


Yüksek Enerji Fiziğinde Yapay Zeka Uygulamaları-I

Doç. Dr. Serpil Yalçın Kuzu*
*Fırat Üniversitesi

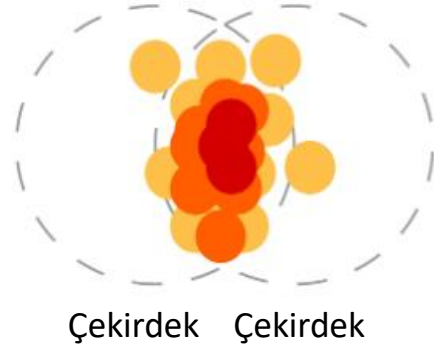
UPHDYO-XV
5-10 Eylül 2023

- Yüksek Enerji FiziĐi
- Yenilikçi Bir Yaklaşım: Yapay Zeka
- Makine Öğrenimi (MÖ)
 - Denetimli Öğrenme Modelleri
 - Karar Ağacı Modelleri
 - Çalışma Prensipleri, Kullanılan Algoritmalar, Avantajları
 - Sinir AĐı Modelleri
 - Yapay Sinir AĐı, Derin Sinir AĐları, Avantajları
 - Destek Vektör Makineleri
 - Temel Prensipleri, Avantajları
 - MÖ Modelleme Süreci
 - MÖ Performans DeĐerlendirmesi
 - Sınıflandırma
 - Regresyon
- Özet



Mini 'Büyük Patlama':

1. Başlangıç Durumu





Zaman

1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.

Mini 'Büyük Patlama':

1. Başlangıç Durumu


2. Termalizasyon



Zaman


1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir (~ 1 fm/c).

Mini 'Büyük Patlama':




1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir (~ 1 fm/c).
3. İçinde kuarkların ve gluonların serbest bırakıldığı sıcak, yoğun bir ortam oluşur (KGP).

Mini 'Büyük Patlama':




1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir (~ 1 fm/c).
3. İçinde kuarkların ve gluonların serbest bırakıldığı sıcak, yoğun bir ortam oluşur (KGP).
4. Sistem genişler ve soğur, partonlar parçalanma ve yeniden birleştirme yoluyla sınırlı durumlara dönüşür.

Mini 'Büyük Patlama':




1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir (~ 1 fm/c).
3. İçinde kuarkların ve gluonların serbest bırakıldığı sıcak, yoğun bir ortam oluşur (KGP).
4. Sistem genişler ve soğur, partonlar parçalanma ve yeniden birleştirme yoluyla sınırlı durumlara dönüşür.
5. Hadron gazı, artık etkileşen bir parçacık sistemi olmadığından, donma meydana gelene kadar genişlemeye ve soğumaya devam eder.

Mini 'Büyük Patlama':



1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir (~ 1 fm/c).
3. İçinde kuarkların ve gluonların serbest bırakıldığı sıcak, yoğun bir ortam oluşur (KGP).
4. Sistem genişler ve soğur, partonlar parçalanma ve yeniden birleştirme yoluyla sınırlı durumlara dönüşür.
5. Hadron gazı, artık etkileşen bir parçacık sistemi olmadığından, donma meydana gelene kadar genişlemeye ve soğumaya devam eder.
6. Parçacıklar genişlemeye devam eder ve dedektörlere çarpar.

Mini 'Büyük Patlama':



1. Nükleonlar arasındaki ilk çarpışmalar yüksek momentumlu parçacıklar üretir.
2. Çarpışma alanındaki diğer parçacıklar termalleşir ($\sim 1 \text{ fm}/c$).
3. İçinde kuarkların ve gluonların serbest bir şekilde hareket ettiği bir durum (KGP).
4. Sistem genişler ve soğur ve hadronlar oluşmaya başlar.
5. Hadron gazı parçacık sistemi olmadığına kadar genişler ve soğur. Donma meydana gelene kadar genişleme devam eder.
6. Parçacıklar dışarı doğru gider ve dedektörlere çarpar.

Sofistike analiz teknikleri ve yüksek programlama becerisi gerektirmektedir!

Yenilikçi Bir Yaklaşım: Yapay Zekâ

- Yapay zekâ; bilgisayarların karmaşık görevleri gerçekleştirmek için insan beyninden esinlenerek programlanmasıdır.
- Makine öğrenimi (MÖ), bir tür yapay zekâ elde etme yöntemi olup günümüzün ilgi çekici bilimsel alanlarından bir tanesidir [1].
- MÖ, makinelerin var olan veriler ile eğitilerek insan zekasının yapabileceği bilgiyi algılama, genelleme ve kullanma gibi yetenekleri kazanmasıdır.
- Makine, algoritmaların yardımıyla belirli bir işlevi yerine getirmeyi öğrenir.
- Yapay zeka otomasyon süreçleri, veri analizi, doğal dil işleme, resim ve video işleme gibi alanlarda hızla gelişmektedir.

1

Denetimli Öğrenme

Veri setinde verileri inceleyerek ve sınıflandırarak öğrenir. Belirli bir çıktı hedefine doğru yapılandırılmış örneklerle birlikte öğrenir.

Denetimsiz Öğrenme

Tahmin yapmak ve verileri kümelendirmek için kullanılır. Hedef olarak tanımlanmamış verileri kullanarak öğrenir ve düzenler.



Denetimli Öğrenme

Veri setinde verileri inceleyerek ve sınıflandırarak öğrenir. Belirli bir çıktı hedefine doğru yapılandırılmış örneklerle birlikte öğrenir.

Denetimsiz Öğrenme

Tahmin yapmak ve verileri kümelendirmek için kullanılır. Hedef olarak tanımlanmamış verileri kullanarak öğrenir ve düzenler.

1

2

3

Denetimli Öğrenme


Veri setinde verileri inceleyerek ve sınıflandırarak öğrenir. Belirli bir çıktı hedefine doğru yapılandırılmış örneklerle birlikte öğrenir.

Pekiştirmeli Öğrenme


Bir karar verme sürecinin en iyisini bulmak için bir hedefi optimize etmeyi öğrenir.

- Yüksek enerji fiziği analizlerine denetimli öğrenmeye dayalı MÖ algoritmaları uygundur [1].
- Denetimli öğrenmede
 - Verinin karşılık geldiği bilginin belirli olduğu etiketli bir veri seti kullanılır.
 - Eğitim veri kümesi kullanılarak makine bilgi edinir.
 - Eğitim kümesine benzer özelliklere sahip fakat daha önce hiç görmediği (test veri seti) yeni verilere makinenin en uygun çıktılarını üretmesi beklenir.
- Denetimli öğrenme regresyon ve sınıflandırmada kullanılır.

Regresyon ve sınıflandırma arasındaki temel fark; regresyon sürekli değerleri tahmin etmek için kullanılırken; sınıflandırma ayrık değerleri tahmin etmek için kullanılır.



Regresyon



Sınıflandırma

- Yüksek enerji fiziği analizlerine denetimli öğrenmeye dayalı MÖ algoritmaları uygundur [1].
- Denetimli öğrenmede
 - Verinin karşılık geldiği bilginin belirli olduğu etiketli bir veri seti kullanılır.
 - Eğitim veri kümesi kullanılarak makine bilgi edinir.
 - Eğitim kümesine benzer özelliklere sahip fakat daha önce hiç görmediği (test veri seti) yeni verilere makinenin en uygun çıktılarını üretmesi beklenir.
- Denetimli öğrenme regresyon ve sınıflandırmada kullanılır.

Regresyon ve sınıflandırma arasındaki temel fark; regresyon sürekli değerleri tahmin etmek için kullanılırken; sınıflandırma ayrık değerleri tahmin etmek için kullanılır.
- Denetimli Öğrenme Modelleri genellikle üç ana kategori altında toplanır:
 - Karar Ağacı Modelleri
 - Sinir Ağı Modelleri
 - Destek Vektör Makineleri

Çalışma Prensipleri

Verilerin Ön İşlenmesi

Verilerin ön işleme adımları uygulanır. Bu adımlar, verilerin daha kolay okunmasını sağlar ve sınıflandırma sürecinin daha doğru olmasını sağlar.

Karar Ağacı Modelinin Oluşturulması

Seçilen algoritmaların birleştirilmesiyle karar ağacı modeli oluşturulur. Model oluşturma sürecinde birden fazla veri seti kullanılabilir.

1. Adım



2. Adım



3. Adım



4. Adım

Verilerin Toplanması

Öncelikle, model oluşturma için gerekli olan veri setleri toplanır ve incelenir. Bu süreç, verilerin doğrulanması ve kontrolü için oldukça önemlidir.

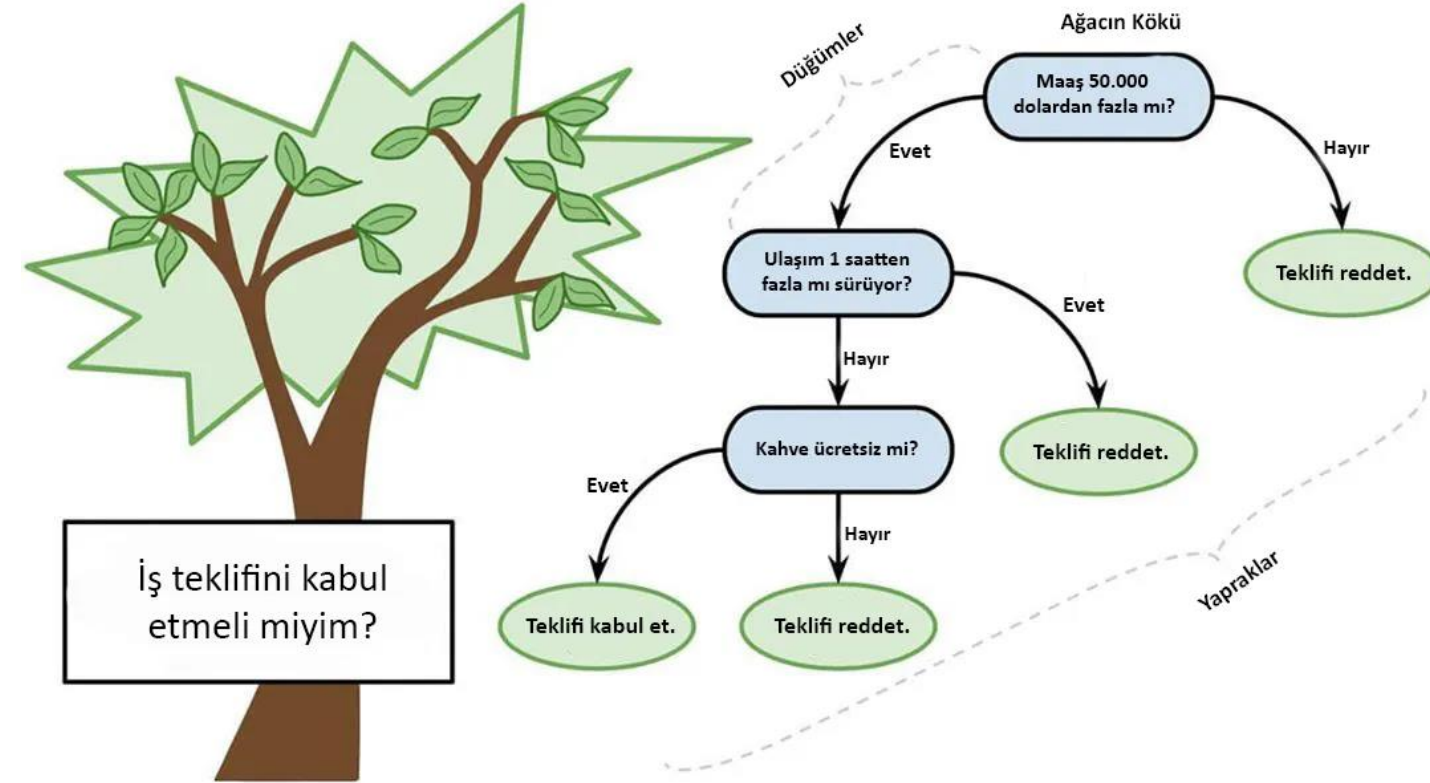
Özellikleri Seçme

Veriler özellikleri açısından incelenir ve karar ağacı modelinin daha etkili olması için gereksiz veya kaynak tüketen veriler çıkarılır.

Kullanılan Algoritmalar

1. Basit Karar Ağacı

- Bir dizi basit karar uygulayarak veriyi daha küçük gruplara bölmek için kullanılan bir yapıdır.
- Kök, düğümler ve yapraklardan oluşur.
Kök: Ağacın başlama noktası.
Düğümler: Veri setinde bulunan özellikler
Yapraklar: Algoritmanın kararları
- Düğüm sayısı arttıkça modelin karmaşıklığı da artar.
- Kökün veri setini mümkün olduğunca anlamlı şekilde ayrıştırabilmesi gerekir.

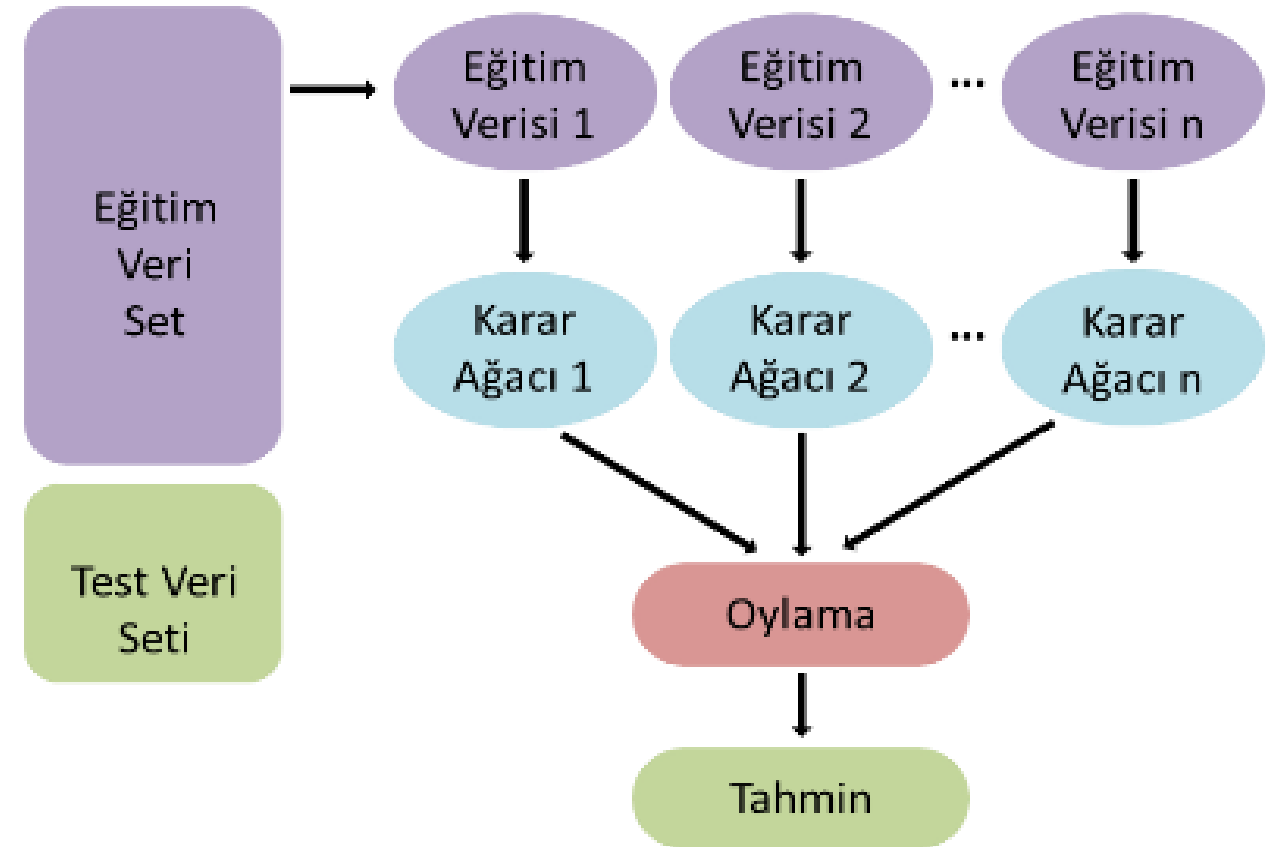


<https://medium.com/deep-learning-turkiye/karar-a%C4%9Fa%C3%A7lar%C4%B1-makine-%C3%B6%C4%9Frenmesi-serisi-3-a03f3ff00ba5>

Kullanılan Algoritmalar

2. Rastgele Orman

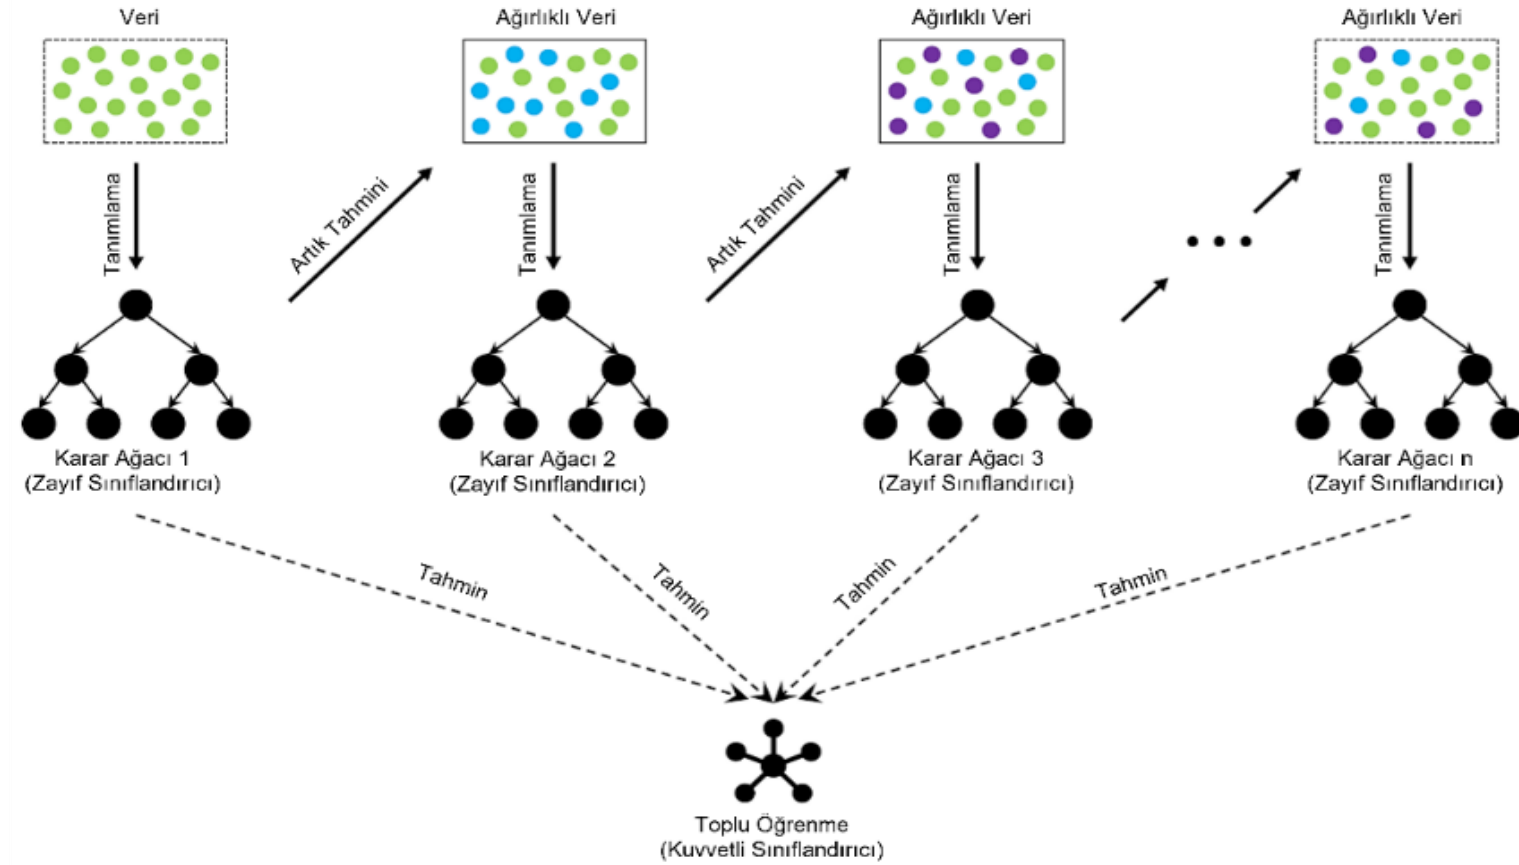
- Bir takım alt kararlara göre kararlar üretmek ve birbirlerini bireysel hatalardan korumak için bir komite gibi çalışan karar ağaçlarından oluşur.
- Model, her bir ağaç için düğümlerde kullanılacak özellikleri, varyasyonu sağlamak ve ağaçlar arasındaki korelasyonu azaltmak için rastgele seçer.
- Algoritmanın iki bölümü vardır.
 - Birinci Bölüm: Eğitim veri setinin rastgele seçilmiş bir alt kümesinden karar ağaçları üretir.
 - İkinci Bölüm: Test veri setinin nihai kararını vermek için farklı karar ağaçlarından oylar alır.



Kullanılan Algoritmalar

3. Gradyan Artırma

- Algoritma karar ağaçlarını birbirlerinin zayıf yönlerini çoklu yineleme yoluyla telafi ederek daha güçlü bir sınıflandırıcı model oluşturur.
- Zayıf bir karar ağacı mevcut artıklara (hatalara) sıralı olarak uydurularak yeni karar ağacı oluşturur. Böylece, modelin tahmin performansı uyarlamalı olarak iyileşir.
- Her bir karar ağacı oluşturulurken önceki karar ağacında yapılan hatalara odaklanarak düzenlenen ağırlıklı veri kümesi kullanılır.



Avantajları:

1. Yüksek Doğruluk Oranı

Karar ağacı modelleri, yüksek doğruluk düzeyine sahiptir. Model geliştirme sürecinde daha az hata yapılır ve öğrenme oranı yüksek olur.

2. Eğitim Sürecinin Kolaylığı

Veriler üzerinde yapılan işlemler basittir. Bu nedenle karar ağacı modelleri, eğitim sürecinde daha kolay öğrenilir ve zaman açısından avantaj sağlar.

3. Veri Ön İşleme İhtiyacı

Karar ağacı modelleri, verilerin ön işleme ihtiyacını düşürür. Bu nedenle veri setleri daha hızlı ve etkili bir şekilde kullanılır.

Avantajları:

1. Yüksek Doğruluk Oranı

Karar ağacı modelleri, yüksek doğruluk düzeyine sahiptir. Model geliştirme sürecinde daha az hata yapılır ve öğrenme oranı yüksek olur.

2. Eğitim Sürecinin Kolaylığı

Veriler üzerinde yapılan işlemler basittir. Bu nedenle karar ağacı modelleri, eğitim sürecinde daha kolay öğrenilir ve zaman açısından avantaj sağlar.

3. Veri Ön İşleme İhtiyacı

Karar ağacı modelleri, verilerin ön işleme ihtiyacını düşürür. Bu nedenle veri setleri daha hızlı ve etkili bir şekilde kullanılır.

Dezavantajları:

1. Veri Kirliliği

Veri kümesindeki eksik veya yanıltıcı veriler modelin doğruluğunu azaltabilir. Bu nedenle veri kirliliği, özenle ele alınmalıdır.

2. Doğrusal Olmayan

Değişkenler

Karar ağacı modelleri, doğrusal olmayan veriler üzerinde zayıf sonuçlar verebilir.

3. Aşırı Öğrenme Problemi

Model geliştirme sürecinde, modelin sadeleştirilmesi ve verilerin daha iyi öğrenilmesi aşırı öğrenme problemi oluşabilir.

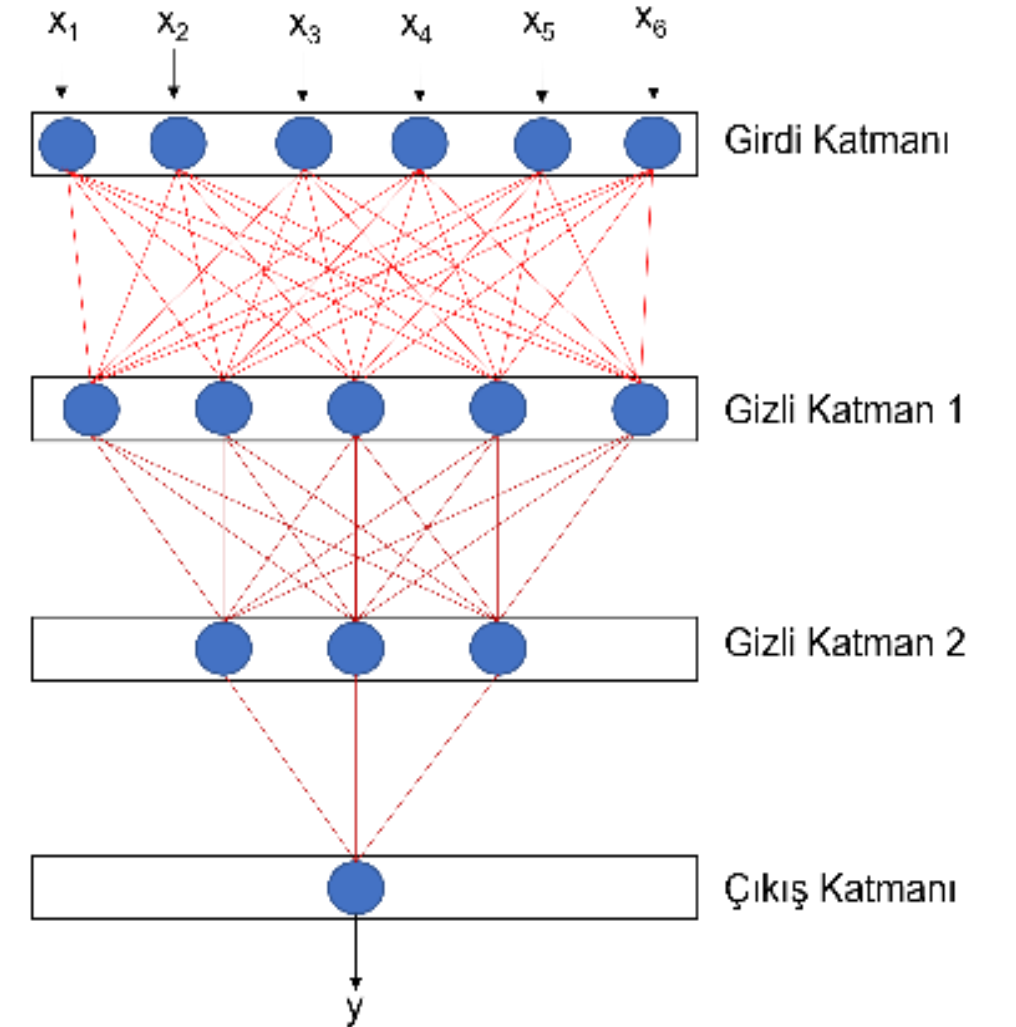
Yapay Sinir Ağı-YSA (Nöron):

- Girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş bölümden oluşur [2].
 - Girdi, ağın öğrenmesi istenen örneklerden oluşan bilgilerdir.
 - Her girdinin önemini ve etkisini gösteren değişken veya sabit kendi nispi ağırlığı vardır.
 - Bir YSA'da her girdinin ve sinaps denilen nöronlar arasındaki her bağlantının ağırlık değeri vardır.
 - Toplam fonksiyonu bir hücreye ağırlıkla çarpılarak gelen girdileri toplayıp net girdiyi hesaplar.
 - Aktivasyon fonksiyonu net girdiyi işleyerek, hücrenin üreteceği çıktıyı belirleyen fonksiyondur. YSA'da çıktılar, aktivasyon fonksiyonunun ürettiği değerler olarak tanımlanır.
- Bir sinir ağı olan YSA özellik alanıyla eşleşen bir girdi katmanına ve çıktı alanıyla eşleşen çıktı katmanına sahiptir [2].



Derin Sinir Ağları (DSA):

- YSA'nın girdi ve çıktı tabakaları arasında gizli tabakalar olarak da tanımlanan ara katmanlar eklendiğinde ağ derinleşir ve DSA oluşur.
- DSA'da veri bilgisi girdi katmanı tarafından alınır, ara katmanlar tarafından işlenir ve çıktı katmanı tarafından sonuçlandırılır.
- DSA'da giriş ve çıkış katmanları bir tane iken, ara katmanlar birden fazla olabilir.
- Ara katman sayısı ile bu katmanlardaki nöronların artması hesaplama karmaşıklığını ve süresini arttırabilir.
- DSA'da ara katmanlar modelin doğrusal olmayan problemleri çözme başarısını artırır.



Avantajları:

1. Yüksek Doğruluk

Karmaşık verilerin sınıflandırılması ve tahmini için yüksek doğruluk sağlar.

2. Güçlü Öğrenme Kapasitesi

Verileri hafızalarında depolayarak, karmaşık problemleri öğrenebilir ve daha sonra uygulayabilirler.

3. Çok Yönlü Kullanım

Veri madenciliği, tahmin, sınıflandırma, optimizasyon ve robotik gibi birçok alanda kullanılabilir.

Avantajları:

1. Yüksek Doğruluk

Karmaşık verilerin sınıflandırılması ve tahmini için yüksek doğruluk sağlar.

2. Güçlü Öğrenme Kapasitesi

Verileri hafızalarında depolayarak, karmaşık problemleri öğrenebilir ve daha sonra uygulayabilirler.

3. Çok Yönlü Kullanım

Veri madenciliği, tahmin, sınıflandırma, optimizasyon ve robotik gibi birçok alanda kullanılabilir.

Dezavantajları:

1. Karmaşık Yapı

Gizemli yapıları nedeniyle tahmin edilebilirliği zordur. Bu durum, güvenilirliği azaltabilir.

2. Eğitim Maliyeti

Yüzlerce parametreyle eğitildiği için, işlemci zamanı ve kaynakları açısından oldukça maliyetlidir.

3. Veriye Bağlılık

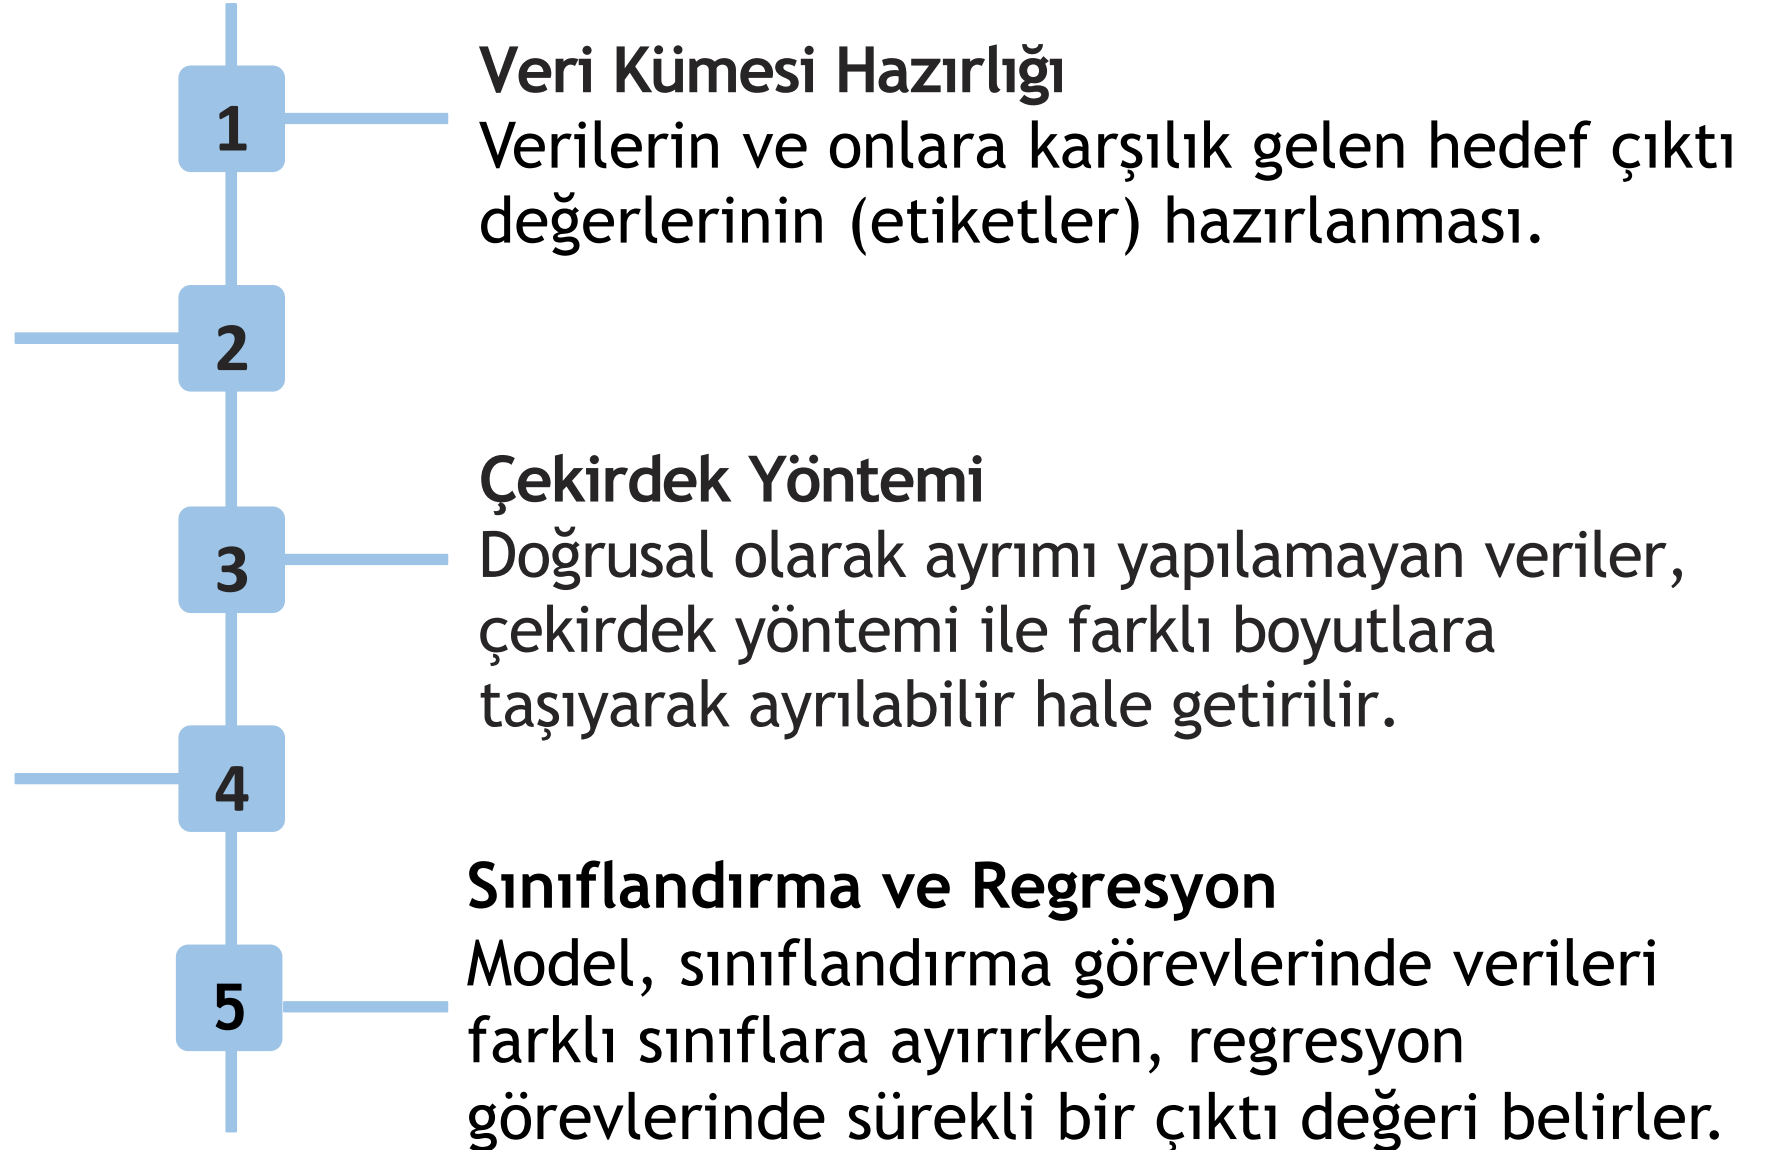
Verilerin kalitesi, yapay sinir ağlarının doğruluğunu etkiler. Yanlı ya da eksik veriler, modelin yanlış sonuçlar vermesine neden olabilir.

İyi genelleştirme yeteneğine sahip, verilerin yüksek boyutlu uzaylara taşınmasını sağlayan ve doğrusal olarak ayıramayan verileri ele alabilen güçlü bir denetimli öğrenme modelidir.

Temel Prensipleri:

Maksimum Boşluğun (Marj) Hedefleme
Destek vektörleri olarak adlandırılan veri noktaları kullanılarak sınıflar arasındaki maksimum marj belirlenir.

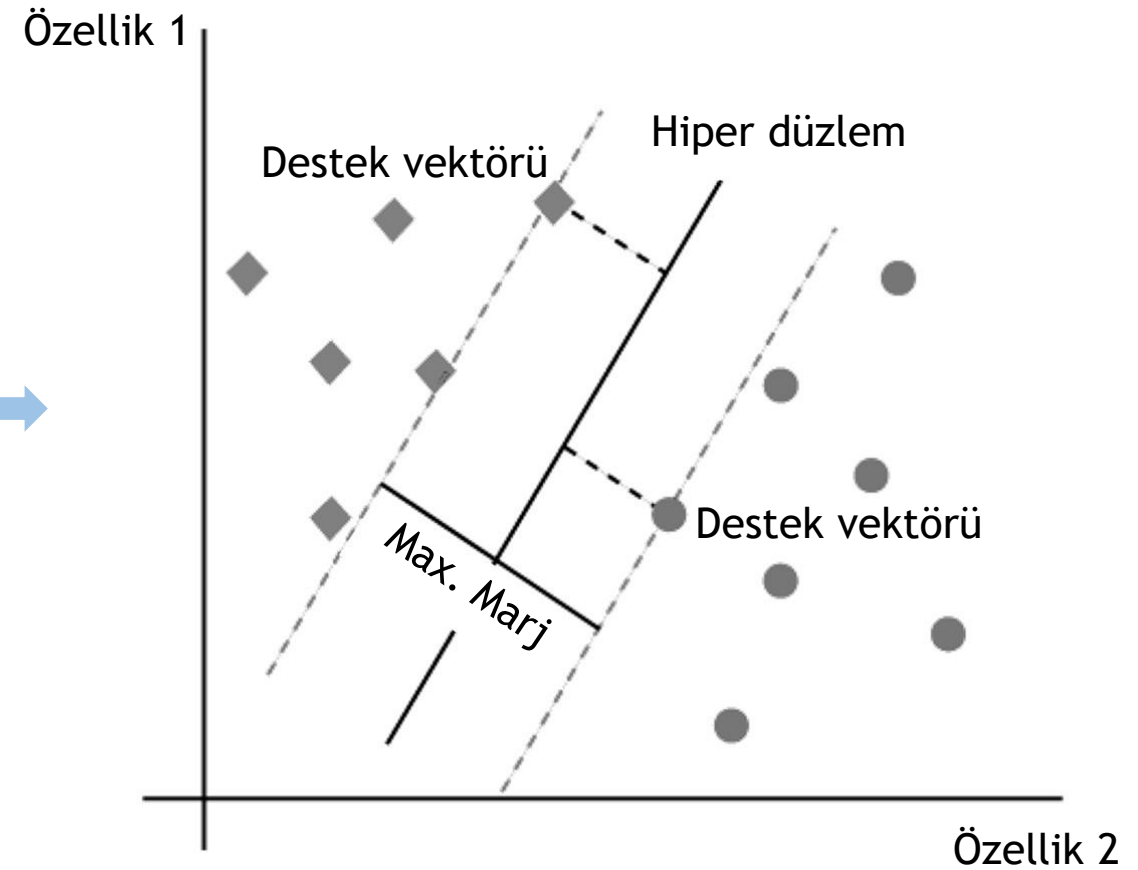

Hiper Düzlem ve Çekirdek Seçimi
Verileri doğru bir şekilde sınıflandıran en iyi hiper düzlem belirlenir.



Destek Vektör Makineleri

İyi genelleştirme yeteneğine sahip, verilerin yüksek boyutlu uzaylara taşınmasını sağlayan ve doğrusal olarak ayıramayan verileri ele alabilen güçlü bir denetimli öğrenme modelidir.


Doğrusal olan:



Destek Vektör Makineleri

İyi genelleştirme yeteneğine sahip, verilerin yüksek boyutlu uzaylara taşınmasını sağlayan ve doğrusal olarak ayıramayan verileri ele alabilen güçlü bir denetimli öğrenme modelidir.

Doğrusal olmayan:



Avantajları:

1. Yüksek Doğruluk

Yüksek boyutlu veri kümesi üzerinde etkili doğruluk sağlar. Az sayıda veri örneği üzerinde iyi performans gösterebilir.

2. Karmaşık Verilere Uygulanabilirliği

Doğrusal olarak ayıramayan veriler için de uygulanabilir.

3. Verimlilik

Verileri farklı boyutlara anlamlı bir şekilde dönüştürmesi performansını artırır.

Avantajları:

1. Yüksek Doğruluk

Yüksek boyutlu veri kümesi üzerinde etkili doğruluk sağlar. Az sayıda veri örneği üzerinde iyi performans gösterebilir.

2. Karmaşık Verilere Uygulanabilirliği

Doğrusal olarak ayıramayan veriler için de uygulanabilir.

3. Verimlilik

Verileri farklı boyutlara anlamlı bir şekilde dönüştürmesi performansını artırır.

Dezavantajları:

1. Zaman

Büyük veri kümeleri üzerinde çalışması zaman alabilir ve bellek yoğun olabilir.

2. Çoklu Sınıf Problemi

Çoklu sınıf sınıflandırma problemleri için uygulanması zordur, genellikle "bir-iki" sınıf kategorizasyonuna daha uygun kabul edilir.


3. Optimizasyon Zorluğu

Yüksek boyutlu verilerde modelin çok parametreye sahip olması model optimizasyonunu zorlaştırabilir.

1

Veriyi Temizleme

Veriler
temizlenir
ve
özellikler
belirlenir.

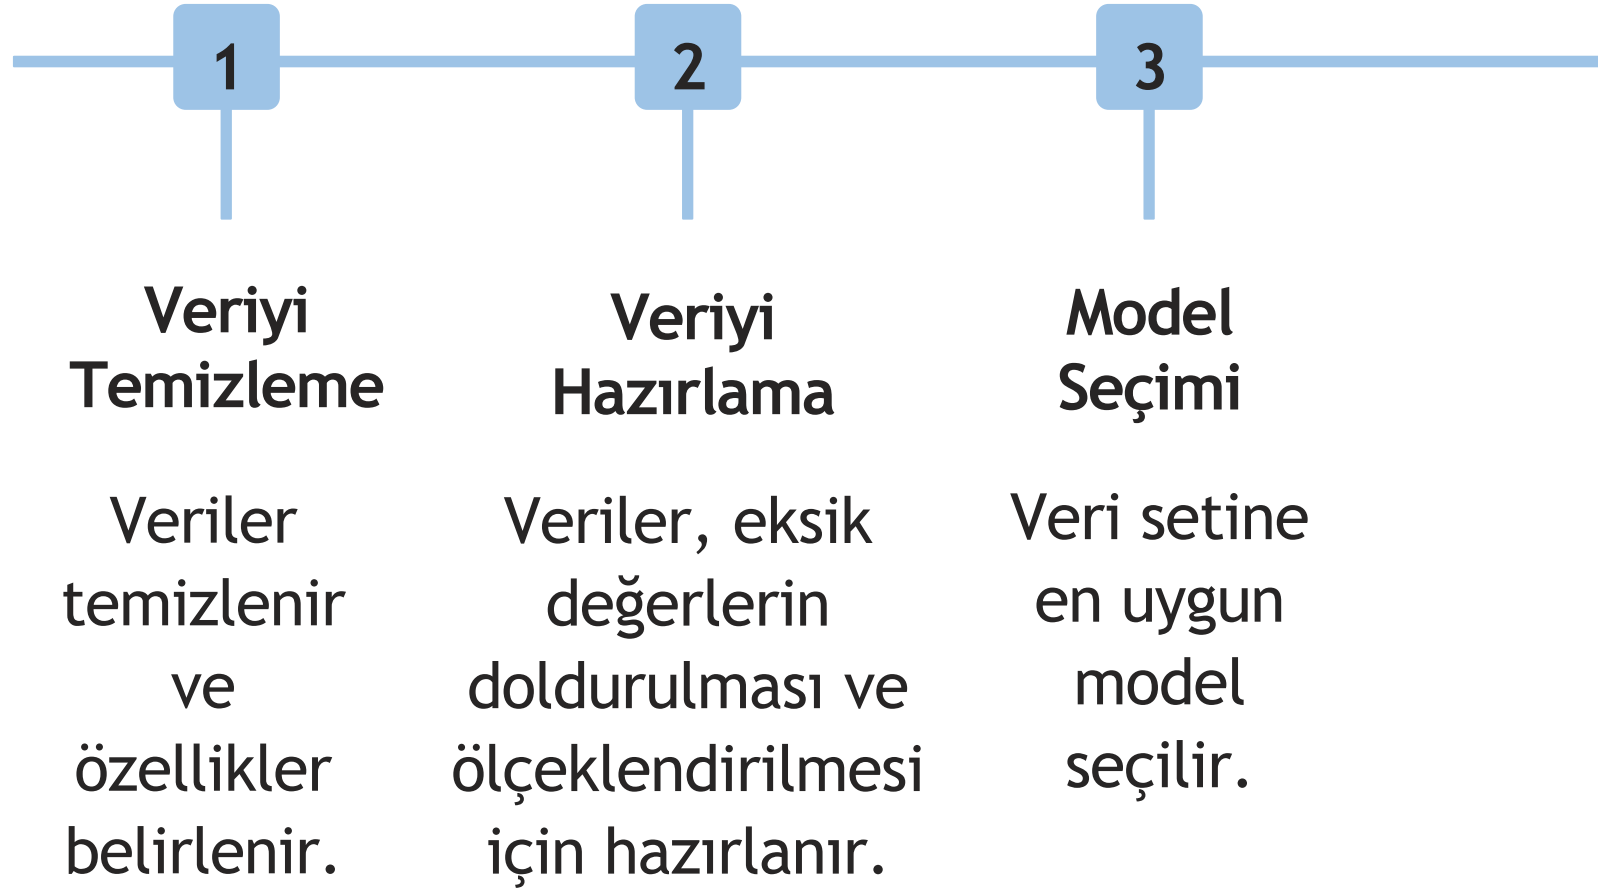


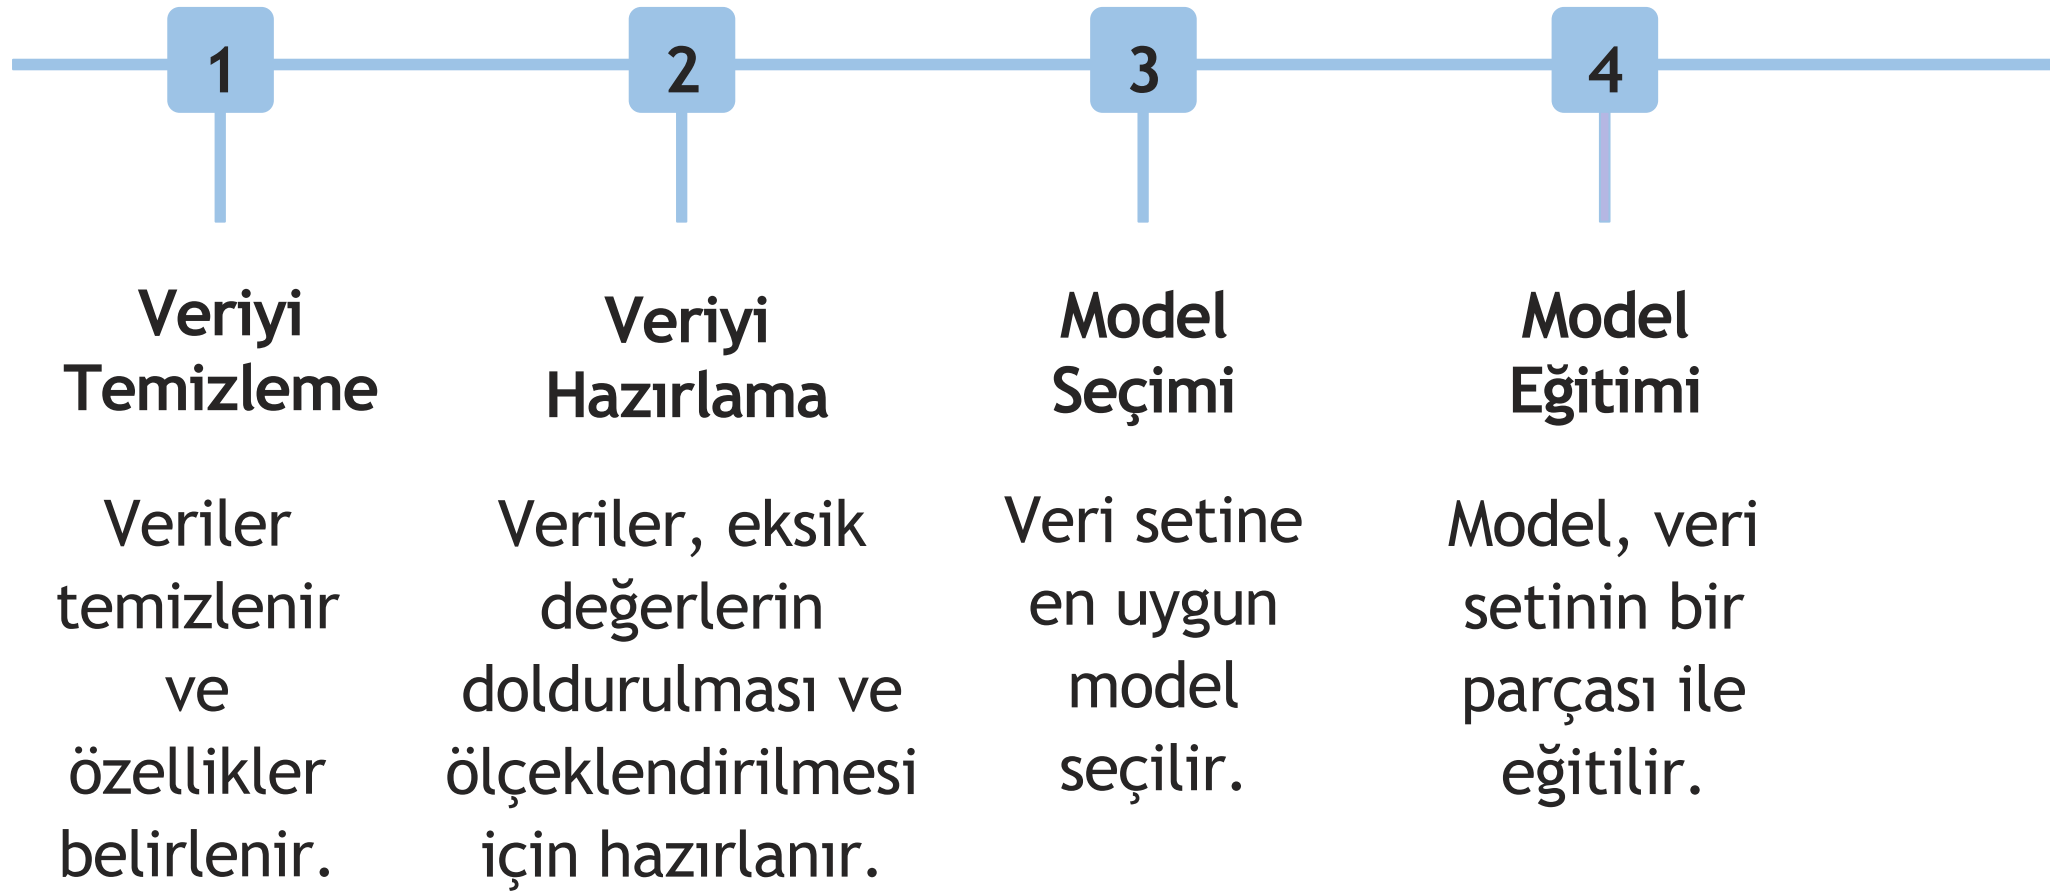
Veriyi Temizleme

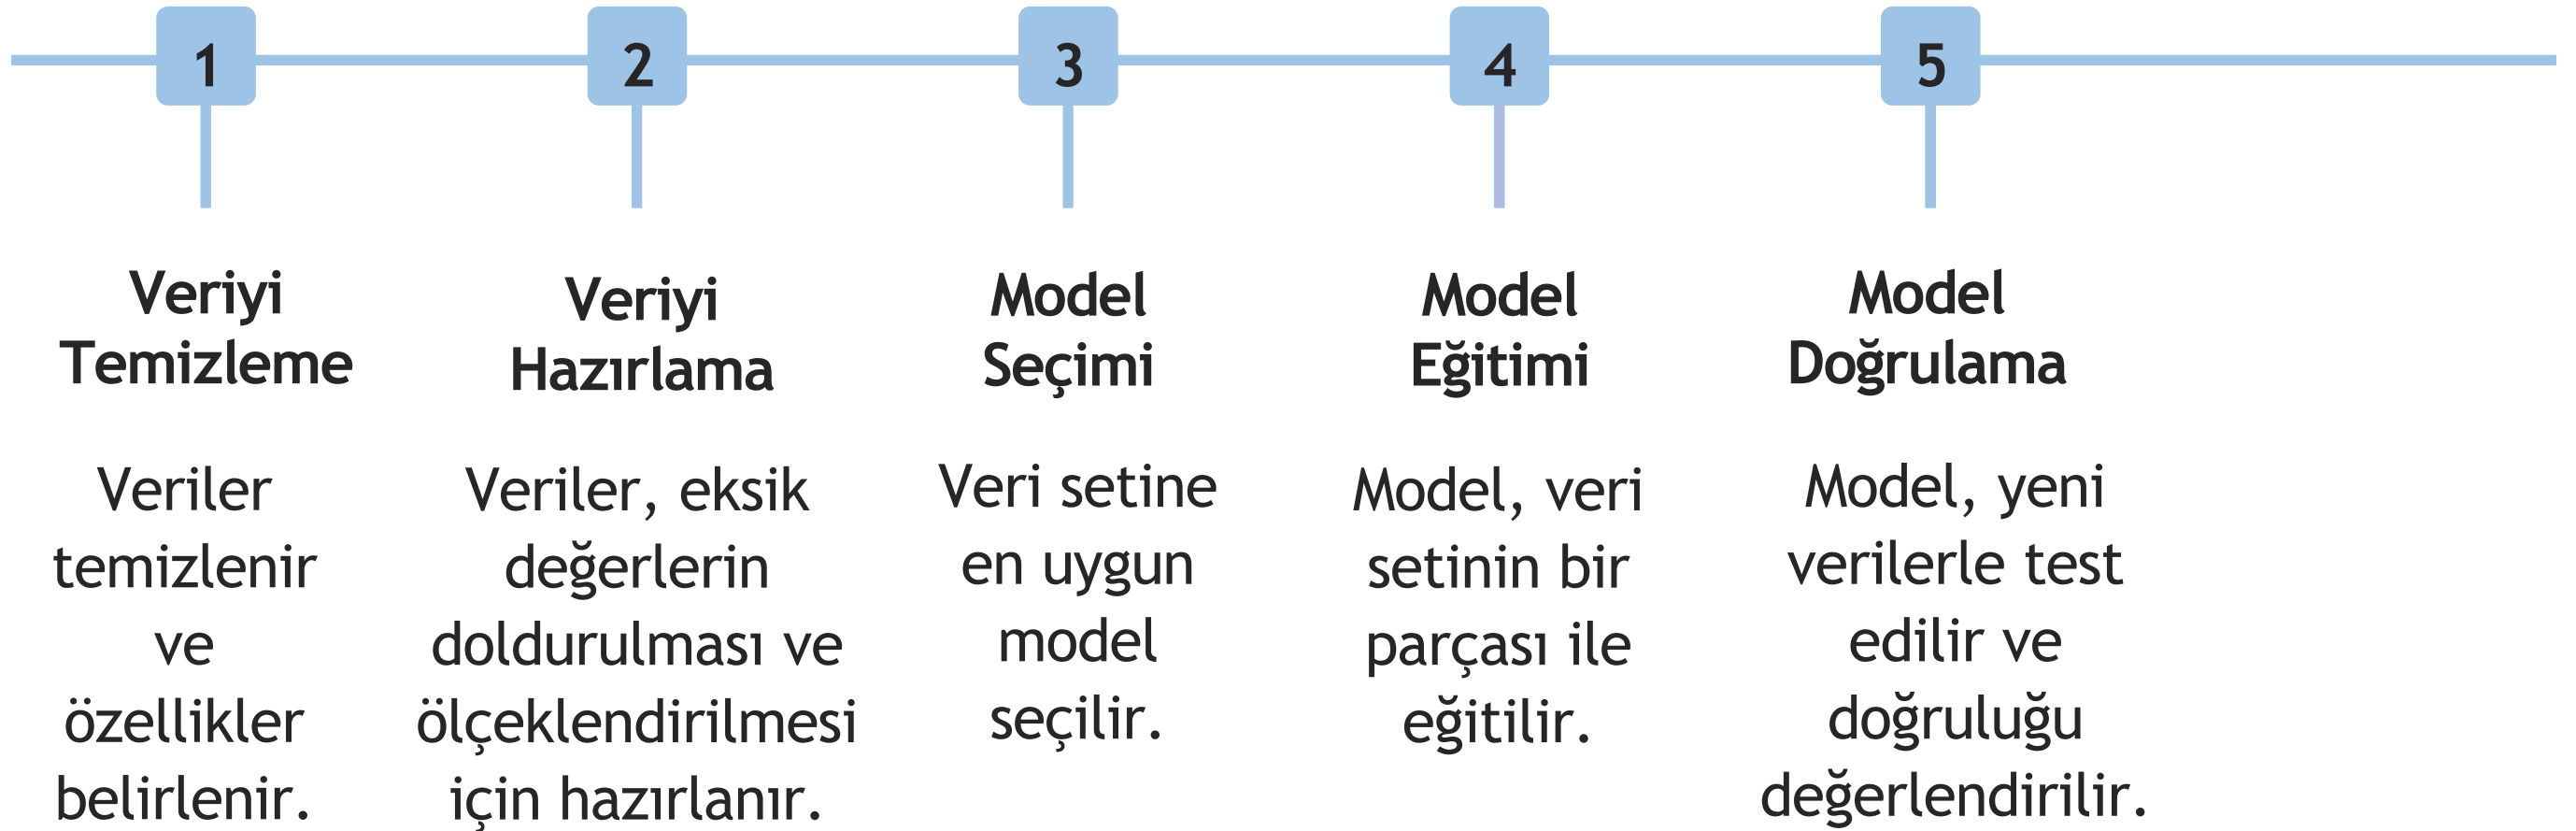
Veriler temizlenir ve özellikler belirlenir.

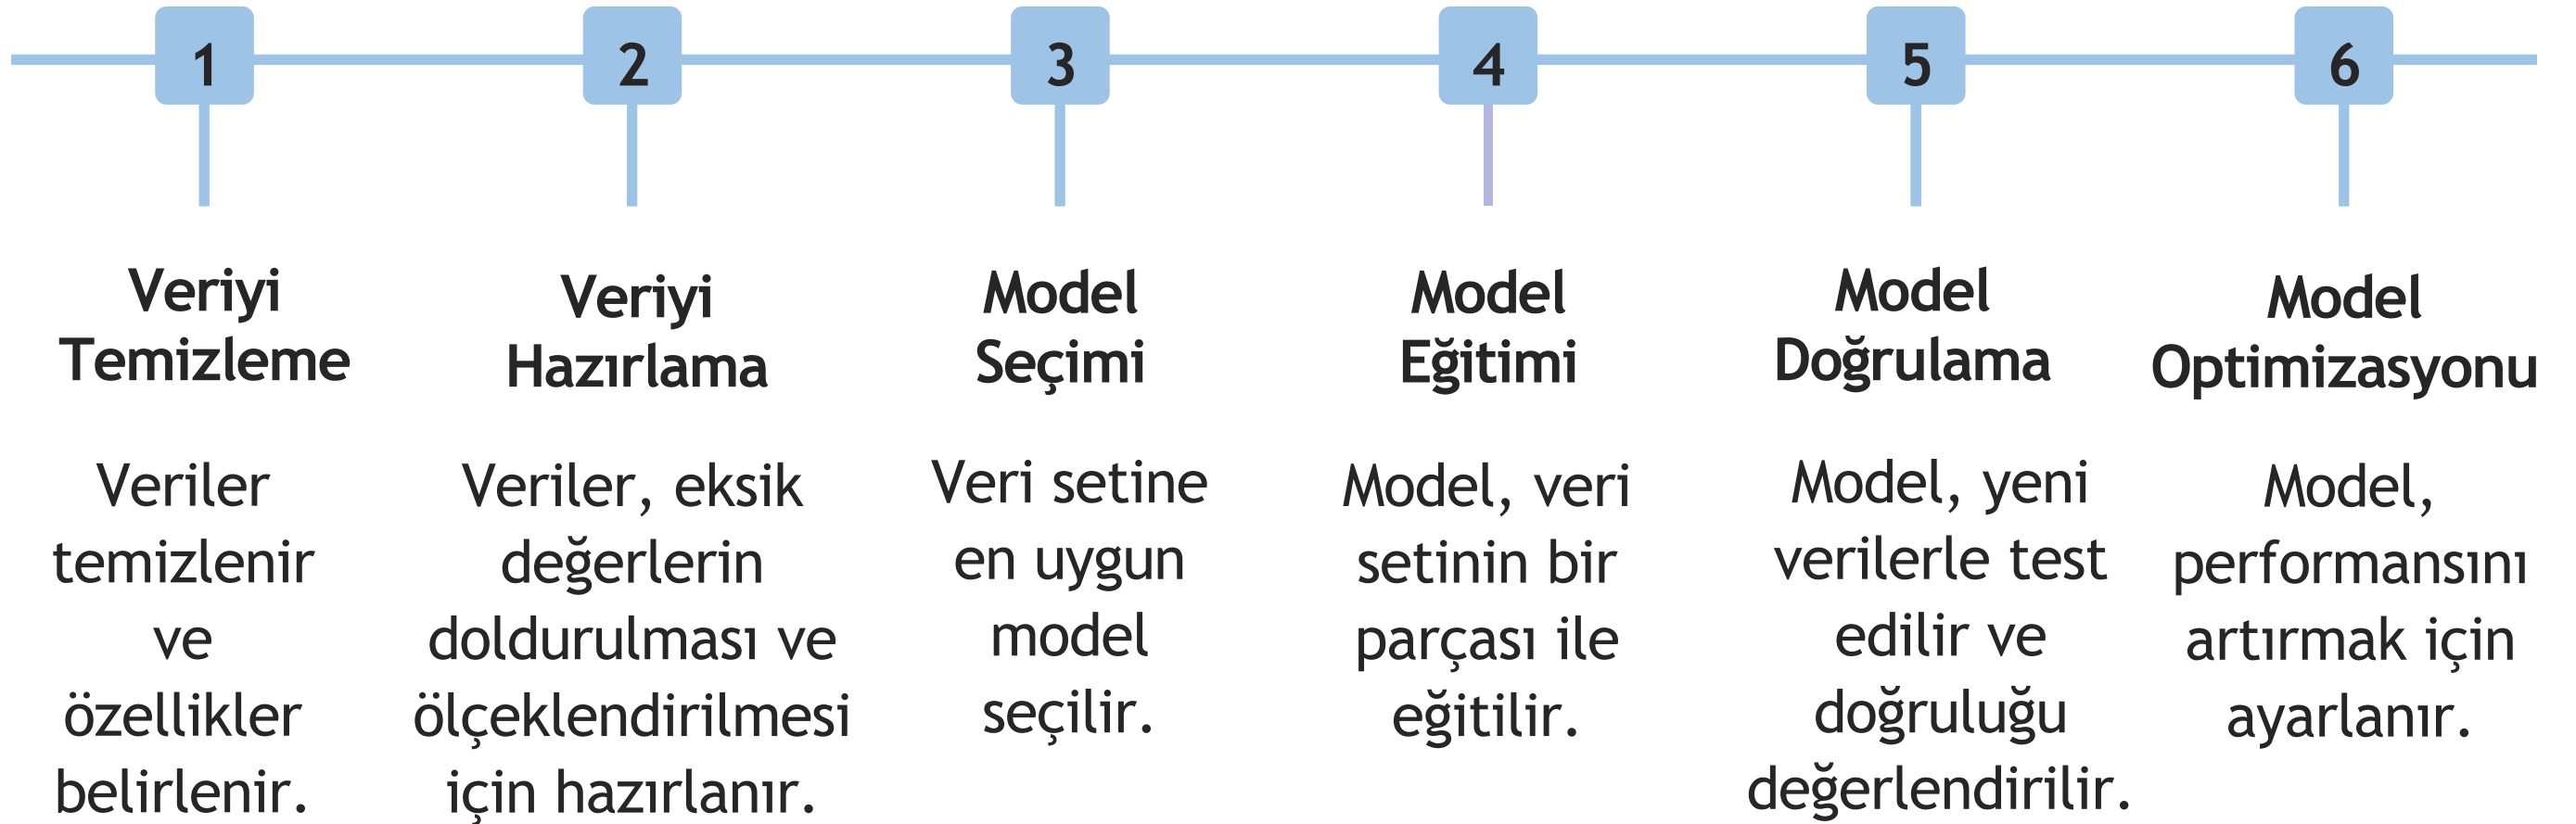
Veriyi Hazırlama

Veriler, eksik değerlerin doldurulması ve ölçeklendirilmesi için hazırlanır.









MÖ Performans Değerlendirmesi

Denetimli öğrenmede model performansları farklı yapıları sebebiyle sınıflandırma ve regresyon için farklılık gösterir.


Hangi metriğin kullanılacağı, **problem** ve **veri seti özelliklerine** göre değişebilir.

Sınıflandırma Performansı:


- Hata matrisinden elde edilen değerler kullanılarak hesaplanan ölçütlerle değerlendirilir.

Regresyon Performansı:

- Genellikle hata metrikleri ile değerlendirilir.



Regresyon



Sınıflandırma

MÖ Performans Değerlendirmesi: Sınıflandırma

Hata Matrisi:

- Veri setinde bulunan gerçek sınıf bilgisi ile MÖ model tahminlerinin bir tablo olarak gösterilmesidir [3, 4].
- Gerçek değerler veri seti sınıf bilgisini; tahmin edilen değerler ise model tespiti sonucu elde edilen sınıf bilgisini temsil eder.
- Matris ile modelin kategorize etme performansı tespit edilir.
 - **Doğru Pozitif (DP):** Modelin örneği pozitif olarak tahmin ettiği ve gerçekte pozitif olduğu doğru durum.
 - **Yanlış Pozitif (YP):** Modelin örneği pozitif olarak tahmin ettiği fakat gerçekte negatif olduğu yanlış durum.
 - **Doğru Negatif (DN):** Modelin örneği negatif olarak tahmin ettiği ve gerçekte negatif olduğu doğru durum.
 - **Yanlış Negatif (YN):** Modelin örneği negatif olarak tahmin ettiği fakat gerçekte pozitif olduğu yanlış durum.
- En ideal durumda YP ve YN değerlerinin 0 olması beklenir.

Gerçek Değerler	Negatif Sınıf	DN (Doğru Negatif)	YP (Yanlış Pozitif)
	Pozitif Sınıf	YN (Yanlış Negatif)	DP (Doğru Pozitif)
		Negatif Sınıf	Pozitif Sınıf
		Tahmin Edilen Değerler	

MÖ Performans Değerlendirmesi: Sınıflandırma

Performans Ölçütleri:

Doğruluk (Accuracy): Modelin doğru tahminlerinin toplam örnek sayısına oranını temsil eder.

$$\text{Doğruluk} = (\text{DP} + \text{DN}) / (\text{DP} + \text{DN} + \text{YP} + \text{YN})$$

Kesinlik (Precision): Modelin doğru pozitif olarak tahmin ettiği örneklerin tüm pozitif tahminlere oranını temsil eder.

$$\text{Kesinlik} = \text{DP} / (\text{DP} + \text{YP})$$

Duyarlılık (Recall): Modelin doğru pozitif olarak tahmin ettiği örneklerin gerçek pozitif olan örneklerle oranını gösterir.

$$\text{Duyarlılık} = \text{DP} / (\text{DP} + \text{YN})$$

F1-Skoru (F1-Score): Kesinlik ve duyarlılığın harmonik ortalamasını temsil eder.

$$\text{F1*Skoru} = 2 * (\text{Kesinlik} * \text{Duyarlılık}) / (\text{Kesinlik} + \text{Duyarlılık})$$

Gerçek Değerler


Gerçek Değerler	Negatif Sınıf	DP (Doğru Pozitif)
	Pozitif Sınıf	YP (Yanlış Pozitif)
Tahmin Edilen Değerler	Negatif Sınıf	DN (Doğru Negatif)
	Pozitif Sınıf	YN (Yanlış Negatif)

MÖ Performans Değerlendirmesi: Sınıflandırma

Performans Ölçütleri:

Alıcı İşletim Karakteristik Eğrisi (ROC):

- ROC eğrisi, **duyarlılığın** ve “**yanlış pozitif oranı** (YPO=YP/(YP+DN))” ölçütlerinin iki boyutlu grafiklerinin belirlenerek eğri altında kalan alanın hesaplanması (AUC ROC) temeline dayanır.
- AUC ROC iki sınıfın MÖ modeli tarafından ne kadar iyi ayırt edebildiğinin bir ölçüsüdür [5].
- Yüksek AUC ROC değeri, MÖ modelinin sınıfları ayırt etme gücünü gösterir. Alanın 0.9’dan büyük olması mükemmel sınıflama olarak yorumlanabilir [5].



https://en.wikipedia.org/wiki/Receiver_operating_characteristic

MÖ Performans Değerlendirmesi: Regresyon

Yaygın olarak kullanılan bazı regresyon metrikleri:

Ortalama Kare Hata (Mean Squared Error - MSE):

- Tahmin edilen değerler ile gerçek değerler arasındaki farkların karesinin ortalamasıdır.
- MSE ne kadar düşükse, modelin tahminleri o kadar iyi demektir.

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

Ortalama Mutlak Hata (Mean Absolute Error- MAE):

- Tahmin edilen değerler ile gerçek değerler arasındaki mutlak farkların ortalamasıdır.
- Büyük hatalara daha az hassas olduğu için MSE'ye göre daha dengelidir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|$$


Kök Ortalama Kare Hata (Root Mean Squared Error - RMSE):

- MSE'nin karekökü alınarak hesaplanır.
- Kareler alınan hataların orijinal birimlere dönüştürülmesini sağlar. Bu nedenle RMSE, orijinal veri birimlerinde yorumlanabilen bir metriktir.


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

n veri noktalarının toplam sayısını temsil eder.
 y_i gerçek değerleri gösterir.
 \hat{y}_i model tarafından yapılan tahminleri gösterir.

- Yoğun programlama bilgisi ve sofistike analiz teknikleri gerektiren yüksek enerji fiziği çalışmalarına MÖ tabanlı algoritmaların uygulanması bir ihtiyaç olup son dönemlerde oldukça önemli hale gelmiştir.
- Makine öğrenimi (MÖ), bir tür **yapay zekâ elde etme yöntemi** olup bilgisayarların karmaşık görevleri gerçekleştirmesidir.
- MÖ modelleri **denetimsiz**, **denetimli** ve **pekiştirmeli** öğrenme yapabilir.
- Yüksek enerji fiziği analizlerinde denetimli öğrenmeye dayalı MÖ algoritmaları oldukça **başarılıdır**.
- Denetimli öğrenme **sınıflandırma** ve **regresyon** analizlerinde kullanılır.



Regresyon



Sınıflandırma

- Denetimli öğrenme modelleri ‘**Karar Ağacı Modelleri**’, ‘**Sinir Ağı Modelleri**’ ve ‘**Destek Vektör Makineleri**’ olmak üzere üç başlık altında toplanabilir.
- Genel olarak bir MÖ modelleme süreci: *(i)* verinin temizlenmesi, *(ii)* verinin hazırlanması, *(iii)* model seçimi, *(iv)* model eğitimi, *(v)* modelin yeni veri setine uygulanması ve *(vi)* optimizasyonundan oluşur.
- Denetimli öğrenmede model performansları **farklı yapıları sebebiyle** sınıflandırma ve regresyon için farklılık gösterir.
- **Sınıflandırma performansı hata matrisinden** elde edilen değerler kullanılarak hesaplanan ölçütlerle değerlendirilirken **regresyon performansı genellikle hata metrikleri** yardımıyla değerlendirilir.

- Hangi metriğin kullanılacağı, **problem** ve **veri seti özelliklerine** göre değişebilir.
- Sınıflandırma için genel olarak kullanılan performans metrikleri, hata matrisi kullanılarak elde edilen **doğruluk**, **kesinlik**, **duyarlılık**, **F1-Skoru** ve alıcı işletim karakteristik eğrisi (ROC) altında kalan alandır (**ROC AUC**).
- Regresyon için genel olarak kullanılan başarı ölçütleri tahmin edilen değerler ile gerçek değerler arasındaki farkların kullanılmasıyla hesaplanan **ortalama kare hata**, **ortalama mutlak hata** ve **kök ortalama kare hata** ölçütleridir.

Bu eğitim
Türkiye Bilimsel Ve Teknolojik Araştırma Kurumu (TÜBİTAK) **123F060**
nolu proje tarafından desteklenmiştir.

- [1] Radovic, A. vd. 2018. “Machine learning at the energy and intensity frontiers of particle physics”, Nature, 560, 41-48, doi: <https://doi.org/10.1038/s41586-018-0361-2>.
- [2] Haykin, S., 1999. Neural Network: A Comprehensive Foundation 2nd ed., Amerika: Prentice-Hall.
- [3] Müller A. C., Guido, S., 2016. Introduction to Machine Learning with Python, O'Reilly Media Inc., Amerika: Sebastopol Kaliforniya.
- [4] Pedregosa, F. vd. 2011. “Scikit-learn: machine learning in python”, Journal of Machine Learning Research, 12, 2825-2830.
- [5] Narsky, I., Porter, F.C., 2014. Statistical Analysis Techniques in Particle Physics, Almanya:Wiley-VCH, 2014.