İSTANBUL TİCARET ÜNİVERSİTESİ FEN BİLİMLERİ DERGİSİ

İstanbul Commerce University Journal of Science

http://dergipark.org.tr/ticaretfbd

Araştırma Makalesi / Research Article

ÇAMAŞIR KURUTMA MAKİNESİ VERİLERİNDEN TEKSTİL ÖZELLİKLERİ ALGILANARAK KURUTMA VERİMLİLİĞİNİN ARTIRILMASI

TEXTILE PROPERTIES DETECTION FROM DRYER MACHINE DATA TO IMPROVE DRYING EFFICIENCY

Mustafa GİDER[1] **Mustafa Cem KASAPBAŞI**[2]

Sorumlu Yazar / Corresponding Author
mustafa.gider34@hotmail.com.

Geliş Tarihi / Received
……

Kabul Tarihi / Accepted
-

Öz

Bu çalışma, çamaşır kurutma makinelerinde yer alan iletkenlik sensörlerinden elde edilen veriler yardımıyla tekstil türü, yük miktarı ve giriş nem seviyesini belirlemeyi; bu sayede kurutma süresini optimize etmeyi amaçlamaktadır. Yapay zekâ tabanlı modeller, tekstil özelliklerini otomatik olarak tanımlayarak her yüke özel kurutma stratejileri geliştirmeye imkân tanımaktadır. Uygulanan makine öğrenmesi ve yapay sinir ağı algoritmaları sayesinde, kurutma süresinde ortalama %33 oranında tasarruf sağlanmıştır. Model doğruluk oranları %86 ile %95 arasında değişmiş, en yüksek başarı Çok Katmanlı Algılayıcı (Multilayer Perceptron – MLP) mimarisi ile elde edilmiştir. Bu bulgular, önerilen sistemin hem kullanıcı deneyimini iyileştirdiğini hem de sürdürülebilir kurutma teknolojilerine katkı sunduğunu göstermektedir.

Anahtar Kelimeler: Kurutma makinesi, tekstil özellikleri, enerji verimliliği, iletkenlik sensörü, makine öğrenmesi

Abstract

This study aims to optimize drying time in tumble dryers by determining textile type, load amount, and initial moisture level using data obtained from built-in conductivity sensors. Artificial intelligence-based models enable the automatic identification of textile characteristics, allowing the development of customized drying strategies for each load. Through the implementation of machine learning and artificial neural network algorithms, an average of 33% reduction in drying time was achieved. The model accuracy ranged between 86% and 95%, with the highest performance obtained using a Multilayer Perceptron (MLP) architecture. These findings indicate that the proposed system not only improves user experience but also contributes to the advancement of sustainable drying technologies.

Keywords: Dryer machine, textile properties, energy efficiency, conductivity sensor, machine learning.

[*] *Bu yayın Mustafa GİDER isimli öğrencinin İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Programındaki Yüksek Lisans tezinden üretilmiştir.*

[1] İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Yüksek Lisans Programı, İstanbul, Türkiye.
mustafa.gider34@hotmail.com, Orcid.org/0009-0008-4533-3761

[2] Beykoz Üniversitesi Mühendislik ve Mimarlık Fakültesi, Bilgisayar Mühendisliği Bölümü, İstanbul, Türkiye.
mustafacemkasapbasi@beykoz.edu.tr, Orcid.org/0000-0001-6444-6659

Sensitivity: Internal / Non-Personal Data

1. GİRİŞ

Günümüzde çamaşır kurutma makineleri, ev içi kullanımdan endüstriyel uygulamalara kadar geniş bir alanda yaygınlaşmış durumdadır. Ancak bu makineler, yüksek enerji tüketimi nedeniyle sürdürülebilirlik ve verimlilik açısından çeşitli zorluklar barındırmaktadır. Elektrikli kurutma makineleri, farklı kumaş türlerine, yük miktarına ve nem oranlarına sahip çamaşırları kurutma sürecinde standart programlar kullanmakta, ancak bu yöntem çamaşırın türüne ve özelliklerine göre verimli bir şekilde ayar yapamadığı için gereksiz enerji tüketimine ve uzun kurutma sürelerine neden olabilmektedir.

Çamaşır kurutma süreci, farklı faktörlerden etkilenerek değişen bir dinamiğe sahiptir. Bu faktörlerin başında kumaş türü, yük miktarı ve başlangıç nem oranı gelmektedir. Her tekstil türü, suyu farklı oranlarda emer ve bu da kurutma sürecini doğrudan etkiler. Pamuklu kumaşlar, suyu yüksek oranda emme kapasitesine sahipken, sentetik kumaşlar suyu daha az tutar ve bu nedenle daha hızlı kurur. Bu farklar, tekstilin türüne göre kurutma süresinin farklı olmasına yol açar. Dolayısıyla, kurutma makinelerinin her kumaş türü için ayrı ayarlamalar yapması gereklidir. Geleneksel makineler, kumaş türünü göz önünde bulundurmadan genel bir program uygular, bu da bazı kumaşların aşırı kurutulmasına ve enerji kaybına neden olabilir.

Yük miktarı, çamaşır kurutma sürecinde önemli bir başka faktördür. Yük miktarının artması, tambur içinde hava akışını ve ısı transferini etkiler. Bu durumda, daha fazla çamaşır aynı anda kurutulmaya çalışıldığında, hava akışı sınırlanabilir ve ısı dağılımı dengesiz hale gelebilir. Sonuç olarak, yük miktarı arttıkça kurutma süresi uzar ve enerji tüketimi artar. Küçük yüklerde, havalandırma daha etkili olabilecekken, büyük yüklerde bu etkinlik azalır ve kurutma işlemi daha verimsiz hale gelir. Geleneksel kurutma makineleri, sabit süre ve sıcaklık bazlı kurutma programlarıyla çalışır, ancak bu yöntem, yük miktarındaki değişimleri dikkate almaz. Bu durum, her yük miktarına uygun verimli bir kurutma sağlamak için yetersiz kalır.

Başlangıç nem oranı da çamaşır kurutma sürecinde belirleyici bir faktördür. Çamaşırın nem oranı ne kadar yüksekse, kurutma süresi de o kadar uzun olur. Çünkü daha fazla nemin buharlaşması gerekecektir, bu da daha fazla enerji tüketimi anlamına gelir. Bunun yanında, başlangıç nemi düşük olan çamaşırlar daha hızlı kurur, çünkü daha az enerji gerektirir. Başlangıçtaki nem oranı, tambur içindeki su buharı yoğunluğunu etkiler ve bu yoğunluk arttıkça, kurutma süreci uzayabilir. Geleneksel kurutma makineleri, nem oranını ölçmeden sabit bir süre ve sıcaklıkla çalıştıkları için, her çamaşırın ihtiyacına göre ayarlama yapmazlar. Bu, bazen çamaşırların gereğinden fazla kurumasına ya da yeterince kuruyamamasına yol açar.

Ancak, tüm bu faktörler tek başına ele alındığında, en verimli kurutma süreci sağlanamaz. Kumaş türü, yük miktarı ve nem oranı birbirini etkileyen ve bir arada dikkate alınması gereken değişkenlerdir. Çamaşır kurutma makinelerinin bu faktörleri dinamik bir şekilde değerlendirmesi, kurutma sürecini daha verimli hale getirebilir. Geleneksel makineler her faktörü göz ardı ederken, gelişmiş sensörler ve makine öğrenmesi algoritmaları sayesinde, bu parametreler doğru bir şekilde ölçülüp, programa entegre edilebilir. Böylece, her yük için enerji tasarrufu sağlanırken, çamaşırların aşırı kurutulması engellenebilir. Ayrıca, bu dinamik sistemler sayesinde tekstilin ömrü korunur ve kullanıcıya daha verimli bir kurutma deneyimi sunulur.

Bu çalışma, çamaşır kurutma makinelerinde kullanılan iletkenlik sensörlerinden elde edilen verileri işleyerek tekstil türlerinin ve özelliklerinin belirlenmesini buna göre kurutma sürecinin optimize edilmesini amaçlamaktadır. Çalışmada, makine öğrenmesi algoritmaları ile elde edilen veriler analiz edilerek, çamaşır yükünün tipi, miktarı ve giriş nem seviyesi doğru şekilde tespit edilmekte ve böylece enerji tasarrufu sağlanmaktadır. Sonuçlar, bu tür bir sistemin geleneksel kurutma süreçlerine göre önemli avantajlar sunduğunu göstermektedir.

2. LİTERATÜR ÖZETİ

Geleneksel çamaşır kurutma makineleri, genellikle zaman ve sıcaklık gibi sabit parametrelerle çalışan programlar kullanmakta olup, tekstil yükünün türü, giriş nem seviyesi ve miktarına göre özelleştirme yapamamaktadır. Bu durum hem enerji verimliliğini düşürmekte hem de giysilerin ömrünü kısaltmaktadır. Son yıllarda, tekstil özelliklerinin doğru tespit edilmesi ve kurutma süreçlerinin optimize edilmesi için makine öğrenmesi tabanlı yaklaşımlar ön plana çıkmıştır. (Ersöz & Çınar, 2021), makine öğrenmesinin tekstil sektöründe doğru tahmin ve sınıflandırma sağladığını;

(Ala & Bakıcı, 2016) ise farklı kumaş tiplerinin nem ve hava geçirgenliği açısından modellenmesinde veri temelli analizlerin avantaj sağladığını ortaya koymuştur. Bu çalışmalar, veri odaklı algoritmaların geleneksel yöntemlere göre daha esnek ve başarılı sonuçlar sunduğunu göstermektedir.

Son iki yılda, özellikle yük türü tanıma, makine öğrenmesi ile kumaş sınıflandırma ve IoT/bulut entegrasyonu ile kurutma makinesi adaptasyonu şeklinde odaklanan araştırmalar artış göstermiştir. Örneğin, (Taur ve ark., 2019), endüstriyel düzeyde kurutma süreçleri için yapay sinir ağları modelleri kullanarak kurutma süresi ve nem kaybı tahmini gerçekleştirmiştir. Bunu destekleyen bir diğer çalışma olan (Orperia ve ark., 2025), sensör tabanlı otomatik yerleştirme ve kurutma sistemleri geliştirerek tekstil konumlandırmasının enerji verimliliği üzerindeki etkisini analiz etmiştir. Bu gelişmeler, sensör–makine öğrenmesi entegrasyonunun çamaşır kurutma makinelerinde zaman ve enerji verimliliğini artırmaya yönelik önemli katkılar sunduğunu göstermektedir.

Buna rağmen literatürde hâlâ bazı boşluklar mevcuttur. Özellikle ev tipi makineler için yük türü, giriş nemi ve kumaş karışımı gibi birden fazla değişkenin eş zamanlı tahmin edilmesi konusunda sınırlı sayıda çalışma bulunmaktadır. Örneğin, (Jasiūnas ve ark., 2025), ev tipi makinelerde enerji performansını değerlendirmek üzere düşük maliyetli bir yumuşak sensör çözümü önermiş; ancak yük türü sınıflandırması ve yük miktarı tahmini gibi alt görevler açısından yeterli doğruluk elde edilememiştir. Bu bağlamda, mevcut çalışmada geliştirilen sistemin hem üçlü sınıflandırma başarısı hem de gerçek zamanlı uygulamaya uygunluğu, literatürdeki eksik alanlara doğrudan katkı sağlamaktadır.

Makine öğrenmesi ve özellikle yapay sinir ağları yöntemleri, çok boyutlu sensör verilerinin işlenmesinde önemli fırsatlar sunmaktadır. (LeCun ve ark., 2015), yapay sinir ağları tekniklerinin görüntü işleme, konuşma tanıma ve zaman serisi analizi gibi alanlarda yüksek doğruluk sağladığını belirtirken; (Goodfellow ve ark., 2016) bu yöntemlerin doğrusal olmayan ilişkileri başarıyla modelleyerek klasik makine öğrenmesi algoritmalarının sınırlamalarını aştığını vurgulamaktadır. Ayrıca, tekstil tanıma ve giriş nem seviyesi tahmini gibi görevlerde kullanılan Çok Katmanlı Algılayıcı (MLP), uzun kısa süreli bellek (LSTM) ve destek vektör makineleri (SVM) gibi algoritmaların, farklı tekstil kombinasyonları üzerinde tatmin edici sonuçlar verdiği birçok çalışmada gösterilmiştir (Alom ve ark., 2019; Mitchell, 1997). Bu bağlamda, çamaşır kurutma makinelerinde makine öğrenmesi tabanlı sistemlerin entegrasyonu hem enerji tasarrufu sağlamakta hem de kullanıcıya özel çözümler geliştirme potansiyeli sunmaktadır.

3. YÖNTEM

3.1. Veri Toplama

Bu çalışmada kullanılan veri seti, ev tipi çamaşır kurutma makinesi prototipi üzerinde gerçekleştirilen deneysel çalışmalar sonucunda elde edilen sensör verilerinden oluşturulmuştur. Veri seti, farklı kumaş türleri, yük miktarları ve başlangıç nem seviyelerini içeren toplam 340 farklı kurutma çevriminden elde edilen sensör ölçümlerini içermektedir. Veri setindeki temel bağımlı değişkenler olan Kumaş Türü (3 sınıf: Pamuklu, Karışık, Sentetik), Yük Miktarı (3 sınıf: Az, Orta, Çok) ve Giriş Nemi (3 sınıf: Düşük, Orta, Yüksek) için test veri setindeki sınıf dağılımları aşağıda detaylandırılmıştır (Toplam Test Örneği N=85):

- **Kumaş Türü:** Pamuklu (31), Karışık (24), Sentetik (30)
- **Yük Miktarı:** Az (26), Orta (30), Çok (29)
- **Giriş Nemi:** Düşük (23), Orta (26), Yüksek (36)

Model eğitiminden önce verilerin kalitesi ve tutarlılığı sağlanmış, ön işleme adımları uygulanmıştır. Sensör verilerinde nadiren karşılaşılan eksik (null) değerler, veri bütünlüğünü korumak ve istatistiksel yanlılığı en aza indirmek amacıyla ilgili değişkenin medyan değeri kullanılarak doldurulmuştur. Makine öğrenmesi ve yapay sinir ağları modellerine girdi olarak sunulan tüm sayısal özellikler (iletkenlik, sıcaklık, nem vb.), değişkenler arası ölçek farklarını gidermek ve modelin yakınsama hızını artırmak amacıyla Standartlaştırma (Z-Skoru Normalizasyonu) yöntemi ile ölçeklendirilmiştir. Bu sayede model performansının optimize edilmesi hedeflenmiştir.

Kullanılan veri seti, çamaşır kurutma makinelerinde yer alan iletkenlik sensörlerinden elde edilen verileri içermektedir:

- **İletkenlik Sensörleri:** Çamaşırın direncini ölçerek, kurutma sürecinin tamamlanıp tamamlanmadığını belirlemek için kullanılır.

Tablo 1. Kurutma Makinesi Sensör Verileri

Sensör Türü	Ölçülen Değer	Ölçüm Aralığı	Ölçüm Sıklığı
İletkenlik Sensörü 1	Direnç Ω	0-200 Ω	Her 1 Sn
İletkenlik Sensörü 2	Direnç Ω	0-200 Ω	Her 1 Sn

- **İletkenlik Sensörü 1:** Toplamda 200 saniye boyunca aktif olarak çalışmaktadır. Bu süre zarfında elde edilen direnç verileri analiz edilerek, ölçümlerin ortalaması ve standart sapması hesaplanmaktadır.

- **İletkenlik Sensörü 2:** Toplamda 400 saniye süreyle aktif olarak çalışmakta olup, bu süreç iki eşit periyoda ayrılmaktadır. Her biri 200 saniyeden oluşan bu periyotlar boyunca belirli ölçümler gerçekleştirilmektedir. İlk 200 saniyelik periyotta, ölçülen veriler arasında ortalama, standart sapma, tekstilin sensör ile etkileşim sıklığı ve tekstilin sensöre çarpma frekansı yer almaktadır. Aynı hesaplamalar, ikinci 200 saniyelik periyot boyunca da tekrarlanarak veri sürekliliği sağlanmaktadır.

Toplanan bu veriler hem kurutma sürecinin optimizasyonu hem de tekstil özelliklerine bağlı olarak enerji tasarrufu sağlanması açısından önemli bir kaynak oluşturmuştur. Veriler, belirli bir sistem üzerinden kaydedilmiş ve analiz için uygun formatta düzenlenmiştir.

3.2. Model Eğitimi ve Doğrulama Stratejisi

Modelin genelleme yeteneğini ve performansını doğru bir şekilde değerlendirmek amacıyla, ön işleme adımlarından geçen toplam veri seti, literatürde yaygın olarak kullanılan Hold-Out stratejisi ile rastgele olarak %80 eğitim ve kalan %20 test kümesi şeklinde iki ana kümeye ayrılmıştır. Modellerin eğitim süreci tamamen %80'lik eğitim kümesi üzerinde gerçekleştirilmiş ve tüm nihai başarı oranları, daha önce model tarafından hiç görülmemiş olan %20'lik test kümesi üzerinde raporlanmıştır.

Bu süreçte aşırı öğrenme (overfitting) problemiyle mücadele edilmiştir. Özellikle ya mimarilerinde (Çok Katmanlı Algılayıcı- MLP), aşırı öğrenmeyi kontrol etmek ve modelin eğitim verisini ezberlemesini engellemek amacıyla Erken Durdurma (Early Stopping) tekniği kullanılmış ve model parametrelerinin güncellenmesi için Adam Optimizasyon Algoritması tercih edilmiştir. Klasik makine öğrenmesi modellerinin genelleme yeteneğini artırmak için ise çapraz doğrulama tekniklerinden faydalanılmıştır.

3.3. Yapay Sinir Ağları

Yapay Sinir Ağları (YSA), insan beyninin çalışma prensiplerinden esinlenerek tasarlanan bir yapay zekâ (YZ) modelidir (LeCun ve ark., 2015). YSA, birçok giriş katmanından geçen ve bir çıkış katmanında sonlanan bir dizi düğümden oluşur. Bu düğümler, sinir hücrelerini temsil eder ve birbirleriyle bağlantılıdır. Bu bağlantılar, ağırlıklar aracılığıyla belirlenir ve öğrenme süreci boyunca uyarlanabilir. YSA modeli Şekil 1. de gösterilmiştir.

YSA'nın temel amacı, veri setlerindeki karmaşık ilişkileri öğrenmek ve bu öğrenilen bilgiyi kullanarak öngörüde bulunmaktır (Haykin, 1994). YSA modelleri genellikle bir eğitim sürecinden geçirilir, bu süreçte algoritmalar, ağırlıkları ve bağlantıları optimize etmek için gerçek veri örneklerini kullanır. Öğrenme süreci tamamlandıktan sonra, YSA, yeni, görülmemiş verileri analiz etme ve sınıflandırma yeteneğine sahip olur.

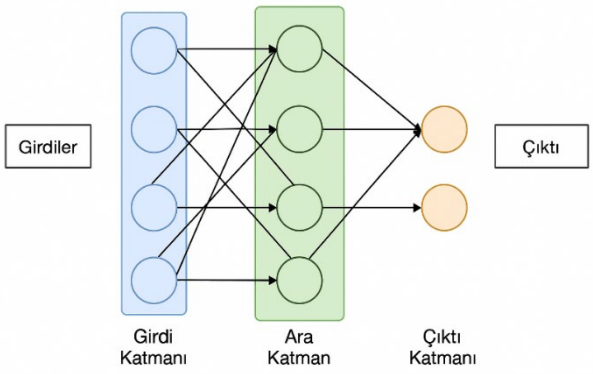

Şekil 1. Yapay Sinir Ağı Modeli

YSA'ların temel amaçları şunlardır:

- Öğrenme: YSA'lar, kendilerine verilen verilerden öğrenebilirler (Yılmazel ve ark., 2020). Bu, YSA'ların yeni durumlara uyum sağlamasını ve performanslarını iyileştirmesini sağlar.
- Tahmin: YSA'lar, geçmiş verilere dayanarak gelecekteki olayları tahmin edebilirler (Taş ve ark., 2018). Bu, YSA'ların risk yönetimi, pazarlama ve üretim gibi uygulamalarda kullanılmasını sağlar.
- Karmaşıklık: YSA'lar, karmaşık ilişkileri öğrenebilirler. Bu, YSA'ların doğal dünyayı anlamamıza yardımcı olma potansiyeline sahiptir.

YSA, YZ araştırmasının önemli bir parçasıdır. YSA'nın gelişimi, YZ'nin gerçek dünyadaki uygulamalarına önemli katkılarda bulunmuştur.

3.4. Makine Öğrenmesi

Makine öğrenmesi (MO), yapay zekâ (YA) alanında önemli bir disiplindir ve bilgisayar sistemlerinin verilerden öğrenmesine ve bu öğrenmeyi kullanarak gelecekteki görevleri daha iyi gerçekleştirmesine odaklanır. Makine öğrenmesi modelleri, verilerden kalıpları ve ilişkileri öğrenerek, verilerden yeni bilgiler üreterek veya verilere dayalı kararlar vererek çalışır (Mitchell, 1997). MO, geniş bir uygulama yelpazesine sahiptir ve bu uygulamalarda genellikle büyük ve karmaşık veri setlerinden öğrenme yeteneği sayesinde etkili sonuçlar elde edilir (Hastie ve ark., 2009).

MO'nun temelinde, algoritmaların veri setlerindeki desenleri tanıma ve öğrenme becerisi bulunmaktadır. Bu desenler, sınıflandırma, regresyon, kümeleme gibi çeşitli görevlerde kullanılabilir. Örneğin, bir sınıflandırma görevinde, algoritma belirli bir girişin hangi sınıfa ait olduğunu öğrenir ve gelecekteki benzer girişleri bu sınıflara atar (Goodfellow ve ark., 2016).
Makine öğrenmesi, çeşitli uygulamalarda kullanılmaktadır. Örneğin, makine öğrenmesi, görüntü tanıma, doğal dil işleme, konuşma tanıma, öneri sistemleri, finansal modelleme ve robotik gibi uygulamalarda kullanılmaktadır (Bishop, 2006).

Makine öğrenmesi çalışmalarının temelini oluşturan önemli kavramlardan biri, denetimli ve denetimsiz öğrenme yöntemleridir. Denetimli öğrenme, etiketlenmiş veri setleri üzerinde eğitilirken, denetimsiz öğrenme etiketlenmemiş veri setlerini kullanarak desenleri keşfetmeye odaklanır (Hastie ve ark., 2009). Ayrıca, derin öğrenme, çok katmanlı yapay sinir ağları kullanarak karmaşık görevleri başarma yeteneğini içeren bir makine öğrenmesi alt dalıdır (Goodfellow ve ark., 2016).

3.4.1. Makine Öğrenmesi Uygulamaları

Toplanan veriler, makine öğrenmesi algoritmaları kullanılarak analiz edilmiştir. Kurutma sürecini optimize etmek için aşağıdaki yöntemler uygulanmıştır.

3.4.1.1. Denetimli Öğrenme (Supervised Learning):

Denetimli öğrenme, makine öğrenmesi ve uzaktan algılama alanlarında yaygın olarak kullanılan bir tekniktir. Bu yöntem, öğrenme sürecinde kullanılan veri setinin etiketli olmasını gerektirir (Mitchell, 1997). Yani, her veri örneği

ile ilişkilendirilmiş doğru sınıf etiketlerine sahip bir eğitim veri seti kullanılır. Denetimli öğrenme, algoritmanın giriş verileri ile bu etiketler arasındaki ilişkiyi öğrenmesini sağlar ve bu öğrenmeyi kullanarak yeni, etiketlenmemiş veri örneklerini sınıflandırmasını gerçekleştirir.

Denetimli öğrenmenin başarı faktörlerinden biri, doğru ve temsilci bir eğitim veri setinin oluşturulmasıdır. Bu, algoritmanın genelleme yeteneğini artırır ve farklı koşullar altında da etkili olmasını sağlar. Yine de uygun algoritma seçimi, özellik mühendisliği ve modelin optimize edilmesi gibi faktörler de denetimli öğrenmenin başarısını etkileyen kritik unsurlardır.

- **Kullanılan Algoritmalar:**
  - **Destek Vektör Makineleri (SVM):**

Destek Vektör Makineleri (DVM), özellikle sınıflandırma ve regresyon problemlerinde etkili bir şekilde kullanılan güçlü bir makine öğrenmesi algoritmasıdır (Cortes & Vapnik, 1995). Temelde, veri noktalarını belirli bir hiper düzlemle ayırmaya çalışan DVM, bu hiper düzlemi seçerken sınıflar arasındaki marjı maksimize etmeye odaklanır. Bu marj, sınıflar arasındaki uzaklığı ifade eder ve modelin genelleme yeteneğini artırır.

DVM, özellikle yüksek boyutlu veri setlerinde etkili olan bir özellik haritalama tekniği olan çekirdek yöntemleri kullanır. Çekirdek fonksiyonları, verileri başka bir uzayda temsil ederek doğrusal olarak ayrılamayan problemleri çözmeye yardımcı olur. Bu, özellikle görüntü tanıma, metin sınıflandırma ve biyomedikal uygulamalar gibi karmaşık veri yapılarına sahip problemlerde DVM'in avantajını ortaya koyar (Bishop, 2006).

DVM, genellikle modelin karmaşıklığını kontrol etmek ve aşırı uyumu önlemek amacıyla düzenleme parametreleri ile birleştirilir. Ayrıca, çoklu sınıflı problemleri ele alabilen ve regresyon analizlerinde kullanılabilen çeşitli varyantlara sahiptir.

Bu çalışmada SVM uygulaması için Standart Ölçekleyici ile normalize edilmiş veriler kullanılmış ve Scikit-learn kütüphanesinin varsayılan parametreleri tercih edilmiştir:

- **Kernel Tipi:** Doğrusal olmayan ilişkileri modellemek için varsayılan Radyal Temel Fonksiyon (RBF) Kernel'i kullanılmıştır.
- **Regülarizasyon Parametresi (C):** Hata cezası parametresi C, varsayılan değeri olan 1,0 olarak belirlenmiştir.
- **Gamma Değeri (γ):** RBF Kernel'inin etki alanını belirleyen γ değeri, varsayılan ayarında bırakılmıştır.

Tablo 2. Destek Vektör Makineleri (SVM) modellerinin performans sonuçları

Tahmin Edilen	Doğruluk (Accuracy)	Precision	Recall	F1 Skoru
Giriş Nemi	0,861	0,867	0,861	0,854
Yük Miktarı	0,906	0,905	0,906	0,905
Kumaş Türü	0,894	0,899	0,894	0,895

  - **Karar Ağaçları (Decision Trees):**

Karar ağaçları, çamaşır kurutma makinelerinde tekstil türünün belirlenmesi ve giriş nem seviyesinin tahmin edilmesinde yaygın olarak kullanılan, açıklanabilir yapısıyla öne çıkan bir makine öğrenmesi algoritmasıdır. Bu algoritmalar, veri setini özelliklere göre dallara ayırarak karar kuralları oluşturur. Tekstil tanıma süreçlerinde, örneğin iletkenlik sensörü çıktıları, sıcaklık ve nem verileri gibi özellikler üzerinden ayrımlar yapılabilir. Her bir dal, farklı tekstil türlerine (pamuklu, sentetik vb.) veya nem kategorilerine (az, orta, çok) karşılık gelebilir.

Karar ağaçlarının en büyük avantajlarından biri, modelin görselleştirilebilir ve yorumlanabilir olmasıdır. Bu, mühendislik ekiplerinin model çıktısını doğrudan analiz edebilmesine ve sistem davranışını şeffaf bir şekilde değerlendirmesine olanak tanır (Rokach & Maimon, 2005). Bunun yanı sıra, eksik verilerle başa çıkabilmesi ve farklı veri türleriyle çalışabilmesi, kurutma makineleri gibi çok değişkenli sistemler için önemli bir avantajdır (Loh, 2011).

Ancak karar ağaçları aşırı öğrenmeye (overfitting) yatkın olduğundan, kurutma döngülerine göre oluşturulacak modellerde budama (pruning) işlemlerinin uygulanması önerilir. Bu sayede modelin genel doğruluğu artar ve yeni tekstil tiplerine daha iyi genellenebilir.

Bu çalışmada, Random Forest modeli için (RandomForestClassifier kullanılarak) sadece varsayılan hiperparametreler kullanılmıştır:

- **Ağaç Sayısı:** Topluluğu oluşturan temel karar ağacı sayısı, varsayılan değer olan 100 ağaç olarak belirlenmiştir.
- **Maksimum Derinlik:** Aşırı öğrenmeyi engellemek amacıyla maksimum derinlik kısıtlanmamıştır.
- **Özellik Seçimi:** Her bir bölme noktasında değerlendirilecek özellik sayısı, varsayılan olarak özellik sayısının karekökü $\sqrt{p}$ formülüne göre belirlenmiştir.

Tablo 3. Karar Ağaçları Modelin Performans Sonuçları

Tahmin Edilen	Doğruluk (Accuracy)	Precision	Recall	F1 Skoru
Giriş Nemi	0,888	0,888	0,888	0,887
Yük Miktarı	0,929	0,929	0,929	0,929
Kumaş Türü	0,894	0,901	0,894	0,895

- Kullanım Amacı: Kumaş türü ve giriş nem seviyesinin doğru tahmin edilmesi
- Modellerin Başarı Oranı: %88- %92 arasında değişmektedir

3.4.1.2. Denetimsiz Öğrenme (Unsupervised Learning):

Denetimsiz öğrenme algoritmaları, çamaşır kurutma makinelerinde tekstil türlerini ve yük miktarını otomatik olarak sınıflandırmak için etkili bir yaklaşımdır. Özellikle kümeleme yöntemleri, iletkenlik sensörleri, sıcaklık ve nem gibi özelliklere dayalı olarak benzer davranışlar sergileyen tekstil gruplarını belirlemek için kullanılabilir. K-means algoritması, bu tür çok boyutlu verilerden yola çıkarak farklı tekstil türlerini ve ağırlık sınıflarını temsil eden kümeleri ortaya çıkarabilir (Ding & He, 2004).

Boyut indirgeme yöntemleri ise, yüksek sayıda sensör verisiyle çalışan sistemlerde veri yapısını sadeleştirerek analiz sürecini kolaylaştırır. Ana Bileşenler Analizi (PCA), özellikle yük miktarına bağlı olarak değişen sensör çıktılarının daha anlamlı biçimde temsil edilmesini sağlayarak kümelerin ayrımını güçlendirir (Ding & He, 2004).

Kümeleme başarımının nicel olarak değerlendirilmesinde, sınıflandırma sonuçları ile referans etiketler arasındaki benzerliği ölçen Düzeltilmiş Rand Endeksi (Adjusted Rand Index – ARI) kullanılmıştır. ARI değeri 1'e yaklaştıkça mükemmel bir eşleşme, 0'a yaklaştıkça rastlantısal bir benzerlik söz konusudur. Zhang ve arkadaşlarının (2020) çalışmasında da benzer şekilde, etiketlenmemiş verilerle gerçekleştirilen denetimsiz öğrenme uygulamaları sayesinde tekstil özellikleri ve yük miktarına göre ayrışan veri grupları elde edilmiş, bu grupların sistem performansına doğrudan katkı sağladığı gösterilmiştir. Bu yöntemler sayesinde kurutma makineleri, kullanıcıdan ön bilgi almadan tekstil türünü ve yük miktarını algılayabilir hale gelmekte, böylece kurutma süreci hem enerji hem de zaman açısından optimize edilebilmektedir.

- **Kullanılan Algoritmalar:**
  - **Kümeleme (K-Means Clustering)**

Kümeleme, denetimsiz öğrenme yöntemlerinden biri olup, benzer özelliklere sahip veri noktalarını gruplandırarak verideki gizli yapıları ortaya çıkarmayı amaçlar. Bu yöntem, özellikle büyük ve etiketlenmemiş veri kümeleriyle çalışırken, verilerin içsel yapısını anlamak ve gruplamak için kullanılır.

K-means algoritması, veri noktalarını önceden belirlenen k sayıda kümeye ayırarak, her bir kümenin merkezini iteratif olarak günceller ve veri noktalarını en yakın merkeze atar. Bu süreç, kümeler arası varyansı maksimize etmeyi ve her küme içindeki veri noktalarının benzerliğini artırmayı hedefler. Ancak, algoritmanın başarısı, başlangıçta seçilen merkezlerin konumuna bağlıdır ve farklı başlangıç noktaları farklı sonuçlar doğurabilir (Ding & He, 2004).

Modelin kurulumu ve optimizasyonu için aşağıdaki hiperparametreler belirlenmiş ve uygulanmıştır:

- **Küme Sayısı (K) Belirleme:** Optimal küme sayısı (K) değeri, k ∈ [2,8] aralığında deneme yanılma yoluyla veya hedef sınıflara göre sabitlenmek yerine, Silhouette Analizi kullanılarak veri yapısının kendisinden türetilmiştir. Yapılan analizler sonucunda en uygun küme sayısı (K_{best}) değeri K = 7 olarak belirlenmiştir. Bu değer hem küme içi tutarlılığı hem de kümeler arası ayrımı en üst düzeye çıkaran sonucu temsil eder.
- **Mesafe Ölçütü:** Kümelerin merkezlerinin hesaplanmasında ve veri noktalarının en yakın merkeze atanmasında varsayılan olarak Öklid (Euclidean) Mesafesi kullanılmıştır.
- **İlklendirme Yöntemi:** Küme merkezlerinin başlangıç konumlarının seçimi için, kötü başlangıç noktalarının yol açabileceği yerel minimumlardan kaçınmayı sağlayan ve standart K-Means için en yaygın kabul gören yöntem olan k-means++ yöntemi kullanılmıştır (Scikit-learn kütüphanesinin varsayılanı). Bu yöntem, başlangıç merkezlerini birbirinden olabildiğince uzakta seçerek kümeleme kalitesini artırmayı hedefler.

Tablo 4. Kümeleme (K-Means) kümelerin değişkenler ile benzerlik performansı

Tahmin Edilen	Düzeltilmiş Rand Endeksi (ARI)
Giriş Nemi	0,278
Yük Miktarı	0,385
Kumaş Türü	0,259

- **Hiyerarşik Kümeleme**

Hiyerarşik kümeleme, veri noktaları arasındaki benzerlikleri kullanarak çok seviyeli bir küme yapısı oluşturan denetimsiz öğrenme algoritmalarındandır. Bu yöntem, özellikle küme sayısının önceden bilinmediği veya çok katmanlı örüntülerin var olduğu durumlarda tercih edilmektedir (Murtagh & Contreras, 2012).

İki temel yaklaşım mevcuttur: agglomeratif (birleştirici) ve divisive (bölücü). Agglomeratif yöntem, her veri noktasını başlangıçta ayrı bir küme olarak kabul eder ve benzerlik ölçütüne göre en yakın kümeleri aşamalı olarak birleştirir. Bu süreç, tüm veriler tek bir kümede toplanana kadar devam eder. Her bir birleşme adımı bir ağaç yapısı (dendrogram) ile görselleştirilebilir; bu yapı, farklı kesim noktalarından farklı sayıda küme elde edilmesini sağlar (Murtagh & Contreras, 2012).

Divisive yaklaşım ise ters yönde çalışır: tüm veriler tek bir küme olarak başlatılır ve bu küme, içindeki heterojenliği azaltmak üzere yine benzerlik ölçütlerine dayanarak alt kümelere bölünür. Bu yöntem daha az yaygın olmakla birlikte, bazı özel veri setlerinde daha başarılı olabilir (Murtagh & Contreras, 2012).

Modelin kurulumu ve optimizasyonu için aşağıdaki hiperparametreler kullanılmıştır:

- **Küme Sayısı (K):** Analiz, önceden belirlenmiş sabit bir küme sayısı olan K=7 üzerinden gerçekleştirilmiştir. Bu değer, elde edilen kümelerin, veri setindeki kategorik etiket sütunları (Giriş Nemi, Yük Miktarı, Kumaş Türü) ile karşılaştırılmasına olanak sağlamıştır.
- **Bağlantı Tipi (Linkage):** Kümeler arası uzaklığı hesaplamak ve birleştirme kriterini belirlemek için Ward bağlantı tipi kullanılmıştır.
- **Mesafe Ölçütü (Affinity/Metric):** İki veri noktası veya küme arasındaki benzerliği hesaplamak için varsayılan Öklid (Euclidean) Mesafesi kullanılmıştır.

Tablo 5. Hiyerarşik Kümeleme (Agglomerative Clustering) kümelerin değişkenler ile benzerlik performansı

Tahmin Edilen	Düzeltilmiş Rand Endeksi (ARI)
Giriş Nemi	0,211
Yük Miktarı	0,420
Kumaş Türü	0,246

- Kullanım Amacı: Farklı kumaş türlerini ve tekstilin ağırlığını otomatik sınıflandırma
- Modellerin Başarı Oranı: %21- %42 arasında değişmektedir.

3.4.1.3. Yapay Sinir Ağları (Artificial Neural Networks – ANN):

Yapay sinir ağları, çok katmanlı yapıları sayesinde karmaşık örüntüleri öğrenme kapasitesi ile çamaşır kurutma makinelerinde kullanılan sensör verilerinden tekstil türü ve yük miktarını tahmin etmede etkili bir çözüm sunmaktadır. Geleneksel makine öğrenmesi yöntemleri belirli özellik mühendisliği adımlarına ihtiyaç duyarken, yapay sinir ağları bu özellikleri doğrudan ham verilerden çıkarabilme yeteneğine sahiptir (Goodfellow ve ark., 2016). Bu özellik, pamuklu, sentetik ve karışık gibi farklı tekstil türlerinin sensör verilerinde oluşturduğu karmaşık varyasyonların daha hassas şekilde analiz edilmesini mümkün kılmaktadır.

Yapay sinir ağlarının temel yapı taşlarından biri olan Çok Katmanlı Algılayıcı (Multilayer Perceptron – MLP), özellikle tekstil tanıma ve yük miktarı tahmini gibi görevlerde başarıyla kullanılmaktadır. Bu model, iletkenlik, sıcaklık ve nem gibi sensör verileri ile tekstilin fiziksel özellikleri arasındaki doğrusal olmayan ilişkileri modelleyerek; kumaş türü, yük miktarı ve giriş nemi gibi parametreleri sınıflandırabilir. Derin yapılı MLP ağları, yeterli sayıda gizli katman ve nöron içerdiğinde yüksek genelleme yeteneği gösterebilir. Ayrıca eğitim sürecinde kullanılan geri yayılım (backpropagation) algoritması, ağ ağırlıklarının sürekli olarak optimize edilmesini sağlayarak modelin doğruluğunu artırmaktadır (Alom ve ark., 2019).

- **Kullanılan Algoritma:**
  - **Çok Katmanlı Algılayıcı (Multilayer Perceptron- MLP)**

MLP, yapay sinir ağlarının temel yapı taşlarından biri olup, doğrusal olmayan ilişkileri öğrenme kapasitesi sayesinde tekstil tanıma ve yük tahmini gibi problemler için etkili bir araçtır. MLP, giriş katmanına alınan sensör verilerini bir veya daha fazla gizli katmandan geçirerek işleyip, sonuçta hedef sınıfları (örneğin tekstil türü) veya sürekli değişkenleri (örneğin kg cinsinden yük miktarı) tahmin edebilir (Goodfellow ve ark., 2016).

Bu çalışmada, üç farklı sınıflandırma görevi (Nem, KG ve Tekstil Türü) için Standart Ölçekleyici kullanılarak ölçeklenmiş sensör verileri girdi olarak verilmiştir. Kullanılan MLP mimarisi ve eğitim parametreleri aşağıdaki gibidir:

- **Mimari:** Model, iki gizli katmandan oluşmaktadır. Bu katmanlarda sırasıyla 100 ve 50 nöron kullanılmıştır.
- **Aktivasyon:** Gizli katmanlarda varsayılan olarak ReLU (Rectified Linear Unit) fonksiyonu, çıkış katmanında ise (sınıflandırma problemi olduğu için) Softmax veya benzeri bir sınıflandırma aktivasyonu kullanılmıştır.
- **Optimizasyon:** Model, varsayılan olarak Adam (Adaptive Moment Estimation) algoritması ile optimize edilmiştir.
- **Eğitim:** Maksimum iterasyon sayısı 1000 olarak belirlenmiştir.

Tekstil kurutma makinelerinde yer alan iletkenlik, sıcaklık ve nem gibi çok değişkenli sensör verileri, farklı tekstil türlerinin fiziksel özelliklerine göre farklı tepkiler verir. Bu veriler, MLP'ye giriş olarak verildiğinde, ağ bu örüntüleri öğrenerek tekstilin pamuklu, sentetik veya karışık türde olup olmadığını yüksek doğrulukla sınıflandırabilir. Aynı zamanda, MLP modelleri regresyon problemi şeklinde formüle edilerek, tekstilin ağırlığını da sürekli bir değer olarak tahmin edebilir (LeCun ve ark., 2015).

MLP modellerinin avantajı, veri boyutu çok yüksek olmadığında eğitim sürecinin hızlı olması ve yapısının kolayca uyarlanabilir olmasıdır. Ancak, başarı oranı; ağ mimarisi (katman sayısı, nöron sayısı), aktivasyon fonksiyonu seçimi ve eğitim verisinin kalitesi gibi faktörlere doğrudan bağlıdır. Özellikle tekstil gibi fiziksel olarak karmaşık yapıların sınıflandırılmasında, iyi yapılandırılmış MLP modelleri, yüksek doğruluk ve genelleme başarısı gösterebilir (Alom ve ark., 2019).

Tablo 6. Çok Katmanlı Algılayıcı (MLP- Multilayer Perceptron) modellerinin performans sonuçları

Tahmin Edilen	Doğruluk (Accuracy)	Precision	Recall	F1 Skoru
Giriş Nemi	0,871	0,872	0,871	0,871
Yük Miktarı	0,941	0,942	0,941	0,941
Kumaş Türü	0,953	0,954	0,953	0,953

- Kullanım Amacı: Karmaşık tekstil türlerinin tespiti ve tekstilin yük miktarı tahmini

- Modelin Başarı Oranı: %87- %95 arasında değişmektedir

3.4.2. Model Değerlendirme ve Performans Analizi

Makine öğrenmesi modellerinin başarısını ölçmek ve en iyi performansı gösteren algoritmayı belirlemek için çeşitli metrikler kullanılmıştır. Bu değerlendirme sürecinde aşağıdaki temel kriterler esas alınmıştır:

- ❖ Doğruluk (Accuracy): Modelin doğru tahmin yapma oranını ölçmek için kullanılmıştır. Algoritmalar arasında doğruluk oranı %86- %95 arasında değişmiştir.
- ❖ Kesinlik (Precision): Kurutma süresi tahmininde kullanılan kumaş türü, yük miktarı ve nem seviyelerinin sınıflandırmasının ne kadar doğru yapıldığını belirler. Ortalama kesinlik oranı %87 olarak hesaplanmıştır.
- ❖ Duyarlılık (Recall): Modelin yanlış negatif oranlarını ölçerek, kaçırılan doğru tahminlerin miktarını belirler. En iyi duyarlılık oranı %95 olarak elde edilmiştir.
- ❖ F1-Skoru: Kesinlik ve duyarlılığın dengelenmiş bir ölçümünü sunarak, model performansını kapsamlı bir şekilde değerlendirmek için kullanılmıştır. En iyi model için %95 F1-skoru elde edilmiştir.

Model değerlendirmeleri sonucunda, yapay sinir ağları algoritması tabanlı MLP ve denetimli öğrenme tabanlı Karar Ağaçları algoritmalarının en yüksek başarı oranına sahip olduğu tespit edilmiştir. Özellikle, MLP modellerinde kumaş türü %95, yük miktarı tahmini %94 doğruluk oranına ulaşırken, karar ağaçları modellerinde giriş nem seviyesi sınıflandırmada %88 doğruluk oranı sağlamıştır. Bu bulgular, önerilen sistemin geleneksel kurutma makinelerine kıyasla daha verimli ve enerji tasarruflu çalışabileceğini göstermektedir.

Bundan sonraki aşamada, daha büyük veri setleri ile modelin test edilmesi ve gerçek zamanlı uygulamalar için entegrasyon çalışmalarına başlanması önerilmektedir.

4. BULGULAR VE TARTIŞMA

4.1. Kurutma Süresi ve Enerji Tüketimi Üzerine Etkiler

Önerilen makine öğrenmesi destekli kurutma sistemi, farklı tekstil türlerine göre kurutma süresini optimize ederek süreci daha verimli hale getirmiştir. Geleneksel kurutma makinelerinde belirlenen sabit süreler yerine, sensör verileri ve makine öğrenmesi algoritmaları kullanılarak anlık olarak güncellenen ve her çamaşır yüküne özel bir kurutma süresi hesaplanmıştır. Bu süreç, gereksiz uzun süreli çalışmayı engelleyerek hem zaman tasarrufu sağlamış hem de gereksiz enerji tüketimini azaltmıştır.

4.1.1. Farklı Tekstil Türlerinde Kurutma Süresi ve Enerji Verimliliği Karşılaştırması

Test edilen 2 kg'lık çamaşır yükleri için (pamuklu, sentetik ve karışık) hem kurutma süresi hem de enerji tüketimi analiz edilmiştir. Veriler, özel bir veri toplama sistemi ve harici wattmetre yardımıyla doğrulanmıştır. Ölçüm sonuçları aşağıdaki gibidir:

- **Pamuklu Kumaşlar:** Geleneksel pamuklu programında 120 dakika ve 0,889 kWh tüketim gerçekleşirken, makine öğrenmesi tabanlı programla bu değerler sırasıyla 90 dakika ve 0,672 kWh olarak ölçülmüştür. Bu da %25 zaman ve %24,4 enerji tasarrufu anlamına gelmektedir.
- **Sentetik Kumaşlar:** Geleneksel sentetik programında 95 dakika ve 0,708 kWh tüketim gerçekleşmiştir. Optimize edilmiş programda bu değerler 50 dakika ve 0,327 kWh düşmüştür. Zaman açısından %47,4, enerji açısından ise %53,8 oranında tasarruf sağlanmıştır.
- **Karışık Yükler:** Geleneksel mix programında 105 dakika ve 0,768 kWh tüketim ölçülmüş; optimize edilmiş programda ise 75 dakika ve 0,546 kWh tüketilmiştir. Bu da sırasıyla %28,6 zaman ve %28,9 enerji tasarrufu sağlamıştır.

Bu optimizasyon, özellikle yüksek hassasiyetli nem sensörlerinden elde edilen verilerin anlık analiz edilmesiyle mümkün olmuştur. Çamaşır kurutma makinesinin tambur içindeki nem sensörleri, her 30 saniyede bir güncellenen nem seviyelerine bağlı olarak kurutma süresini dinamik şekilde belirlemektedir. Bu sayede çamaşırın gereğinden fazla ısıya maruz kalması önlenmiş, kumaşın yapısı korunarak hem daha uzun ömürlü giysiler sağlanmış hem de enerji tasarrufu elde edilmiştir.

4.1.2. Nem Sensörleri ile Adaptif Kurutma Süresi Yönetimi

Geleneksel kurutma makineleri, genellikle önceden belirlenmiş süreler ile çalışırken, önerilen sistem sayesinde dinamik süre belirleme mümkün hale gelmiştir. Bunun temel bileşenleri şunlardır:

1. **Gerçek zamanlı nem sensörleri**: Nem seviyeleri anlık olarak ölçülerek gereksiz çalışmayı önler.
2. **Sıcaklık sensörleri entegrasyonu:** Sıcaklık değişimleri ile nem buharlaşma oranları arasındaki ilişki analiz edilerek en verimli kurutma profili oluşturulur.
3. **Makine öğrenmesi tabanlı adaptif süre belirleme:** Makine, önceki kurutma işlemlerinden öğrendiği verileri kullanarak her yeni yük için en iyi kurutma süresini tahmin eder.

Bu sayede, özellikle hassas kumaşların gereksiz uzun süre ısıya maruz kalması önlenmiş ve giysilerin yıpranma oranı azaltılmıştır.

4.2. Genel Değerlendirme

Geleneksel programlar ile yapılmış testlerin sonucunda, optimize edilmiş sistemin şu avantajları sağladığı gözlemlenmiştir:

1. Kurutma süresinde ortalama %33 azalma
2. Daha kısa kurutma süresi sayesinde elektrik tüketiminde azalma
3. Kumaşların daha uzun ömürlü olması ve renk solmasının önlenmesi

4.2.1. Geleneksel ve Akıllı Sistem Arasındaki Farklar

Geleneksel kurutma makineleri genellikle sabit süre ve sıcaklık değerleri ile çalışırken, makine öğrenmesi destekli sistem dinamik ayarlamalar yaparak gereksiz enerji kullanımını engellemektedir.

Tablo 7. Kurutma Makinesi Karşılaştırması

Özellik	**Geleneksel Kurutma Makinesi**	**Makine Öğrenmesi Destekli Kurutma**
Sabit Çalışma Süresi	Var (Süre manuel belirleniyor)	Yok (Sensör verileri ile dinamik ayarlanıyor)
İletkenlik Sensörü Kullanımı	Sınırlı (Sadece belirli modellerde mevcut)	Var (Anlık veri analizi yapılıyor)
Sıcaklık Optimizasyonu	Yok (Sabit sıcaklıkta çalışır)	Var (Kumaş türüne göre sıcaklık değişiyor)
Enerji Verimliliği	Düşük (Sabit süre boyunca çalıştığı için fazla enerji harcar)	Yüksek (Sadece gerektiği kadar çalışarak enerji tasarrufu sağlar)

4.3. Model Doğruluk Oranları ve Sınıflandırma Başarıları

Önerilen makine öğrenmesi tabanlı sistem, çamaşır kurutma sürecinin farklı aşamalarında kritik kararlar verebilmek için çeşitli sınıflandırma ve tahmin algoritmaları kullanmıştır. Sistemin temel amacı, farklı kumaş türlerini doğru şekilde tanımlamak, nem seviyelerini ve yük miktarını doğru tahmin etmek bunlara bağlı olarak kurutma süresini optimize etmektir.

Bu hedeflere ulaşabilmek için çamaşır yüküne ait sensör verileri, farklı makine öğrenmesi ve yapay sinir ağları modelleri ile analiz edilmiş ve aşağıdaki bileşenler değerlendirilmiştir:

1. Kumaş Türü Tanımlama (Pamuk, Sentetik, Karışık vb.)
2. Giriş Nem Seviyesi Tahmini (Kurutma süresi belirlemede kritik rol oynar)
3. Yük Miktarı Tahmini (Enerji tasarrufu ve zaman yönetimi için önemlidir)

Bu üç temel hedef doğrultusunda eğitilen modellerin doğruluk oranları aşağıda detaylandırılmıştır.

4.3.1. Kumaş Türü Tanımlama Başarı Oranları

Farklı tekstil türlerinin doğru şekilde tanımlanması, kurutma sıcaklığı ve süresinin en iyi şekilde ayarlanması açısından büyük önem taşımaktadır. Yapılan testlerde Yapay Sinir Ağları (MLP) modelinin en yüksek doğruluk oranına ulaştığı gözlemlenmiştir.
Özellikle pamuk ve sentetik kumaşlar, dokularındaki farklılıklar ve ısı emme kapasitelerinden dolayı yüksek doğrulukla tanımlanabilmiştir. Karışık kumaşlar, yapı olarak daha değişken özelliklere sahip olduklarından dolayı diğer kumaşlara göre daha düşük doğruluk oranına sahip olmuştur.

Tablo 8. Kumaş Türü Tanımlama Başarı Oranları

Makine Öğrenmesi Algoritması	Kumaş Tanıma Doğruluk Oranı (%)
Karar Ağaçları (Decision Trees)	%89
Destek Vektör Makineleri (SVM)	%90
Yapay Sinir Ağları (MLP)	%95

4.3.2. Giriş Nem Seviyesi Tahmininde Model Performansı

Kurutma işlemi sırasında çamaşırların gerçek zamanlı giriş nem seviyesi, kurutma süresinin belirlenmesi açısından kritik bir değişkendir. Sistem, nem sensörlerinden gelen verileri analiz ederek çamaşırların ne zaman tamamen kuruduğunu tahmin etmeye çalışmıştır.
Farklı algoritmaların giriş nem seviyesi tahmini doğruluk oranları şu şekildedir:

Tablo 9. Giriş Nem Seviyesi Tahmininde Model

Makine Öğrenmesi Algoritması	Giriş Nem Seviyesi Tahmini Doğruluk Oranı (%)
Yapay Sinir Ağları (MLP)	%86
Destek Vektör Makineleri (SVM)	%87
Karar Ağaçları (Decision Trees)	%88

Özellikle Karar Ağaçları modeli, nem sensörlerinden gelen zaman serisi verilerini analiz ederek en yüksek doğruluk oranına ulaşmıştır. Bu model sayesinde nem değişim oranları tahmin edilmiş ve çamaşırların gerçek kuruluk durumları en hassas şekilde belirlenmiştir.

4.3.3. Yük Miktarı Tahmininde Modelin Performansı

Makinenin her yük için en uygun kurutma süresini belirlemesi hem enerji tasarrufu hem de çamaşırların aşırı kurumasını önleme açısından kritik bir faktördür. Yük tahmini için farklı algoritmalar kullanılmış ve başarı oranları aşağıdaki şekilde hesaplanmıştır:

Tablo 10. Yük Miktarı Tahmini

Makine Öğrenmesi Algoritması	Yük Miktarı Tahmin Doğruluk Oranı (%)
Destek Vektör Makineleri (SVM)	%90
Karar Ağaçları (Decision Trees)	%92
Yapay Sinir Ağları (MLP)	%94

4.3.4. Modelin Genel Başarı Değerlendirmesi

Tüm modellerin genel doğruluk performansları aşağıdaki şekilde özetlenmiştir:

Tablo 11. Modelin Genel Başarısı

Tahmin Edilen Özellik	En Başarılı Algoritma	En Yüksek Doğruluk Oranı (%)
Kumaş Türü Tanımlama	MLP(Multilayer Perceptron)	%95
Giriş Nem Seviyesi Tahmini	Karar Ağaçları	%88
Yük Miktarı Tahmini	MLP(Multilayer Perceptron)	%94

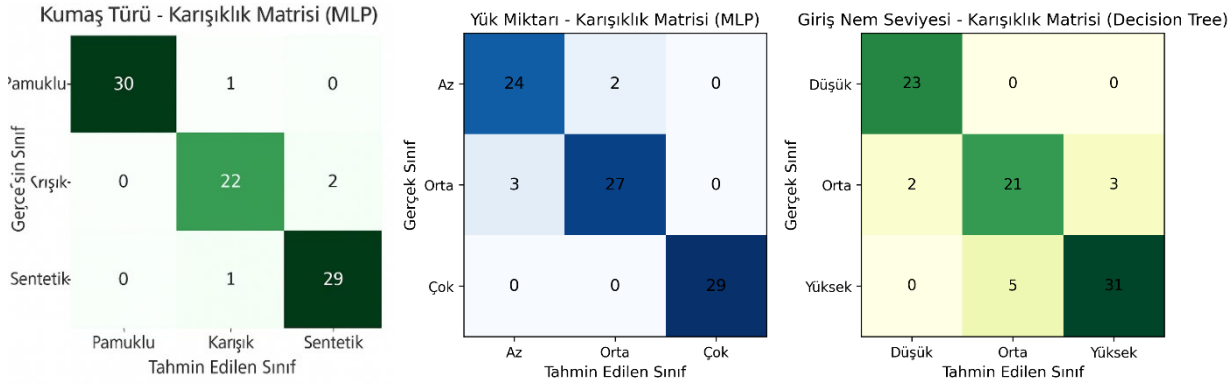

Şekil 2. Modelin Genel Başarısının Konfüzyon Matrisleri ile Gösterimi

5. SONUÇ VE ÖNERİLER

Bu çalışmada, çamaşır kurutma makinelerinde sensör verileri kullanılarak tekstil özelliklerinin algılanması ve kurutma sürecinin optimize edilmesi ele alınmıştır. Önerilen sistem, makine öğrenmesi ve yapay sinir ağları algoritmaları kullanarak, farklı kumaş türlerini tanımlayabilen, nem seviyelerini doğru tahmin edebilen ve kurutma süresini en uygun şekilde belirleyebilen akıllı bir kurutma yönetim modeli geliştirmiştir. Yapılan deneysel çalışmalar ve model performans analizleri sonucunda, önerilen sistemin kurutma süresi, enerji tüketimi ve kullanıcı deneyimi açısından önemli iyileştirmeler sağladığı tespit edilmiştir.İ

5.1. Çalışmanın Temel Bulguları

Geleneksel yöntemlerle karşılaştırıldığında, makine öğrenmesi destekli sistemin kurutma süresini ortalama %33 oranında azalttığı gözlemlenmiştir. Özellikle nem sensörleri ve kumaş türü tanıma sisteminin entegre edilmesi sayesinde, kurutma süreci dinamik ve optimize edilmiş bir hale getirilmiştir.

5.2. Çalışmanın Katkıları ve Öneriler

Bu çalışma, çamaşır kurutma makinelerinde yapay zekâ ve veri analitiğinin kullanımına yönelik önemli katkılar sağlamıştır. Önerilen model sayesinde çamaşır kurutma sürecinin daha akıllı, verimli ve sürdürülebilir hale getirilmesi sağlanmıştır.

5.2.1. Endüstriyel Katkılar

Bu çalışma, geleneksel çamaşır kurutma makinelerinin enerji verimliliğini iyileştirmek amacıyla geliştirilen yapay zekâ tabanlı bir sistem önererek endüstriyel anlamda önemli bir katkı sunmaktadır. Sistem, çamaşır yükü özelliklerini algılayarak gereksiz enerji tüketimini azaltmakta ve her yüke özel optimize edilmiş kurutma stratejileri sunmaktadır. Geliştirilen model, yalnızca ev tipi kurutma makineleri için değil, aynı zamanda endüstriyel çamaşırhaneler, oteller ve hizmet sektöründeki büyük ölçekli çamaşırhane sistemlerinde de uygulanabilir niteliktedir. Böylece, yüksek hacimli ve çeşitli tekstil yükleriyle çalışan profesyonel ortamlar için de sürdürülebilir ve verimli bir çözüm ortaya konmuştur.

5.2.2. Akademik Katkılar

Araştırma, makine öğrenmesi ve yapay sinir ağı tabanlı yöntemlerin tekstil kurutma süreçlerinde nasıl uygulanabileceğini göstererek enerji yönetimi ve tekstil teknolojileri alanında önemli akademik katkılar sunmaktadır.

Özellikle sensör verilerine dayalı veri işleme teknikleri ve öznitelik çıkarımı süreçleri literatürdeki eksik alanlara yenilikçi bir perspektif kazandırmaktadır. Bu kapsamda, farklı tekstil türlerinin nem ve sıcaklık tepkilerini anlamlandırma sürecine yapay zekâ ile yaklaşılması, klasik yöntemlerin ötesine geçerek akademik alanda modelleme ve sınıflandırma çalışmaları için örnek teşkil etmektedir.

5.2.3. Gelecek Çalışmalar İçin Öneriler

Gelecek çalışmalarda, modelin genellenebilirliğini artırmak amacıyla daha geniş ve çeşitli bir veri setiyle doğruluk oranlarının iyileştirilmesi hedeflenebilir. Ayrıca, farklı kumaş türleri ve karışımları için daha ayrıntılı öznitelik çıkarımı yapılarak modellerin hassasiyeti artırılabilir. Bununla birlikte, makine öğrenmesi modellerinin bulut tabanlı altyapılara entegre edilmesi sayesinde hem uzaktan veri takibi hem de gerçek zamanlı güncellemeler mümkün hale gelebilir. Böylece, sistemin öğrenme yeteneği sürekli gelişerek farklı kullanıcı senaryolarına uyum sağlayabilecek daha esnek ve akıllı bir yapı oluşturulabilir.

5.3. Genel Değerlendirme

Bu çalışmada geliştirilen sistem, çamaşır kurutma makinelerinde yapay zekâ destekli bir dönüşüm sağlayarak kurutma sürecinin daha akıllı, hızlı ve enerji verimli hale getirilmesini sağlamıştır.

Sonuç olarak, geleneksel kurutma makineleri yerine yapay zekâ tabanlı sistemlerin tercih edilmesi, çevre dostu, sürdürülebilir ve enerji verimli bir teknolojiye geçişi hızlandıracaktır. Bu model, gelecekte akıllı ev sistemlerine entegre edilebilir, IoT (Nesnelerin İnterneti) desteği ile uzaktan kontrol edilebilir hale getirilebilir ve enerji tüketimini daha da optimize edecek yeni yöntemlerle geliştirilebilir.

Bu bulgular ışığında, yapay zekâ tabanlı çamaşır kurutma makinelerinin endüstriyel ve bireysel kullanıma yönelik büyük avantajlar sunduğu ortaya konmuştur.

Yazarların Katkısı
Bu çalışmada birinci yazar; fikir üretimi, araştırma süreci, veri toplama, analiz, bilgisayar ortamının hazırlanması, kaynak taraması ve makalenin yazımı aşamalarında aktif rol almıştır. İkinci yazar ise, düzeltme, gözden geçirme, veri analizi ve yorumlama süreçlerine katkı sağlamıştır.

Teşekkür

Bu çalışmanın gerçekleştirilmesinde sundukları kıymetli katkılar için Beko A.Ş. Araştırma ve Geliştirme Merkezi'ne teşekkür ederim. Sensör Teknolojileri biriminde görev yaptığım süreçte, hem teknik bilgi birikimim hem de laboratuvar altyapısına erişimim bu araştırmanın sağlıklı bir şekilde yürütülmesini mümkün kılmıştır. Başta, araştırmanın yönlendirilmesinde bilimsel ve yönetsel katkılarıyla büyük destek sağlayan değerli yöneticim Sayın Dr. Bekir Özyurt'a; ayrıca deneysel tasarım, veri toplama ve analiz süreçlerinde birlikte çalıştığımız ekip arkadaşlarım Sergen Erkan Arslan ve Aykut Sinekoğlu'na içtenlikle teşekkür ederim. Çalışmada kullanılan prototip çamaşır kurutma makinesinin temini ve testlerin gerçekleştirilmesi için sağlanan laboratuvar imkânları dolayısıyla da Beko A.Ş.'ye özel bir teşekkürü borç bilirim.

Çıkar Çatışması Beyanı
Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı
Yapılan çalışmada araştırma ve yayın etiğine uyulmuştur.

KAYNAKÇA

Ala, D. M., & Bakıcı, G. G. (2016). Ev tipi yıkama ve kurutma işlemlerinin denim görünümlü örme kumaşların kalınlık ve hava geçirgenlik özelliklerine etkisi. *Tekstil ve Mühendis*, *23*(104), 263–270.

Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., ... & Asari, V. K. (2019). The history began from AlexNet: A comprehensive survey on deep learning approaches. *arXiv preprint arXiv:1803.01164*.

Alom, M. Z., Yakopcic, C., Taha, T. M., & Asari, V. K. (2019). A state-of-the-art survey on deep learning theory and architectures. Electronics, 8(3), 292. https://doi.org/10.3390/electronics8030292

Beko. (2023). *Çamaşır kurutma makinesi kullanım kılavuzu*.

Bishop, C. M. (2006). *Pattern recognition and machine learning*. Springer.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, *20*, 273–297.

Ding, C., & He, X. (2004). K-means clustering via principal component analysis. In *Proceedings of the 21st International Conference on Machine Learning (ICML)*.

Ersöz, F., & Çınar, Y. (2021). Veri madenciliği ve makine öğrenimi yaklaşımlarının karşılaştırılması: Tekstil sektöründe bir uygulama. *Avrupa Bilim ve Teknoloji Dergisi*, (29), 397–414.

Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction*. Springer.

Haykin, S. (1994). *Neural networks: A comprehensive foundation*. Prentice Hall PTR.

Jasiūnas, Ž., Julião, T., Cecílio, J., da Graça, G. C., & Ferreira, P. M. (2025). A soft sensor to assess the energy performance of laundry washing machines. *Applied Energy*, 383, 125349. https://doi.org/10.1016/j.apenergy.2025.125349

LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, *521*(7553), 436–444. https://doi.org/10.1038/nature14539

Loh, W.-Y. (2011). Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, *1*(1), 14–23.

Mitchell, T. M. (1997). *Machine learning* (Vol. 1, No. 9). McGraw-Hill.

Murtagh, F., & Contreras, P. (2012). Algorithms for hierarchical clustering: An overview. *WIREs Data Mining and Knowledge Discovery*, *2*(1), 86–97. https://doi.org/10.1002/widm.53

Orperia, F. O., Abalos, M. S., Agustin, C. A., Gallo, F., Alburo, A. L., & Ramos, R. S. (2025). Project SAMPAY: A Sensor-Activated Machine for Cloth-Placing and Drying. https://doi.org/10.58806/ijirme.2025.v4i3n07

Rokach, L., & Maimon, O. (2005). Decision trees. In *Data mining and knowledge discovery handbook* (pp. 165–192). Springer.

T.C. Millî Eğitim Bakanlığı. (t.y.). *Elektrik-elektronik teknolojisi: Kurutucular*. Mesleki Eğitim ve Öğretim Sisteminin Güçlendirilmesi Projesi (MEGEP).

T.C. Sanayi ve Teknoloji Bakanlığı. (2022). *Ev tipi çamaşır kurutma makineleri ile ilgili çevreye duyarlı tasarım gereklilikleri*. *Resmî Gazete*, Sayı: 31903.

Taur, K. H., Deng, X. Y., Chou, M. H., Chen, J. W., Lee, Y. H., & Wang, W. J. (2019, November). A study on machine learning approaches for predicting and analyzing the drying process in the textile industry. In *2019 International Automatic Control Conference (CACS)* (pp. 1-5). IEEE.

Tas, O., Yakak, E., & Ugurlu, U. (2018). Using artificial neural network and a statistical method for the estimation of Euro/Turkish Lira exchange rate. *PressAcademia Procedia (PAP)*, *7*, 414–417.

TMMOB Makina Mühendisleri Odası. (2013). Isı pompalı tekstil kurutma makinelerinde kurutma süresi ve enerji tüketimi. *Sanayi ve Teknoloji Dergisi*, *556*, 45–52.

Yılmazel, Ö., Afşar, A., & Yılmazel, S. (2020). Konut fiyat tahmininde yapay sinir ağları yönteminin kullanımı. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, *21*(1), 1–21.

Zhang, Y., Bengio, S., & Singer, Y. (2020). Are all layers created equal? An empirical study of normalization in deep learning. In *Proceedings of the 37th International Conference on Machine Learning (ICML)*.