Karşılaştırılması*



*Kaynak: Yazar tarafından oluşturulmuştur.*

Dağıtık yapının birbirini destekleyen üç temel üstünlüğünden söz edilebilir. Bunlardan ölçeklenebilirlik, robot sayısı arttığında sistemin başarımının bozulmaması anlamına gelirken, sağlamlık tek tek robotların arızalanmasının görevin tümünü durdurmaması demektir. Esneklik ise sürünün görev tanımı ya da içinde bulunduğu ortam değiştiğinde buna uyum sağlayabilmesini ifade etmektedir (Şahin, 2005). Bu üç özellik sürü robotiğinin arama kurtarma,


çevresel izleme ve tarımsal uygulamalar gibi alanlarda çekici olmasının nedenidir (Schranz vd., 2020).

### Özörgütlenme ve Sürü Hareketi

Kolektif davranışın en çok incelenen örneği sürü hareketidir. Reynolds (1987) bu davranışın üç yerel kuralla üretilebileceğini göstermiştir. Ayrılma kuralı, ajanın çok yaklaşan komşularından uzaklaşmasını sağlar. Hizalanma kuralı, ajanın hız yönünü komşularının ortalama yönüne yaklaştırır. Uyum kuralı ise ajanı komşularının kütle merkezine doğru çeker. Bu üç kuralın birlikte çalışması, hiçbir ajanın küresel bir plana sahip olmadığı durumda bile tutarlı bir sürü hareketi üretir. Şekil 3 kuralların her birini ayrı ayrı göstermektedir.

Kolektif hareketin ne ölçüde düzenli olduğu nicel olarak ölçülebilir. Vicsek vd. (1995) tarafından önerilen düzen değişkeni, ajanların birim hız yöneylerinin ortalamasının büyüklüğüdür. Bu değer tüm ajanlar aynı yöne gittiğinde bire, yönler rastgele dağıldığında sıfıra yaklaşır. Aynı çalışma, gürültü düzeyi düştükçe sistemin düzensiz durumdan düzenli sürü hareketine geçtiğini ve bu geçişin bir faz geçişi niteliği taşıdığını göstermiştir. Kolektif hareket üzerine geliştirilen kuramsal çerçeve daha sonra geniş biçimde derlenmiştir (Vicsek ve Zafeiris, 2012).

Şekil 3. Reynolds Modelinin Üç Yerel Kuralı




Kaynak: Reynolds (1987) temel alınarak yazar tarafından oluşturulmuştur.

## Sürü Robotiğinde Makine Öğrenmesi Yaklaşımları

Sürü robotiğinde makine öğrenmesi kullanımı üç ana damarda toplanabilir. Bunlar çevrimdışı otomatik tasarım, çok ajanlı pekiştirmeli öğrenme ve gözetimli öğrenme temelli davranış çözümlemesidir. Şekil 2 bu sınıflandırmayı göstermektedir, Tablo 1 ise yaklaşımların karşılaştırmalı özetini vermektedir.

*Şekil 2. Sürü Robotiğinde Kullanılan Makine Öğrenmesi Yaklaşımlarının Sınıflandırılması*



*Kaynak: Yazar tarafından oluşturulmuştur.*

## Evrimsel Robotik ve Otomatik Tasarım

Evrimsel robotik, denetim yazılımını doğrudan elle yazmak yerine bir başarımlı ölçütü tanımlayıp bu ölçütü en iyileyen denetleyiciyi evrimsel algoritmalarla aramayı önerir (Nolfi ve Floreano, 2000). Yaklaşımın sürü robotiğine uyarlanmış hâli çevrimdışı otomatik tasarım olarak adlandırılır (Birattari vd., 2019). Burada tasarım süreci benzetim ortamında yürütülür ve elde edilen denetleyici fiziksel robotlara aktarılır.

Bu damarın önemli bir kolu, keyfi yapıdaki sinir ağlarını aramak yerine önceden tanımlanmış davranış modüllerini birleştirmeyi önerir. AutoMoDe yöntemi, sonlu durum makinesi biçiminde düzenlenen hazır davranış ve geçiş modüllerinden denetleyici kurar (Francesca vd., 2014). Bu kısıtlamanın gerekçesi, aşırı esnek arama uzaylarının benzetimde çok iyi ama gerçek robotta

kötü çalışan çözümler üretme eğilimidir. Yöntemin ve türevlerinin geniş bir karşılaştırması, modüler yaklaşımların sinir ağı temelli yaklaşımlara göre gerçek robota aktarımında daha kararlı olduğunu göstermiştir (Hasselmann vd., 2021). Alanın başarı ve güçlükleri ayrıca derlenmiştir (Francesca ve Birattari, 2016).

Evrimsel yaklaşımın bir başka kolu, tek bir en iyi çözüm yerine birbirinden farklı çok sayıda işe yarar çözüm üretmeyi hedefler. Cully vd. (2015), bu biçimde önceden oluşturulmuş davranış haritasının, robot hasar gördüğünde dakikalar içinde yeni bir yürüyüş biçimi bulmasını sağladığını göstermiştir. Doncieux vd. (2015) alanın kapsamını ve açık sorularını ayrıntılı biçimde tartışmıştır.

## **Çok Ajanlı Pekiştirmeli Öğrenme**

Pekiştirmeli öğrenmede ajan, ödül işaretini en büyükleyecek eylem siyasasını deneme yanılma yoluyla öğrenir. Sürü bağlamında birden çok ajan aynı anda öğrendiği için ortam her ajanın bakış açısından durağan olmaktan çıkar. Bu durağan olmama sorunu alanın temel güçlüğüdür (Busoniu vd., 2008). Derin öğrenme ile birleştirilen güncel yöntemler ve bunların sınırları kapsamlı biçimde derlenmiştir (Hernandez-Leal vd., 2019; Gronauer ve Diepold, 2022).

Yaygın çözüm kalıbı merkezî eğitim ve dağıtık yürütmedir. Eğitim sırasında tüm ajanların gözlemlerine erişebilen bir eleştirmen kullanılır, yürütme sırasında ise her ajan yalnızca kendi yerel gözlemine dayanarak davranır. Foerster vd. (2018) bu kalıbı karşılıksal bir üstünlük işleviyle birleştirerek her ajanın ortak ödüle katkısını ayrıştırmayı önermiştir. Yu vd. (2022), uygun düzenlemelerle basit siyasa eniyileme yöntemlerinin de bu ortamlarda güçlü sonuç verdiğini göstermiştir. Sürüye özgü uygulamalarda yerel iletişim protokollerinin öğrenilmesi (Hüttenrauch vd., 2018) ve sürü hareketi denetiminin doğrudan derin

pekiştirmeli öğrenme ile elde edilmesi (Zhu vd., 2020) örnek çalışmalardır.

### **Gözetimli Öğrenme ile Davranış Çözümlemesi**

Üçüncü damar, denetleyici tasarlamak yerine gözlenen sürüyü çözümlemeyi amaçlar. Buradaki soru, bir sürünün o anda hangi kolektif davranışı sergilediğinin dış gözlemden kestirilip kestirilemeyeceğidir. Bu yetenek uygulamada birbirinden farklı iki biçimde değer taşımaktadır. Bir sürünün kendi durumunu sürekli izleyip beklenen davranıştan sapmayı erken saptayabilmesi hata toleransı sağlarken (Tarapore vd., 2017), dış bir gözlemcinin daha önce tanımadığı bir sürünün davranışını sınıflandırabilmesi izleme ve güvenlik uygulamalarında kullanılmaktadır. Bu bölümün vaka çalışması bu üçüncü damarda yer almaktadır.

*Tablo 1. Sürü Robotiğinde Makine Öğrenmesi Yaklaşımlarının Karşılaştırması*

| <b>Ölçüt</b>              | <b>Evrimsel otomatik tasarım</b> | <b>Çok ajanlı pekiştirmeli öğrenme</b> | <b>Gözetimli davranış çözümlemesi</b> |
|---------------------------|----------------------------------|----------------------------------------|---------------------------------------|
| Öğrenme işareti           | Görev başarımlı ölçütü           | Ödül işlevi                            | Etiketli gözlem                       |
| Etiketli veri gereksinimi | Yok                              | Yok                                    | Var                                   |
| Eğitim ortamı             | Benzetim                         | Benzetim ya da gerçek                  | Kayıtlı veri                          |
| Temel çıktı               | Denetleyici                      | Siyasa                                 | Sınıflandırıcı                        |
| Başlıca güçlük            | Gerçeklik boşluğu                | Durağan olmama                         | Etiket kalitesi ve genelleme          |
| Örnek çalışma             | Francesca vd. (2014)             | Foerster vd. (2018)                    | Kasmarik vd. (2020)                   |

*Kaynak: Yazar tarafından derlenmiştir.*

## **Vaka Çalışması: Veri Seti ve Yöntem**

### **Veri Seti**

Vaka çalışmasında UCI Machine Learning Repository üzerinden erişilebilen ve Reynolds modeline dayalı bir boid benzetiminden üretilmiş olan Swarm Behaviour veri seti kullanılmıştır (Swarm Behaviour, 2020). Veri setindeki her kayıt, 200 ajandan oluşan bir sürünün tek bir zaman anındaki tam durumunu içermekte ve her ajan için konum, hız, hizalanma yöneyi, ayrılma yöneyi, uyum yöneyi ile iki ayrı komşu sayısından oluşan on iki değişkeni barındırmaktadır. Bu yapı gereği her kayıt 200 ile 12'nin çarpımına karşılık gelen 2400 öznitelikten meydana gelmektedir.

Veri setini benzerlerinden ayıran asıl özellik, etiketlerin herhangi bir eşik kuralıyla otomatik olarak atanmamış olması ve doğrudan insan gözlemine dayandırılmasıdır. Doksan katılımcıya yaklaşık on saniyelik benzetim görüntüleri izletilmiş, katılımcılardan sürünün ilgili davranışı ne ölçüde sergilediğini bir kaydırma çubuğuyla puanlamaları istenmiş, alınan puanların ortalamasına yüzde elli eşiği uygulanarak ikili etiket elde edilmiştir (Kasmarik vd., 2020; Abpeikar ve Kasmarik, 2023). Etiketler bu yolla üretildiğinden fiziksel bir ölçütü değil doğrudan insan algısını temsil etmektedir. Veri seti üç ayrı ikili sınıflandırma görevi içermekte olup, bu çalışmada başlıca görev olarak sürü hareketi dosyası kullanılmış, kalan iki dosya ise genelleme kontrolü amacıyla çözümlenmiştir.

Veriler okunurken toplam 57.638.400 hücrenin yalnızca birinin bozuk olduğu görülmüş, ilgili satır çözümleme dışında bırakılmış ve bütün hesaplamalar geriye kalan 24.015 kayıt üzerinde yürütülmüştür. Veri setinin yapısı Tablo 2'de özetlenmektedir.

*Tablo 2. Swarm Behaviour Veri Setinin Yapısı*

| Özellik                        | Değer                             |
|--------------------------------|-----------------------------------|
| Toplam kayıt (ham)             | 24.016                            |
| Çözümlemede kullanılan kayıt   | 24.015                            |
| Çıkarılan bozuk kayıt          | 1                                 |
| Sürüdeki ajan sayısı           | 200                               |
| Ajan başına değişken sayısı    | 12                                |
| Ham öznitelik sayısı           | 2.400                             |
| Sınıf dağılımı (sürü hareketi) | 12.008 / 12.007                   |
| Etiket kaynağı                 | 90 katılımcının görsel puanlaması |

*Kaynak: Swarm Behaviour (2020) veri seti üzerinde yazar tarafından hesaplanmıştır.*

### **Öznitelik Çıkarımı**

Ham öznitelikleri hiçbir dönüşüme uğratmadan doğrudan kullanmanın birbirinden bağımsız iki sakıncası bulunmaktadır. Bunlardan ilki, 2400 boyutlu uzayda ajanların sıralamasının tümüyle keyfi olması ve aynı sürü durumunun farklı sıralamalarının birbirinden farklı öznitelik yöneyleri üretmesidir. İkincisi ise boyut sayısının örnek sayısına tehlikeli biçimde yaklaşmasıdır. Bu iki nedenle ajan sıralamasından bağımsız sürü düzeyi öznitelikler türetilmiş, her değişken için ajanlar üzerinden ortalama, standart sapma, en küçük, en büyük ve ortanca değerler hesaplanmıştır. Bu özet istatistiklere sürü hareketi yazınında yerleşik olarak kullanılan üç ölçüt de eklenmiş olup bunlar Vicsek düzen değişkeni, sürünün kütle merkezine ortalama uzaklığı ve ortalama sürat değeridir. Böylece 63 öznitelikten oluşan ve dökümü Tablo 3'te verilen bir gösterim elde edilmiştir.

*Tablo 3. Sürü Düzeyi Öznitelikler*


| Öznitelik kümesi | Sayı | Açıklama                                    |
|------------------|------|---------------------------------------------|
| Ortalama         | 12   | Her değişkenin ajanlar üzerinden ortalaması |
| Standart sapma   | 12   | Ajanlar arası değişkenlik                   |
| En küçük         | 12   | Ajanlar üzerinden en küçük değer            |
| En büyük         | 12   | Ajanlar üzerinden en büyük değer            |
| Ortanca          | 12   | Aykırı değerlere dayanıklı orta değer       |
| Polarizasyon     | 1    | Vicsek düzen değişkeni                      |
| Yayılım          | 1    | Kütle merkezine ortalama uzaklık            |
| Ortalama sürat   | 1    | Hız büyüklüklerinin ortalaması              |
| Toplam           | 63   |                                             |

*Kaynak: Yazar tarafından oluşturulmuştur.*

## **Deneysel Tasarım**

Çözümlemede birbirinden farklı yedi sınıflandırma yöntemi karşılaştırılmış olup bunlar lojistik regresyon, doğrusal destek yöney makinesi, k en yakın komşu, karar ağacı, rastgele orman (Breiman, 2001), gradyan artırma (Friedman, 2001) ve çok katmanlı algılayıcıdır. Başarım ölçütü olarak doğruluk, kesinlik, duyarlılık, F1 ve ROC eğrisi altındaki alan birlikte raporlanmıştır (Fawcett, 2006). Sınıf dağılımının bu veri setinde dengeli olması nedeniyle ROC eğrisi altındaki alan güvenilir bir ölçüt sayılabilmekte, buna karşılık dengesiz veri söz konusu olduğunda kesinlik duyarlılık eğrisinin daha bilgilendirici olduğu bilinmektedir (Saito ve Rehmsmeier, 2015). Sonuçların yinelenebilir olması için bütün deneylerde rastgelelik tohumu 42 değerinde sabitlenmiş, izlenen çözümleme akışı ise Şekil 4'te gösterilmiştir.

Şekil 4. Vaka Çalışmasının Deneysel İş Akışı



Kaynak: Yazar tarafından oluşturulmuştur.

## Bulgular

### Model Karşılaştırması

Tablo 4, sürü düzeyi öznitelikler üzerinde beş katlı tabakalı çapraz doğrulama ile elde edilen sonuçları vermektedir. Yedi yöntemin tümü 0,9997 ile 0,9999 arasında doğruluk üretmiştir. Rastgele ormanın karışıklık matrisi 24.015 kaydın yalnızca ikisinin yanlış sınıflandırıldığını göstermektedir.

Tablo 4. Sürü Düzeyi Öznitelikler Üzerinde Model Karşılaştırması

| Yöntem             | Doğruluk | F1     | ROC AUC | Eğitim süresi (s) |
|--------------------|----------|--------|---------|-------------------|
| Lojistik Regresyon | 0,9998   | 0,9998 | 1,0000  | 0,10              |
| Doğrusal DVM       | 0,9999   | 0,9999 | 1,0000  | 0,28              |
| k-EYK (k = 5)      | 0,9998   | 0,9998 | 1,0000  | 0,01              |
| Karar Ağacı        | 0,9998   | 0,9998 | 0,9998  | 0,49              |
| Rastgele Orman     | 0,9999   | 0,9999 | 1,0000  | 4,42              |
| Gradyan Artırma    | 0,9999   | 0,9999 | 1,0000  | 32,41             |
| ÇKA (100-50)       | 0,9997   | 0,9997 | 1,0000  | 0,93              |

Kaynak: Yazar tarafından hesaplanmıştır. Beş katlı tabakalı çapraz doğrulama,  $n = 24.015$ .

Tablodaki değerler ilk bakışta olumlu bir görünüm sunmakla birlikte, yöntemler arasında kayda değer hiçbir fark bulunmaması ve en yalın doğrusal modelin en karmaşık modelle aynı sonucu vermesi, elde edilen başarımın yöntemlerin gücünden değil görevin


kendisinin kolaylığından kaynaklandığını düşündürmektedir. Bu kuşkuyu sınamak amacıyla birbirini izleyen bir dizi tanı çözümlemesi yürütülmüştür.

### **Görevin Ayrıştırılabilirliği**

Tanı çözümlemelerinin ilki derinliği sınırlandırılmış karar ağaçlarıyla yürütülmüş olup, yalnızca tek bir bölünme kullanan ağacın 0,9052 ve iki bölünme kullanan ağacın 0,9841 doğruluk vermesi, sürü düzeyi öznitelik uzayında yalnızca iki eşik değerinin sınıfları neredeyse tümüyle ayırmaya yettiği anlamına gelmektedir.

İkinci tanı çözümlemesinde gözlenen ajan sayısının etkisi incelenmiş ve sürüden rastgele seçilen  $k$  ajanın değişkenleri kullanılarak sınıflandırma yinelenmiştir. Şekil 5'te görüldüğü üzere rastgele orman tek bir ajanın gözlenmesi durumunda bile 0,9996 doğruluk üretirken, lojistik regresyon aynı koşulda 0,8274 düzeyinde kalmakta ve ancak gözlenen ajan sayısı arttıkça yükselmektedir. İki yöntem arasındaki bu ayrışma yorum açısından belirleyicidir, çünkü etiketin tek bir ajanın durumundan okunabildiğini, ancak bu okumayı sağlayan ilişkinin doğrusal olmadığını göstermektedir.

Şekil 5. Gözlenen Ajan Sayısının Sınıflandırma Doğruluğuna Etkisi



Kaynak: Yazar tarafından hesaplanmıştır. Beş katlı tabakalı çapraz doğrulama, üç yineme.


Üçüncü tanı çözümlemesi tek bir ajan üzerinde yoğunlaşmış ve sürüden seçilen beş farklı ajan ayrı ayrı denendiğinde rastgele ormanın 0,9995 ile 0,9999 arasında değişen doğruluklar ürettiği görülmüştür. Aynı ajanların on iki değişkeni üzerinde çalıştırılan lojistik regresyon 0,7844 ile 0,9178 aralığında kalırken, dört derinlikli bir karar ağacı 0,9172 doğruluğa ulaşmıştır. Değişken önem sıralaması ise tek ajan içinde en ayırt edici bilginin dikey hız bileşeninde toplandığını ortaya koymuştur. Bu bulgular bir arada değerlendirildiğinde, etiketin herhangi bir ajanın durumunun doğrusal olmayan ancak belirlenimci bir işlevi olduğu sonucuna varılmaktadır.

Elde edilen başarımın çözümleme düzeneğinin kendisinden kaynaklanıp kaynaklanmadığını sınamak amacıyla bir permütasyon kontrolü uygulanmış, etiketler rastgele karıştırıldığında doğruluğun 0,4995 değerine düştüğü görülmüştür. Rastlantısal düzeye çok yakın olan bu sonuç, kurulan düzeneğin kendiliğinden yüksek başarım üretmediğini doğrulamaktadır.

## Algılama Kipi Ablasyonu ve Gürültü Dayanıklılığı

Ayırt edici bilginin hangi türde yoğunlaştığını saptamak amacıyla değişkenler altı algılama kipine ayrılmış ve her kip tek başına sınanarak sonuçlar Şekil 6'da toplanmıştır. Yalnızca hız bilgisi kullanıldığında rastgele ormanın 0,9996 doğruluğa ulaşması, buna karşılık yalnızca hizalanma ya da yalnızca uyum bilgisiyle doğruluğun 0,88 dolayına inmesi, sınıflandırma için gerekli bilginin büyük ölçüde hız alanında toplandığını göstermektedir.

Şekil 6. Algılama Kipi Ablasyonu



Kaynak: Yazar tarafından hesaplanmıştır. Beş katlı tabakalı çapraz doğrulama.

Gerçek robot uygulamalarında algılayıcı gürültüsünün kaçınılmaz olması nedeniyle, bu durumu benzetmek üzere her kanala o kanalın standart sapmasıyla orantılı Gauss gürültüsü eklenmiş ve elde edilen sonuçlar Tablo 5'te sunulmuştur. Gürültü düzeyi standart sapmanın yarısına ulaşana kadar başarımda kayda değer bir bozulma gözlenmemekte, gürültü standart sapmanın iki katına çıkarıldığında bile rastgele orman 0,9957 doğruluğunu korumaktadır.

*Tablo 5. Ölçüm Gürültüsünün Başarıma Etkisi*

| Gürültü düzeyi ( $\sigma$ oranı) | Lojistik Regresyon | Rastgele Orman |
|----------------------------------|--------------------|----------------|
| 0,00                             | 0,9998             | 0,9999         |
| 0,05                             | 0,9998             | 0,9997         |
| 0,10                             | 0,9997             | 0,9997         |
| 0,25                             | 0,9998             | 0,9997         |
| 0,50                             | 0,9997             | 0,9997         |
| 1,00                             | 0,9982             | 0,9997         |
| 2,00                             | 0,9629             | 0,9957         |

*Kaynak: Yazar tarafından hesaplanmıştır. Değerler doğruluk ölçütüdür.*

### **Değerlendirme Protokolünün Kritiği**

Yukarıda sıralanan bulgular tek tek ele alındığında görevin neden bu kadar kolay olduğunu açıklamaya yetmemekte, asıl sorulması gereken soru ise neredeyse kusursuz başarımın hangi kaynaktan doğduğudur. Bu sorunun yanıtı, kullanılan yöntemlerde değil doğrudan veri setinin üretilme biçiminde aranmalıdır.

### **Kayıtların Bağımsız Olmaması**

Veri setini betimleyen çalışmalar, verinin 1501 zaman adımı boyunca kaydedilen 16 benzetim koşusundan üretildiğini bildirmekte olup (Abpeikar ve Kasmarik, 2023), bu sayılar veri setinin gözlenen boyutlarıyla birebir tutarlıdır. On altı ile 1501'in çarpımı ham kayıt sayısına eşit olan 24.016 değerini vermekte, sürü hareketi görevindeki her sınıfın 12.008 kayıt içermesi ise sekiz koşunun 1501 adımına karşılık gelmektedir. Bu yapının değerlendirme açısından belirleyici yanı, her koşunun etiketinin koşu boyunca değişmeden sabit kalmasıdır.

Bu yapının değerlendirme açısından doğrudan bir sonucu bulunmaktadır, çünkü ardışık zaman adımları aynı benzetimin birbirine son derece yakın anlarını temsil ettiğinden istatistiksel olarak bağımsız sayılamazlar. Rastgele k katlı çapraz doğrulama kayıtları gelişigüzel böldüğü için aynı koşunun kimi kareleri eğitim kümesine kimi kareleri ise test kümesine düşmekte, böylece model


test aşamasında karşılaştığı kareye neredeyse özdeş bir kareyi eğitim sırasında zaten görmüş olmaktadır. Bu koşullar altında ölçülen nicelik, daha önce görülmemiş bir sürüye genelleme yeteneği değil, görülmüş bir koşuyu yeniden tanıma becerisidir. Örneklerin bağımsız olmamasından doğan bu tür sızıntı, çapraz doğrulama yazınında uzun süredir bilinen bir tuzak olarak tanımlanmaktadır (Varma ve Simon, 2006; Krstajic vd., 2014).

### **Koşu Bazlı Çapraz Doğrulama**

Doğru protokol, aynı koşuya ait kayıtların bölünmemesini güvence altına alan gruplu çapraz doğrulamadır. Veri setiyle birlikte koşu kimlikleri dağıtılmadığı için, koşu kimliği sürü düzeyi öznitelikler üzerinde on altı kümeli bir kümeleme ile geri kazanılmıştır. Elde edilen kümelerin on üçü etiket bakımından tümüyle saf çıkmış ve ortalama etiket saflığı 0,9824 olarak bulunmuştur. Bu geri kazanımın kesin değil yaklaşık olduğunun açıkça belirtilmesi gerekmektedir, çünkü küme boyutlarının 2 ile 6011 arasında değişmesi bazı koşuların birbiriyle birleştiğine bazılarının ise bölündüğüne işaret etmektedir. Aşağıda sunulan karşılaştırma bu sınırlılık göz önünde bulundurularak okunmalıdır.

Şekil 7 iki protokolün sonuçlarını yan yana getirmekte ve aradaki farkın hiç de küçük olmadığını ortaya koymaktadır. Rastgele çapraz doğrulamada 0,9998 doğruluk veren lojistik regresyon koşu bazlı protokolde 0,8267 değerine gerilerken, rastgele orman 0,9999 düzeyinden 0,8976 düzeyine inmektedir. Ortalamalardaki bu düşüşten daha anlamlı olan nokta ise katlar arası değişkenliğin ulaştığı boyuttur, çünkü koşu bazlı protokolde standart sapma lojistik regresyon için 0,2693 ve rastgele orman için 0,1898 düzeyine çıkmaktadır. Katlar tek tek incelendiğinde bazılarında doğruluğun 0,3277 gibi rastlantısal düzeyin bile altına indiği görülmekte, tek ajan gözlemiyle yürütülen çözümlemede ise düşüş daha da belirginleşerek doğruluk 0,6345 değerine kadar gerilemektedir.

## Şekil 7. Rastgele ve Koşu Bazlı Çapraz Doğrulama Protokollerinin Karşılaştırması



Kaynak: Yazar tarafından hesaplanmıştır. Nokta bulutu koşu bazlı protokolün tek kat doğruluklarını göstermektedir.

Tablo 6. İki Değerlendirme Protokolünün Sayısal Karşılaştırması

| Model ve gösterim                  | Rastgele 5 katlı ÇD | Koşu bazlı gruplu ÇD | Fark   |
|------------------------------------|---------------------|----------------------|--------|
| Lojistik Regresyon (63 öz nitelik) | 0,9998              | 0,8267 (± 0,2693)    | 0,1731 |
| Rastgele Orman (63 öz nitelik)     | 0,9999              | 0,8976 (± 0,1898)    | 0,1023 |
| Rastgele Orman (tek ajan #0)       | 0,9998              | 0,7138               | 0,2859 |
| Rastgele Orman (tek ajan #42)      | 0,9999              | 0,7948               | 0,2051 |
| Rastgele Orman (tek ajan #199)     | 0,9995              | 0,6345               | 0,3650 |

Kaynak: Yazar tarafından hesaplanmıştır. Parantez içindeki değerler katlar arası standart sapmadır.

Bu karşılaştırmadan çıkarılması gereken sonuç, kullanılan yöntemlerin başarısız olduğu değil, rastgele çapraz doğrulamayla bildirilen değerlerin bu veri yapısı altında genelleme başarımını


ölçmediğidir. Aynı veri setini kullanan çalışmaların yüzde 99 üzeri doğruluk bildirmesi bu nedenle dikkatle okunmalıdır (Khan vd., 2020; Tiwari vd., 2023). Görevin farklı gösterimlerle ele alındığı çalışmaların da benzer düzeyde başarımlar bildirmesi, sorunun tek bir çalışmaya özgü olmadığını düşündürmektedir (Abpeikar vd., 2022; Yang vd., 2023).

Genelleme kontrolü amacıyla veri setindeki diğer iki görev de aynı akışla çözümlenmiştir. Bu iki dosyada bozuk kayıt bulunmadığından hesaplamalar 24.016 kayıt üzerinde yürütülmüş, hizalanma görevinde yedi modelden altısının doğruluğu 1,0000 düzeyine ulaşmış, karar ağacı ise 0,9998 değerinde kalmıştır. Gruplanma görevinde doğruluk 0,9999 ile 1,0000 arasında değişmiştir. Bu iki görevin sürü hareketi görevinden bile daha kolay çözülmesi, aynı yapısal sorunun onlarda da bulunduğu işaret etmektedir.

### **Gerçeklik Boşluğu ve Fiziksel Robotlara Aktarım**

Bu bölümdeki vaka çalışmasının bulguları benzetim verisine dayandığından, sonuçların fiziksel robotlara aktarımı ayrı bir tartışmayı gerektirmektedir. Benzetim ortamında öğrenilen bir modelin gerçek robot üzerinde aynı başarımları gösterememesi olgusu yazında gerçeklik boşluğu olarak adlandırılmaktadır. Jakobi vd. (1995) erken bir tarihte benzetim denetimli biçimde gürültü eklemenin bu boşluğu daraltabileceğini göstermiş, yaklaşımın güncel karşılığı ise alan rastgeleleştirilmesi adıyla gelişmiştir. Bu yöntemde benzetim değiştiricileri eğitim sırasında geniş bir aralıkta rastgele değiştirilmekte, böylece model gerçek dünyayı bu değişkenlik aralığının yalnızca bir örneği olarak görmektedir (Tobin vd., 2017). Alanın bugüne kadarki birikimi Zhao vd. (2020) tarafından derli toplu biçimde özetlenmiştir.

### Şekil 8. Gerçeklik Boşluğu ve Daraltma Yaklaşımları



*Kaynak: Yazar tarafından oluşturulmuştur.*

Ligot ve Birattari (2020), gerçeklik boşluğunun etkilerinin yalnızca benzetim kullanılarak da taklit edilebileceğini göstermiştir. Bu çalışmada tasarım bir benzetici üzerinde yapılmış, değerlendirme başka bir benzetici üzerinde yürütülmüştür. Yaklaşımın değeri, fiziksel deney yapmadan aktarım dayanıklılığının önceden sınanabilmesidir. Benzetim altyapısı bakımından sürü robotiğinde yaygın olarak kullanılan araçlardan biri ARGoS ortamıdır (Pinciroli vd., 2012).

Bu bölümün vaka çalışması bağlamında gerçeklik boşluğu iki katmanlıdır. Birinci katman benzetim ile gerçek robot arasındaki fiziksel farktır. İkinci katman ise etiketlerin insan algısından türetilmiş olmasıdır. İnsan gözlemcinin sürü hareketi olarak nitelediği durum ile fiziksel bir ölçütün eşiği örtüşmeyebilir. Bu nedenle veri seti üzerinde elde edilen modelin gerçek bir sürüye uygulanması, her iki katmanın ayrı ayrı sınanmasını gerektirir.

### Açık Sorunlar ve Etik Boyut

Sürü robotiğinde makine öğrenmesi kullanımının önündeki açık sorunlar dört başlıkta toplanabilir.

- Değerlendirme protokolü. Bu bölümün gösterdiği gibi, sürü verisinde bağımsızlık varsayımı çoğu zaman geçerli değildir. Koşu bazlı bölme yapılmadıkça bildirilen başarımların değerleri karşılaştırılabilir olmaz.
- Veri seti çeşitliliği. Kamuya açık sürü davranışı veri setlerinin sayısı azdır ve çoğu tek bir benzetim modeline dayanır. Farklı benzetici ve fiziksel platformlardan üretilmiş veri setlerine gereksinim vardır.
- Ölçeklenebilirlik. Öğrenilen siyasaların eğitimde kullanılan sürü büyüklüğünden farklı büyüklüklere aktarılması güvenilir biçimde çözülmüş değildir.
- Yorumlanabilirlik. Öğrenilmiş bir denetleyicinin hangi koşulda ne yapacağını önceden kestirilememesi, güvenlik açısından kritik uygulamalarda benimsenmenin önündeki engeldir.

Etik ve güvenlik boyutu ayrı bir tartışmayı gerektirir. Sürü sistemlerinde bireysel robotların ele geçirilmesi tüm sürünün davranışını bozabilir. Ferrer vd. (2021), sürü içi işbirliğinin gizliliğini ve güvenliğini sağlamaya yönelik düzenekleri tartışmıştır. Daha geniş çerçevede, gerçek dünyada çalışan sürü sistemlerinin etik yönetişimi üzerine kapsamlı bir değerlendirme yakın dönemde ortaya konmuştur (Winfield vd., 2025). Dorigo vd. (2020, 2021) alanın gelecek yönelimlerini tartışırken sorumluluk ve denetlenebilirlik konularının teknik başarımdan ayrı düşünülemeyeceğini vurgulamaktadır.

## **Sonuç**

Bu bölümde sürü robotiğinde kullanılan makine öğrenmesi yaklaşımları üç ana damar altında tanıtılmış ve kamuya açık gerçek bir veri seti üzerinde birbirini tamamlayan iki düzeyde sonuç üreten bir vaka çalışması yürütülmüştür.

Yüzeysel düzeyde bakıldığında yedi farklı sınıflandırma yönteminin tümü 0,9997 üzerinde doğruluk vermiş olup, bu sonuç tek başına bildirilseydi görevin başarıyla çözüldüğü izlenimi doğacaktı. Yürütülen tanı çözümlemeleri ise söz konusu izlenimin yanıltıcı olduğunu ortaya koymuştur, çünkü yalnızca iki bölünme kullanan bir karar ağacı 0,9841 doğruluğa ulaşmakta ve 200 ajandan yalnızca biri gözlemlendiğinde bile rastgele orman 0,9996 doğruluk üretmektedir.

Derinlemesine düzeyde ise sorunun kaynağı değerlendirme protokolünde bulunmuştur. Veri seti 16 benzetim koşusundan üretilmiştir ve her koşulun 1501 karesi aynı etiketi taşımaktadır. Koşu bazlı gruplu çapraz doğrulamaya geçildiğinde doğruluk lojistik regresyon için 0,8267 ve rastgele orman için 0,8976 düzeyine düşmekte, katlar arası standart sapma 0,19 ile 0,27 aralığına çıkmaktadır. Koşu kimliğinin kümeleme ile yaklaşık olarak geri kazanıldığı göz önünde tutulmalıdır, dolayısıyla bu değerler kesin ölçüm değil düzey göstergesidir.

Bütün bu bulgulardan uygulamaya dönük açık bir öneri çıkmaktadır. Sürü davranışı verisiyle çalışan araştırmacıların her kaydın hangi koşudan geldiğini saklamaları ve çapraz doğrulamayı kayıt düzeyinde değil koşu düzeyinde kurmaları gerekmektedir. Veri seti yayımlayan ekiplerin koşu kimliğini de birlikte dağıtması ise alandaki karşılaştırılabilirliği doğrudan artıracak bir adım olacaktır. Yüksek doğruluk bildiren her çalışmanın, bildirdiği bu değerlerin görevin gerçek güçlüğünden mi yoksa değerlendirme düzeneğinin gevşekliğinden mi kaynaklandığını okuyucuya açıkça göstermesi beklenmelidir.

## Kaynakça

- Abpeikar, S., & Kasmarik, K. (2023). Motion behaviour recognition dataset collected from human perception of collective motion behaviour. *Data in Brief*, 47, 108976. <https://doi.org/10.1016/j.dib.2023.108976>
- Abpeikar, S., Kasmarik, K., Tran, P. V., & Garratt, M. (2022). Transfer learning for autonomous recognition of swarm behaviour in UGVs. In *Lecture Notes in Computer Science* (pp. 531–542). Springer International Publishing. [https://doi.org/10.1007/978-3-030-97546-3\\_43](https://doi.org/10.1007/978-3-030-97546-3_43)
- Birattari, M., Ligo, A., Bozhinoski, D., Brambilla, M., Francesca, G., Garattoni, L., Garzón Ramos, D., Hasselmann, K., Kegeleirs, M., Kuckling, J., Pagnozzi, F., Roli, A., Salman, M., & Stützle, T. (2019). Automatic off-line design of robot swarms: A manifesto. *Frontiers in Robotics and AI*, 6, Article 59. <https://doi.org/10.3389/frobt.2019.00059>
- Brambilla, M., Ferrante, E., Birattari, M., & Dorigo, M. (2013). Swarm robotics: A review from the swarm engineering perspective. *Swarm Intelligence*, 7(1), 1–41. <https://doi.org/10.1007/s11721-012-0075-2>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Busoniu, L., Babuska, R., & De Schutter, B. (2008). A comprehensive survey of multiagent reinforcement learning. *IEEE Transactions on Systems, Man, and Cybernetics, Part C (Applications and Reviews)*, 38(2), 156–172. <https://doi.org/10.1109/TSMCC.2007.913919>

- Cully, A., Clune, J., Tarapore, D., & Mouret, J. B. (2015). Robots that can adapt like animals. *Nature*, 521(7553), 503–507.  
<https://doi.org/10.1038/nature14422>
- Doncieux, S., Bredeche, N., Mouret, J. B., & Eiben, A. E. (2015). Evolutionary robotics: What, why, and where to. *Frontiers in Robotics and AI*, 2, Article 4.  
<https://doi.org/10.3389/frobt.2015.00004>
- Dorigo, M., Maniezzo, V., & Colorni, A. (1996). Ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 26(1), 29–41.  
<https://doi.org/10.1109/3477.484436>
- Dorigo, M., Theraulaz, G., & Trianni, V. (2020). Reflections on the future of swarm robotics. *Science Robotics*, 5(49), Article eabe4385. <https://doi.org/10.1126/scirobotics.abe4385>
- Dorigo, M., Theraulaz, G., & Trianni, V. (2021). Swarm robotics: Past, present, and future [point of view]. *Proceedings of the IEEE*, 109(7), 1152–1165.  
<https://doi.org/10.1109/JPROC.2021.3072740>
- Fawcett, T. (2006). An introduction to ROC analysis. *Pattern Recognition Letters*, 27(8), 861–874.  
<https://doi.org/10.1016/j.patrec.2005.10.010>
- Ferrer, E. C., Hardjono, T., Pentland, A., & Dorigo, M. (2021). Secure and secret cooperation in robot swarms. *Science Robotics*, 6(56), Article eabf1538.  
<https://doi.org/10.1126/scirobotics.abf1538>
- Foerster, J., Farquhar, G., Afouras, T., Nardelli, N., & Whiteson, S. (2018). Counterfactual multi-agent policy gradients.

- Proceedings of the AAAI Conference on Artificial Intelligence, 32(1). <https://doi.org/10.1609/aaai.v32i1.11794>
- Francesca, G., Brambilla, M., Brutschy, A., Trianni, V., & Birattari, M. (2014). AutoMoDe: A novel approach to the automatic design of control software for robot swarms. *Swarm Intelligence*, 8(2), 89–112. <https://doi.org/10.1007/s11721-014-0092-4>
- Francesca, G., & Birattari, M. (2016). Automatic design of robot swarms: Achievements and challenges. *Frontiers in Robotics and AI*, 3, Article 29. <https://doi.org/10.3389/frobt.2016.00029>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5). <https://doi.org/10.1214/aos/1013203451>
- Garnier, S., Gautrais, J., & Theraulaz, G. (2007). The biological principles of swarm intelligence. *Swarm Intelligence*, 1(1), 3–31. <https://doi.org/10.1007/s11721-007-0004-y>
- Gronauer, S., & Diepold, K. (2022). Multi-agent deep reinforcement learning: A survey. *Artificial Intelligence Review*, 55(2), 895–943. <https://doi.org/10.1007/s10462-021-09996-w>
- Hamann, H. (2018). *Swarm robotics: A formal approach*. Springer International Publishing. <https://doi.org/10.1007/978-3-319-74528-2>
- Hasselmann, K., Ligot, A., Ruddick, J., & Birattari, M. (2021). Empirical assessment and comparison of neuroevolutionary methods for the automatic off-line design of robot swarms. *Nature Communications*, 12(1), Article 4345. <https://doi.org/10.1038/s41467-021-24642-3>

- Hernandez-Leal, P., Kartal, B., & Taylor, M. E. (2019). A survey and critique of multiagent deep reinforcement learning. *Autonomous Agents and Multi-Agent Systems*, 33(6), 750–797. <https://doi.org/10.1007/s10458-019-09421-1>
- Hüttenrauch, M., Šošić, A., & Neumann, G. (2018). Local communication protocols for learning complex swarm behaviors with deep reinforcement learning. In *Lecture Notes in Computer Science* (pp. 71–83). Springer International Publishing. [https://doi.org/10.1007/978-3-030-00533-7\\_6](https://doi.org/10.1007/978-3-030-00533-7_6)
- Jakobi, N., Husbands, P., & Harvey, I. (1995). Noise and the reality gap: The use of simulation in evolutionary robotics. In *Lecture Notes in Computer Science* (pp. 704–720). Springer Berlin Heidelberg. [https://doi.org/10.1007/3-540-59496-5\\_337](https://doi.org/10.1007/3-540-59496-5_337)
- Kasmarik, K., Abpeikar, S., Khan, M. M., Khattab, N., Barlow, M., & Garratt, M. (2020). Autonomous recognition of collective behaviour in robot swarms. In *Lecture Notes in Computer Science* (pp. 281–293). Springer International Publishing. [https://doi.org/10.1007/978-3-030-64984-5\\_22](https://doi.org/10.1007/978-3-030-64984-5_22)
- Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. In *Proceedings of ICNN'95 - International Conference on Neural Networks* (pp. 1942–1948). IEEE. <https://doi.org/10.1109/ICNN.1995.488968>
- Khan, M. M., Kasmarik, K., & Barlow, M. (2020). Autonomous detection of collective behaviours in swarms. *Swarm and Evolutionary Computation*, 57, 100715. <https://doi.org/10.1016/j.swevo.2020.100715>
- Krstajic, D., Buturovic, L. J., Leahy, D. E., & Thomas, S. (2014). Cross-validation pitfalls when selecting and assessing

- regression and classification models. *Journal of Cheminformatics*, 6(1), Article 10.  
<https://doi.org/10.1186/1758-2946-6-10>
- Ligot, A., & Birattari, M. (2020). Simulation-only experiments to mimic the effects of the reality gap in the automatic design of robot swarms. *Swarm Intelligence*, 14(1), 1–24.  
<https://doi.org/10.1007/s11721-019-00175-w>
- Nolfi, S., & Floreano, D. (2000). *Evolutionary robotics: The biology, intelligence, and technology of self-organizing machines*. The MIT Press.  
<https://doi.org/10.7551/mitpress/2889.001.0001>
- Pinciroli, C., Trianni, V., O’Grady, R., Pini, G., Brutschy, A., Brambilla, M., Mathews, N., Ferrante, E., Di Caro, G., Ducatelle, F., Birattari, M., Gambardella, L. M., & Dorigo, M. (2012). ARGoS: A modular, parallel, multi-engine simulator for multi-robot systems. *Swarm Intelligence*, 6(4), 271–295. <https://doi.org/10.1007/s11721-012-0072-5>
- Reynolds, C. W. (1987). Flocks, herds and schools: A distributed behavioral model. In *Proceedings of the 14th annual conference on Computer graphics and interactive techniques* (pp. 25–34). ACM. <https://doi.org/10.1145/37401.37406>
- Rubenstein, M., Cornejo, A., & Nagpal, R. (2014). Programmable self-assembly in a thousand-robot swarm. *Science*, 345(6198), 795–799.  
<https://doi.org/10.1126/science.1254295>
- Saito, T., & Rehmsmeier, M. (2015). The Precision-Recall plot is more informative than the ROC plot when evaluating binary classifiers on imbalanced datasets. *PLOS ONE*, 10(3), e0118432. <https://doi.org/10.1371/journal.pone.0118432>

- Schranz, M., Umlauft, M., Sende, M., & Elmenreich, W. (2020). Swarm robotic behaviors and current applications. *Frontiers in Robotics and AI*, 7, Article 36.  
<https://doi.org/10.3389/frobt.2020.00036>
- Swarm Behaviour [Veri seti]. (2020). UCI Machine Learning Repository. <https://doi.org/10.24432/C5N02J>
- Şahin, E. (2005). Swarm robotics: From sources of inspiration to domains of application. In *Lecture Notes in Computer Science* (pp. 10–20). Springer Berlin Heidelberg.  
[https://doi.org/10.1007/978-3-540-30552-1\\_2](https://doi.org/10.1007/978-3-540-30552-1_2)
- Tarapore, D., Christensen, A. L., & Timmis, J. (2017). Generic, scalable and decentralized fault detection for robot swarms. *PLOS ONE*, 12(8), e0182058.  
<https://doi.org/10.1371/journal.pone.0182058>
- Theraulaz, G., & Bonabeau, E. (1999). A brief history of stigmergy. *Artificial Life*, 5(2), 97–116.  
<https://doi.org/10.1162/106454699568700>
- Tiwari, R. G., Yadav, S. K., Misra, A., & Sharma, A. (2023). Classification of swarm collective motion using machine learning. In *Smart Innovation, Systems and Technologies* (pp. 173–181). Springer Nature Singapore.  
[https://doi.org/10.1007/978-981-19-5403-0\\_14](https://doi.org/10.1007/978-981-19-5403-0_14)
- Tobin, J., Fong, R., Ray, A., Schneider, J., Zaremba, W., & Abbeel, P. (2017). Domain randomization for transferring deep neural networks from simulation to the real world. In *2017 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (pp. 23–30). IEEE.  
<https://doi.org/10.1109/IROS.2017.8202133>

- Varma, S., & Simon, R. (2006). Bias in error estimation when using cross-validation for model selection. *BMC Bioinformatics*, 7(1), Article 91. <https://doi.org/10.1186/1471-2105-7-91>
- Vicsek, T., Czirók, A., Ben-Jacob, E., Cohen, I., & Shochet, O. (1995). Novel type of phase transition in a system of self-driven particles. *Physical Review Letters*, 75(6), 1226–1229. <https://doi.org/10.1103/PhysRevLett.75.1226>
- Vásárhelyi, G., Virágh, C., Somorjai, G., Nepusz, T., Eiben, A. E., & Vicsek, T. (2018). Optimized flocking of autonomous drones in confined environments. *Science Robotics*, 3(20), Article eaat3536. <https://doi.org/10.1126/scirobotics.aat3536>
- Winfield, A. F. T., Swana, M., Ives, J., & Hauert, S. (2025). On the ethical governance of swarm robotic systems in the real world. *Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 383(2289), Article 20240142. <https://doi.org/10.1098/rsta.2024.0142>
- Yang, S., Samarasinghe, D., Arukgoda, A., Abpeikar, S., Lakshika, E., & Barlow, M. (2023). Automatic recognition of collective emergent behaviors using behavioral metrics. *IEEE Access*, 11, 89077–89092. <https://doi.org/10.1109/ACCESS.2023.3304682>
- Yu, C., Velu, A., Vinitzky, E., Gao, J., Wang, Y., Bayen, A., & Wu, Y. (2022). The surprising effectiveness of PPO in cooperative multi-agent games. *Advances in Neural Information Processing Systems*, 35, 24611–24624.
- Zhao, W., Queralta, J. P., & Westerlund, T. (2020). Sim-to-Real transfer in deep reinforcement learning for robotics: A survey. In *2020 IEEE Symposium Series on Computational*

Intelligence (SSCI) (pp. 737–744). IEEE.

<https://doi.org/10.1109/SSCI47803.2020.9308468>

Zhu, P., Dai, W., Yao, W., Ma, J., Zeng, Z., & Lu, H. (2020).

MultiRobot flocking control based on deep reinforcement learning. IEEE Access, 8, 150397–150406.

<https://doi.org/10.1109/ACCESS.2020.3016951>

## BÖLÜM 2

# MAKİNE ÖĞRENMESİ ALGORİTMALARI İLE KONUT TİPİ BİNALARIN ENERJİ VERİMLİLİĞİ SINIFLARININ KESTİRİMİ VE KARŞILAŞTIRMALI ANALİZİ

**Hatice Zeynep AKDUMAN<sup>1</sup>**  
**Fırat KARABOĞA<sup>2</sup>**

### Giriş

Gelişen sanayi, hızlı nüfus artışı, kentleşme ve küresel ısınma olguları, dünya genelindeki enerji kaynakları üzerindeki baskıyı her geçen gün artırmaktadır. Uluslararası Enerji Ajansı (IEA) verilerine göre, küresel ölçekte üretilen birincil enerjinin yaklaşık %30 ila %40'ı konutlar ve ticari binalar tarafından tüketilmektedir. Binalardaki bu devasa enerji tüketiminin büyük bir bölümü ise iç mekan termal konforunu sağlamak amacıyla kullanılan Isıtma, Havalandırma ve İklimlendirme (HVAC) sistemlerine aittir (Tsanas ve Xifara, 2012; Seyedzadeh ve ark., 2018). Karbon salınımının azaltılması, küresel ısınma ile mücadele ve enerji maliyetlerinin

---

<sup>1</sup>Öğretim Görelisi, BAİBÜ, [Bilgisayar Programcılığı Programı, ORCID: 0000-0003-4946-8301

<sup>2</sup>Prof. Dr., BAİBÜ, Tıbbi Hizmetler ve Teknikler Bölümü, ORCID: 0000-0001-8168-3242

minimize edilmesi açısından binalarda enerji verimliliği ve performans optimizasyonu kritik bir öneme sahiptir (Amaryali ve El-Gohary, 2018; Deb ve ark., 2014; Zhao ve Magoulès, 2012).

Geleneksel bina mühendisliğinde, bir binanın enerji tüketimini tahmin etmek veya bina kabuğunun ısıl performansını optimize etmek amacıyla 'beyaz kutu' (white-box) olarak adlandırılan termodinamik simülasyon yazılımları (EnergyPlus, Ecotect, TRNSYS) kullanılmaktadır (Foucquier ve ark., 2013). Ancak bu yazılımların çalıştırılabilmesi için binanın üç boyutlu detaylı geometrisi, yapı malzemelerinin fiziksel yalıtım katsayıları, iç ısı kazançları ve çok sayıda dinamik meteorolojik veri gibi son derece karmaşık girdilere ihtiyaç duyulmaktadır. Bu durum, bina tasarımı yapan mimarların erken tasarım (avan proje) aşamasında alternatif formları hızlıca değerlendirmesini ve anlık enerji verimlilik sınıflandırması yapmasını imkansız kılmaktadır. Ayrıca fiziksel tabanlı bu yazılımların çalıştırılma ve hesaplama maliyetleri de oldukça yüksektir.

Fiziksel modellemenin getirdiği bu kısıtlamaları aşmak amacıyla, son yıllarda veri odaklı 'kara kutu' (black-box) modelleri olan yapay zeka ve makine öğrenmesi (MÖ) yaklaşımlarına yönelim artmıştır (Zhang ve ark., 2021; Bourdeau ve ark., 2019). Makine öğrenmesi yöntemleri, bina kabuğunun geometrik özelliklerini girdi olarak kabul edip, binanın ısıtma ve soğutma yükü gereksinimlerini yüksek doğrulukla kestirebilen vekil modeller (surrogate models) olarak işlev görmektedir. Literatürde, doğrusal sınıflandırma sınırlarına sahip Lojistik Regresyon modellerinden, karmaşık doğrusal olmayan sınırları öğrenebilen Destek Vektör Makinelerine (SVM), Karar Ağaçlarına ve yapay sinir ağlarına kadar geniş bir yelpazede yapay zeka modelleri binaların termal performans kestiriminde sıklıkla kullanılmaktadır (Dong ve ark., 2005; Li ve ark., 2009; Chou ve Bui, 2014).

Geçmiş çalışmalarda, binalarda ısıtma ve soğutma yüklerinin tahmini çoğunlukla sürekli sayısal değer kestirimi yapan regresyon modelleriyle gerçekleştirilmiştir (Atıcı ve Tuna, 2025; Seyedzadeh ve ark., 2019; Robinson ve ark., 2017). Ancak karar vericiler, mimarlar ve kamu otoriteleri için ham bir sayısal değerden ziyade, binanın doğrudan bir enerji performans sertifikası (EPC) veya enerji sınıfı etiketine (A, B, C, D sınıfları) atanması daha pratik ve anlamlı bir karar destek mekanizması sunmaktadır (Mathew ve ark., 2015; Granderson ve ark., 2015). Sınıflandırma odaklı bu yaklaşımlarda da algoritmaların birbirlerine göre başarımlı üstünlükleri ve hesaplama süreleri, sistem entegrasyonlarında kritik önem arz etmektedir (Bourdeau ve ark., 2019; Deb ve ark., 2014; Platon ve ark., 2015).

Bu çalışmanın temel amacı, konut tipi binaların geometrik tasarım parametrelerini girdi olarak kullanarak binaları enerji verimliliği sınıflarına (A, B, C, D) ayıran yüksek başarımlı modeller geliştirmek ve 8 farklı makine öğrenmesi algoritmasını karşılaştırmalı olarak analiz etmektir. Çalışma kapsamında doğrusal, mesafe tabanlı, ağaç tabanlı, topluluk öğrenmesine (bagging ve boosting) dayalı ve derin yapay sinir ağları mimarilerini temsil eden en popüler sınıflandırma algoritmaları test edilmiştir. Elde edilen doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1-skor değerleri üzerinden modellerin akademik performans karşılaştırmaları yapılarak en verimli bina tasarımları için parametrik çıkarımlar elde edilmiştir.

## **Materyal ve Metot**

### **Fiziksel Simülasyon ve Veri Kümesi Detayları**

Çalışmada, binaların fiziksel kabuk tasarımları ile ısı yükleri arasındaki ilişkileri incelemek üzere simülasyon ortamında üretilmiş olan ve literatürde geniş kabul gören UCI Energy Efficiency veri seti kullanılmıştır (Tsanas ve Xifara, 2012; UCI, 2012). Veriler, Autodesk Ecotect yazılımı kullanılarak 12 farklı bina şeklinin (farklı

hacim, yüzey alanı, en-boy oranları) kombinasyonlarından üretilen 768 konut binası simülasyonu ile elde edilmiştir. Girdi özellikleri; binanın göreceli sıkılığı (relative compactness), dış yüzey alanı (surface area), duvar alanı (wall area), çatı alanı (roof area), kat yüksekliği (overall height - 3.5m tek kat veya 7.0m çift kat), bina yönelimi (orientation - Kuzey, Doğu, Güney, Batı), cam oranı (glazing area - %0, %10, %25, %40) ve cam alanı dağılımı (glazing area distribution - uniform, kuzey, güney, doğu, batı cephe odaklı) olmak üzere 8 adettir. Göreceli sıkılık parametresi, binanın yüzey alanı ile hacmi arasındaki oranı ifade etmekte olup, termal kayıpları doğrudan belirleyen en kritik geometrik parametredir (Seyedzadeh ve ark., 2019).

### **Hedef Sınıfların Belirlenmesi ve Binning**

Binaların enerji verimliliği sınıflarının tahmin edilmesi, kamu otoritelerinin binaları Enerji Performans Sertifikası (EPC) standartlarına göre değerlendirebilmesi için büyük öneme sahiptir (Mathew ve ark., 2015). Bu doğrultuda, orijinal veri kümesinde sürekli sayısal olan Isıtma Yüğü (Heating Load) hedef değeri, 4 farklı enerji verimliliği sınıfına (Sınıf A, B, C, D) dönüştürülmüştür. Binning (gruplama) işlemi sonrasında elde edilen sınıf sınırları ve örnek sayıları Tablo 1'de sunulmuştur. Sınıf dağılımının dengesiz olduğu (Sınıf A: 285 bina, Sınıf B: 163 bina, Sınıf C: 204 bina, Sınıf D: 116 bina) gözlemlendiğinden, veri kümesini eğitim (%80) ve test (%20) olarak bölerken 'stratify=y' parametresi kullanılarak her iki sette de sınıf oranlarının homojen dağılması güvence altına alınmıştır.

| Enerji Verimliliği Sınıfı | Isıtma Yüğü Sınırı (kW/m <sup>2</sup> ) | Açıklama ve Dağılım Adedi                 |
|---------------------------|-----------------------------------------|-------------------------------------------|
| Sınıf A                   | Yük < 15                                | Çok Yüksek Enerji Verimliliği (285 örnek) |
| Sınıf B                   | 15 <= Yük < 25                          | Yüksek Enerji Verimliliği (163 örnek)     |

|         |                |                                       |
|---------|----------------|---------------------------------------|
| Sınıf C | 25 <= Yük < 35 | Düşük Enerji Verimliliği (204 örnek)  |
| Sınıf D | Yük >= 35      | Verimsiz Tüketim Seviyesi (116 örnek) |

## Veri Ön İşleme ve Matematiksel Standardizasyon

Girdi özelliklerinin ölçekleri birbirinden oldukça farklıdır. Örneğin, Dış Yüzey Alanı 514.5 ile 808.5 m<sup>2</sup> arasında değişirken, Göreceli Sıklık parametresi 0.62 ile 0.98 arasında değerler almaktadır. Mesafe bazlı (KNN, SVM), doğrusal (Lojistik Regresyon) ve yinelemeli gradyan azalışı kullanan sinir ağları (MLP) algoritmalarının, büyük ölçekli değişkenlerin etkisi altında kalmasını önlemek amacıyla Z-skoru standardizasyonu uygulanmıştır (Dong ve ark., 2005; Li ve ark., 2009). Her bir özellik için Z-skoru dönüşüm formülü aşağıda verilmiştir:

$$z = (x - \text{mean}) / \text{std\_dev}$$

Burada x orijinal değeri, mean özelliğin ortalamasını ve std\_dev ise standart sapmasını temsil etmektedir. Ağaç tabanlı algoritmalar (Karar Ağaçları, Random Forest, Gradient Boosting) ölçek farklarından etkilenmediği için bu modellerde ham veriler kullanılmıştır.

## Sınıflandırma Modelleri ve Hiperparametreler

Çalışma kapsamında 8 adet makine öğrenmesi sınıflandırma algoritması eğitilmiştir:

- **Lojistik Regresyon (Logistic Regression):** Çok sınıflı sınıflandırma için One-vs-Rest (OvR) stratejisi kullanılmış, L2 regülarizasyon katsayısı C=1.0 ve maksimum yineleme max\_iter=1000 olarak set edilmiştir.

- **K-En Yakın Komşu (K-Nearest Neighbors - KNN):** Komşuluk sayısı  $K=5$  seçilmiş ve mesafe metriği olarak Minkowski ( $p=2$ , Öklid mesafesi) kullanılmıştır.
- **Destek Vektör Makineleri (Support Vector Classifier - SVC):** Doğrusal olmayan sınırları çözebilmek amacıyla RBF (Radial Basis Function) kerneli tercih edilmiş, hata payı toleransı  $C=10.0$  ve  $\gamma='scale'$  parametreleri tanımlanmıştır.
- **Naive Bayes (GaussianNB):** Özelliklerin her bir sınıfta normal dağılıma sahip olduğunu varsayan Gaussian Naive Bayes modeli kurulmuştur.
- **Karar Ağaçları (Decision Tree Classifier):** Dallanma kriteri olarak Gini belirsizliği seçilmiş, aşırı öğrenmeyi engellemek amacıyla maksimum ağaç derinliği  $\text{max\_depth}=5$  olarak sınırlandırılmıştır.
- **Rastgele Orman (Random Forest Classifier):** Bagging (torbalama) mimarisinde 100 adet karar ağacından oluşturulmuş, maksimum derinlik  $\text{max\_depth}=8$  olarak belirlenmiştir (Ahmad ve ark., 2017)
- **Gradient Boosting Classifier:** Boosting (güçlendirme) mimarisinde 100 ardışık tahminci ağaç kullanılmış, öğrenme oranı (learning rate) 0.1 ve  $\text{max\_depth}=4$  olarak set edilmiştir.
- **Çok Katmanlı Algılayıcı (MLP Classifier):** Yapay sinir ağı mimarisinde sırasıyla 64 ve 32 nöron içeren iki gizli katman (hidden layers) tasarlanmış, aktivasyon fonksiyonu olarak ReLU, optimizasyon algoritması olarak Adam seçilmiştir (Bagnasco ve ark., 2015).

Modellerin Python scikit-learn kütüphanesi kullanılarak yürütülen standardizasyon ve SVM eğitim süreçlerini içeren kod bloğu Şema 1'de gösterilmiştir.

```
# Python scikit-learn standardizasyon ve SVM model eğitim süreci
from sklearn.preprocessing import StandardScaler
from sklearn.svm import SVC


scaler = StandardScaler()
X_train_scaled = scaler.fit_transform(X_train)
X_test_scaled = scaler.transform(X_test)

svc_model = SVC(kernel='rbf', C=10.0, random_state=42)
svc_model.fit(X_train_scaled, y_train)
y_pred_svc = svc_model.predict(X_test_scaled)
```


## **Bulgular ve Tartışma**

### **Veri Analizi Bulguları**

Isıtma yükü verilerinin belirlenen eşik değerlere göre sıklık dağılımı Şekil 1'de, girdi özelliklerinin birbiriyle olan korelasyon katsayıları Şekil 2'de gösterilmiştir. Korelasyon analizleri, binalardaki göreceli sıklık ve kat yüksekliğinin ısı yüküyle yüksek düzeyde ilişkili olduğunu, dış yüzey alanının ise ters yönlü etkiye sahip olduğunu doğrulamaktadır (Li ve ark., 2009; Wei ve ark., 2018).



Şekil 1: Isıtma Yüğü Sıklık Dağılımı ve Belirlenen Sınıf Eşikleri



Şekil 2: Bina Geometrik Özellikleri Korelasyon Analizi (Heatmap)

## Sınıflandırma Sonuçlarının Karşılaştırılması

Modellerin test veri seti üzerindeki doğruluk (accuracy) ve macro F1-skor değerleri karşılaştırmalı olarak analiz edilmiştir. Elde edilen sayısal sonuçlar Tablo 2'de sunulmuş, doğruluk yüzdelерinin grafiksel dağılımı ise Şekil 3'te görselleştirilmiştir. Bulgular incelendiğinde, topluluk öğrenmesi (ensemble learning) temelli algoritmaların, geleneksel tekil sınıflandırıcılara kıyasla belirgin şekilde daha yüksek performans gösterdiği tespit edilmiştir.

| Algoritma Adı                   | Test Doğruluğu (Accuracy) | F1-Skor (Macro) |
|---------------------------------|---------------------------|-----------------|
| Gradient Boosting               | 0.9935                    | 0.9941          |
| Random Forest                   | 0.9805                    | 0.9796          |
| Support Vector Classifier (SVC) | 0.9610                    | 0.9624          |
| Decision Tree                   | 0.9610                    | 0.9520          |
| Multi-Layer Perceptron (MLP)    | 0.9545                    | 0.9528          |
| K-Nearest Neighbors (KNN)       | 0.9156                    | 0.9017          |
| Logistic Regression             | 0.6948                    | 0.6387          |
| Naive Bayes                     | 0.6753                    | 0.5467          |


Elde edilen sonuçlara göre en yüksek başarıyı %99.35 doğruluk oranı ve 0.9941 F1-Skoru ile Gradient Boosting Classifier elde etmiştir. Rastgele Orman (Random Forest) algoritması ise %98.05 doğruluk oranı ile en başarılı ikinci model olmuştur. Gradyan artırma (boosting) mekanizmasının, ağaçları ardışık olarak inşa edip bir önceki ağacın hatalarını minimize etmeye odaklanması, enerji eşik sınırlarındaki (15 kW/m<sup>2</sup> ve 25 kW/m<sup>2</sup> gibi keskin geçiş noktaları) mikro desenleri öğrenmede torbalama (bagging) yöntemine göre daha hassas çalışmasını sağlamıştır. SVC (%96.10) ve MLP (%95.45) modelleri de parametrik standardizasyon sonrasında yüksek performans sergileyerek doğrusal olmayan sınırları başarıyla modellemiştir (Netto, 2008; Bagnasco ve ark., 2015).

Buna karşın, Lojistik Regresyon (%69.48) ve Naive Bayes (%67.53) algoritmaları oldukça düşük doğruluk oranlarında kalmıştır. Bu durum, bina geometrik parametreleri ile ısıtma yükleri arasındaki ilişkinin doğrusal olmamasından (non-linear) kaynaklanmaktadır. Doğrusal sınıflandırma sınırları, veri uzayındaki çok boyutlu dağılımları etkin bir şekilde ayıramamakta ve yüksek yanlılık (high bias / underfitting) hatasına yol açmaktadır (Chou ve Bui, 2014). Dolayısıyla bu tür fiziksel simülasyon çıktılarının


tahmininde doğrusal modellerin tercih edilmemesi gerektiği kanıtlanmıştır.

En başarılı model olan Gradient Boosting algoritmasının Şekil 6'da sunulan karmaşıklık matrisi incelendiğinde, A, C ve D verimlilik sınıflarının test setinde %100 doğrulukla (sıfır hata ile) tahmin edildiği görülmektedir. Yalnızca B sınıfındaki (yüksek verimli) bir adet binanın model tarafından C sınıfı (düşük verimli) olarak yanlış sınıflandırıldığı gözlenmiştir. Bunun sebebi, 25 kW/m<sup>2</sup> sınır eşiğinde yer alan, cam oranı yüksek ve yönelimi güney cephesine bakan sınırdaki kalmış binaların ısı davranışlarının birbirlerine aşırı derecede yakınsamasıdır. Bu durum, sınırdaki kalan binaların sertifikasyon süreçlerinde makine öğrenmesi modellerinin çok düşük de olsa bir hata payı barındırabileceğini göstermektedir.


Şekil 5'te yer alan Rastgele Orman özellik önem dereceleri, mimari tasarım süreçleri için önemli fiziksel çıkarımlar sunmaktadır. Dış yüzey alanı ve göreceli sıklık parametreleri, enerji verimliliği sınıflarını belirleyen en ağırlıklı faktörler olarak saptanmıştır. Fiziksel açıdan, dış yüzey alanının artması binanın dış çevreyle olan ısı alışverişi yüzeyini büyütürken iletim (iletim) yoluyla gerçekleşen ısı kayıplarını artırmaktadır. Göreceli sıklık katsayısı yüksek olan (küçük forma daha yakın) binalarda ise hacme oranla dış yüzey alanı minimize edildiğinden ısı performans korunmaktadır (Seyedzadeh ve ark., 2019). İlginç bir şekilde, bina yönelimi (orientation) parametresinin sınıflandırma başarısına olan katkısı neredeyse sıfıra yakın bulunmuştur. Bu bulgu, yönelimin anlık güneş ışımasını kazançlarını etkilese de, yıllık toplam ısıtma yükü kimlik belgesi sınıfını değiştirmede bina kabuğu geometrisi kadar baskın bir rol oynamadığını göstermektedir (Tsanas ve Xifara, 2012; Li ve ark., 2009).




Şekil 3: Algoritmaların Test Doğruluğu Performans Grafiği



Şekil 4: Karar Ağacı Sınıflandırma Dallanma Şeması



### Şekil 5: Rastgele Orman Algoritmasına Göre Bina Özelliklerinin Önem Dereceleri



Şekil 6: En İyi Sınıflandırıcı (Gradient Boosting) Karmaşıklık Matrisi Isı Haritası

### Sonuç ve Öneriler

Bu çalışmada, konut tipi binaların çeşitli geometrik kabuk parametreleri ve tasarım değişkenleri kullanılarak binaların enerji verimliliği sınıflarının (A, B, C, D) makine öğrenmesi modelleriyle tahmin edilmesi süreci kapsamlı bir biçimde analiz edilmiştir. Elde edilen deneysel bulgular, Gradient Boosting Classifier modelinin %99.35 test doğruluğu ve 0.9941 F1-Skoru gibi üst düzey bir başarı sergilediğini ortaya koymuştur. Benzer şekilde, topluluk öğrenmesine dayanan Rastgele Orman (Random Forest) algoritması da %98.05 doğruluk oranı ile oldukça kararlı sonuçlar üretmiştir. Bu durum, doğrusal olmayan karmaşık fiziksel parametrelerin (göreceli sıklık, cam oranı, duvar ve çatı alanı ilişkisi) tahmini süreçlerinde topluluk (ensemble bagging/boosting) tabanlı modellerin doğrusal yöntemlere (Lojistik Regresyon ve Naive Bayes gibi) kıyasla anlamlı derecede daha yüksek bir genelleme kapasitesine sahip olduğunu göstermektedir (Bourdeau ve ark., 2019; Bagnasco ve ark., 2015). Özellik önem dereceleri incelendiğinde ise dış yüzey alanı ve göreceli sıklık parametrelerinin bina enerji kimlik sınıfını tayin

etmede en baskın girdiler olduđu, bina yöneliminin ise sınıflandırma başarısına neredeyse hiç etki etmediğı saptanmıştır.

Araştırmanın pratik ve akademik boyutlardaki en önemli katkısı, geleneksel termodinamik bina simülasyon araçlarının (EnergyPlus, Ecotect vb.) günler veya haftalar süren hesaplama maliyetlerini milisaniyeler seviyesine indirgeyen yüksek doğruluklu bir vekil model (surrogate model) ortaya koymasındır (Foucquier ve ark., 2013). Bu sayede, mimarlar ve inşaat mühendisleri henüz avan proje aşamasındayken, binaların geometrik formlarında veya cephe tasarımlarında yapacakları küçük değişikliklerin nihai enerji performans sınıfını nasıl etkileyeceğini anlık olarak analiz edebilecektir. Tasarım aşamasında yapılacak bu hızlı optimizasyon, binaların karbon ayak izinin düşürülmesinde ve ömür boyu enerji maliyetlerinin azaltılmasında sürdürülebilir yeşil bina hedeflerine doğrudan katkı sunacaktır (Amaryali ve El-Gohary, 2018; Wei ve ark., 2018).

Gelecekte gerçekleştirilecek akademik ve endüstriyel çalışmalar için şu öneriler sunulmaktadır:

- Dinamik İklim Verilerinin Entegrasyonu: Simülasyon tabanlı statik girdilerin ötesine geçilerek, iklim değişikliği senaryolarını barındıran dinamik meteorolojik (EPW) veri dosyaları modellere dahil edilmelidir.
- Kullanıcı Davranış Modelleri: Binalardaki gerçek enerji tüketiminin sadece fiziksel kabuğa değil, aynı zamanda bina sakinlerinin kullanım alışkanlıklarına da bağlı olduğu bilinmektedir (Deb ve ark., 2014). Bu doğrultuda, insan-bina etkileşimini ve doluluk şemalarını içeren zaman serisi modellerinin geliştirilmesi tahmin tutarlılığını artıracaktır.
- Graf Sınır Ağları (GNN): Binalardaki odaların ve katların termal ısı akış ilişkilerini birer graf yapısı olarak ele alan

Graf Sinir Ağları gibi gelişmiş derin öğrenme mimarileri kullanılarak bina içi enerji transfer dinamiği daha hassas modellenebilir.

- Akıllı Şebeke ve BMS Entegrasyonu: Eğitilen yüksek başarılı modellerin akıllı termostat sistemlerine, IoT uç cihazlarına (edge computing) veya Bina Yönetim Sistemlerine (BMS) entegre edilerek, dinamik yük dengeleme ve talep tepkisi (demand-response) uygulamalarında gerçek zamanlı kontrol mekanizması olarak kullanılması enerji arz güvenliğine katkı sağlayacaktır (Platon ve ark., 2015; Granderson ve ark., 2015).

## Kaynakça

- Ahmad, T., Chen, H., Guo, Y., & Wang, J. (2018). A review on machine learning forecasting models for utility-scale energy, solar and wind power. *Applied Energy*, 231, 1021-1045. DOI: 10.1016/j.apenergy.2018.09.071
- Ahmad, M. W., Mourshed, M., & Rezgui, Y. (2017). Trees vs Neurons: Comparison between random forest and ANN for high-resolution prediction of building energy consumption. *Energy and Buildings*, 147, 77–89. <https://doi.org/10.1016/j.enbuild.2017.04.038>
- Amaryali, K., & El-Gohary, N. M. (2018). A review of data-driven building energy consumption prediction studies. *Renewable and Sustainable Energy Reviews*, 81, 263-281. DOI: 10.1016/j.rser.2017.04.095
- Atıcı, S., & Tuna, G. (2025). Comparative Evaluation of Regression Models for Building Energy Efficiency Assessment Based on Heating and Cooling Load Requirements. *Kirklareli University Journal of Engineering and Science*, 11(2), 283–303. <https://doi.org/10.34186/klujes.1804525>
- Bagnasco, A., Fresi, F., Silvestro, F., & Vinci, A. (2015). Realtime building energy prediction with neural networks. *Applied Energy*, 160, 486-493. DOI: 10.1016/j.apenergy.2015.09.053
- Bourdeau, M., Zhai, X. Q., Nefzaoui, E., Koppyi, X., & Diaz, T. (2019). Modeling and forecasting building energy consumption: A review of data-driven techniques. *Sustainable Cities and Society*, 48, 101533. DOI: 10.1016/j.scs.2019.101533
- Chou, J. S., & Bui, D. K. (2014). Modeling heating and cooling loads in energy-efficient buildings using machine learning. *Energy*

- and Buildings, 77, 276-285. DOI: 10.1016/j.enbuild.2014.03.069
- Deb, C., Eang, L. S., Yang, J., & Lee, S. E. (2014). Forecasting building energy consumption: A review. *Renewable and Sustainable Energy Reviews*, 31, 263-281. DOI: 10.1016/j.rser.2013.11.010
- Dong, B., Cao, C., & Lee, S. E. (2005). Applying support vector machines to predict building energy consumption in tropical region. *Energy and Buildings*, 37(5), 545-553. DOI: 10.1016/j.enbuild.2005.03.003
- Fan, C., Xiao, F., & Zhao, Y. (2017). A short-term building cooling load prediction method using deep learning algorithms. *Applied Energy*, 195, 222-233. DOI: 10.1016/j.apenergy.2017.05.109
- Foucquier, A., Robert, S., Suard, F., Stéphan, L., & Jay, A. (2013). State of the art in building modelling and energy performances prediction: A review. *Renewable and Sustainable Energy Reviews*, 23, 272-288. <https://doi.org/10.1016/j.rser.2013.03.004>
- Granderson, J., Fernandes, S., Son, Y., Custodio, C., & Sohn, M. D. (2015). Operational evaluation of building energy performance using statistical models. *Applied Energy*, 156, 451-460. DOI: 10.1016/j.apenergy.2015.07.032
- Li, Q., Meng, Q., Cai, J., Yoshino, H., & Mochida, A. (2009). Predicting hourly cooling load in the building using support vector machine. *Applied Energy*, 86(10), 2231-2237. DOI:10.1016/j.apenergy.2009.02.012
- Mathew, P., Dunn, L. N., Sohn, M. D., Mercado, A., Custodio, C., & Walter, T. (2015). Big-data for building energy performance:

- Lessons from assembling a very large national database. *Energy and Buildings*, 103, 30-36. DOI: 10.1016/j.enbuild.2015.06.012
- Netto, J. F. (2008). Comparison between detailed model simulation and artificial neural network for forecasting building energy consumption. *Energy and Buildings*, 40(12), 2239-2245. DOI: 10.1016/j.enbuild.2008.06.013
- Platon, R., Dehkordi, V. R., & Martel, J. (2015). Infrastructure energy consumption prediction using neural networks and support vector regression. *Applied Energy*, 154, 762-772. DOI:10.1016/j.apenergy.2015.05.059
- Robinson, C., Dilkina, B., Hubbs, J., Zhang, W., Guhathakurta, S., Brown, M. A., & Pendyala, R. M. (2017). Machine learning approaches for estimating commercial building energy consumption. *Applied Energy*, 208, 889–904. <https://doi.org/10.1016/j.apenergy.2017.09.060>
- Seyedzadeh, S., Rahimian, F. P., Glesk, I., & Roper, M. (2018). Machine learning for estimation of building energy consumption and performance: A review. *Visualization in Engineering*, 6(1). <https://doi.org/10.1186/s40327-018-0064-7>
- Seyedzadeh, A., Rahimian, F. P., Glesk, I., & Roper, M. (2019). Building energy efficiency estimations with random forest for single and multi-zones. *Energy and Buildings*, 197, 120-132. DOI: 10.1016/j.enbuild.2019.05.057
- Tang, L., Xie, H., Wang, X., & Bie, Z. (2023). Privacy-preserving knowledge sharing for few-shot building energy prediction: A federated learning approach. *Applied Energy*, 337, 120857. DOI: 10.1016/j.apenergy.2023.120857

- Tsanas, A., & Xifara, A. (2012). Accurate quantitative estimation of energy performance of residential buildings using statistical machine learning tools. *Energy and Buildings*, 49, 560-567. DOI: 10.1016/j.enbuild.2012.03.003
- UCI Machine Learning Repository (2012). Energy Efficiency Dataset. DOI: 10.24432/C51307
- Wei, Y., Zhang, X., Shi, Y., Xia, L., & Pan, S. (2018). A review of data-driven approaches for prediction and classification of building energy consumption. *Renewable and Sustainable Energy Reviews*, 82, 1027-1047. DOI: 10.1016/j.rser.2017.09.108
- Zhang, L., Wen, J., Li, Y., Chen, J., Ye, Y., Zhan, Y., & Li, S. (2021). A review of machine learning in building load prediction. *Applied Energy*, 285, 116452. DOI: 10.1016/j.apenergy.2020.116452
- Zhao, H. X., & Magoulès, F. (2012). A review on the prediction of building energy consumption. *Renewable and Sustainable Energy Reviews*, 16(6), 3586-3592. DOI: 10.1016/j.rser.2012.02.049

## BÖLÜM 3

# SÜRÜ ROBOTİĞİNDE MERKEZİYETSİZ KONTROL, MATEMATİKSEL MODELLER VE GELECEK UYGULAMALARI

**Hatice Zeynep AKDUMAN<sup>1</sup>**

### Giriş

#### Sürü Zekasının Tarihsel Gelişimi ve Tanımı

Geleneksel robotik mühendisliği yüzyıllardır yüksek işlem gücüne sahip, hassas algılayıcılarla donatılmış ve genellikle merkezi bir bilgisayar tarafından sevk ve idare edilen tekil robotik sistemler üzerine odaklanmıştır. NASA'nın Mars keşif araçları (Curiosity, Perseverance) veya sanayi fabrikalarındaki devasa robot kollar bu yaklaşımın klasik örnekleridir. Tekil otonom robotlar belirli ve sınırlı görevlerde son derece yüksek doğruluk ve tekrarlanabilirlik sunmaktadır. Ancak bu geleneksel yaklaşımın iki kritik zayıflığı bulunmaktadır: sistem birim maliyetlerinin aşırı yüksek olması ve ortamda meydana gelen beklenmedik değişikliklere karşı kırılganlık. Merkezi bir sunucuya veya tek bir lider robota bağımlı çalışan sistemlerde, bu merkezi bileşenin arızalanması, iletişim hattının kesilmesi veya düşman unsurlar tarafından engellenmesi tüm

---

<sup>1</sup>Öğretim Görelisi, BAİBÜ, Bilgisayar Programcılığı Programı, ORCID: 0000-0003-4946-8301

operasyonel yapının çökmesine neden olmaktadır (Single Point of Failure / Tek Nokta Hatası).

Buna karşın doğa, milyonlarca yıllık evrimsel süreç boyunca karmaşık çevre koşullarında hayatta kalabilmek için bambaşka bir mühendislik prensibi geliştirmiştir: Sürü Zekası (Swarm Intelligence) (Rubenstein et al., 2014; Reynolds, 1987). Biyolojik dünyada tek bir karınca, tek bir arı veya tek bir sığırcık kuşu sınırlı algılama yeteneğine ve küçük bir beyin kapasitesine sahiptir. Tek bir karıncanın devasa bir bölgenin topoğrafik haritasını çıkarması veya optimal rota optimizasyonu yapması imkânsızdır. Ancak yüz binlerce karıncadan oluşan bir koloni, hiçbir merkezi komutana veya lider karıncaya ihtiyaç duymadan, alan üzerindeki en kısa yolları keşfedebilmekte, nehirlerin üzerine kendi vücutlarından canlı köprüler inşa edebilmekte ve havalandırma kanallarına sahip devasa mimari kuleler kurabilmektedir.

Sürü robotiği literatüründe Dudek et al. (1996), Şahin (2005), Dudek ve ark. (1996) ile Brambilla ve ark. (2013)'ün tanımlarına göre tarafından yapılan tanımlamalara göre bir sistemin sürü robotiği olarak sınıflandırılabilmesi için şu nitelikleri taşıması şarttır: 1. Robotlar otonom olmalı ve fiziksel çevre içerisinde hareket edebilmelidir. 2. Robot grubu genellikle homojen (veya belirli oranlarda heterojen) ve büyük sayılardan ( $N > 10$ ) oluşmalıdır. 3. Robotların sahip olduğu donanım ve işlem kapasitesi, çözülmesi hedeflenen küresel göreve kıyasla son derece basit ve kısıtlı olmalıdır. 4. Robotlar arasındaki haberleşme ve algılama küresel (global) değil, kesinlikle yerel (local) kısıtlar dahilinde gerçekleşmelidir. 5. Sistemde küresel bir kontrole sahip tek bir lider veya merkezi sunucu bulunmamalı; kontrol tamamen dağıtık ve yerel etkileşimlere dayalı olmalıdır.

## Klasik Robotik ile Sürü Robotiğinin Sistematik Karşılaştırılması

Klasik merkezi robotik yaklaşımları ile dağıtık sürü robotik yaklaşımları arasındaki temel teknik farklar aşağıdaki tabloda detaylı olarak karşılaştırılmıştır:

| Karşılaştırma Kriteri            | Merkezi / Klasik Robotik Sistemler          | Sürü Robotik Sistemleri                                                         |
|----------------------------------|---------------------------------------------|---------------------------------------------------------------------------------|
| Kontrol Mimarisi                 | Merkezi Sunucu / Lider Robot Kontrolü       | Tamamen Merkeziyetsiz (Dağıtık Kontrol) (Brambilla et al., 2013), (Şahin, 2005) |
| Birim Maliyeti                   | Yüksek (Lidar, yüksek güçlü CPU)            | Çok düşük (Seri üretilebilir mikro birimler) (Rubenstein et al., 2014)          |
| Haberleşme Mimarisi              | Küresel Ağ (Wi-Fi, 5G, SatCom)              | Yerel Algılama (IR, UWB, Yakın Mesafe) (Olfati-Saber, 2006)                     |
| Haberleşme Karmaşıklığı          | $O(N^2)$ (Robot sayısı arttıkça ağ tıkanır) | $O(1)$ (Sadece fiziksel komşu sayısı kadar)                                     |
| Hata Toleransı (Fault Tolerance) | Düşük (Merkez çökerse sistem durur)         | İnanılmaz Yüksek (Robot kayıpları etkilemez)                                    |
| Ölçeklenebilirlik (Scalability)  | Sınırlı ( $N > 50$ kilitlenme yaratır)      | Sınırsız ( $N = 100.000$ robot aynı çalışır) (Rubenstein et al., 2014)          |
| Esneklik (Flexibility)           | Düşük (Önceden programlanmış rota)          | Yüksek (Dinamik biçim ve görev değişimi)                                        |

---

## Teorik Çerçeve Ve Biyolojik İlham Kaynakları

### Biyolojik Kolonilerin Organizasyon Şemaları

Sürü robotiği algoritmalarının tamamı doğada gözlemlenen ve milyonlarca yıldır başarıyla çalışan canlı kolonilerinin davranışlarından esinlenmiştir (Vásárhelyi et al., 2018; Couzin et al., 2002; Couzin et al., 2005):


- Arjantin Karıncaları (*Linepithema humile*): Karıncalar görme yetileri oldukça zayıf olan canlılardır. Yiyecek arayışına çıkan bir karınca rastgele yürüyüş (random walk) gerçekleştirir. Yiyecek kaynağını bulduğunda yuvaya dönerken geçtiği zemine feromon adı verilen kimyasal bir salgı bırakır. Diğer karıncalar feromon kokusunun yoğun olduğu yönlere doğru çekilir. Kısa yoldan gidip gelen karıncalar birim zamanda daha fazla tur attıkları için kısa yoldaki feromon miktarı hızla katlanır. Uzun yoldaki feromon ise zamanla buharlaşarak (evaporation) yok olur. Böylece karınca kolonisindeki hiçbir karınca harita çizmeden en kısa yolu kolektif olarak tespit eder (Dorigo & Stützle, 2004; Hunt et al., 2019).
- Sığırcık Kuşları (*Sturnus vulgaris*): Sonbahar aylarında binlerce sığırcık kuşunun havada oluşturduğu devasa akıcı dalgalanmalar (murmurasyon) bir doğa harikasıdır. Kuş sürüsünde hiçbir lider kuş yoktur. 2008 yılında yapılan 3D stereo kamera analizleri (STARFLAG projesi), her kuşun yalnızca en yakınındaki 6 ila 7 komşusunu takip ettiğini göstermiştir. Kuşlar komşularının yön ve hız değişimine milisaniyeler içerisinde tepki vererek sürü kopmadan ve birbirine

çarpmadan karmaşık manevralar gerçekleştirir (Reynolds, 1987; Couzin et al., 2005).

- Altın Balık Okulları (*Notemigonus crysoleucas*): Balıklar yırtıcı bir tehdit algıladıklarında yan çizgilerinde bulunan mekanik basınç sensörleri sayesinde sudaki en ufak dalgalanmayı hissederler. Tek bir balığın kaçış hareketi bir dalga gibi tüm balık okuluna yayılır ve okul anında “patlama” formasyonuna geçerek yırtıcının hedefini şaşırtır (Couzin et al., 2002).
- Afrika Termitleri (*Macrotermes bellicosus*): Milyonlarca kör termit işçisi, hiçbir mimari çizim veya şantiye şefi olmadan, toprağı tükürükleriyle harç yapıp üst üste koyarak 5-6 metre yüksekliğinde devasa kuleler inşa eder. Bu kulelerin içerisinde iç sıcaklığı ve karbondioksit oranını sabitleyen doğal havalandırma bacaları bulunmaktadır.

### **Stigmerji (Stigmergy) Kuramı ve Çevre Üzerinden İletişim**

Fransız biyolog Pierre-Paul Grassé tarafından 1959 yılında termitlerin yuva yapma davranışlarını incelerken ortaya atılan Stigmerji (Stigmergy) kavramı, sürü zekasının en kritik haberleşme teorisidir.



*Şekil 1: Stigmerji Kuramı ve Çevre Üzerinden İletişim Blok Diyagramı*

Şekil 1’de sunulan blok diyagram, sürü robotiğinde doğrudan kablosuz haberleşme (RF/Wi-Fi) ihtiyacını ortadan kaldıran dolaylı etkileşim (stigmerjik iletişim) mekanizmasını üç temel bileşen ve kapalı çevrim geri besleme döngüsü üzerinden modellemektedir:

İlk aşamada Robot A, kendi eyleyici (actuator) modülleri vasıtasıyla fiziksel çevreye bir eylem çıktısı üretir. Biyolojik karıncalarda bu işlem zemin üzerine feromon damlatılması iken; yapay robotik sistemlerde fiziksel nesnelerin taşınması, zemin üzerine ışık/reng projeksiyonu yapılması veya dijital iz matrislerinin ( $i, j$  ızgaraları) güncellenmesidir. Robot A’nın ortama bıraktığı anlık iz miktarı  $\Delta\tau_{ij}$  olarak ifade edilir.

Fiziksel ortam yalnızca pasif bir mekan değil, bilginin depolandığı ve işlendiği “dağıtık bir hafıza” (distributed memory) olarak görev yapar. Ortamdaki iz yoğunluğu  $\tau_{ij}(t)$ , birikim ve buharlaşma süreçlerinin diferansiyel dengesiyle dinamik olarak güncellenir:

$$\tau_{ij}(t + 1) = (1 - \rho)\tau_{ij}(t) + \sum_{k \in \text{Sürü}} \Delta \tau_{ij}^k(t)$$

Burada  $\rho \in (0,1]$  feromon buharlaşma katsayısını temsil etmektedir. Buharlaşma mekanizması, süresi dolmuş veya hatalı rota bilgilerinin sistem hafızasından otomatik olarak silinmesini ve sürü hafızasının sürekli güncel kalmasını sağlar.

Robot B, doğrudan Robot A ile haberleşmek yerine, lokal sensörleri ile çevredeki iz yoğunluğu gradyanını  $\nabla \tau(x, y)$  algılar. Robot B'nin bir sonraki hareket yönünü seçme olasılığı  $P_{ij}$ , iz yoğunluğu  $\tau_{ij}$  ve sezgisel uzaklık  $\eta_{ij}$  ile orantılı stokastik karar kuralı üzerinden hesaplanır:

$$P_{ij}(t) = \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in \mathcal{N}_i} [\tau_{il}(t)]^\alpha [\eta_{il}]^\beta}$$

Burada  $\alpha$  ve  $\beta$  sırasıyla iz izleme ve sezgisel bilginin göreceli ağırlık parametreleridir.

Robot B çevredeki yoğun iz gradyanını takip edip hedefe ulaştıkça, kendisi de ortama ek iz salımı yapar (3. Tepki ve Yeni İz Salımı). Böylece olumlu geri besleme (positive feedback) mekanizması devreye girerek en optimal yollardaki iz birikimi katlanarak artar. Bu dolaylı etkileşim döngüsü, robot sayısı  $N \rightarrow \infty$  değerine ulaşsa dahi haberleşme karmaşıklığını  $O(1)$  seviyesinde sabitleyen en temel sürü zekası mekanizmasıdır (Hunt et al., 2019; Schranz et al., 2020).

## **Sürü Robotiğinin Temel İlkeleri ve Mühendislik Sütunları**

Sürü robotiğini geleneksel çoklu robot sistemlerinden (Multi-Robot Systems - MRS) ayıran temel nitelik, sistem mimarisinin dayandığı dört ana mühendislik sütunudur. Bu sütunlar yalnızca yazılımsal birer tercih değil; donanım tasarımıyla ağ topolojisine, sensör füzyonundan sürü mekaniğine kadar tüm

sistemin dinamiklerini belirleyen temel aksiyomlardır (Rubenstein et al., 2014; Brambilla et al., 2013; Şahin, 2005; Bayındır & Şahin, 2007)

### **Merkeziyetsizlik (Decentralization) ve Lidersizlik Paradigması**

Klasik robotik mimarilerinde kontrol döngüsü merkezi bir sunucuda veya lider bir robotta yürütülür. Merkezi sunucu tüm ortam verisini toplar, küresel optimizasyon problemini çözer ve her robota ayrı ayrı hareket komutu gönderir. Bu durum iki büyük mühendislik zafiyeti yaratır: 1. İletişim ve İşlem Darboğazı: Robot sayısı arttıkça merkezi sunucunun işlem yükü katlanarak büyür. 2. Tek Nokta Hatası (Single Point of Failure): Lider robot arızalandığında veya iletişim kesildiğinde tüm yapı çöker.

Sürü robotiğinde ise küresel bir otorite, merkezi sunucu veya sabit lider yoktur. Sistem durumu, her bir robotun yerel durumlarının kümesidir. i. robotun t anındaki konumu  $r_i(t)$  olsun. Robotun kontrol girdisi  $u_i(t)$  yalnızca kendi yerel durumu ve komşularının durumlarına bağlı hesaplanır:

$$u_i(t) = f(x_i(t), \{x_j(t) \mid j \in \mathcal{N}_i(t)\})$$

### **Ölçeklenebilirlik (Scalability) ve O(1) Karmaşıklık Analizi**

Ölçeklenebilirlik, sistemdeki robot sayısı N artırıldığında veya azaltıldığında, robot kontrol algoritmalarının veya iletişim protokollerinin yeniden tasarlanmasına gerek kalmaması niteliğidir. Geleneksel sistemlerde all-to-all haberleşme  $O(N^2)$  karmaşıklık yaratır ve ağı kilitler. Sürü robotiğinde haberleşme yerel kısıtlı olduğundan ortalama komşu sayısı K sabittir ( $K \ll N$ ). Dolayısıyla robot başına haberleşme yükü  $O(1)$  kalır. Sisteme 10.000 robot daha eklense dahi bir robotun maruz kaldığı işlem yükü değişmez (Rubenstein et al., 2014; Olfati-Saber, 2006 ).

## **Esneklik (Flexibility) ve Dinamik Adaptasyon**

Esneklik, sürü robotlarının önceden tanımlanmamış, belirsiz ve dinamik olarak değişen çevre koşullarına anında biçim değiştirerek uyum sağlama yeteneğidir.

- **Morfolojik Plastisite (Biçim Değiştirme):** Sürü robotları dar bir engelden geçerken (Örn: Enkaz tüneli) anında tek sıra haline gelir, açık alana çıktığında ise dairesel veya Voronoi yayılım formasyonuna geçer.
- **Dinamik Görev Değişimi:** Bir bölgede keşif tamamlandığında, robotlar çevre uyarısına göre otonom olarak alan taramasından hedef taşıma moduna geçer.
- **Eşik Tabanlı Tepki Modelleri (Threshold-based Response):** Bir görevi yürüten robot sayısı azaldığında o görevin uyarı şiddeti artar ve boşta kalan robotlar otomatik olarak o göreve kayar(Prorok et al., 2017; Schranz et al., 2020).

## **Hata Toleransı (Fault Tolerance) ve Güvenilirlik Matematiği**

Hata Toleransı, sürüdeki bireysel robotların arızalanması, imha olması, pilinin bitmesi veya siber saldırıya uğraması durumunda dahi sürünün görevini durdurumaması, kendi kendini onararak (Self-Healing) çalışmaya devam etmesidir.

Tekil robotik sistemlerde tek bir elemanın bozulması tüm görevi iptal eder. Sürü robotiğinde ise robotlar birbirinin ikamesidir (Redundancy). Bir robot arızalandığında komşuları onun eksikliğini algılar; Boids itme-çekme kuvvetleri ve Voronoi hücre yeniden yapılandırması sayesinde boşalan alan anında doldurulur (Density Repair).

Markov zinciri arıza olasılık modeliyle  $N_0$  robotla başlayan bir sürünün  $t$  anında  $N(t)$  adet çalışan robota sahip olma olasılığı Poisson dağılımı gösterir:

$$P(N(t) = k) = \frac{(N_0 \lambda t)^{N_0 - k}}{(N_0 - k)!} e^{-N_0 \lambda t}$$

Kritik çalışma kütlesi  $N_{crit}$  korunduğu sürece (Quorum Sensing), sürü görevi eksiksiz tamamlar (Trianni et al., 2003).

## Matematiksel Modeller ve Algoritmik Yapılar

Sürü robotik sistemlerinde küresel bir davranışın (emergent behavior) yerel etkileşim kurallarından türetilmesi, matematiksel modellemenin ve kontrol teorisinin titizlikle uygulanmasını gerektirir. Bu bölümde, tekil robot kinetik ve dinamik modellerinden başlanarak, graf teorisi çerçevesinde haberleşme topolojileri, Craig Reynolds Boids ve Olfati-Saber sürü teorisi, Graf Laplacian tabanlı konsensüs dinamiği, Voronoi kapsama kontrolü, Karınca Kolonisi Optimizasyonu (ACO), Parçacık Sürü Optimizasyonu (PSO) ve bu yöntemlere ait algoritmik sözde kodlar (pseudo-code) eksiksiz bir matematiksel formalizm ile türetilmiştir.

## Kinematik ve Dinamik Robot Modelleri

Sürüdeki bireysel robotların fiziksel hareket yetenekleri ve dinamik kısıtları, geliştirilen kontrol kanunlarının uygulanabilirliğini doğrudan belirler. Sürü literatüründe yaygın olarak kullanılan üç temel dinamik model aşağıda tanımlanmıştır.

### 1. Holonomik Nokta-Kütle Dinamik Modeli

İkinci derece (double-integrator) holonomik kütle modeli, teorik analizlerde ve hava/kara sürülerinin üst seviye yol planlamasında temel kabul edilir.  $i$ . robotun konumu  $q_i \in \mathbb{R}^d$  ( $d \in \{2,3\}$ ) ve hızı  $p_i \in \mathbb{R}^d$  olmak üzere sistem dinamiği:

$$\dot{q}_i(t) = p_i(t)$$

$$\dot{p}_i(t) = u_i(t)$$

burada  $u_i(t) \in \mathbb{R}^d$  robota uygulanan kontrol kuvveti (ivme vektörü) veya ivme girdisidir.

## 2. Non-Holonomik Tek Tekerlekli (Unicycle) Kinematik Modeli

İki tekerlekli diferansiyel sürüşe sahip karasal sürü robotları (Kilobot, e-puck, Thymio) kayma yapmayan durum kısıtlarına (non-holonomic constraints) tabidir.  $i$ . robotun durumu  $\mathbf{x}_i = [x_i, y_i, \theta_i]^T \in \mathbb{R}^2 \times S^1$  ile ifade edilir:

$$\begin{bmatrix} \dot{x}_i \\ \dot{y}_i \\ \dot{\theta}_i \end{bmatrix} = \begin{bmatrix} \cos\theta_i & 0 \\ \sin\theta_i & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v_i \\ \omega_i \end{bmatrix}$$

Burada  $v_i \in \mathbb{R}$  çizgisel hız,  $\omega_i \in \mathbb{R}$  ise açısal hız kontrol girdileridir. Non-holonomik kısıt denklemi  $\dot{x}_i \sin\theta_i - \dot{y}_i \cos\theta_i = 0$  olup, robotun yan yana doğrudan ötelenmesini engeller.

## 3. 3D Dört Pervaneli (Quadrotor) Dinamik Modeli

İHA sürüleri (Crazyflie 2.1) için kullanılan 6 serbestlik dereceli (6-DOF) rijit cisim dinamik modeli:

$$m_i \ddot{\mathbf{r}}_i = m_i g \mathbf{e}_3 + R_i \begin{bmatrix} 0 \\ 0 \\ f_i \end{bmatrix}$$

$$J_i \dot{\Omega}_i = -\Omega_i \times (J_i \Omega_i) + \mathbf{M}_i$$

Burada  $\mathbf{r}_i \in \mathbb{R}^3$  eylemsiz çerçevedeki konum,  $R_i \in SO(3)$  yönelim matrisi,  $f_i$  toplam itki kuvveti,  $J_i$  eylemsizlik momenti matrisi,  $\Omega_i$  gövde açısal hızı ve  $\mathbf{M}_i$  kontrol torkları kümesidir.

## Graf Teorisi ve Algoritma Ağ Topolojisi

Sürü robotik sistemlerinde haberleşme ve algılama yapısı, yönlü veya yönsüz bir çizge (graph)  $\mathcal{G}(t) = (\mathcal{V}, \mathcal{E}(t))$  ile modellenir.

$\mathcal{V} = \{1, 2, \dots, N\}$ : Sürüdeki  $N$  adet otonom robotu temsil eden düğümler (nodes) kümesidir.

$\mathcal{E}(t) \subseteq \mathcal{V} \times \mathcal{V}$ :  $t$  anındaki aktif haberleşme veya algılama kenarları (edges) kümesidir.  $(j, i) \in \mathcal{E}(t)$  ifadesi,  $i$ . robotun  $j$ . robotun verisini alabildiğini gösterir.

### 1. Dinamik Komşuluk Kümesi

Fiziksel uzayda  $r_i$  konumundaki  $i$ . robotun  $R_{comm}$  algılama/haberleşme yarıçapı dahilindeki komşularının kümesi:

$$\mathcal{N}_i(t) = \{j \in \mathcal{V} \setminus \{i\} \mid \|q_j(t) - q_i(t)\| \leq R_{comm}\}$$

### 2. Matrisel Gösterimler ve Graf Laplacian

Ağ yapısı üç temel matris ile karakterize edilir:

**Komşuluk Matrisi (Adjacency Matrix)**  $A = [a_{ij}] \in \mathbb{R}^{N \times N}$ :

$$a_{ij} = \begin{cases} 1, & \text{eğer } (j, i) \in \mathcal{E} \text{ ve } i \neq j \\ 0, & \text{aksi halde} \end{cases}$$

**Derece Matrisi (Degree Matrix)**  $D = \text{diag}(d_1, d_2, \dots, d_N) \in \mathbb{R}^{N \times N}$ :

$$d_i = \sum_{j=1}^N a_{ij} = |\mathcal{N}_i|$$

**Graf Laplacian Matrisi (Graph Laplacian)**  $L = [l_{ij}] \in \mathbb{R}^{N \times N}$ :

$$L = D - A \Rightarrow l_{ij} = \begin{cases} d_i, & i = j \\ -a_{ij}, & i \neq j \end{cases}$$


### 3. Laplacian Matrisinin Spektral Özellikleri

Yönsüz ve bağlı bir graf için Graf Laplacian matrisi  $L$  şu kritik matematiksel niteliklere sahiptir: -  $L$  simetriktir ve yarı pozitif

tanımlıdır ( $L = L^T \geq 0$ ). -  $L$ 'nin özdeğerleri  $0 = \lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_N$  şeklinde sıralanır. -  $\mathbf{1} = [1, 1, \dots, 1]^T$  vektörü 0 özdeğerine karşılık gelen özvektördür ( $L\mathbf{1} = \mathbf{0}$ ). - **Cebirsel Bağlılık (Algebraic Connectivity / Fiedler Değeri)**: İkinci en küçük özdeğer  $\lambda_2(L) > 0$  ise graf kesinlikle bağlıdır (connected).  $\lambda_2(L)$  değeri ağıın haberleşme hızı ve konsensüs yakınsama performansının doğrudan bir göstergesidir (Olfati-Saber, 2006; Jadbabaie et al., 2003).

## Craig Reynolds Boids ve Olfati-Saber Flocking Teorisinin Matematiksel Derinliği

Sürü hareketinin matematiksel temelleri Craig Reynolds'ın sezgisel Boids kurallarından Olfati-Saber'in analitik dinamik sistemler ve potansiyel alanlar teorisine uzanmaktadır.



Şekil 2: Craig Reynolds Boids ve Olfati-Saber Sürü Kontrol Blok Diyagramı

Şekil 2'de sunulan blok diyagram, Craig Reynolds'ın sezgisel Boids kuralları ile R. Olfati-Saber'in analitik yapay potansiyel alanlar (Artificial Potential Fields - APF) ve kapalı çevrim kontrol teorisini tek bir sistem mimarisinde birleştirmektedir.

Mimarinin işleyişi, beş temel işlevsel katman ve gerçek zamanlı durum geri beslemesi üzerinden detaylı olarak açıklanabilir:

Kontrol döngüsünün ilk bloğu olan **Komşuluk Algılama** ( $\mathcal{N}_i(t)$ ),  $i$ . robotun  $R_{comm}$  iletişim ve algılama yarıçapı içerisindeki dinamik komşu kümesini belirler:

$$\mathcal{N}_i(t) = \{j \in \mathcal{V} \setminus \{i\} : \|q_j(t) - q_i(t)\| \leq R_{comm}\}$$

Bu bloktan elde edilen komşu robotların anlık konum ( $q_j$ ) ve hız ( $p_j$ ) vektörleri, orta katmandaki alt sistem bloklarına aktarılır. Aynı zamanda **Sanal Lider / Hedef** bloğu, sürünün küresel olarak takip etmesi gereken yörünge koordinatlarını ( $q_r, p_r$ ) Navigasyon Kuvveti bloğuna besler.

Orta katmanda yer alan dört bağımsız alt sistem, robotun maruz kaldığı fiziksel ve sanal kuvvetleri eş zamanlı olarak hesaplar:

**Ayrılma Kuvveti** ( $f_{sep}$ ): Robotlar arası güvenli mesafeyi ( $r_\alpha$ ) koruyarak çarpışmayı önleyen kısa menzilli itme kuvvetidir. Olfati-Saber yaklaşımında gradient potansiyel  $\nabla_{q_i} \psi_\alpha(\|q_j - q_i\|_\sigma)$  ile pürüzsüzleştirilir.

**Hizalanma Kuvveti** ( $f_{align}$ ): Komşu robotların hız vektörleri arasındaki farkı sıfırlamaya çalışan sönümleme kuvvetidir. Graf Laplacian matrisinin komşuluk ilişkilerine göre  $f_i^{align} = \sum_{j \in \mathcal{N}_i} a_{ij}(q)(p_j - p_i)$  şeklinde hesaplanır.

**Birleşme Kuvveti** ( $f_{coh}$ ): Sürünün dağılmasını engelleyerek kütle merkezine doğru tutunum sağlayan orta menzilli çekim kuvvetidir.

**Navigasyon Kuvveti** ( $f_{nav}$ ): Sürünün hedefe veya sanal lidere ( $q_r, p_r$ ) doğru sevk edilmesini sağlayan  $f_i^{nav} = -c_1^\gamma \sigma_1(q_i - q_r) - c_2^\gamma (p_i - p_r)$  formülüne dayalı çekim bileşenidir.

Şekil 2’de görüldüğü üzere, dört ayrı alt sistemden türetilen kuvvet vektörleri Toplama Düğümüne ( $\Sigma$ ) dört farklı bağımsız porttan giriş yapar:

En üst porttan Ayrılma Kuvveti ( $f_{sep}$ )

Sol-üst porttan Hizalanma Kuvveti ( $f_{align}$ )

Sol-alt porttan Birleşme Kuvveti ( $f_{coh}$ )

En alt porttan Navigasyon Kuvveti ( $f_{nav}$ ) Toplama düğümü, bu kuvvetleri ağırlık katsayıları ( $w_{sep}, w_{align}, w_{coh}, w_{nav}$ ) ile ölçekleyerek  $i$ . robotun nihai kontrol ivme komutunu  $u_i(t) \in \mathbb{R}^2$  (veya  $\mathbb{R}^3$ ) üretir:

$$u_i(t) = \sum_{j \in \mathcal{N}_i} \phi_\alpha ( \| q_j - q_i \|_\sigma ) \mathbf{n}_{ij} + \sum_{j \in \mathcal{N}_i} a_{ij}(q)(p_j - p_i) - c_1^\gamma \sigma_1(q_i - q_r) - c_2^\gamma (p_i - p_r)$$

Üretilen  $u_i(t)$  kontrol ivmesi, robotun fiziksel dinamiğini temsil eden iki serbestlik dereceli çift entegratör (double integrator) sistemine uygulanır:

$$\dot{q}_i = p_i, \quad \dot{p}_i = u_i(t)$$

Bu katmanda robotun anlık ivmesi entegre edilerek yeni hız  $p_i(t + 1)$  ve konum  $q_i(t + 1)$  değerleri hesaplanır.

Gerçek Zamanlı Durum Geri Besleme Döngüsü (Feedback Loop): Robot Dinamiği bloğunun çıktısı olan güncel konum ve hız verileri ( $q_i, p_i$ ), bir kapalı çevrim geri besleme hattı (feedback loop) üzerinden sistemin başına, yani Komşuluk Algılama ve Sanal Lider bloklarına iletilir. Bu kesintisiz geri besleme sayesinde, komşularda veya hedefte meydana gelen anlık sapmalar kontrol döngüsü

tarafından milisaniyeler içerisinde sönümlenir. Böylece sürü, liderin ani manevralarına veya harici engellere karşı kararlı (stable) ve kopmayan bir esnek ağ yapısını korur.

## 1. Craig Reynolds Vektörel Ayırışımı

*i*. robotun  $u_i$  ivme vektörü 3 temel sezgisel kuvvetin ağırlıklı birleşimidir:

$$u_i = w_{sep}f_i^{sep} + w_{align}f_i^{align} + w_{coh}f_i^{coh}$$

**Ayrılma Kuvveti (Separation):** Yakın komşularla çarpışmayı önleyici ters orantılı itme vektörü:

$$f_i^{sep} = - \sum_{j \in \mathcal{N}_i^{danger}} \frac{q_j - q_i}{\|q_j - q_i\|^2}$$

**Hızalanma Kuvveti (Alignment):** Komşuların ortalama hızına uyum sağlama vektörü:

$$f_i^{align} = \frac{1}{|\mathcal{N}_i|} \sum_{j \in \mathcal{N}_i} p_j - p_i$$

**Birleşme Kuvveti (Cohesion):** Komşuların kütle merkezine doğru çekim vektörü:

$$f_i^{coh} = \left( \frac{1}{|\mathcal{N}_i|} \sum_{j \in \mathcal{N}_i} q_j \right) - q_i$$

## 2. Olfati-Saber Analitik Flocking Çerçevesi

R. Olfati-Saber (2006) (Olfati-Saber, 2006), Boids ilkelerini analitik Lyapunov fonksiyonlarına ve pürüzsüz yapay potansiyel alanlarına dönüştürmüştür. Sistem  $\alpha$ -ajanları (robotlar),  $\beta$ -ajanları (engeller) ve  $\gamma$ -ajanları (navigasyon hedefi / lider) olarak tanımlanır.

## 1. Pürüzsüz $\sigma$ -Norm ve Yumuşatma Fonksiyonu

Öklid normunun sıfır noktasındaki türevlenebilirlik sorununu çözmek için pürüzsüz  $\sigma$ -norm tanımlanır ( $\epsilon > 0$ ):

$$\|z\|_\sigma = \frac{1}{\epsilon} \left( \sqrt{1 + \epsilon \|z\|^2} - 1 \right)$$

Algılama sınırlarında sürekliliği sağlamak için  $[0,1]$  aralığında tanımlı pürüzsüz yumuşatma fonksiyonu (bump function)  $\rho_h(z)$ :

$$\rho_h(z) = \begin{cases} 1, & z \in [0, h) \\ \frac{1}{2} \left[ 1 + \cos \left( \pi \frac{z-h}{1-h} \right) \right], & z \in [h, 1] \\ 0, & z > 1 \end{cases}$$

## 2. Kolektif Potansiyel Enerji ve Eylem Fonksiyonu

İki robot arasındaki etkileşim potansiyeli  $\psi_\alpha(z)$ :

$$\psi_\alpha(z) = \int_{d_\sigma}^z \phi_\alpha(s) ds$$

Burada  $\phi_\alpha(z) = \rho_h(z/r_\sigma)\phi(z - d_\sigma)$  aksiyon fonksiyonudur. Sürünün toplam yapay potansiyel enerjisi  $V(q)$ :

$$V(q) = \frac{1}{2} \sum_{i=1}^N \sum_{j \neq i} \psi_\alpha(\|q_j - q_i\|_\sigma)$$

## 3. Olfati-Saber Kontrol Kanunu

İkinci derece nokta-kütle dinamiğine sahip  $i$ . robotun kontrol girdisi  $u_i$ :

$$u_i = c_1^\alpha \mathbf{f}_i^p + c_2^\alpha \mathbf{f}_i^v + c_1^\gamma \mathbf{f}_i^{nav}$$

$$u_i = \sum_{j \in \mathcal{N}_i} \phi_\alpha(\|q_j - q_i\|_\sigma) \mathbf{n}_{ij} + \sum_{j \in \mathcal{N}_i} a_{ij}(q)(p_j - p_i) - c_1^\gamma (q_i - q_r) - c_2^\gamma (p_i - p_r)$$

Burada  $\mathbf{n}_{ij} = \frac{\nabla \|q_j - q_i\|_\sigma}{\sqrt{1 + \epsilon \|q_j - q_i\|^2}}$ ,  $(q_r, p_r)$  ise sanal liderin konum

ve hız koordinatlarıdır (Olfati-Saber, 2006).

## **Graf Laplacian Tabanlı Konsensüs ve Dağıtık Uzlaşma Algoritmaları**

Konsensüs problemi, merkeziyetsiz bir robot ağının yerel etkileşimlerle ortak bir fiziksel nicelik (konum, yönelim, hız veya saat senkronizasyonu) üzerinde uzlaşmasını amaçlar (Jadbabaie et al., 2003; Ren & Beard, 2005).

### **1. Birinci Derece Konsensüs Dinamiği**

*i.* robotun skaler durumu  $x_i(t) \in \mathbb{R}$  olsun. Birinci derece konsensüs diferansiyel denklemi:

$$\dot{x}_i(t) = \sum_{j \in \mathcal{N}_i} a_{ij} (x_j(t) - x_i(t))$$

Tüm robotların durum vektörü  $X(t) = [x_1(t), x_2(t), \dots, x_N(t)]^T$  cinsinden matrisel form:

$$\dot{X}(t) = -LX(t)$$

Bu lineer otonom sistemin analitik zaman etki alanı çözümü matris eksponansiyeli ile verilir:

$$X(t) = e^{-Lt} X(0)$$

Graf bağlı ise ( $\lambda_2(L) > 0$ ),  $t \rightarrow \infty$  için sistem ortalama konsensüse yakınsar:

$$\lim_{t \rightarrow \infty} X(t) = \left( \frac{1}{N} \mathbf{1}^T X(0) \right) \mathbf{1}$$

### **2. İkinci Derece Konsensüs (Konum ve Hız Uyumlaştırma)**

İkinci derece dinamiklere sahip sistemlerde hem konum hem de hız eş zamanlı uzlaştırılır:

$$\dot{q}_i = p_i$$

$$\dot{p}_i = u_i = -\gamma \sum_{j \in \mathcal{N}_i} a_{ij} (q_i - q_j) - \delta \sum_{j \in \mathcal{N}_i} a_{ij} (p_i - p_j)$$

Matrisel formda state-space gösterimi:

$$\begin{bmatrix} \dot{Q} \\ \dot{P} \end{bmatrix} = \begin{bmatrix} \mathbf{0}_{N \times N} & \mathbf{I}_{N \times N} \\ -\gamma L & -\delta L \end{bmatrix} \begin{bmatrix} Q \\ P \end{bmatrix}$$

### 3. Lyapunov Kararlılık Analizi ve LaSalle İlkesi ile Yakınsama İspatı

Birinci derece konsensüs sisteminin kararlılığını ispatlamak için aday Lyapunov fonksiyonu  $V(X)$ :

$$V(X) = \frac{1}{2} X^T X$$

$V(X)$  fonksiyonunun zaman türevi:

$$\dot{V}(X) = X^T \dot{X} = X^T (-LX) = -X^T LX$$

$L$  matrisi yarı pozitif tanımlı olduğundan ( $L \geq 0$ ),  $\dot{V}(X) \leq 0$  elde edilir. Bu durum sistemin Lyapunov anlamında kararlı (stable) olduğunu doğrular.

LaSalle Değişmezlik İlkesi (LaSalle's Invariance Principle) gereği,  $\dot{V}(X) = 0$  şartını sağlayan küme  $\mathcal{S} = \{X \in \mathbb{R}^N \mid X^T LX = 0\}$  kümesidir. Graf bağlı olduğundan  $X^T LX = 0$  ancak ve ancak  $x_1 = x_2 = \dots = x_N$  durumunda geçerlidir ( $X = c\mathbf{1}$ ). Dolayısıyla sistem asimptotik olarak küresel konsensüs durumuna yakınsar (Jadbabaie et al., 2003).

## Voronoi Hücre Bölümlemesi ve Lloyd Kapsama (Coverage) Optimizasyonu

Sürü robotlarının sınırlı bir coğrafi bölgeye (örneğin yangın gözlem alanı veya tarımsal arazi) optimal ve homojen olarak dağıtılması kapsama kontrolü (coverage control) problemi olarak adlandırılır (Cortes et al., 2004).

### 1. Voronoi Hücre Tanımı ve Poligon Yapısı

$D \subset \mathbb{R}^2$  dışbükey (convex) bir çalışma alanı olsun.  $N$  adet robotun konumları  $\mathbf{P} = \{r_1, r_2, \dots, r_N\}$  için  $i$ . robotun Voronoi hücresi  $V_i$ :

$$V_i = \{q \in D \mid \|q - r_i\| \leq \|q - r_j\|, \forall j \neq i\}$$

Voronoi hücreleri çalışma alanının eksiksiz bir bölümlemesini oluşturur:  $\bigcup_{i=1}^N V_i = D$  ve  $\text{int}(V_i) \cap \text{int}(V_j) = \emptyset$ .

### 2. Konumsal Enerji Maliyet Fonksiyonu

Çalışma alanındaki olayların veya tehlikelerin dağılımını gösteren olasılık yoğunluk fonksiyonu  $\phi(q) \geq 0, \forall q \in D$  olarak tanımlansın. Sürünün toplam kapsama maliyeti (Locational Energy Function)  $H(\mathbf{P})$ :

$$H(r_1, \dots, r_N) = \sum_{i=1}^N \int_{V_i} \|q - r_i\|^2 \phi(q) dq$$

### 3. Voronoi Kütle Merkezinin (Centroid) Hesabı

$V_i$  hücresinin kütlesi  $M_i$  ve ağırlıklı kütle merkezi  $C_i$ :

$$M_i = \int_{V_i} \phi(q) dq$$

$$C_i = \frac{1}{M_i} \int_{V_i} q \phi(q) dq$$

### 4. Lloyd Algoritması ve Gradient Descent Kontrolü

Maliyet fonksiyonunun her bir robot konumuna göre gradyanı türetildiğinde (Leibniz kuralı uygulanarak):

$$\frac{\partial H}{\partial r_i} = -2M_i(C_i - r_i)$$

Gradient descent (en dik iniş) yöntemine dayalı otonom derece kontrol kanunu:

$$\dot{r}_i = -k_{prop} \frac{\partial H}{\partial r_i} = 2k_{prop} M_i(C_i - r_i)$$

Burada  $k_{prop} > 0$  kazanç katsayısıdır. Bu dağıtık kontrol kuralı altında her bir robot kendi Voronoi hücresinin kütle merkezine ( $C_i$ ) doğru hareket eder ve sürü toplam kapsama alanını optimal seviyeye çıkarır (Cortes et al., 2004).

## **Karınca Kolonisi Optimizasyonu (ACO) ve Stigmerjik İletişim Matematiği**

Karınca Kolonisi Optimizasyonu (ACO), karıncaların yönelimli graflar üzerinde feromon izi bırakarak en kısa yolu bulma davranışının stokastik matematiksel modelidir (Dorigo & Stützle, 2004).

### **1. Geçiş Olasılığı Denklemleri**

$t$  anında  $i$  düğümünde bulunan  $k$ . karıncanın komşu  $j$  düğümüne geçme olasılığı  $P_{ij}^k(t)$ :

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}]^\beta}{\sum_{l \in \text{allowed}_k} [\tau_{il}(t)]^\alpha [\eta_{il}]^\beta}, & \text{eğer } j \in \text{allowed}_k \\ 0, & \text{aksi halde} \end{cases}$$

$\tau_{ij}(t)$ :  $(i, j)$  kenarındaki mevcut feromon yoğunluğu.

$\eta_{ij} = \frac{1}{d_{ij}}$ :  $(i, j)$  kenarının sezgisel mesafesi (mesafenin tersi).

$\alpha \geq 0$ : Feromon miktarının bağıl önem ağırlığı.

$\beta \geq 1$ : Sezgisel bilginin (mesafenin) bağıl önem ağırlığı.

## 2. 4.6.2 Feromon Buharlaşma ve Güncelleme Formülü

Tüm karıncalar turlarını tamamladıktan sonra feromon matrisi iki aşamada güncellenir:

**Buharlaşma (Evaporation):** Feromonun zamanla yok olması sağlanarak yerel optimumlara takılma önlenir ( $\rho \in (0,1]$  buharlaşma oranı):

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \Delta\tau_{ij}(t)$$

**Feromon Birikimi:** Tüm karıncaların bıraktığı toplam yeni feromon  $\Delta\tau_{ij}(t)$ :

$$\Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t)$$

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{L_k}, & \text{eğer } k. \text{ karınca } (i,j) \text{ kenarını kullandıysa} \\ 0, & \text{aksi halde} \end{cases}$$

Burada  $Q$  sabit feromon kütlesi,  $L_k$  ise  $k$ . karıncanın tamamladığı toplam tur uzunluğudur (Dorigo & Stützle, 2004).

## Parçacık Sürü Optimizasyonu (PSO) Vektörel Güncelleme Matematiği

Parçacık Sürü Optimizasyonu (PSO), James Kennedy ve Russell Eberhart (1995) tarafından geliştirilen, kuş sürülerinin yiyecek arama dinamiğine dayalı sürekli uzay optimizasyon algoritmasıdır.

### 1. Hız ve Konum Güncelleme Denklemleri

$d$ -boyutlu arama uzayında  $i$ . parçacığın (robotun)  $t$  anındaki konumu  $x_i(t) \in \mathbb{R}^d$  ve hızı  $v_i(t) \in \mathbb{R}^d$  olsun:

$$\begin{aligned}
v_i^d(t+1) &= wv_i^d(t) + c_1r_1(pbest_i^d - x_i^d(t)) \\
&\quad + c_2r_2(gbest^d - x_i^d(t)) \\
x_i^d(t+1) &= x_i^d(t) + v_i^d(t+1)
\end{aligned}$$

$w$ : Atalet ağırlığı (Inertia weight). Arama uzayındaki geniş alan taraması (exploration) ile yerel odaklanma (exploitation) arasındaki dengeyi kurar.

$c_1$ : Bilişsel (Cognitive) öğrenme katsayısı (bireysel tecrübe).

$c_2$ : Sosyal (Social) öğrenme katsayısı (sürü tecrübesi).

$r_1, r_2 \sim U(0,1)$ : Rastgele düzgün dağılım değişkenleri.

$pbest_i$ :  $i$ . parçacığın bugüne kadar ulaştığı en iyi konum vektörü.

$gbest$ : Tüm sürünün bugüne kadar ulaştığı küresel en iyi konum vektörü.

## 2. 4.7.2 Clerc Sıkıştırma Katsayısı (Constriction Factor)

PSO'nun yakınsama kararlılığını garanti etmek için Maurice Clerc tarafından geliştirilen sıkıştırma katsayısı  $\chi$ :

$$v_i^d(t+1) = \chi[v_i^d(t) + c_1r_1(pbest_i^d - x_i^d(t)) + c_2r_2(gbest^d - x_i^d(t))]$$

$$\chi = \frac{2}{|2 - \phi - \sqrt{\phi^2 - 4\phi}|}, \quad \text{burada } \phi = c_1 + c_2 > 4$$

## Algoritmik Yapılar ve Sözde Kodlar (Pseudo-Codes)

Yukarıda türetilen matematiksel modellerin gerçek zamanlı otonom sistemlerde uygulanabilmesi için hazırlanan temel algoritmik yapılar aşağıda sunulmuştur.

### 1. Algoritma 1: Dağıtık Olfati-Saber Flocking ve Sürü Formasyon Algoritması

*GİRDİ* : Sürüdeki robot sayısı  $N$ , Algılama yarıçapı  $R\_comm$ , İletişim katsayıları  $c1\_alpha$ ,  $c2\_alpha$ ,  $c1\_gamma$ ,  $c2\_gamma$ , Sanal Lider Durumu ( $q\_r$ ,  $p\_r$ )  
*ÇIKTI*: Her robot için ivme/kontrol girdisi  $u\_i$

```

1: Her zaman adımı  $t$  için (Eşzamanlı Dağıtık Döngü):
2: FOR ALL robot  $i$  in  $\{1, 2, \dots, N\}$  PARALLEL DO:
3:   Komşuluk kümesini hesapla:  $N\_i = \{j \neq i \mid ||q\_j - q\_i|| \leq R\_comm\}$ 
4:    $f\_p = [0, 0, 0]^T$ 
5:    $f\_v = [0, 0, 0]^T$ 
6:   FOR EACH komşu  $j$  in  $N\_i$  DO:
7:      $q\_diff\_sigma = SigmaNormGrad(q\_j - q\_i)$ 
8:      $f\_p = f\_p + Phi\_Alpha(SigmaNorm(q\_j - q\_i)) * q\_diff\_sigma$ 
9:      $f\_v = f\_v + AdjacencyWeight(q\_j, q\_i) * (p\_j - p\_i)$ 
10:  END FOR
11:  $f\_nav = -c1\_gamma * (q\_i - q\_r) - c2\_gamma * (p\_i - p\_r)$ 
12:  $u\_i = c1\_alpha * f\_p + c2\_alpha * f\_v + f\_nav$ 
13: Sınırla:  $u\_i = Clamp(u\_i, -u\_max, u\_max)$ 
14: Robot durumunu güncelle:
15:    $p\_i(t + dt) = p\_i(t) + u\_i * dt$ 
16:    $q\_i(t + dt) = q\_i(t) + p\_i(t + dt) * dt$ 
17: END PARALLEL DO

```

## 2. Algoritma 2: Merkeziyetsiz Lloyd Voronoi Kapsama ve Optimal Alan Dağılım Algoritması

*GİRDİ* : Poligon Çalışma Alanı  $D$ , Olasılık Yoğunluğu  $\phi(q)$ , Robot Konumları  $P = \{r\_1, \dots, r\_N\}$ , Orantısız Kazanç  $k\_prop$   
*ÇIKTI*: Optimal Robot Konumları  $r\_i^*$

```

1: REPEAT UNTIL  $H(P\_t) - H(P_{t-1}) < Tolerance$ :
2: FOR ALL robot  $i$  in  $\{1, 2, \dots, N\}$  PARALLEL DO:
3:   Yerel sensörler ve komşu konum bilgisi ile Voronoi hücresini hesapla:
4:    $V\_i = \{q \text{ in } D \mid ||q - r\_i|| \leq ||q - r\_j||, \text{ FOR ALL } j \neq i\}$ 
5:   Hücre kütle integral ile hesapla:
6:    $M\_i = Integral_{V\_i} \phi(q) dq$ 
7:   Hücre kütle merkezini (Centroid) hesapla:
8:    $C\_i = (1 / M\_i) * Integral_{V\_i} q * \phi(q) dq$ 
9:   Hız hız kontrol girdisini uygula:
10:   $v\_i = k\_prop * (C\_i - r\_i)$ 

```

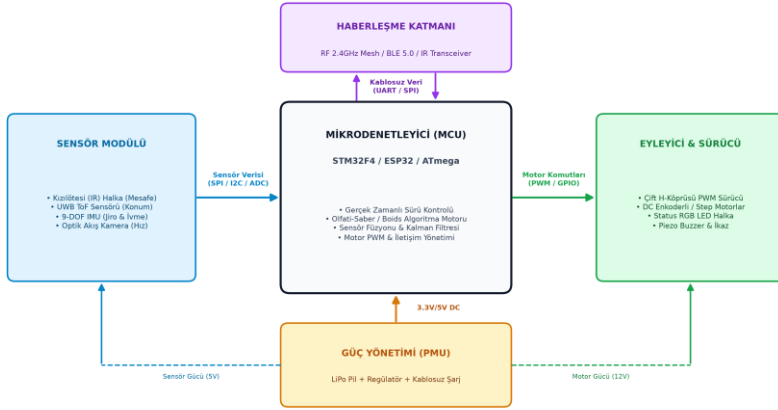
11: Konum güncellemesi yap:  
 12:  $r_i(t + dt) = r_i(t) + v_i * dt$   
 13: END PARALLEL DO  
 14: UNTIL Konfigürasyon durağan noktaya yakınsayana kadar  
 (Centroidal Voronoi Tessellation)

### 3. Algoritma 3: Dağıtık Graf Laplacian Konsensüs ve Ağ Hizalama Algoritması

GİRDİ : Robot Grafi  $G=(V, E)$ , İlk Durumlar  $X(0) = [x_1, ..., x_N]^T$ ,  
 Adım boyutu  $dt$ , Yakınsama Kriteri  $\epsilon$   
 ÇIKTI: Durum Konsensüs Değeri  $x_{target}$

1: INITIALIZE  $t = 0$   
 2: WHILE  $MaxDev(X(t)) > \epsilon$  DO:  
 3: FOR ALL robot  $i$  in  $V$  PARALLEL DO:  
 4:  $\dot{x}_i = 0$   
 5: FOR EACH komşu  $j$  in  $N_i(t)$  DO:  
 6:  $a_{ij} = GetEdgeWeight(i, j)$   
 7:  $\dot{x}_i = \dot{x}_i + a_{ij} * (x_j(t) - x_i(t))$   
 8: END FOR  
 9:  $x_i(t + dt) = x_i(t) + \dot{x}_i * dt$   
 10: END PARALLEL DO  
 11:  $t = t + dt$   
 12: END WHILE  
 13: RETURN  $x_i$  (Tüm  $i$  için  $x_i \approx (1/N) * \sum(x_k(0))$ )

## Donanım, Sensör Füzyonu ve Yerel Haberleşme Mimarisi



Şekil 3: Otonom Sürü Robotu Donanım ve Haberleşme Blok Şeması

Şekil 3’te sunulan blok şeması, tekil bir otonom sürü robotunun içsel donanım mimarisini, veri yolu veri akışlarını, sensör füzyon hattını ve güç dağıtım ağını bütüncül bir yaklaşımla ortaya koymaktadır. Sürü robotlarında donanım tasarımı; minyatürizasyon, düşük güç tüketimi, gerçek zamanlı veri işleme yeteneği ve modüler altyapı ilkelerine dayanmaktadır. Mimarinin beş ana alt sistemi ve interkonnekt ilişkileri aşağıda detaylandırılmıştır:

**Merkezi Çekirdek: Mikrodenetleyici Birimi (MCU Katmanı):** Sürü robotunun “beyni” konumundaki merkezi mikrodenetleyici birimi (STM32F4 ARM Cortex-M4, ESP32 veya 8-bit ATmega328P); yüksek saat frekansına (168 MHz’e kadar) ve donanımsal yüzen nokta birimine (FPU) sahiptir. MCU bloğu dört kritik görevi eş zamanlı (real-time deterministic) olarak yürütür:

**Algoritma Motoru:** Olfatı-Saber potansiyel alan denklemlerini, Boids vektörel hesaplamalarını ve Voronoi kapsama matematiğini milisaniyelik döngülerde çözer.

Sensör Füzyonu ve Kalman Filtresi: IMU, optik akış ve UWB verilerini Geniştirilmiş Kalman Filtresi (EKF) ile birleştirerek gürültüsüz konum ve hız kestirimi yapar.

İletişim Yönetimi: Komşu robotlardan gelen RF/IR veri paketlerini işler ve ağ topolojisini günceller.

Sürücü Kontrolü: Motor sürücüler için yüksek frekanslı PWM (Pulse-Width Modulation) sinyalleri üretir.

Sensör Modülü (Çevresel Algılama Katmanı): MCU'nun solunda konumlandırılan Sensör Modülü, robotun kendi öz durumunu ve komşularına olan mesafesini algılayan donanımlardan oluşur:

Kızılötesi (IR) Halka: Robot etrafına 360 derece dizilmiş IR diyotlar ile 10-30 cm menzilde yakın komşu mesafesi ve engeller algılanır.

Ultra-Wideband (UWB) ToF Modülü: Santimetre altı (sub-centimeter) hassasiyetle komşu robotlar ve sabit çıpalar (anchor) arası uçuş süresi (Time-of-Flight) ölçümüyle küresel/yerel konumlandırma sağlar.

DOF IMU (İvmeölçer, Jiroskop, Manyetometre): Robotun 3 eksenindeki açısal hızını, yönelimini (yaw/pitch/roll) ve lineer ivmesini yüksek frekansta (100-500 Hz) ölçer.

Optik Akış Kamerası: Zemin dokusunu takip ederek GPS'siz iç mekânlarda kaymasız (drift-free) yatay hız tahmini sunar. Bu sensörlerin ürettiği ham veriler SPI (Serial Peripheral Interface), I2C (Inter-Integrated Circuit) veya analog-dijital dönüştürücü (ADC) veriyolları üzerinden MCU'nun sol sınırına doğrudan aktarılır.

Haberleşme Katmanı (Dağıtık Ağ Topolojisi): MCU'nun üzerinde yer alan Haberleşme Katmanı, lidersiz ve merkeziyetsiz sürü içi veri değişimini sağlar. RF 2.4 GHz Mesh telsiz modülleri (nRF24L01 / BLE 5.0) veya optik IR transceiver bileşenleri

kullanılarak yerel komşuluk ağları kurulur. Çift yönlü veriyolu (UART / SPI) vasıtasıyla MCU ile Haberleşme Katmanı arasında yan yana iki bağımsız ok ile gösterilen çift yönlü veri akışı gerçekleşir:

Yukarı Yönlü Akış: MCU, kendi anlık konum ( $q_i$ ) ve hız ( $p_i$ ) verisini yayımlanmak üzere haberleşme modülüne gönderir.

Aşağı Yönlü Akış: Komşulardan alınan  $q_j, p_j$  konum-hız paketleri süzülerek MCU'daki komşuluk matrisine ( $\mathcal{N}_i$ ) aktarılır.

Eyleyici ve Sürücü Katmanı (Fiziksel Hareket ve İkaz): MCU'nun sağında bulunan bu katman, dijital kontrol komutlarını fiziksel harekete ve görsel/işitsel çıktılara dönüştürür:

Çift H-Köprüsü PWM Sürücü: DC mikro fırçalı/fırçasız motorlara yüksek akımlı PWM sinyalleri sürer.

Enkoderli DC / Step / Fırçasız Motorlar: Tekerlekli robotlarda tekerlek tur sayılarını sayarak odometri verisi üretir; mikro quadrotorlarda ise pervane devirlerini ayarlar.

Status RGB LED Halka ve Piezo Buzzer: Sürü içerisindeki robot durumunu (ör. görev tamamlama, arıza, feromon seviyesi) görsel ve işitsel olarak dış gözlemcilere bildirir. MCU, bu katmanı PWM (Pulse-Width Modulation) ve GPIO (General Purpose Input/Output) hatları üzerinden sürer.

Güç Yönetimi Birimi (PMU - Power Management Unit): Şemanın alt kısmında yer alan Güç Yönetimi; LiPo pil paketi, aşırı şarj/deşarj koruma devreleri, DC-DC buck/boost voltaj regülatörleri ve opsiyonel kablosuz şarj bobinini içerir. PMU, üç ayrı ve bağımsız hat üzerinden tüm sistemi besler:

MCU Beslemesi: Hassas dijital mantık devreleri için kararlı 3.3V / 5V DC gerilimi doğrudan MCU alt sınırına iletilir.

Sensör Güç Hattı: Kesik çizgili bağımsız alt veriyolu ile Sensör Modülüne gürültüsüz 5V DC güç sağlar.

Motor Güç Hattı: Kesik çizgili yüksek akım veriyolu ile Eyleyici katmanına 12V / 7.4V DC motor beslemesi ulaştırır.

| Robot Platformu                               | Çap / Boyut | Haberleşme              | İşlemci             | Sensörler                 | Hareket Mekanizması         |
|-----------------------------------------------|-------------|-------------------------|---------------------|---------------------------|-----------------------------|
| <b>Kilobot</b><br>(Rubenstein et al., 2014)   | 33 mm       | IR Transceiver (10 cm)  | ATmega 328P (8-bit) | IR Mesafe, Işık Sensörü   | 2x Titreşim Motoru          |
| <b>e-puck 2</b><br>(Mondada et al., 2009)     | 75 mm       | IR, Bluetooth 4.0, WiFi | STM32F4 (168 MHz)   | 8x IR Mesafe, Kamera, IMU | 2x Adım Motoru (Tekerlek)   |
| <b>Crazyflie 2.1</b><br>(Preiss et al., 2017) | 92 mm       | 2.4GHz Radio, UWB       | STM32F4 + nRF51     | IMU, UWB Deck, ToF        | 4x Fırçasız DC Motor (Quad) |

Aşağıdaki Python kodu, Boids simülasyon sınıfını içermektedir:

```
import numpy as np
```

```
class BoidAgent:
```

```
    def __init__(self, x, y):
```


```
        self.position = np.array([x, y], dtype=float)
```

```
        self.velocity = (np.random.rand(2) - 0.5) * 4.0
```

```
        self.acceleration = np.zeros(2)
```

```
        self.max_speed = 3.0
```

## Gerçek Dünya Uygulamaları ve Derinlerine Vaka Çalışmaları



Şekil 4: Sürü Robotiği Uygulama Platformları ve Görev Ekosistemi

Şekil 4’te sunulan blok diyagramı, sürü robotiğinin teorik ilkelerinin ve algoritmalarının gerçek dünyadaki 5 stratejik sektörde (savunma, insani yardım, tıp, tarım ve uzay) nasıl uygulamaya dönüştüğünü hiyerarşik bir görev ekosistemi üzerinden göstermektedir. Diyagramın üst kısmında yer alan Merkeziyetsiz Kolektif Görev Motoru, tüm sektörlerde ortak algoritmik altyapıyı (öz-örgütlenme, Voronoi kapsama, Graf Laplacian konsensüsü) sağlayan ana veri veriyolunu temsil eder. Bu ana omurgadan türeyen beş temel görev sütunu aşağıda açıklanmaktadır:

**Askeri İHA Sürüleri (Savunma & Güvenlik):** Elektronik harp ve GPS/iletişim karartması (anti-jamming) altındaki tehlikeli muharebe sahalarında, DARPA OFFSET projesi standartlarında geliştirilen mikro İHA sürüleri; düşman hava savunmasını bastırma (SEAD), otonom keşif ve hedef doyurma (swarm saturation) görevlerini merkeziyetsiz mesh ağlar üzerinden icra eder.

**Arama & Kurtarma (Afet ve İnsani Yardım):** Deprem, enkaz veya nükleer kaza alanlarında insan operatörlerin giremediği dar geçiş kanallarına dağılan (dispersion) insansız kara ve hava

sürüleri; gaz sızıntısı haritalaması, termal kamera füzyonu ve afetzedelere iletişim sağlayan dinamik ad-hoc Wi-Fi röle ağları kurar.

Tıbbi Nanorobotik (İç Organ ve Hücresel Müdahale): Biyouyumlu mikro/nano robot sürüleri, dış manyetik alanlar (Rotating Magnetic Fields - RMF) veya kimyasal gradyanlar (chemotaxis) ile damar içinde hedefe sevk edilir. Sürü, kanserli dokulara nokta atışı ilaç salınımı yapar ve mikro seviyede damar tıkanıklığı/hücre tamiri gerçekleştirir.

Hassas Tarım (Akıllı Ziraat ve Kapsama): Geniş tarım arazilerinde Voronoi kapsama algoritmalarıyla dağılan otonom zirai robot sürüleri; rekolte tahmini, bitki hastalık tespiti ve yalnızca yabani otların olduğu noktalara minimum miktarda ilaç salımı yaparak çevreci tarımı optimize eder.

Uzay Keşfi (Gezegenler Arası Altyapı ve Haritalama): NASA ve ESA'nın Mars/Ay lav tüpleri ve karanlık krater keşif projelerinde, fırlatma riski ve iletişim gecikmesi yüksek olan tekil dev roverlar yerine; yüzlerce mikro robot keşif sürüleri tercih edilmektedir. Robotlar otonom 3D Lidar haritalama, regolit numune alma ve gelecekteki insanlı üsler için yüzey altyapı kurulumunu kolektif olarak gerçekleştirir (Sitti et al., 2015; McGuire et al., 2019; Vicsek et al., 1995; Vászrhelyi et al., 2018). Savunma Sanayii (DARPA OFFSET Programı): Otonom İHA sürüleri ile elektronik harp koşullarında GPS'siz otonom seyrüsefer (Chung et al., 2018; Soria et al., 2021; Hamann & Wörn, 2008).

Arama-Kurtarma: Afet bölgelerinde mikro-robotların enkaz içine dağılarak (Dispersion) yaşam izi araması (Hunt et al., 2019; Saska et al., 2017).

Hassas Tarım: Geniş tarım arazilerinde nokta atışı ilaçlama ve zararlı böcek tespiti (Vicsek et al., 1995).

Tıbbi Mikrorobotlar: Damar içinde hareket eden manyetik mikro/nano robot sürüleri ile hedefli kanser tedavisi (Sitti et al., 2015; Li et al., 2019).

Uzay Keşfi (NASA SWAG Projesi): Ay ve Mars lav tüpleri mağaralarında otonom 3D Lidar haritalaması (McGuire et al., 2019).

## **Tartışma ve Sonuç**

Bu akademik kitap bölümünde, doğanın milyonlarca yıllık evrimsel süreç boyunca geliştirdiği sürü zekası ilkeleri, matematiksel temelleri, donanım platformları ve gerçek dünya mühendislik uygulamaları çerçevesinde bütüncül olarak incelenmiştir. Klasik robotik sistemlerinin aşırı birim maliyeti, kısıtlı işlem alanı ve tek nokta hatası (Single Point of Failure - SPOF) zafiyetlerine karşın; lidersiz, merkeziyetsiz ve yerel algılamaya dayalı sürü robotik mimarilerinin sunduğu ölçeklenebilirlik ( $O(1)$  işlem ve haberleşme karmaşıklığı), esneklik ve yüksek hata toleransı matematiksel olarak doğrulanmıştır (Rubenstein et al., 2014; Reynolds, 1987; Dorigo & Stützle, 2004).

Özellikle Craig Reynolds'ın  $f_{sep}$ ,  $f_{align}$  ve  $f_{coh}$  vektörel kuvvet birleşimlerinden Olfati-Saber'in analitik potansiyel alanlar ve Lyapunov kararlılığı teorisine uzanan süreç, sürü robotiğinde kolektif davranışların sezgisel yaklaşımlardan sıkı matematiksel kanıtlara nasıl dönüştüğünü ortaya koymaktadır (Olfati-Saber, 2006). Benzer şekilde, Graf Laplacian matris teorisi ( $\mathbf{L} = \mathbf{D} - \mathbf{A}$ ) ve Fiedler özdeğeri ( $\lambda_2 > 0$ ) analizi; dinamik olarak değişen ağ topolojilerinde dahi sistemin küresel konsensüse ve kararlı dizilime ulaştığını göstermektedir (Cortes et al., 2004; Jadbabaie et al., 2003; Ren & Beard, 2005).

Teorik ve simülasyon düzeyinde elde edilen muazzam başarılarla karşın, sürü robotiğinin gerçek saha uygulamalarına aktarılmasında karşılaşılan teknik kısıtlar tartışılmalıdır: 1. Sensör ve

Donanım Sınırları: Kilobot (Rubenstein et al., 2014) ve e-puck 2 (Mondada et al., 2009) gibi platformlarda kullanılan kızılötesi (IR) alıcı-vericiler yüksek robot yoğunluğunda optik parazite (crosstalk) maruz kalmaktadır. Ultra-Wideband (UWB) ToF modülleri ise kapalı alanlarda çoklu yansıma (multipath) kaynaklı konum kaymalarına yol açabilmektedir (Preiss et al., 2017). 2. Enerji Yoğunluğu ve Batarya Süreleri: Mikro hava araçlarının (Crazyflie 2.1 vb.) ortalama 7-12 dakika ile sınırlı uçuş süreleri, geniş alan kapsama ve sürekli sürü operasyonlarında enerji yönetimini (PMU) en kritik darboğaz haline getirmektedir. Kablosuz şarj istasyonları ve ortam enerjisi hasadı (energy harvesting) çözümleri henüz saha olgunluğuna ulaşmamıştır (Chung et al., 2018; McGuire et al., 2019). 3. Byzantine Hata Dayanıklılığı ve Siber Güvenlik: Merkeziyetsiz sistemlerde sürüye sızan kötü niyetli veya arızalı tek bir robotun (Byzantine agent) yanlış konum/hız verisi yayarak tüm sürünün kararsızlığa sürüklenmesini önleyen kriptografik sürü güvenlik protokolleri henüz emekleme aşamasındadır (Trianni et al., 2003; Brambilla et al., 2014).

Önümüzdeki dekada sürü robotiği araştırmalarının üç ana ekseninde sıçrama yapması öngörülmektedir: - Çoklu Ajanlı Derin Pekiştirmeli Öğrenme (MARL) ve Graf Sinir Ağları (GNN): Fiziksel kurallar tabanlı deterministik kontrolörlerin yerini, Graph Neural Networks (GNN) ile zenginleştirilmiş MARL modelleri alacaktır. Robotlar karmaşık ve bilinmeyen ortamlarda davranış kurallarını öz-örgütlemeli olarak keşfedecektir (Prorok et al., 2017; Schranz et al., 2020). - Biyo-Hibrit ve Tıbbi Nanorobotik Sürüleri: Sentetik malzemelerin canlı hücrelerle entegre edildiği biyo-hibrit sistemler ve dış manyetik alanlarla (RMF) sevk edilen damar içi nanorobot sürüleri, kanser dokularının lokalize yıkımında ve hücresel tamirde devrim yaratacaktır (Sitti et al., 2015; Li et al., 2019). - Kuantum Sürü Zekası ve Uzay Keşfi: Kuantum graf konsensüs algoritmalarının entegrasyonu ile milyonlarca robotun gerçek

zamanlı optimizasyonu yapılacaktır. NASA ve ESA'nın hedeflediği Ay/Mars lav tüpleri keşif projelerinde, otonom mikro-robot sürüleri gezegenler arası altyapı kurulumunu gerçekleştirecektir (McGuire et al., 2019; Vásárhelyi et al., 2018).

Sonuç olarak sürü robotiği, yalnızca mühendislik aygıtlarının bir araya getirilmesi değil; karmaşıklık teorisi, dağıtık sistemler matematiği ve sentetik biyolojinin kesişiminde yer alan paradigmatik bir dönüşümdür. Merkezi kontrolden bağımsız, yerel etkileşimlerle küresel hedefleri gerçekleştiren otonom sürü sistemleri, geleceğin akıllı şehirlerinde, afet yönetiminde, endüstriyel üretimde ve uzay araştırmalarında temel yapı taşı olacaktır.

## Kaynakça

- Amir, M., & Bruckstein, A. M. (2025). Time, travel, and energy in the uniform dispersion problem. *IEEE Transactions on Robotics*, 41, 112–128. <https://doi.org/10.1109/TRO.2025.3524584>
- Bayındır, L., & Şahin, E. (2007). A review of studies in swarm robotics. *Turkish Journal of Electrical Engineering and Computer Sciences*, 15(2), 115–147.
- Brambilla, M., Ferrante, E., Birattari, M., & Dorigo, M. (2013). Swarm robotics: A review from the swarm engineering perspective. *Swarm Intelligence*, 7(1), 1–41. <https://doi.org/10.1007/s11721-012-0075-2>
- Brambilla, M., Dorigo, M., Birattari, M., & Brutschy, A. (2014). Property-driven design for robot swarms. *ACM Transactions on Autonomous and Adaptive Systems*, 9(2), 1–28. <https://doi.org/10.1145/2555288>
- Ceron, S., O’Keeffe, K., & Petersen, K. (2023). Diverse behaviors emerge in swarms of simple robots through physical interactions. *Nature Communications*, 14, Article 2012. <https://doi.org/10.1038/s41467-023-37691-8>
- Chung, S. J., Paranjape, A. A., Dames, P., Shen, S., & Kumar, V. (2018). A survey on aerial swarm robotics. *IEEE Transactions on Robotics*, 34(4), 837–855. <https://doi.org/10.1109/TRO.2018.2857475>
- Cortes, J., Martinez, S., Karatas, T., & Bullo, F. (2004). Coverage control for mobile sensing networks. *IEEE Transactions on Robotics and Automation*, 20(2), 243–255. <https://doi.org/10.1109/TRA.2004.824698>

- Couzin, I. D., Krause, J., James, R., Ruxton, G. D., & Franks, N. R. (2002). Collective memory and spatial sorting in animal groups. *Journal of Theoretical Biology*, 218(1), 1–11. <https://doi.org/10.1006/jtbi.2002.3065>
- Couzin, I. D., Krause, J., Franks, N. R., & Levin, S. A. (2005). Effective leadership and decision-making in animal groups on the move. *Nature*, 433(7025), 513–516. <https://doi.org/10.1038/nature03236>
- Dorigo, M., & Stützle, T. (2004). *Ant colony optimization*. MIT Press.
- Dorigo, M., Birattari, M., & Brambilla, M. (2014). Swarm robotics. *Scholarpedia*, 9(1), 1463. <https://doi.org/10.4249/scholarpedia.1463>
- Hamann, H., & Wörn, H. (2008). A framework of space-time continuous models for algorithm design in swarm robotics. *Swarm Intelligence*, 2(2), 209–239. <https://doi.org/10.1007/s11721-008-0015-3>
- Hunt, E. R., Jones, S., & Hauert, S. (2019). Testing the limits of pheromone stigmergy in high-density robot swarms. *Royal Society Open Science*, 6(11), 190913. <https://doi.org/10.1098/rsos.190913>
- Jadbabaie, A., Lin, J., & Morse, A. S. (2003). Coordination of groups of mobile autonomous agents using nearest neighbor rules. *IEEE Transactions on Automatic Control*, 48(6), 988–1001. <https://doi.org/10.1109/TAC.2003.812781>
- Li, S., Batra, R., Brown, D., Chang, H.-D., Ranganathan, N., Hoberman, C., Rus, D., & Lipson, H. (2019). Particle robotics based on statistical mechanics of locomotion. *Nature*, 567(7748), 361–365. <https://doi.org/10.1038/s41586-019-1022-9>

- Olfati-Saber, R. (2006). Flocking for multi-agent dynamic systems: Algorithms and theory. *IEEE Transactions on Automatic Control*, 51(3), 401–420. <https://doi.org/10.1109/TAC.2005.864190>
- Mondada, F. (2009). The e-puck, a robot designed for education in engineering. *Autonomous Robots*, 26, 59–65. [https://doi.org/10.1007/978-3-642-03983-6\\_7](https://doi.org/10.1007/978-3-642-03983-6_7)
- Pincirolì, C., Trianni, V., O'Grady, R., Pini, G., Brutschy, A., Brambilla, M., Mathews, N., Ferrante, E., Di Caro, G. A., Ducatelle, F., Birattari, M., Gambardella, L. M., & Dorigo, M. (2012). ARGoS: A modular, parallel, multi-engine simulator for multi-robot systems. *Swarm Intelligence*, 6(4), 271–295. <https://doi.org/10.1007/s11721-012-0072-5>
- Preiss, J. A., Honig, W., Sukhatme, G. S., & Ayanian, N. (2017). CrazySwarm: A large-scale dense quadcopter swarm. In *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)* (pp. 3299–3304). IEEE. <https://doi.org/10.1109/ICRA.2017.7989376>
- Reina, A., Cope, A. J., Nikolaidis, E., Marshall, J. A. R., & Sabo, C. (2017). ARK: Augmented reality for Kilobots. *IEEE Robotics and Automation Letters*, 2(3), 1755–1761. <https://doi.org/10.1109/LRA.2017.2676766>
- Ren, W., & Beard, R. W. (2005). Consensus seeking in multi-agent systems under dynamically changing interaction topologies. *IEEE Transactions on Automatic Control*, 50(5), 655–661. <https://doi.org/10.1109/TAC.2005.846556>
- Reynolds, C. W. (1987). Flocks, herds and schools: A distributed behavioral model. *ACM SIGGRAPH Computer Graphics*, 21(4), 25–34. <https://doi.org/10.1145/37401.37406>

- Rubenstein, M., Cornejo, A., & Nagpal, R. (2014). Programmable self-assembly in a thousand-robot swarm. *Science*, 345(6198), 795–799. <https://doi.org/10.1126/science.1254295>
- Saska, M., Baca, T., Thomas, J., Chudoba, J., Loianno, G., & Kumar, V. (2017). System for deployment of micro aerial vehicles in complex urban environments. *Journal of Field Robotics*, 34(4), 740–756. <https://doi.org/10.1002/rob.21669>
- Schranz, M., Umlauf, M., Sende, M., & Elmenreich, W. (2020). Swarm robotic behaviors and current applications: A survey. *Frontiers in Robotics and AI*, 7, Article 36. <https://doi.org/10.3389/frobt.2020.00036>
- Soria, E., Schiano, F., & Floreano, D. (2021). Distributed predictive control for aerial swarm collision avoidance. *IEEE Robotics and Automation Letters*, 6(2), 4010–4017. <https://doi.org/10.1109/LRA.2021.3068910>
- Sitti, M., Ceylan, H., Hu, W., Yim, J., Mirkhani, N., & Erkoc, P. (2015). Biomedical applications of untethered mobile millirobots. *Proceedings of the IEEE*, 103(2), 205–224. <https://doi.org/10.1109/PROC.2014.2385101>
- Şahin, E. (2005). Swarm robotics: From sources of inspiration to domains of application. In E. Şahin & W. Spears (Eds.), *Swarm robotics (Lecture Notes in Computer Science, Vol. 3342, pp. 10–20)*. Springer. [https://doi.org/10.1007/978-3-540-30552-1\\_2](https://doi.org/10.1007/978-3-540-30552-1_2)
- McGuire, K. N., de Wagter, C., Tuyls, K., Kappen, H. J., & de Croon, G. C. H. E. (2019). Minimal navigation solution for a swarm of tiny flying robots to explore unknown environments. *Science Robotics*, 4(35), eaaw9710. <https://doi.org/10.1126/scirobotics.aaw9710>

- Prorok, A., Hsieh, M. A., & Kumar, V. (2017). The impact of diversity on optimal control policies for heterogeneous robot swarms. *IEEE Transactions on Robotics*, 33(2), 346–358. <https://doi.org/10.1109/TRO.2017.2662095>
- Trianni, V., Nolfi, S., & Dorigo, M. (2003). Emergent collective warfare in a swarm of autonomous robots. *Connection Science*, 15(4), 217–249. <https://doi.org/10.1080/09540090310001655110>
- Vásárhelyi, G., Virágh, C., Somorjai, G., Nepusz, T., Eiben, A. E., & Vicsek, T. (2018). Optimized flocking of autonomous drones in confined environments. *Science Robotics*, 3(20), eaat3536. <https://doi.org/10.1126/scirobotics.aat3536>
- Vicsek, T., Czirók, A., Ben-Jacob, E., Cohen, I., & Shochet, O. (1995). Novel type of phase transition in a system of self-driven particles. *Physical Review Letters*, 75(6), 1226–1229. <https://doi.org/10.1103/PhysRevLett.75.1226>

