

**T.C. İSTANBUL KÜLTÜR ÜNİVERSİTESİ  
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ KULLANARAK TİCARİ BİNALARDA ENERJİ  
TÜKETİMİNİN AZALTILMASI**

**DOKTORA TEZİ**

**Mustafa Çakır**

**(1009112001)**

**Anabilim dalı : İNŞAAT MÜHENDİSLİĞİ**

**Programı : PROJE YÖNETİMİ**

**Tez Danışmanı : Doç.Dr. Akhan AKBULUT**

**OCAK 2022**

**T.C. İSTANBUL KÜLTÜR ÜNİVERSİTESİ**  
**LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**

**MAKİNE ÖĞRENMESİ KULLANARAK TİCARİ BİNALARDA ENERJİ**  
**TÜKETİMİNİN AZALTILMASI**

**DOKTORA TEZİ**

**Mustafa Çakır**

**(1009112001)**

**Anabilim dalı : İNŞAAT MÜHENDİSLİĞİ**

**Programı : PROJE YÖNETİMİ**

**Tez Danışmanı : Doç.Dr. Akhan AKBULUT**  
**Jüri Üyeleri : Prof. Dr. Özgür Koray ŞAHİNGÖZ**  
**Prof. Dr. Ahmet Murat TÜRK**  
**Doç. Dr. Muhammed Ali AYDIN**  
**Dr. Öğr. Üyesi Mehmet Nurettin UĞURAL**

**OCAK 2022**

## ÖNSÖZ

İstanbul Kültür Üniversitesi, Lisansüstü Eğitim Enstitüsü, İnşaat Mühendisliği Anabilim Dalı, Proje Yönetiminde tezi olarak hazırlanan bu çalışmanın konusu; Makine Öğrenmesi Kullanarak Ticari Binalarda Enerji Tüketiminin Azaltılmasıdır.

Bu doktora tezinin hazırlanmasında bana yol gösteren, tez çalışmamın planlanmasında, geliştirilmesinde her zaman yanımda olan, akademik tecrübesinden fazlasıyla yararlandığım tez danışmanım Sayın Doç. Dr. Akhan AKBULUT'a; teorik bilgi birikimi ve tecrübesiyle desteğini esirgemeyen Sayın Dr. Öğr. Üyesi Fatma Patlar Akbulut'a; deneysel çalışmalarda verdiği destekten dolayı Beatriz Monedero Orenes'e ve jüri üyelerine sonsuz teşekkür ederim.

Manevi desteğiyle yanımda olan, yol arkadaşım, sevgili eşim Didem'e; çocuğu olmaktan her zaman gurur duyduğum anneme ve babama; ayrıca isimlerini saymadığım tezimde katkısı bulunan tüm dostlarıma, çalışma arkadaşlarıma destek ve anlayışlarından ötürü teşekkür ederim.

Ocak 2022

MUSTAFA ÇAKIR

## İÇİNDEKİLER

ÖNSÖZ .....	i
İÇİNDEKİLER.....	ii
KISALTMALAR .....	iv
TABLO LİSTESİ .....	v
ŞEKİL LİSTESİ.....	vi
KISA ÖZET .....	viii
ABSTRACT .....	ix
1. GİRİŞ .....	1
1.1. Araştırmanın Konusu.....	1
1.2. Araştırmanın Amacı.....	1
2. ARAŞTIRMANIN KAVRAMSAL ÇERÇEVESİ .....	6
2.1. HVAC Sistemleri.....	6
2.2. HVAC Modelleme Teknikleri .....	8
2.2.1. Beyaz Kutu Modelleme Tekniği .....	8
2.2.2. Kara Kutu Modelleme Tekniği .....	8
2.2.3. Gri Kutu Modelleme Tekniği .....	9
2.3. Isıl Konfor .....	10
2.4. Enerji Tasarrufu Yöntemleri.....	15
2.5. Derin Öğrenme .....	16
2.6. Yapay Öğrenme ile Termal Konforun Artırılması .....	23
2.7. Yapay Öğrenme ile Enerji Tasarrufu Sağlanması .....	32
3. YÖNTEM.....	47
3.1. Veriseti .....	51
3.2. Verisetinin Önışlemesi.....	56
3.2.1. Aykırı Verilerin Çıkarılması .....	57
3.2.2. Ölçeklendirme.....	59
3.2.3. Dönüştürme .....	60
3.2.4. Örneklem Oluşturma .....	63
3.3. Model Geliştirme .....	63
3.4. Modelin Değerlendirilmesi .....	75
3.4.1. Tutarlılık.....	76
3.4.2. Kesinlik .....	76
3.4.3. Duyarlılık.....	76
3.4.4. F1 Puanı .....	77

3.4.5. ROC – AUC .....	77
4. SONUÇLAR .....	78
5. TARTIŞMA VE ÖNERİLER.....	82
6. SONUÇ .....	87
KAYNAKLAR.....	89
EK-1 (ÖRNEK VERİ SETİNDEKİ DEĞİŞKENLER VE AÇIKLAMALARI) .....	99



## KISALTMALAR

HVAC	: Isıtma, Havalandırma ve Soğutma
PMV	: Ortalama Isıl Duyum
PPD	: Tahmin edilen Memnuniyetsizlik Oranı
ASHRAE	: Amerikan Isıtma, Soğutma, Dondurma ve İklimlendirme Mühendisleri Topluluğu
SET	: Standart Etkin Sıcaklık
ANN	: Yapay Sinir Ağları
ML	: Yapay Öğrenme
DL	: Derin Öğrenme
SNN	: Başaklanmış Yapay Sinir Ağları
DNN	: Derin Sinir Ağları
CNN	: Evrişimli Sinir Ağları
SVM	: Destek Vektör Makineleri
RF	: Rassal Orman
LR	: Lojistik Regresyon
kNN	: k En yakın Komşu
GPU	: Grafik İşlemci

## TABLO LİSTESİ

Tablo 1.1. Tezdeki araştırma soruları ve motivasyonları .....	4
Tablo 2.1. Tipik takımlar için giysi izolasyon değerleri (Standart, ASHRAE. 2017) .	13
Tablo 2.2. Tipik ofis aktiviteleri için hareketlilik seviyesi (Standart, ASHRAE. 2017)	14
Tablo 3.1. Girdi değişkenleri ve açıklamaları .....	52
Tablo 3.2. Sayısal girdi değişkenlerinin verisetinde aldığı en düşük, en yüksek ve ortalama değerler .....	53
Tablo 3.3. Arama yapılan uzaydaki üst değişkenler ve alabilecekleri değerler.....	66
Tablo 3.4. DNN ve CNN modelleri için Bayesian arama algoritması tarafından seçilen üst değişkenler.....	72
Tablo 5.1. Farklı yöntemlerin ürettiği sonuçların karşılaştırması.....	82



## ŞEKİL LİSTESİ

Şekil 2.1. Tek ortamda çalışan HVAC sisteminin bileşenleri.....	7
Şekil 2.2. HVAC sisteminde kullanılan veri güdümlü modellerin sınıflandırılması .....	9
Şekil 2.3. İnsan termal konforuna etki eden faktörler .....	11
Şekil 2.4. PMV ve termal hissiyat.....	12
Şekil 2.5. Yapay Öğrenme Sınıflandırılması: .....	16
Şekil 2.6. İnsan nöronu ve yapay nöronun karşılaştırılması (Magoulès ve Zhao, 2016).....	17
Şekil 2.7. ReLU fonksiyonunun grafiksel gösterimi .....	19
Şekil 2.8. Softmax fonksiyonunun grafiksel gösterimi .....	19
Şekil 2.9. Tek katmanlı yapay sinir ağı.....	20
Şekil 2.10. Çok katmanlı yapay sinir ağı .....	20
Şekil 2.11. Yapay sinir ağı eğitim akış şeması.....	21
Şekil 2.12. Evrimsel yapay sinir ağlarının genel mimarisi.....	23
Şekil 3.1. Sistemik eşleme çalışmasında izlenen yöntem .....	47
Şekil 3.2. İncelenen çalışmalarda kullanılan akıllı yöntemler .....	48
Şekil 3.3. İncelenen çalışmalarda kullanılan veri toplama yöntemleri .....	48
Şekil 3.4. SMS çalışmasının bulgularının balon grafiği .....	49
Şekil 3.5. Veriye dayalı tahmin problemleri için metodoloji. Noktalı şekiller, metodolojideki her bir soru için çalışmamızdaki cevaplardır. ....	50
Şekil 3.6. Değişkenlerdeki boş (null) değerleri gösteren ısı haritası. Açık renk alanlar boş değerleri ifade etmektedir.....	52
Şekil 3.7. Verisetinde bulunan binaların kullanım amaçları ve o binalarda kullanılan soğutma yöntemleri.....	54
Şekil 3.8. Değişkenlerin korelasyon haritası .....	55
Şekil 3.9. Termal hissiyatın verisetindeki dağılımı .....	55
Şekil 3.10. Veri hazırlığı aşamaları ve genel süreçteki yeri.....	56
Şekil 3.11. Verisetindeki değişkenlerin Q-Q grafiği .....	57
Şekil 3.12. Değişken dağılımları.....	58
Şekil 3.13. Değişkenlerdeki aykırı değerlerin görülebileceği kutu grafiği .....	59
Şekil 3.14. Değişkenlerin farklı dönüşüm yöntemleri sonrasındaki dağılımları .....	62
Şekil 3.15. Model oluşturma süreci .....	64
Şekil 3.16. Bayesian arama algoritması akış şeması.....	67
Şekil 3.17. Bayesian adımlarında DNN'de elde edilen tutarlılık değeri.....	68
Şekil 3.18. Bayesian üst değişken tarama alanı: parça büyüklüğü ve öğrenme oranı .....	68
Şekil 3.19. Öğrenme oranı, ağırlık başlatıcı ve ağırlık optimizasyon algoritması ilişkisi.....	69
Şekil 3.20. Nöron sayısı, ağırlık başlatıcı ve ağırlık optimizasyon algoritması ilişkisi .....	69
Şekil 3.21. Bayesian adımlarında CNN'de elde edilen tutarlılık değeri.....	70
Şekil 3.22. DNN Modeli Mimarisi.....	71
Şekil 3.23. CNN Modeli Mimarisi.....	72
Şekil 3.24. DNN eğitim ilerlem grafiği.....	73
Şekil 3.25. Çapraz doğrulama.....	74
Şekil 3.26. Hata matrisi örneği .....	76
Şekil 4.1. En iyi sonucu üreten DNN modelinin hata matrisi .....	79
Şekil 4.2. Önerilen DNN modelinin ROC eğrisi ve AUC değerleri.....	80
Şekil 4.3. En iyi sonucu üreten CNN modelinin hata matrisi .....	81
Şekil 4.4. Önerilen CNN modelinin ROC eğrisi ve AUC değerleri.....	81

Şekil 5.1. Aynı veriseti ile farklı algoritmaların değerlendirme metriklerinin karşılaştırılması .....	83
Şekil 5.2. Bazı çevresel ve kişisel değişkenlerin ısı hissiyat ile olan ilişkisi.....	84
Şekil 5.3. Herhangi bir veri işleme olmadan önerilen DNN modelinin ROC grafiği..	85
Şekil 5.4. Isı hissiyatın cinsiyete göre histogramı .....	85
Şekil 5.5. Yaşın ısı hissiyat ile ilişkisini gösteren violon grafiği.....	86



Enstitü : Lisansüstü Eğitim Enstitüsü  
Dalı : İnşaat Mühendisliği  
Programı : Proje Yönetimi  
Tez Danışmanı : Doç. Dr. Akhan AKBULUT  
Tez Türü ve Tarihi : Doktora Tezi, Ocak 2022

## KISA ÖZET

### MAKİNE ÖĞRENMESİ KULLANILAN TİCARİ BİNALARDA ENERJİ TÜKETİMİNİN AZALTILMASI

Mustafa ÇAKIR

Bu çalışmanın amacı, yüksek nüfuslu binalarda, ısıtma havalandırma ve iklimlendirme (HVAC) sisteminin plansız ve gereksiz çalışması nedeniyle enerji tüketimini azaltırken, aynı zamanda bina sakinlerinin termal konforunu da azaltan iç ortam termal konfor seviyesini arttırmaktır. Bilgisayar desteği sayesinde herkes için uygun ortam koşulları bulunarak enerji tüketimi azaltılmaktadır. Bu amaca ulaşmak için de günümüzde yapay zeka uygulamalarında sıklıkla kullanılan yapay öğrenme yöntemlerine başvurulmuştur. Tezin temel katkısı, bina tipi, iklim bölgesi veya bir binanın ısıtma ve/veya havalandırma yönteminden bağımsız olarak yüksek derecede tutarlılıkla termal hissiyatı tahmin etmek için bir derin sinir ağı tasarlamak ve değerlendirmektir. Önerilen modelin eğitimde çeşitli üniversiteler tarafından derlenen 1995, 2015 yılları arasında gerçekleştirilmiş olan 66 çalışmadan toplanan verilerden oluşturulmuş olan American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE)'nin Küresel Termal Konfor Veritabanı kullanılmıştır. Önerilen modelin üst değişken ayarlama süreci, Bayes stratejisi kullanılarak optimize edilmiştir. Yapılan deneyler önerilen yöntemin geleneksel ortalama ısıl duyum (PMV) %40 ve diğer sığ ve derin ağırlara göre %4 daha yüksek tutarlılıkla tahmin yürütebildiğini göstermiştir.

Anahtar Kelimeler: HVAC, ısı hissiyat tahmini, yapay öğrenme, derin öğrenme

**University** : İstanbul Kültür University  
**Institute** : Institute of Graduate Education  
**Department** : Civil Engineering  
**Programme** : Project Management  
**Thesis Supervisor** : Assoc. Prof. Dr. Akhan AKBULUT  
**Degree Awarded and Date** : PhD, January 2022

## **ABSTRACT**

### **REDUCING ENERGY CONSUMPTION IN COMMERCIAL BUILDINGS USING MACHINE LEARNING**

**Mustafa ÇAKIR**

The purpose of this study is to increase the indoor thermal comfort level while reducing the energy consumption in high-population buildings due to unplanned and unneeded operation of heating ventilation and air-conditioning (HVAC) system which also decreases the thermal comfort of the occupants. Energy consumption can be reduced by finding suitable environmental conditions for everyone by taking advantage of computer support. In order to achieve this goal, machine learning methods, which are frequently used in decision making process these days, have been used. The main contribution of the thesis is to design and evaluate a deep neural network for predicting thermal sensations with a high degree of accuracy regardless of building type, climate zone, or a building's heating and/or ventilation method. The Global Comfort Database of American Society of Heating, Refrigerating and Air-Conditioning Engineers (ASHRAE) which the data was collected from 66 different studies conducted by different universities starting from 1995 till 2015 was used for the training of the model. The hyperparameter-tuning process of the proposed model is optimized using the Bayesian strategy. Experiments showed that the proposed method can predict with 40% higher accuracy than conventional Predicted Mean Vote (PMV) method and 4% higher than other shallow and deep networks.

**Key words:** HVAC, thermal sensation prediction, machine learning, deep learning

## 1. GİRİŞ

### 1.1. Araştırmanın Konusu

Araştırma; yapay öğrenme yöntemlerinden biri olan derin öğrenme kullanılarak kapalı bir ortamda bulunanların ısı hissiyatlarının geleneksel model tabanlı yöntemlere ya da diğer yapay zeka yöntemlerine göre daha iyi tahmin edilebileceğini ispat etmeyi hedeflemektedir. Böylelikle ihtiyaç dışı Isıtma, Havalandırma ve Soğutma (HVAC) kullanımından oluşacak olan fazla enerji tüketiminin önüne geçilebilecektir. Bunu başarmak için de HVAC sistemlerinin nasıl çalıştığı ve nasıl kontrol edildiği, ısı hissiyatın nasıl tanımladığı, enerji tasarrufunun nasıl sağlanabileceği, yapay zeka ve keşfedildiği günden bu yana hangi yapay zeka yöntemlerinin ısı hissiyatın hesaplanmasında ve HVAC kaynaklı enerji tüketiminin azaltılmasında nasıl kullanıldığına dair geniş çaplı bir araştırma yapılmıştır. Daha sonra da farklı araştırmalarda kullanılmak üzere toplanmış farklı veri setlerinin birleşiminden oluşan bir veri tabanı kullanılarak çeşitli deneyler yapılarak, en iyi sonucu üreten model bulunmuştur. Son olarak da oluşturulan model önceden kullanılan yapa zeka yöntemleri ve geleneksel PMV ile karşılaştırılmıştır.

### 1.2. Araştırmanın Amacı

Günümüzde çoğu insan, zamanının %90'ından fazlasını kapalı ortamlarda geçirdiği için verimli enerji ile çalışan, doğru şekilde çalışan ısıtma, havalandırma ve iklimlendirme (Heating, Ventilation and Air Conditioning – HVAC) sistemleri önemli rol oynamaktadır (Lu vd. 2012). Kapalı ortam hava kalitesi hepimizi doğrudan etkiler. Dünya çapında birçok ülkede astım hastalığı ve binalardaki hava kalitesi memnuniyetsizliği hızla artmaktadır. Bu durumun sebebi ve etkileri oldukça karmaşıktır. Yang ve ark. yapmış olduğu çalışmada, bağıl nemin %50'den az olduğu ortamlarda enflüanza virüslerinin gelişebileceği göstermiştir (Yang vd. 2012). David Peter Wyon'un yaptığı bir araştırmaya göre, iç ortam kötü hava koşulları, baş ağrısı ve konsantrasyon kaybı gibi genel negatif etkiler sebebi ile çalışanların performansının %6 ila %9 arasında düşmesine sebep olmaktadır (Wyon, 2004). Ek olarak, ofis binalarında oda sıcaklığının bireysel olarak kontrol edilmesinin, hasta bina sendromu (Sick Building Syndrome – SBS) belirtilerini ve hastalık izni günlerini azalttığı bulunmuştur. Yapılan araştırmalar, her yıl dünya çapında SBS kaynaklı 200

milyar Dolarlık çalışan performansı kaybı olduğunu, üretkenlikte ise kötü kapalı ortam hava kalitesi kaynaklı en az %2'lik kayıp olduğunu göstermiştir (Avaltroni vd. 2015). Dahası, günümüzde ticari ve bireysel kullanımdaki yapılardaki enerji tüketiminin %20 – %40'ı HVAC işlemleri sebebiyle oluşmaktadır (Perez-Lombard vd. 2008). Enerji üretiminin yaklaşık %80'inin de fosil yakıtlardan sağlanıyor olması bu konunun önemini çevre kirliliğine etkisi açısından daha da artırmaktadır (Desideri vd. 2009). Bu nedenlerden ötürü de doğru şekilde çalışan HVAC sistemleri elzemdir. Bu nedenle de yukarıda belirtilen sorunların araştırılması ve çözümü için önemli miktarda bilimsel ve mühendislik çalışmaları yürütülmektedir (McDowall 3).

Bununla birlikte, kullanıcıların beklentileri ısıtma ve soğutmaktan çok; daha fazla konfor seviyesine yükselirken, ısıl rahatlık her geçen gün önem kazanmaktadır. Isıl rahatlık ile üretkenlik arasında doğru orantı oluşu bilinmektedir (Clements-Croome ve Baizhan, 2000). Bu nedenle de yüksek rahatlık seviyesi ve enerji tasarrufu içeren bir HVAC kontrolü oluşturmak elzemdir (Liang ve Du, 2008). Amerikan Isıtma, Soğutma ve İklimlendirme Mühendisleri Topluluğu (American Society of Heating, Refrigerating and Air-Conditioning Engineers – ASHRAE), ısıl rahatlığı, memnuniyetin termal çevreyle ifade edildiği akıl durumu olarak tanımlamaktadır (Standart, ASHRAE. 2004). Diğer bir deyişle, insanların çevrelerindeki sıcaklıktan duydukları memnuniyet ile alakalıdır (Vakiloroya vd. 2014). Ticari binalarda ve ofislerdeki çevresel konfor, içerdekiler için optimum koşulları sağlamalıdır (Nemethova vd. 2016). Mimarlar, mühendisler ve tesis yöneticileri için bina sakinlerinin termal algısını tahmin etmek, konforlu kapalı ortamları yaratmak ve sürdürmek için önemli bir araçtır. HVAC otomatik kontrol sistemlerinin amacı da hava, su veya buhar akışını durdurup, başlatmak ya da düzenlemek sureti ile tercih edilen kapalı ortam sıcaklık, nem ve basınç miktarlarını koruyarak sistemin dengeli işletilmesini sağlamaktır (Sugarman 218). Termal konfor, üretkenlik ve sağlık arasındaki bağlantı yaygın bir bilgidir ve araştırmacılar son 50 yılda düzinelerce araştırma projesinden birçok modern termal hissiyat modeli geliştirmiştir. Termal hissiyat tahmini, tahmin edilen termal durumu binalardaki ısıtma ve soğutma sistemleri için bir kontrol kriteri olarak kullanan, enerji verimliliği ile bina sakinlerinin konforu arasındaki boşluğu doldurmada yardımcı olabilir (Soh vd. 2018).

Bir yandan da son yıllardaki teknolojik gelişmeler, bina otomasyonu özelliklerini önemli ölçüde artırmıştır. Nesnelerin interneti (Internet of Things – IoT), bulut bilişim ve yapay zekanın (Artificial Intelligence – AI) gelişimi ile akıllı binalar artık bir yandan bizi rahat ettirirken diğer bir yandan da enerji tasarrufu sağlamakta ve emisyonları azaltmaktadır. Fakat elde edilen bu ilerlemelere rağmen, açıkça görülmektedir ki otomasyon, binalardaki yaşayanlar tarafından yaygın olarak

benimsenmemiştir. Otomasyonun kabul edilebilirliğini arttırmak için, binalardaki otomasyon prosedürü, kullanıcının farklı şartlarda tercih ettiği otomasyon seviyelerinin belirlenmesini ve bağlamları kontrol etmeyi ve tercih dinamiklerini zamanla öğrenmeyi içermelidir (Becerik-Gerber vd. 2019). Yapılan güncel literatür taramasında iç ortam termal hissiyatın tahmin edilmesinde kullanılan yöntemler, hangi verilerin nasıl toplandığı ve hangi performans kriterleri ile değerlendirme yapıldığı incelenmiş ve karşılaştırılmıştır. Gözlemlenmiştir ki son yıllarda yapay sinir ağlarının kullanımı geleneksel model tabanlı yöntemlere oranla hızla artmaktadır (Çakır vd. 2019).

Gerekçelendirildiği üzere termal hissiyatın tahmin edilmesi büyük önem arz etmektedir. Bu nedenle, doktora tezinin amacı, bu problemin çözümünde derin öğrenme yöntemlerini kullanarak daha tutarlı sonuçlar üretmeyi sağlamaktır. Bu sayede ister bina otomasyon sistemleri olsun ister tesis yöneticileri, iklimlendirme sistemlerini daha etkin bir şekilde kullanarak hem konfor ve dolaylı olarak üretkenliğin artışı hem de enerji tasarrufu sağlanacaktır. ASHRAE tarafından toplanan, küresel termal konfor veri tabanının ikinci versiyonu üzerinde yapılan deneyler göstermiştir ki önerilen yöntem ile %78 oranında tutarlılık ile termal hissiyat tahmin edilebilmektedir. Bu tutarlılık, aynı veriseti üzerinde uygulanan sığı yöntemlere göre %4, geleneksel yöntemlere göre de yaklaşık %40 daha iyidir. Çalışmada hangi çevresel ve kişisel faktörün ısı hissiyat üzerinde daha fazla etkili olduğu da modelin tahmin etme performansı üzerindeki etkisi göz önünde bulundurularak değerlendirilmiştir. Ayrıca önerilen yöntem iklim kuşağı, coğrafi ortamdan ya da iklimlendirme yöntemlerinden etkilenmemektedir. Bu nedenle dünyanın herhangi bir yerinde kullanılabilir.

Bu tez çalışmasının motivasyonu bir dizi araştırma sorusu ile yanıtlanacak olup, çalışmanın sonunda cevap bulmayı bekleyen araştırma soruları ve motivasyonları Tablo 1.1'de yer almaktadır. Tabloya göre araştırma sonunda ısı rahatlığının tahmin edilmesinde hangi yöntemlerin kullanıldığı, verilerin nasıl toplandığı ve enerji tasarrufunun sağlanmasında doğrudan ya da dolaylı olarak hangi yöntemlerin kullanıldığıın bulunması hedeflenmektedir.

Tablo 1.1. Tezdeki araştırma soruları ve motivasyonları

Araştırma Sorusu	Motivasyon
RS1: HVAC sistemlerinde kullanım için en çok hangi akıllı hesaplama yöntemleri tercih edilir?	Şimdiye kadar yapılan çalışmalarda en çok tercih edilen akıllı hesaplama yöntemini ve her bir yöntem kullanılarak en sık hangi iyileştirmenin sağlandığını belirlemek.
RS2: HVAC sistemlerinin konfigürasyonunda ve termal konforun hesaplanmasında kullanılan veri tipleri nelerdir?	Sunulan verilerin sensörlerden, anketlerden, simülasyonlardan veya geçmiş çalışmalardan elde edilip edilmediğini belirlemek.
RS3: HVAC sistemlerinde akıllı hesaplama yöntemlerinin kullanımını optimize etmek açısından en çok hangi hedef üzerinde çalışılmıştır?	Hangi konunun (ısı konforunun iyileştirilmesi veya enerji tasarrufunun iyileştirilmesi) iyileştirilmesi için en fazla alanı sunduğunu belirlemek.

Yukarıdaki araştırma sorularına ek olarak reddedilmesi ve kabul edilmesi gereken hipotezler aşağıdaki gibidir:

$H_0$  : Yüksek kullanımlı binalarda termal hissiyatı tahmin etmenin en iyi yöntemi PMV ile hesaplamaktır.

$H_1$  : Termal hissiyat, yüksek kullanımlı binalarda derin öğrenme yöntemleri kullanılarak PMV ya da diğer sığ öğrenme yöntemlerine göre daha yüksek tutarlılıkla tahmin edilebilir.

Çalışma beş bölümden oluşmaktadır. Birinci bölümde araştırmanın konusu, amacı ve önemi belirtilerek neden böyle bir araştırmaya ihtiyaç duyulduğu ve araştırma ile elde edilmek istenen sonuçlar ortaya konulmuştur. İkinci bölümde araştırmanın kavramsal çerçevesi kapsamında temel olarak HVAC yapısı ve kontrol yöntemleri hakkında bilgi verilmiştir. Bununla birlikte model tabanlı termal hissiyat tahminleme yöntemleri hakkında detaylı bilgi verilmiştir. Daha sonra yapay zeka yöntemleri hakkında bilgi verilmiştir. Son olarak da yapay zeka kullanarak enerji tasarrufu ve/veya termal hissiyat tahmini hedefleyen, şimdiye kadar yapılmış çalışmalar özetlenmiştir. Üçüncü bölümde araştırmanın yöntemi belirtilmiş, toplanan veri ve bu verinin nasıl işlendiği hakkında bilgi verilmiştir. Daha sonra da kullanılan yapay öğrenme yöntemi tanıtılmış ve bu yöntemin nasıl değerlendirildiğinden bahsedilmiştir. Dördüncü bölümde önerilen yöntem kullanılarak elde edilen sonuçlar analiz edilmiştir. Beşinci ve son bölümde de sonuçlar tartışılmış, hangi çevresel ve kişisel faktörlerin çıktı üzerinde daha büyük etkisi olduğu belirtilmiş ve çıktılar

geleneksel yöntemlerin çıktıları ile karşılaştırılmıştır. ve gelecekte yapılabilecek değişiklikler için önerilerde bulunulmuştur.



## 2. ARAŞTIRMANIN KAVRAMSAL ÇERÇEVESİ

HVAC sistemlerinin bulunuşundan bu yana daha etkin bir biçimde işletilmesi birçok araştırmaya konu olmuştur. Bazı araştırmacılar nasıl daha az enerji tüketimi ile işletilebileceğini araştırırken bazıları da nasıl daha fazla ısı konfor sağlanabileceği konusuna odaklanmışlardır. Bu bölümde enerji tasarrufunun nasıl tanımlandığı, ısı konforunun ne olduğu ve yapay zekanın ne olduğu gibi bazı kavramlar hakkında kısaca bilgi verilmiştir. Ek olarak HVAC sistemlerinde enerji tasarrufu ve ısı konforunun artırılmasına yönelik yapılan bazı çalışmalar hakkında bilgi verilmiştir.

### 2.1. HVAC Sistemleri

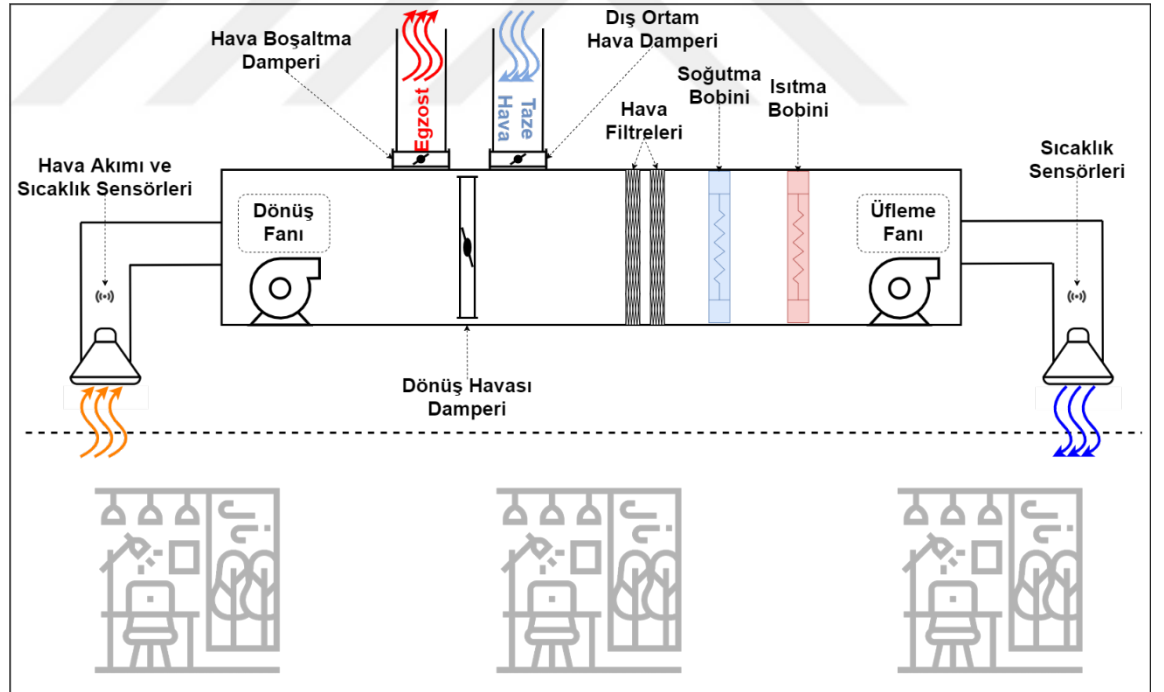
HVAC, ısıtma (Heating), havalandırma (Ventilation) ve soğutma (Air-Conditioning) kelimelerinin İngilizce karşılıklarının baş harflerinden oluşan bir kısaltmadır. Bu kısaltma aynı zamanda, fabrika, hastane, alışveriş merkezi, ofis ve sınıf gibi yaşam alanlarında yer alan ve adında geçen işlemleri yerine getiren sistemlerin genel adıdır. HVAC sistemlerinin amacı, ortam sakinleri için kabul edilebilir seviyede konfor ve işlem fonksiyonu sağlamak, kapalı ortam hava kalitesinin (Indoor Air Quality – IAQ) devamlılığını sağlamak ve işletim maliyetleri ve enerji gereksinimlerini minimum seviyede tutmaktır. HVAC'ın başlıca işlevleri (Zhang vd. 2015);

- 1- Isıtma: İklimlendirilen alana sıcaklığı artırma ya da koruma amaçlı termal enerji ekleme (ısıtma) işlemi.
- 2- Soğutma: İklimlendirilen alandan sıcaklığın azaltılması ya da korunması amaçlı termal enerjinin çıkarılma (soğutma) işlemi.
- 3- Nemlendirme: İklimlendirilen alana havadaki nem oranını koruma ya da artırma amaçlı su buharı (rutubet) eklenmesi işlemi.
- 4- Kurutma: İklimlendirilen alandan havadaki nem oranını koruma ya da azaltma amaçlı su buharının (rutubet) çıkarılması işlemi.
- 5- Temizleme: İklimlendirilen alana verilen havadaki parçacıkların (toz vb.) ya da biyolojik kirleticilerin (böcek, polen vb.) hava kalitesini artırmak ya da korumak amacı ile çıkarılması işlemi.

- 6- Havalandırma: İklimlendirilen alan ve dışarısı arasında hava kalitesini artırmak için kirli gazların uzaklaştırılması amacı ile yapılan hava değişimi işlemidir.
- 7- Hava Akımı: Termal enerji transferi ve doğru düzgün havalandırma yapılması amacı ile binalardaki iklimlendirilen alanlardaki havanın sirkülasyonu ve karıştırılması işlemidir.

Şekil 2.1'de bir HVAC sisteminin en temel bileşenleri gösterilmektedir. Bu şekle göre bileşenler aşağıdaki şekilde özetlenmektedir:

- 1- Havayı ısıtan ya da soğutan bobinler ve nemlendiriciler.
- 2- İklimlendirilmiş havayı iç ortama girdi olarak veren ya da içerdeki havayı sisteme geri toplayan fanlar.
- 3- İç ortama dışarıdan alınan taze havanın toz ve benzeri zararlı maddelerden arındırılmasını sağlayan filtreler.
- 4- Dışarıdan alınan taze havanın ya da içeriden dönen iklimlendirilmiş havanın ve bu ikinin ne kadar oranda karışacağını belirlemeye yardımcı olan damperler.
- 5- Tüm mekanik bileşenlerin çalışıp çalışmamasına karar vermede yardımcı olan sensörler.



Şekil 2.1. Tek ortamda çalışan HVAC sisteminin bileşenleri

Yukarıdaki şekle ek olarak bir de bütün HVAC sisteminin ya da bir bölümünün bir arayüz aracılığıyla yönetilmesini sağlayan bilgisayar destekli, bazı durumlarda doğrudan bina yönetim sistemine bağlı olan yönetim paneli mevcuttur. HVAC

sistemini özelliklerine bağlı olmak koşulu ile bu yönetim paneli üzerinden fanların çalışma hızı, damper açıklıkları, soğutma ve ısıtma bobinlerinin çalışma dereceleri ayarlanabilmektedir. Bazı yönetim panelleri sadece HVAC sisteminin hangi saatlerde aktif olması gerektiği bilgisini alarak dönüş fanından gelen sıcaklık bilgisine bakarak diğer tüm bileşenleri önceden belirlenmiş kurallar dahilinde ayarlar ve gereken saatlerde sistemi aktif eder.

## **2.2. HVAC Modelleme Teknikleri**

Yeni bir binanın maliyeti düşünüldüğünde, ticari binalarda %30'dan %50'ye kadar olan kısım HVAC sistemleri ile ilgilidir (Hensen, 1996). HVAC sistemleri tarafından enerji tüketimini doğru bir şekilde tahmin etmek için, tek-tek bileşenleri ölçülen verilere ya da temel fiziki olgu bilgisine dayanarak modellenmesi gerekir (Janabi-Sharifi ve Afram, 2014). HVAC Modelleme teknikleri temelde üçe ayrılır;

1. Fizik-Temelli (ya da beyaz kutu/matematiksel/ileri yönelik)
2. Veri-Güdümlü (ya da kara kutu/gözleme dayalı/terse yönelik)
3. Gri Kutu (ya da melez)

HVAC modellerinin geliştirilmesi, HVAC sisteminin çalışmasını kopyalamak, enerji tasarrufu stratejilerini uygulamak ve ileri seviyede kontrolörleri geliştirmek için gereklidir. Modeller geliştirilip kalibre edildikten sonra, her bir enerji koruma stratejisinin ve her kontrolör tasarımının etkisi benzetimi yapılabilir ve toplam maliyet tasarrufu hesaplanabilir (Afram ve Janabi-Sharifi, 2015).

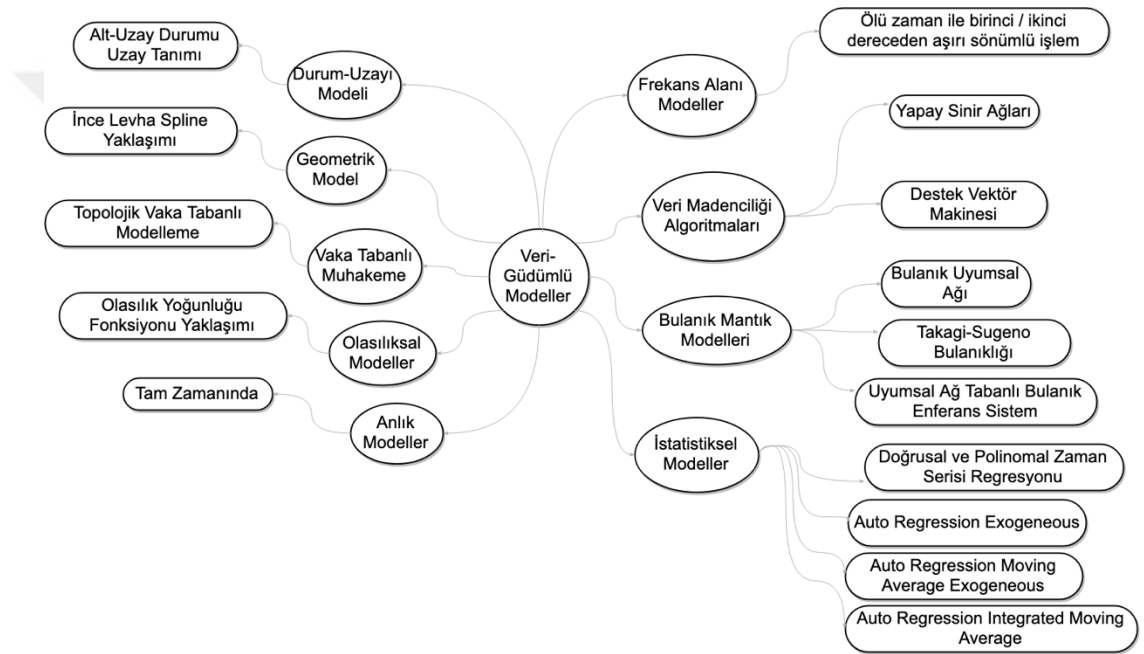
### **2.2.1. Beyaz Kutu Modelleme Tekniği**

Beyaz kutu modelleri (white-box models) bina operasyonu ile ilgili ayrıntılı bilgiler sağlar ve farklı sistemlerin performansı arasındaki ilişkileri keşfetmeyi sağlar (Arendt vd. 2018). Bu nedenle de geliştirmek ve kalibre etmek için büyük miktarda çaba gerektirir (Janabi-Sharifi ve Afram, 2014). Sistemin bölge, fan, depolama, kaynatma gibi tüm bileşenlerin ayrı-ayrı matematiksel olarak modellenmesi anlamına gelir. Ayrıntılı fiziksel model tabanlı denetleyici kontrol stratejileri pratik uygulama için uygun olmayabilir, çünkü detaylı fiziksel modeller genellikle yüksek hesaplama maliyeti ve bellek talebinin yanı sıra kontrol kararsızlığı ile sonuçlanabilecek birçok yineleme gerektirebilir (Wang ve Ma, 2008).

### **2.2.2. Kara Kutu Modelleme Tekniği**

Kara kutu modelleri (black-box models), sistem giriş ve çıkış verilerinin ölçülmesi ve verilere matematiksel bir fonksiyonun yerleştirilmesiyle geliştirilmiştir.

Kara kutu modellerinin geliştirilmesi, sistem fiziğinin anlaşılmasını gerektirmez ve zayıf genelleme yeteneklerinden muzdarip olsalar da fizik tabanlı modellere kıyasla yüksek hassasiyete sahiptir (Afram ve Janabi-Sharifi, Black-box modeling of residential HVAC system and comparison of gray-box and black-box modeling methods, 2015). Kara kutu modellerinin tipik temsilcileri polinom eğrisi uyarlamaları ve yapay sinir ağlarıdır (Artificial Neural Network – ANN) (Aggarwal vd. 2013). Şekil 2.2 kara kutu yani kara kutu modellerinin sınıflandırılmasını göstermektedir. Bunların arasında en çok başvurulan yöntemler veri madenciliği algoritmaları, bulanık mantık modelleri ve istatistiksel modeller yer almaktadır (Çakır vd. 2019).



Şekil 2.2. HVAC sisteminde kullanılan veri güdümlü modellerin sınıflandırılması

Sistemin bileşenleri ve ısı rahatlık arasında tercih edilen bir diğer modelleme yöntemi ise istatistiksel modellerden oto-regresyon yöntemleridir. Bizim çalışmamız, veri madenciliği algoritmalarından yapay sinir ağlarının bir alt kümesi olan derin yapay öğrenme üzerine yoğunlaşmıştır. Daha sonra da çıkan sonuçlar destek vektör makinesi ile karşılaştırılmıştır.


### 2.2.3. Gri Kutu Modelleme Tekniği

Gri kutu modelleri (gray-box models) beyaz kutu ve kara kutu modellerinin kombinasyonu olarak kabul edilebilir (Homod, 2013). Modelin temel yapısı fizik tabanlı yöntemlerden oluşurken, model parametreleri sistemin ölçülen verileri üzerinde parametre tahmin algoritmaları kullanılarak belirlenir (Afroz vd. 2018). Bazı gri kutu

modellemelerde, model yapıları matematiksel olarak fiziksel veya termodinamik ilkelerden türetilirken, parametreleri katalog, devreye alma veya işletim verilerinden belirlenir (Wang vd. 2009). Gri kutu modelleri hem ölçümleri hem de sistem fiziğini kullanır, bu nedenle hem iyi doğruluk hem de yüksek genelleme yetenekleri sağlarlar ancak bu modelleri geliştirmek için daha fazla çalışma gerekir (Afram ve Janabi-Sharifi, Gray-box modeling and validation of residential HVAC system for control system design, 2015).

### **2.3. Isıl Konfor**

ASHRAE'nin Standart 2004'üne göre termal konfor; kapalı bir ortamda bulunan kişiler tarafından yapılan öznel bir değerlendirme olarak tanımlanır (Standart, ASHRAE. 2004). Binanın mimari tasarımının büyük ölçüde etkisi olsa da termal konfor temelde binalardaki HVAC sistemleri tarafından kontrol edilir. Şekil 2.3'te gösterildiği gibi termal konfora etki eden altı faktör vardır. Bunlar kişisel ve çevresel faktörler olmak üzere iki grupta toplanır. Çevresel faktörler ortamın sıcaklığı, radyan sıcaklık, bağıl nem ve ortamdaki hava akımı hızıdır. Kişisel faktörler ise kişinin üzerindeki kıyafetler sayesinde ne kadar ısı koruması altında olduğu ve hareketlilik seviyesidir.



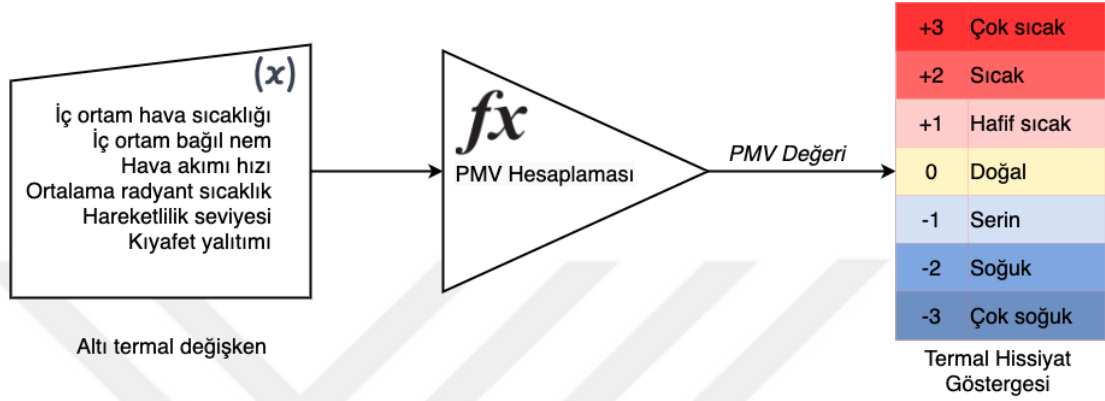
Şekil 2.3. İnsan termal konforuna etki eden faktörler

Bu öznel değerlendirmenin ölçülmesinin bir yöntemi bulunmamaktadır. Bu nedenle, sayısal bir model oluşturmak için toplanan bütün konfor verisi araştırmacıların, özel durumlarda deneklere yönelttikleri sorulara verilen cevaplardan ibarettir. ASHRAE standardına göre termal konfor şartları, binada bulunanların %80'i memnun ise kabul edilebilir. Ek olarak belirtmek gerekir ki ASHRAE Standartlarının geçerli olabilmesi için bulunulan ortamın;

- Yüksekliğin 3000 metreden az olması
- Altı yüzeyi kapalı duvarlarla çevrili olması
- Ortamda bulunanların en az 15 dakikalarını bahsedilen kapalı ortamda geçirmiş olmaları gerekmektedir (Wang vd. 2006).

Uygun termal konfor şartlarını öngörmek için Ortalama Isıl Duyum (Predicted Mean Vote – PMV) adında bir indeks kullanılır. Bu indeks, büyük sayılı insan grupları için standart ölçekli termal hassasiyeti belirtir (Fanger, 1970). PMV insan konforuna tabi olarak kapalı ortamlar için yukarıda bahsedilen altı faktör kullanılarak hesaplanır. PMV indeks, oylamaların ortalama değerini yedi noktalı termal hissiyat ölçeğinde

öngörür; +3: çok sıcak, +2: sıcak, +1: hafif sıcak, 0: doğal, -1: hafif soğuk, -2: soğuk, -3: çok soğuk. Şekil 2.4'de bu durumun basit bir özetidir. Bu şekle göre PMV 6 değişken alan ve +3 ile -3 arasında bir değer üreten matematiksel bir fonksiyondur. ISO 7730 standardına göre PMV'nin -1 ve +1 arasındaki değerleri insanların %75'i tarafından tatmin edici bulunurken, -0,5 ve +0,5 arasındaki değerler için %90'ı memnun olacaktır. O anki termal şartlardan bina sakinlerinin yüzde kaçının rahatsız olduğunu öngören PMV fonksiyonudur.



Şekil 2.4. PMV ve termal hissiyat

Bu noktada PMV'ye girdi olarak sağlanan altı parametreden üçünün açıklanması gerekmektedir. Bunlardan ilki bağıl nemdir. Fakat öncesinde mutlak nemden bahsetmek gerekir. Mutlak nem, belirli bir sıcaklıkta bir hava hacmindeki kuru hava kütesine bölünen su buharı kütesidir. Hava ne kadar sıcaksa, o kadar fazla su buharı içerebilir. Bağıl nem ise mevcut mutlak nemin mümkün olabilecek en yüksek mutlak neme oranıdır. Bu demektir ki %100 bağıl nem okuması, havanın tamamen su buharı ile doyurulduğu ve daha fazla tutamayacağı anlamına gelir. Açıklanması gereken bir diğer değişken ise radyan sıcaklıktır. Diğer bir değişle çevredeki cisimlerden yayılan sıcaklıktır. İşyerinde işin gereği olarak sıcak yüzeyler bulunabilmektedir ve bu yüzeylerden ısı yayılımı sonucu oluşan sıcaklıktır. Isı kaynaklarından ışımaya yolu ile yayılan radyan ısı küre termometre ile ölçülür. Küre termometre ince ve dış yüzü mat siyah boya ile boyanmış 15 cm çapında bakır bir küre merkezine yerleştirilmiş bir kuru termometredir.

ASRAE'nin 2017'de yayımladığı standarda göre kıyafetlerin sağlayabildiği ısı yalıtımı miktarı Tablo 2.1'de *clo* birimi cinsinden yer almaktadır. Bir *clo* değeri, 21 santigrat derecelik bir oda sıcaklığında, dinlenen bir insanın termal konforu korumak için ihtiyaç duyduğu giysi miktarına eşittir. Tablo 2.1'e göre en yüksek ısı yalıtımı tahmin edileceği üzere pantolon, uzun kollu gömlek, uzun kollu kazak, ceket ve alt içlikte oluşan kıyafetlerin giyilmesi ile sağlanmaktadır. Bu kadar fazla ısı yalıtımına

sahip bir bireyin iç ortamın sıcak olduğunu iddia ettiği durumda soğutma sistemine başvurması durumu enerjinin ihtiyaç dışı tüketimi için çok net bir örnek oluşturmaktadır. Ya da tam tersi bir durum, soğuk iklim koşullarına sahip bir ortamda, 0,36 clo değeri ile yalıtım sağlayan yürüyüş şortu ve kısa kollu gömlek giymiş bir kişi için de geçerlidir.

Tablo 2.1. Tipik takımlar için giysi izolasyon değerleri (Standart, ASHRAE. 2017)

Takım Tanımı	Dahil Olan Kıyafetler*	$I_{cl}$ , clo
Kumaş	(1) Pantolon, kısa kollu gömlek	0,57
Pantolon	(2) Pantolon, uzun kollu gömlek	0,61
	(3) #2 ve ceket	0,96
	(4) #2, ceket, yelek ve tişört	1,14
	(5) #2, uzun kollu kazak ve tişört	1,01
	(6) #5, ceket ve alt içlik	1,30
	Etek/Elbise	(7) Diz boyu etek, kısa kollu gömlek ve açık ayakkabı
(8) Diz boyu etek, uzun kollu gömlek ve kapalı ayakkabı		0,67
(9) Diz boyu etek, uzun kollu gömlek, yarı açık ayakkabı ve uzun kollu kazak		1,10
(10) Diz boyu etek, uzun kollu gömlek, yarı açık ayakkabı ve ceket		1,04
(11) Bilek boyu etek, uzun kollu gömlek ve ceket		1,10
Şort	(12) Yürüyüş şortu ve kısa kollu gömlek	0,36
Tulumlar	(13) Uzun kollu işçi tulumu ve tişört	0,72
	(14) Bahçıvan tulum, uzun kollu gömlek ve tişört	0,89
	(15) İzole işçi tulumu, uzun kollu üst ve alt termal içlik	1,37
Spor	(16) Alt ve üst eşofman	0,74
Yatak kıyafeti	(17) Uzun, alt ve üst pijama, $\frac{3}{4}$ kaplayacak kadar hırka (terlik ama çorap yok)	0,96
* Parantez içinde aksi belirtilmediği sürece, tüm giysi grupları ayakkabı, çorap ve kısa külot veya külot içerir. Tam etek / elbise giysi takımları, külotlu çorap ve ek çorap içermez.		

Yine aynı standarda göre ofis ortamında bulunanların yapmış oldukları aktivitelere bağlı olarak hareketlilik seviyeleri de Tablo 2.2'de *met* birimi cinsinden yer almaktadır. Bir *met*, dinlenirken harcanan enerjidir yani dinlenme veya bazal metabolizma hızıdır.

Tablo 2.2'ye göre en az hareketlilik seviyesine sahip aktiviteler oturma, okuma ve yazı yazmaktır. En yüksek hareketlilik seviyesine ise bir şeyleri kaldırırken ya da paketlerken ulaşılmaktadır. Hareketlilik seviyesi arttıkça vücuttaki enerji üretimi/tüketimi artacak, dolayısıyla içinde bulunduğu ortamı bulunduğundan daha sıcak hissedecektir.

Tablo 2.2. Tipik ofis aktiviteleri için hareketlilik seviyesi (Standart, ASHRAE. 2017)

Aktivite	Hareketlilik Seviyesi (met)
Sessizce oturma	1,0
Rahat ayakta	1,2
Oturarak okuma	1,0
Yazı yazma	1,0
Bilgisayarda yazı yazma	1,1
Oturarak dosyalama	1,2
Ayakta durarak dosyalama	1,4
Yürüme	1,7
Kaldırma ya da paketleme	2,1

Bu bilgiler dahilinde Fanger'in modeline göre PMV'nin hesaplanması aşağıdaki gibidir:

$$PMV = (0.028 + 0.303e^{-0.036M}) \times L$$

$$L = (M - V) - 3.05 \times 10^{-3}(5733 - 6.99(M - V) - Pa) - 0.42(M - V - 58.15) - 1.7 \times 10^{-5} (5867 - Pa) - 0.0014M(34 - t_a) - f_{cl}h_c(t_{cl} - t_a) - 3.96 \times 10^{-8}f_{cl}[(t_{cl} + 273)^4 - (t_r + 273)^4]$$

Bu formüllere göre;

L : Bir insanın etrafındaki toplam sıcaklık transferi

M : Hareketlilik seviyesi

V : Hava akımı hızı

W : Kişinin yapmış olduğu iş miktarı

Pa : Buhar basıncı

f<sub>cl</sub> : Kişinin toplam vücut alanının yüzde kaçı kıyafet altında

$h_c$  : Konvektif ısı transferi. Aşağıdaki gibi hesaplanır;

$$h_c = \begin{cases} 2.38(t_{cl} - t_a)^{0.25}, & \text{if } 2.38(t_{cl} - t_a)^{0.25} > 12.1\sqrt{V} \\ 12.1\sqrt{V}, & \text{if } 2.38(t_{cl} - t_a)^{0.25} < 12.1\sqrt{V} \end{cases}$$

$t_{cl}$  : Kıyafetlerle sıcaklık. Aşağıdaki gibi hesaplanır;

$$t_{cl} = 35.7 - 0.028(M - W) - 0.155I_{cl}\{3.96 \times 10^{-8} \times f_{cl}[(t_{cl} + 273)^4 + (t_r + 273)^4] + f_{cl} \times h_c(t_{cl} - t_a)\}$$

M ve  $I_{cl}$  değişkenleri genellikle tipik ofis ortamları için  $M = 1$  met ve kış için  $I_{cl} = 1$  clo ya da yaz için  $I_{cl} = 0.5$  clo olacak şekilde sabit kabul edilmektedir (Fanger, 1970). ASHRAE 2017 de hafif aktivite seviyelerinde ( $\leq 1,2$  met) "tipik kış ve yazlık giysiler" giydirilmiş kişiler (0,5 clo – 1,0 clo) için kabul edilebilir çalışma sıcaklığını kış ayları için 20,0 °C ile 23,6 °C aralığında optimum değeri ise 21,7 °C olarak; yaz ayları için ise 22,8°C ile 26,1 °C aralığında optimum değeri ise 24,4 °C olarak belirtmiştir (Wang vd. 2006). PMV değeri 0'dan ne kadar uzaklaşırsa tahmin edilen tatsızlık oranı (PPD – Predicted Percentage of Dissatisfaction) artar. ASHRAE (55-2004)'e göre PPD'nin kabul edilebilir değeri %10'un altıdır (Standart, ASHRAE. 2004).

#### 2.4. Enerji Tasarrufu Yöntemleri

Enerjinin korunumu ise yeni ve eski binalardaki hava kalitesinden ödün vermeden, tüketimin azaltılması için özgün bir yöntem bulmanın hedeflendiği, süre gelen bir mücadeledir. Bu konu, farklı disiplinlerin büyük ölçüde iş birliğini gerektirmektedir. Temel anlamda bilinen 3 enerji tasarrufu yöntemi mevcuttur;

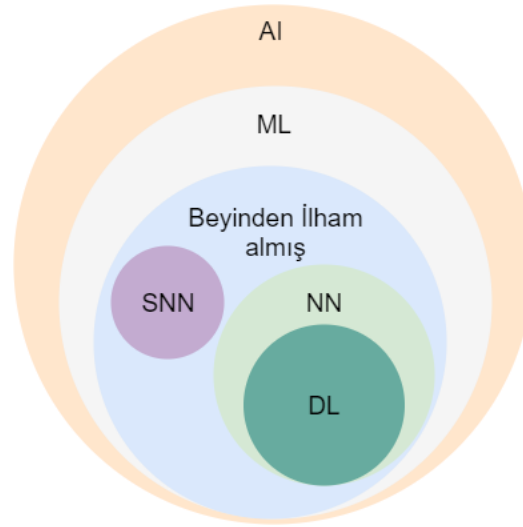
1. Kapat: Bu her zaman uygulaması en basit, en ucuz ve de en fazla tasarruf sağlayan yöntemdir. Eğer bir servise ihtiyaç duyulmuyorsa, kapatılabilir mi? Bunun bir alternatifi de çalışma süresini minimumda tutmaktır.
2. Azalt: İhtiyaç duyulan servisi sağlamaya devam ederken bir yandan da ısıtma ya da soğutma miktarını azalt. İç ortam sakinleri sayısına göre servis miktarının ayarlanması bu yönetime bir örnektir.
3. Değiştir: Yenisiyle değiştir anlamına gelmektedir. Üç yöntem içinde en pahalısı olduğu için gerekçe göstermesi ve uygulaması en zor yöntemdir. Finansal açıdan bir yatırımın onaylanması için dönüş süresinin kısa olması

gerekmektedir ki bu ticari binalardaki HVAC sistemleri için olası değildir (Wong vd. 2005).

Binalardaki enerji tüketimi, daha iyi kontrollerin uygulanarak, sistemlerin etkin olarak işletilmesi ile azaltılabilir. Bütünleşik kontroller kullanarak ve binaları daha zeki hale getirerek enerji tüketimi azaltılabilir (Aria, 2015). HVAC bulunduğu bugüne değin, farklı kontrol yöntemleri önerildi ve bu yöntemlerin, sistemin genel enerji tüketimini azaltmak ve binada bulunanların termal konforunu sağlamak için HVAC sistemlerinin çalıştırılmasını hedef alan, her zaman araştırma ve geliştirme alanlarında çok aktif bir yeri oldu (Wang vd. 2006). Araştırmalar, HVAC sistemlerinin uygun şekilde seçilmesinin ve işletilmesinin, yeterli iç ortam ortamını korurken %25 oranında enerji tasarrufu sağlayabileceğini belirlemiştir (Fasiuddin ve Budaiwi, 2011).

## 2.5. Derin Öğrenme


Derin öğrenme, yapay zekanın bir alt kırılımı olan yapay öğrenmenin bir alt dalıdır. Genel itibariyle yapay zeka Şekil 2.5'de olduğu gibi sınıflandırılmaktadır. Şekilden de anlaşılacağı üzere yapay zeka, derin öğrenme ve yapay sinir ağlarını da kapsayan genel konseptte verilen addır. Yapay zekanın bir alt kümesi yapay öğrenme, onun da bir alt kümesinde yapay sinir ağları vardır ki bu yöntem, insan beyninden ilham alınarak oluşturulmuştur (Alpaydin, 2020).



Şekil 2.5. Yapay Öğrenme Sınıflandırılması:

AI: Artificial Intelligence (Yapay Zeka); ML: Machine Learning (Yapay Öğrenme); NN: Neural Networks (Yapay Sinir Ağları); DL: Deep Learning (Derin Öğrenme); SNN: Spiking Neural Networks (Başaklanmış Yapay Sinir Ağları) (Alom vd. 2019)

Bu çalışmada, kullanılan veri miktarı arttıkça daha iyi sonuçlar üreten ve bir anlamda da yapay sinir ağlarının gelişmiş versiyonu olan Derin Öğrenme yönteminden yararlanılmıştır. Bu nedenle de Derin Öğrenmeye geçmeden önce Yapay Sinir Ağları hakkında bilgi vermekte fayda vardır. Eğitilebilir, kendi kendine organize olup, öğrenebilen ve değerlendirme yapabilen yapay sinir ağları ile insan beyninin öğrenme yeteneği taklit edilmeye çalışılmaktadır. Yapay Sinir Ağları, sistemin geçmişte toplanan performans verileri üzerinde eğitilir ve bu veriler doğrusal olmayan bir matematiksel modele oturtulmaya çalışılır. Algoritma, sürecin altında yatan fiziksel modelin anlaşılmasını gerektirmeyen bir kara kutu modelleme tekniğidir (Afram ve Janabi-Sharifi, Theory and applications of HVAC control systems–A review of model predictive control (MPC), 2014). Yapay Sinir Ağlarının temelinde de tıpkı insan beynindeki biyolojik yapılardan esinlenilmiş olan ve nöron adı verilen yapay sinir hücreleri bulunmaktadır. Şekil 2.6’da bu iki yapının karşılaştırması görülmektedir.



Şekil 2.6. İnsan nöronu ve yapay nöronun karşılaştırılması (Magoulès ve Zhao, 2016)


Şekle göre, insan nöronunda dendritlere diğer sinir hücrelerinin akson uçları vasıtası ile gelen elektriksel sinyaller kullanılarak, hücrenin eşik değerine göre, sinirsel hesaplama yapıp, yapılmayacağına oradan da akson üzerinden çıkış sinyali üretilip,

üretilmeyeceğine karar verilir. Hücre içerisinde sinyal iletim yönü dendritlerden aksona doğru tek yönlüdür. Yapay sinir ağlarında da hücre içindeki iletişim tek yönlüdür. Girdi değerlerinin ağırlıklı toplamları alınarak bir aktivasyon fonksiyonuna tabi tutulur ve çıkan değer ağdaki bir sonraki katmanda yer alan yapay sinir hücresine girdi olarak iletilir. Girdi değerlerinin ağırlıklı toplamları aşağıdaki fonksiyon ile bulunur;

$$\sum_i^n X_i W_i + b$$


Bu formülde;  $X$ : bağımsız değişken yani girdi,  $W$ : ağırlık parametresi ve  $b$ : ek girdi (bias) değeri olarak tanımlanır. Daha sonrasında ağırlıklar toplamından elde edilen değer bir aktivasyon fonksiyonuna girdi olarak kullanılır. Aktivasyon fonksiyonları, bir nöronun giriş genliğini istenilen değerler arasında sınırlamak için kullanılırlar (Tezel, 2007). Doğrusal olmayan gerçek dünya özelliklerini tanıtmak için aktivasyon fonksiyonuna ihtiyaç duyulur. En çok kullanılan aktivasyon fonksiyonları sigmoid, hiperbolik tanjant, rectified linear unit (ReLU) ve eşiksiz en büyük (Softmax) fonksiyonlardır. Bizim çalışmamızda gizli katmanlarda ReLU, çıktının sağlandığı katmanda ise Softmax kullanılmıştır. İlk olarak 2000'de silikon devrelerin analog amplifikasyonu için kullanılan Relu, daha sonra 2011 yılında derin sinir ağlarının eğitimini daha da geliştirdiği göstermiştir (Agarap, 2018). Değerleri 0'da eşitleyerek çalışır, yani  $f(x) = \max(0, x)$ . Bu fonksiyonun grafiksel gösterimi Şekil 2.7'de yer almaktadır. Basitçe ifade etmek gerekirse,  $x$ 'in 0'dan küçük olduğu durumlarda  $y$  değeri 0, tersinde yani  $x$ 'in 0'a eşit ya da 0'dan büyük olduğu durumlarda doğrusal hareket eder. Ayrıca hesaplama yükünün hafif olması çok fazla sinir hücresi içeren ağlarda avantaj sağlamaktadır. Basitliği ve etkinliği sayesinde ReLU, derin öğrenme topluluğunda kullanılan varsayılan aktivasyon fonksiyonu haline gelmiştir (Ramachandran vd. 2017).

$$g(x) = \begin{cases} x < 0 \rightarrow 0 \\ x \geq 0 \rightarrow x \end{cases}$$



Şekil 2.7. ReLU fonksiyonunun grafiksel gösterimi

Çoklu sınıflandırma problemleri için kullanılan Softmax fonksiyonu ise verilen her girdinin belirli sınıfa ait olma olasılığını 0 – 1 aralığında değerler üretmek için kullanılır. Yani olasılıksal bir yorumlama gerçekleştirir. Şekil 2.8'den de görülebileceği gibi bu fonksiyon, x değeri 0'dan küçük değerler aldığı zaman y'nin 0'a, x'in 0'dan büyük olduğu değerlerde ise y'nin 1'e yakınsamasını sağlayan Sigmoid fonksiyonunun ikiden fazla değer için genişletilmiş halidir (Bouchard, 2008).

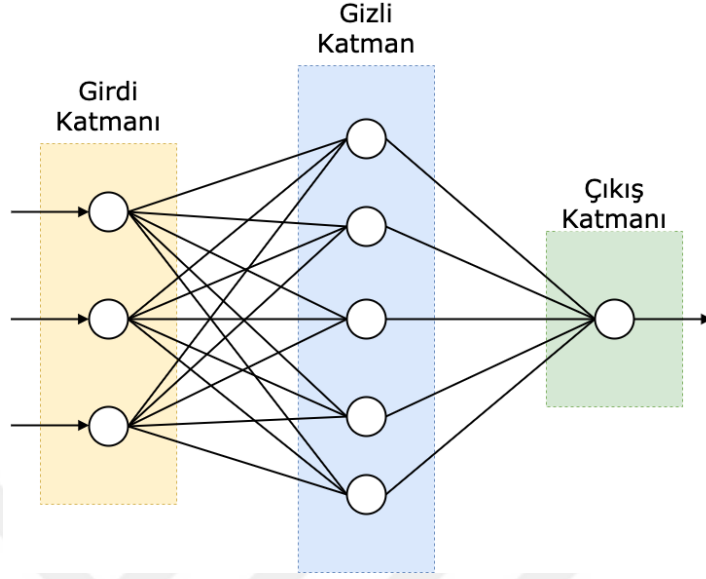


Şekil 2.8. Softmax fonksiyonunun grafiksel gösterimi


$$g(x) = \frac{e^x}{\sum e^x}$$

Yapay sinir ağlarında da aynı insanda olduğu gibi sinir hücrelerinin yani nöronların birbiri ile iletişim halinde olacak şekilde bir araya gelmesi ile sinir hücresi ağı, yani sinir ağı oluşmaktadır. Genelde bu sinir ağları, bir girdi katmanı, sonucun üretildiği bir çıktı katmanı ile aralarında bulunan bir (Şekil 2.9) ya da daha fazla (Şekil 2.10) gizli katmandan oluşmaktadır. Ağ içerisinde bilgi iki türlü akmaktadır. Bunlardan ilki bilginin sürekli ileri aktığı, başka bir deyişle bir katmanda üretilen çıktının sonraki

katmana girdi olarak verilen ileri-beslemeli (feed-forward) modeldir. Diğeri ise bilginin bir döngü halinde ilgili katmana geri döndüğü geri-dönen (recurrent) modeldir. İkincisi daha çok zaman serisi problemlerinin çözümü için tercih edilmektedir.



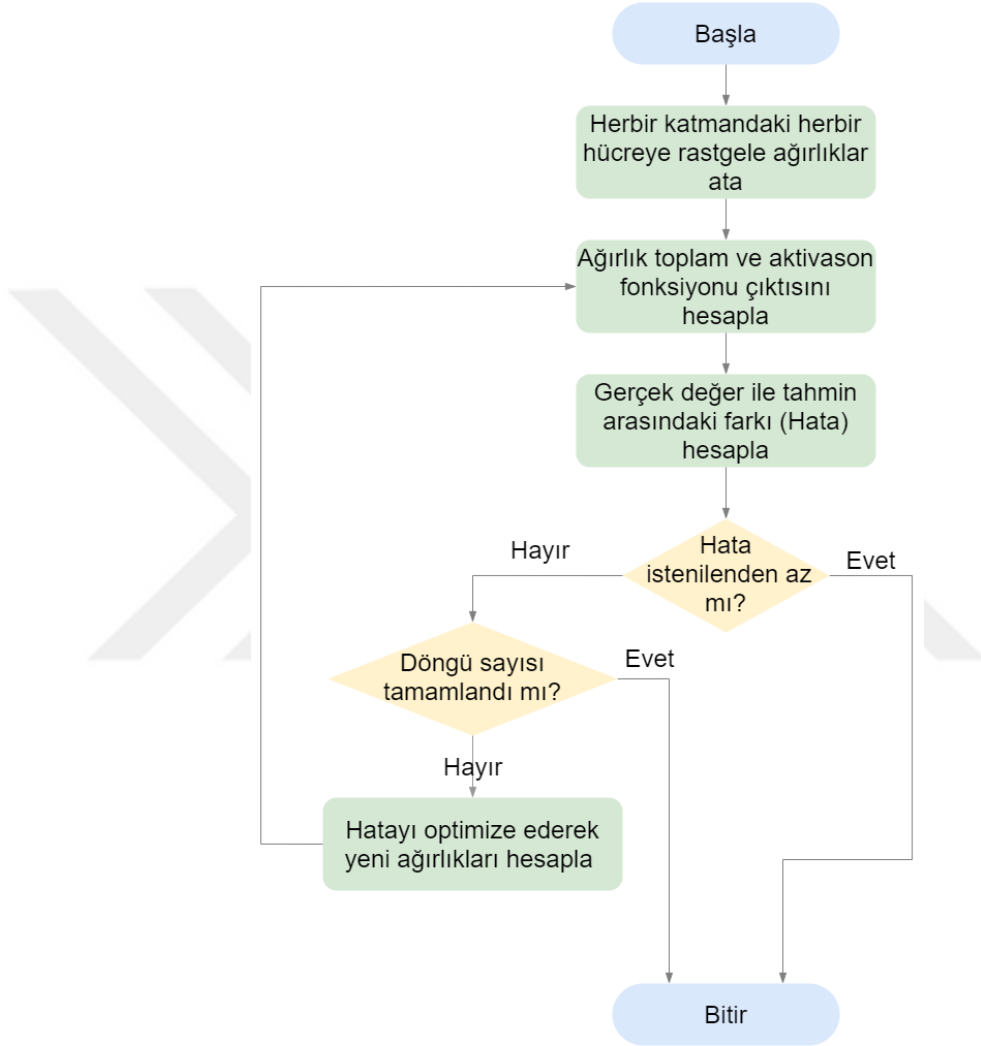
Şekil 2.9. Tek katmanlı yapay sinir ağı



Şekil 2.10. Çok katmanlı yapay sinir ağı

Bütün ağıın amacı, modelin en iyi sonucu vereceği, yani her döngüde olması gereken değer ile hesaplanan değer arasındaki hatayı minimumda tutan  $W$  ve  $b$  parametrelerinin hesabını yapmaktır (Levent ve Diri, 2014). Bu iki değer arasındaki fark, kayıp fonksiyonları ile hesaplanır. Diğeri bir değişle maliyet ya da hedef fonksiyonu olarak da bilinen kayıp fonksiyonları problemin türüne göre farklılık göstermektedir. En küçük hata değerine ulaşana kadar Şekil 2.11'da da gösterildiği

gibi sinir ağı farklı  $W$  ve  $b$  parametreleri ile tekrar etmektedir. Bu değerlerin atanması ilk başta rastgele olsa da daha sonrasında bir optimizasyon algoritması uygulanarak güncellenir ve sinir ağına yeniden girdi olarak eklenir yani geriye doğru yayılım (backward propagation) yapar. Bu tekrarın sonsuza kadar devam etmemesi için de bir döngü sayısı sınırı eklenmelidir. Bütün bu sürece ise yapay sinir ağının eğitimi adı verilmektedir.



Şekil 2.11. Yapay sinir ağı eğitim akış şeması

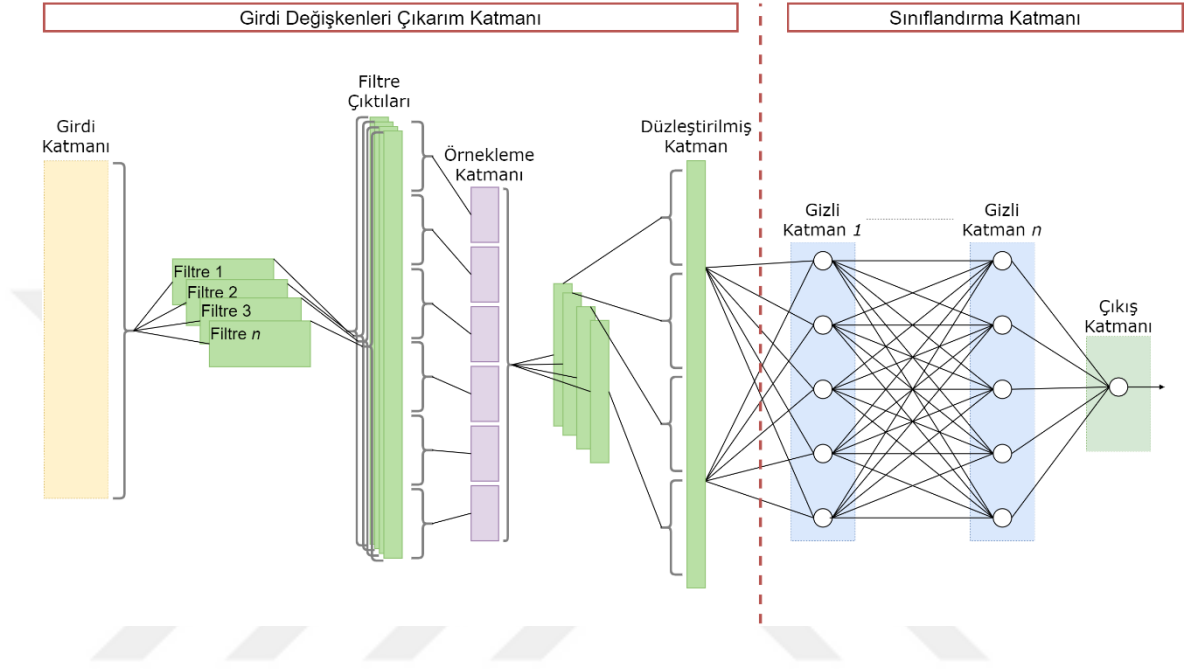
Eğitim süreci tamamlandıktan sonra modelin tamamı farklı veri seti üzerinde test edilir ki bu adımın eğitim üzerinde hiçbir etkisi yoktur. Bu adım sayesinde eğitim sırasında ve sonrasında ağ performansının bağımsız bir ölçüsü elde edilir (Afroz vd. 2017).

Temel olarak bakıldığında üç tiple yapay öğrenme stratejisi mevcuttur. Bunlardan hangisinin tercih edileceği tamamen problemin türüne bağlıdır. Bu stratejiler:

1. Denetimli Öğrenme (Supervised Learning): Bu strateji tipi örnek kümesi üzerinden tahmin üretirler. Eğitim için kullanılan her örnek, katma değeri ile etiketlenir. Bu öğrenme tipi, katma değer etiketlerinde bir şablon arar. Bulunabilecek en uygun şablon bulunduktan sonra da etiketlenmemiş test datası üzerinden tahminler üretmeye çalışılır. Üç tip denetimli öğrenme mevcuttur;
  - a. Sınıflandırma (Classification): Eğer veri, sonlu sayıdaki seçeneklerden birini tahmin etmek için kullanılıyorsa bu işleme sınıflandırma denir. Eğer seçenek sayısı iki ile sınırlıysa ikili-sınıflandırma (binary class classification), daha fazla ise çoklu-sınıflandırma (multi-class classification) uygulanır.
  - b. Regresyon: Eğer sonsuz sayıdaki seçeneklerden bir değer tahmin edilmek isteniyorsa buna bağlanım yani regresyon denir.
  - c. Bozukluk Saptama (Anomaly Detection): Amaç, olağan dışındaki veri noktalarını tespit etmek olduğunda bozukluk saptama kullanılır. Algoritma öncelikle sistemdeki normalin ne olduğunu öğrenir, sonra da içindeki bozuklukları tespit eder.
2. Denetimsiz Öğrenme (Unsupervised Learning): Bu öğrenme tipinde veriler herhangi bir şekilde etiketlenmez. Amaç, verinin bir şekilde organize edilmesini sağlamak ya da yapısını tanımlamaktır. Kümelere (clusters) gruplanması anlamına da gelir. Karmaşık verinin daha basit gözükmesi için farklı yönlerden bakılmasıdır.
3. Kuvvetlendirilmiş Öğrenme (Reinforcement Learning): Bu öğrenme tipinde algoritma her bir veri için bir aksiyon seçmek zorundadır. Öğrenme algoritması verdiği kararın performansına göre ödül sinyali arar. Algoritma her seferinde daha yüksek ödül almak için stratejisini günceller. Bu yöntem genellikle robotik alanında kullanılır.

Derin öğrenmede iki teknik mevcuttur; yoğun bağlı sinir ağları (Densely-Connected Neural Networks – DNN) ve evrişimli sinir ağları (Convolutional Neural Networks – CNN). Yukarıda bahsi geçen yapay sinir ağları DNN tekniğinden sayılabilir. Her ne kadar CNN çoğunlukla resim tanıma, doğal dil işleme ve zaman dizisi tahminleri yürütme gibi işler için tercih edilse de normal sınıflandırma problemleri için de kullanılabilir. Bu tekniğin en önemli özelliği girdi değişkenleri doğrudan farklı evrişim katmanları tarafından öğrenildiğinden, manuel girdi değişken çıkarımı ihtiyacını ortadan kaldırmasıdır. Bu durum sayesinde verinin toplandığı alana dair uzman görüş ihtiyacı da azalmaktadır (Guo vd. 2017). Şekil 2.12'dan da görülebileceği gibi evrişimli yapay sinir ağları temelde iki farklı katmana ayrılır.

Bunlardan ilki, bir veya daha fazla değişken haritalamasının yapıldığı ve daha sonra da her bir değişkenin (boyutun) girdi sayılarının azaltıldığı çıkarım katmanıdır. Burada filtre girdi katmanı üzerinde kayarak matris çarpımı aracılığıyla değişken çıkarımı yapılmaktadır. İkinci katman ise sınıflandırmanın yapıldığı ve yukarıda bahsedilen yoğun bağlı sinir ağıdır (Sharma ve Kumar, 2020).



Şekil 2.12. Evrişimli yapay sinir ağlarının genel mimarisi

## 2.6. Yapay Öğrenme ile Termal Konforun Artırılması

Yukarıda da bahsedildiği gibi yerleşik ortamlarda termal konforu korumak, ortam sakinlerinin sağlığı, refahı ve üretkenliği ve aynı zamanda verimli HVAC sistemi yönetimi için önemlidir. Mevcut yöntemlerde, tahmin etme modelinin eğitimi için ortam sakinlerinden anket vasıtası ile geri bildirim toplanması gerekmektedir. Kişisel termal konfor, zamana ve dış etkenlere bağlı olduğu için genellikle eğitim sürecinden sonra bu yöntemin tutarlılığı azalmaktadır. Bu nedenle Becerik-Gerber ve ark. yaptığı bir çalışmada, kızıl ötesi ısı görüntüleme kullanılarak, kişisel termal konfor modeli oluşturmak için denetimsiz yapay öğrenme yöntemlerinden biri olan Gizli Markov Modelden (Hidden Markov Model – HMM) termal hissiyat üçlü skalada (rahatsız edici derecede sıcak, uygun ortam koşulları, rahatsız edici derecede soğuk) olacak şekilde faydalanmıştır. HMM, gizli Markov zinciri durumlarındaki bağlı değişkenleri gözlemleyerek, gözlemlenmemiş bir Markov zincirinin gizli durumlarını tahmin etmeyi amaçlayan dinamik bir Bayes ağıdır. Başka bir deyişle gözlemlenen değişkenler, gizli durumların olasılıksal işlevleridir ve zamana bağımlıdır. Kapalı ortamda da olsa

herhangi bir örtü gerektirmediği ve diğer kısımlara oranla daha yoğun kan damarlarına sahip olduğu için ısı görüntülemeye insan yüzü tercih edilmiştir. Bu çalışmada gözlemlenebilir değişken ortalama cilt sıcaklığıdır ve ortamda sakinleri arasında farklılık gösteren sürekli bir değişkendir. Dört gün boyunca on kişi üzerinde yapılan gözlemlerden toplanan 457 farklı girdiye sahip veri ile yapılan testler göstermiştir ki rahatsız olunan koşullar %82,8 tutarlılıkla tahmin edilmiştir (Becerik-Gerber vd. 2018).

Yine termal konforun tahmin edilmesi için cilt sıcaklığından faydalanan başka bir çalışmada ise Aşırı Öğrenme Makineleri (Extreme Learning Machine – ELM) ve Destek Vektör Makineleri (Support Vector Machine – SVM) karşılaştırılmıştır. Yirmi adet denekten toplanan üçlü ölçekteki termal konfor ve cilt sıcaklığı datası kullanılarak iki model de eğitilmiştir. Eğitim öncesi cilt sıcaklığı vücut yüzey alanı ve kıyafet izolasyonu kullanılarak normalize edilmiştir. Bu iki değişkene ek olarak, ortam sıcaklığı, kuru küre sıcaklığı, bağıl nem ve içerideki hava akımı hızı da modele girdi olarak verilmek üzere kaydedilmiştir. Elde edilen verisetinde toplam 800 adet veri noktası bulunmaktadır. Yapılan testler göstermiştir ki %87 tutarlılıkla en iyi sonucu 4 gamm ve 64 maliyet değerine sahip SVM modeli ile elde etmişlerdir (Soh vd. 2018).

HVAC sistemlerinde termal konfor, kabul edilebilir kapalı ortam hava kalitesi ve enerji tasarrufu sağlamanın aynı zamanda da sistem güvenilirliğini garanti etmenin bir yöntemi de oluşan hataları ya da arızaları doğru bir şekilde tespit etmektir. Genel olarak listelenen arızalardan üst sıradaki birkaçı HVAC sistemleri için önemli hatalar olduğu bildirilmiştir (Katipamula ve Brambley, 2005). Bu hataları doğru bir şekilde tespit etmek, HVAC sistemlerinde boşa harcanan enerjinin %30'a varan oranda önlenmesini sağlayabilir (EIA-0484, 2009). Gerçekçi bir durumda HVAC sistemleri arızalanabilir ya da çeşitli işletim problemleri nedeniyle performansı düşebilir. Bu nedenle Guo ve ark. HVAC sistemlerindeki hataların tespiti ve bu tespit sırasında kullanılacak olan sensörlerin seçimi için yapay öğrenme yöntemlerine başvurdukları bir çalışma yapmışlardır. Hata tespiti için dinamik Bayes ağları (Dynamic Bayesian Networks – DBNs) ve HMM kullanılmıştır. Hangi sensörlerin hangi özelliklerinin sisteme girdi olarak kullanılması gerektiğine de takım kümeleme algoritması (ensemble clustering algorithm) ve rapid centroid estimation (RCE) birleşimi olan Ensemble Rapid Centroid Estimation (ERCE) yönteminden faydalanılmıştır. Bu yöntemi tercih etmelerindeki sebep ise geleneksel k-means ve fuzzy c-means algoritmalarına göre daha iyi sonuçlar üretmesidir. Sistem dinamik olarak 15 sensörden 6'sı üzerinden veri toplamaya karar vermiştir. Veriler her 1 dakikada kaydedilmiştir. İki aylık bir süreçte toplanan veriler üzerinde yapılan testlere göre sıcak su vanasında sıkışma, dönüş havası ya da dış hava damperlerindeki sıkışma,

besleme havası fanı kemerindeki kaymalar ve kişisel alan sıcaklık hataları gibi arızaları %70 ile %100 arasında yakalayabilmiştir (Guo vd. 2017).

Endüstri yönergelerine göre HVAC kontrolleri sembolik değerlere ayarlanırlar ki bu ayar bina içinde bulunanların tamamını, farklı tercihler, aktiviteler ve ihtiyaçlardan ötürü memnun etmeyebilir. Da Li ve arkadaşları termal konforu maksimize etmeyi hedefleyerek kişiselleştirilmiş HVAC kontrol sistemi geliştirmişlerdir. Bu çalışmada kapalı ortam sıcaklık, nem, CO<sub>2</sub> seviyesi ve pencerelerin açıklık durumu sensörler; hava durumu, dış ortam sıcaklık ve nem oranı internet servisleri; bina sakinlerinin hareketlilik durumları giyilebilir teknoloji cihazları ve bina sakinlerinin giyim seviyesi ile ortam sıcaklığı hakkında hissettikleri mobil uygulama vasıtası ile toplanmıştır. MongoDB üzerinde tutulan veriler 3 tipe ayrılmıştır:

1. Ortamda bulunanların cinsiyeti ve yaşı gibi kişisel bilgilerin saklandığı 'UserInfo'
2. Konfor tahmin modelinin geliştirileceği, zaman etiketi olan kişi ve çevre durumunun saklandığı 'UserData'
3. Her 30 dakikada bir gerçekleştirilen her karar döngüsü sırasında ortam sakinlerinin ortam konforu hakkında verdikleri oyların güncellendiği 'VoteResult'

Lojistik Regresyon (Logistic Regression – LR), k En yakın Komşu (k-Nearest Neighbor – kNN), SVM ve Rassal Orman (RF – Random Forest) yapay öğrenme yöntemleri denenmiş ve en yüksek sınıflandırma tutarlılığına sahip olduğu için çalışmanın tamamında RF kullanılmaya karar verilmiştir. Kişiselleştirilmiş konfor tahmin modelleri, RF algoritması kullanılarak geliştirilmiştir. Bu algoritma, toplanan veriler kullanılarak eğitilir ve sınıflandırılmış çıktı daha sonra kolektif bir karar algoritmasından geçirilir. Karar algoritması bina sakinlerinin çoğunu memnun edecek şekilde HVAC'ı kullanarak sıcaklığı artırmaya ya da azaltmaya karar verir veya pencerelerin açılması için kullanıcıları uyarır. 45 gün boyunca toplanan veri kullanılarak yapılan testler sonunda sıcaklık kaynaklı konfor şikayetlerinde %53,7 oranında azalma gözlemlenmiştir (Menassa vd. 2017).

Yapılan başka bir çalışmada ise termal konforun tahmin edilmesinde PMV'nin eksik yanlarına dikkat çekilmektedir. Bu çalışmaya göre PMV, bireysel sıcaklık algılamadaki farklılıkları yansıtamayan, ortalama bir modeldir. Örneğin bir kişi için nemin %35 olduğu bir ortamda sıcaklık 23 °C ile 27 °C arasında salınması onu rahat hissettirirken bir diğeri için bu aralık 24 °C ile 26 °C olabilir. Bu çalışmada da önceki bölümlerde anlatıldığı gibi bina sakinlerinden geri bildirim toplamak için mobil uygulamadan faydalanılmıştır. Bu veri ile birlikte iç ortam sıcaklığı ve nem oranı da

sensörler vasıtası ile kaydedilmiştir. Sınıflandırma yöntemi olarak Destek Vektör Sınıflandırıcısı (Support Vector Classification – SVC) kullanılmıştır. Toplanan verinin %80'i oluşturulan modelin eğitimi, %20'si de doğrulanması amacı ile kullanılmıştır. Model tamamlandıktan sonra girdiler, ortamda bulunan kişiler için en uygun sıcaklık ve nem oranının bulunması için kullanılır ve bu ayar noktası HVAC'da uygulanmak üzere bina yönetim sistemine (Building Management System – BMS) iletilir. Modelin eğitimi için 2 ay süre ile yaşları 22 ile 26 arasında değişen farklı cinsiyetteki 8 kişiden 1955 satırdan oluşan bir veri seti toplanmıştır. Yapılan vaka analizi şunu göstermiştir ki önerilen yöntem deneklerin termal hissiyatını %86,43 ile %97,04 oranında doğru tahmin etmiştir (Li vd. 2017).

Yukarıdaki çalışmada bina sakinlerinden geri bildirim almadaki zorluklar göz ardı edilmiştir. Özellikle veri boyutu 64 anket girişine ulaştığında kişisel konfor modelleri genellikle anlamlı hale geldiği bir çalışmada belirtilmiştir. Bu demektir ki anket kullanarak geri bildirimlerin toplanması, modelin eğitimi için sınırlayıcı bir faktördür. Joyce Kim ve arkadaşları kâğıt üzerinde ya da bir uygulama aracılığıyla toplanmış olması fark etmeksizin bu tarz anketleri kullanarak bilgi toplamanın zorluğunun farkında oldukları için önerdikleri yöntemlerini kişilerin termostat ayarlarına yaptıkları müdahaleden veri toplama üzerine kurmuşlardır. Çevresel koşullar (ortam sıcaklığı ve nem oranı) her 5 dakikada bir, dış ortam hava koşulları da her saat başı olmak üzere 6 ay boyunca toplanmıştır. Yine 6 ay boyunca 38 kişiden termostat ayarı davranışları kayıt edilmiştir. Modelin eğitimi için deneklerden günde 3 defa, mevcut durumdaki termal kabul edilebilirlik, termal tercih ve giyim durumunu belirten online bir anket doldurmaları istenmiştir. Modelde hangi yapay öğrenme yönteminin kullanılacağına karar vermek için Sınıflandırma Ağacı (Classification Tree – CT), Gauss Süreci Sınıflandırması (Gaussian Process Classification – GPC), Gradyan Artırma Yöntemi (Gradient Boosting Method – GBM), Çekirdek Destek Vektör Makineleri (Kernel Support Vector Machine – kSVM), RF ve Düzenlenmiş Lojistik Regresyon (Regularized Logistic Regression – regLR) karşılaştırılmıştır. Yüksek boyutları kontrol ve verideki gürültü ile baş edebilmeleri üstünlükleri sebebiyle RF, kSVM, regLR en tutarlı sonuçları üretmişlerdir. PMV'nin termal konfor tahminindeki medyan tutarlılığı %51 olduğu durumda önerilen yöntemde bu değer %73'tür (Kim vd. 2018).

Özellikle Singapur gibi sıcak ve nemli bir iklime sahip ülkelerde termal konforun yüksek doğrulukta ölçülmesi, ekstra soğutma yüküne sebep olarak, enerji tasarrufuna engel olacağından büyük öneme sahiptir. Bu nedenle bu bölgede yapılan bir çalışmada, bina sakinlerinin termal konfor seviyesini tahmin etmek için çevresel ve insan faktörünü girdi olarak alan, veri güdümlü bir yöntem önermişler ve bu yöntemi

geleneksel Fanger'in PMV'si ile karşılaştırmışlardır. On iki ofisten 235, dört meskenden de 583 olmak üzere toplamda 818 kişinin bulunduğu farklı binalarda yapılan vaka çalışmasında iç ve dış ortam sıcaklığı, hava akımı hızı, nem oranı gibi çevresel parametreler yanında, cinsiyet, yaş, metabolik oran, giyiniklik miktarı ve termal konfor anketi sonuçları veri olarak toplanmıştır. Toplanan verinin %70'i modelin eğitimi %30'u da doğrulanması için kullanılmıştır. Her bir bina sakinine o an ortamda nasıl hissettiğini (Actual Mean Vote – AMV) (Fanger, 1970) ifade etmesi için anketler dağıtılmıştır. Anketlerde 3 seçenek mevcuttur; rahatsız edici derecede soğuk (PMV'nin -3 ve -1 değer aralığına denk gelmektedir), normal/konforlu (PMV'de -1 – 1 arası) ve rahatsız edici derecede sıcak PMV'de 1 – 3 arası). Öncelikle veriler aralarında SVM, ANN, LR, Lineer Diskriminant Analizi (Linear Discriminant Analysis – LDA), kNN ve Sınıflandırma Ağaçları (Classification Trees – CTs) olan yöntemlerden uygun sınıflandırıcının seçimi için kullanılmıştır. Dış ortam sıcaklığı, yaş ve cinsiyetin tahmin tutarlılığına olan etki ölçülmesi için tüm testler bu parametrelerin olduğu ve olmadığı 2 farklı veri setleri ile 2 defa tekrarlanmıştır. Yapılan testler şunu göstermiştir ki SVM, PMV'ye göre %73,14 ile %81,2 arasında daha tutarlı sonuçlar üretmiştir. Ayrıca PMV'de dış ortam sıcaklığı, yaş ve cinsiyet denklem dışı bırakılırken, bu çalışmada bu değerlerin önemli olduğu tespit edilmiştir (Chaudhuri vd. 2017).

Daha önceden de bahsedildiği gibi bir ortamdaki termal konforu tahmin etmenin standart yöntemi PMV'nin hesaplanmasıdır. Buna alternatif olarak yapılan bir çalışmada En küçük kare – Destek Vektör Makineleri (Least Square Support Vector Machine – LS-SVM) yapay öğrenme yöntemi kullanarak PMV'ye kıyasla daha iyi kapalı ortam termal konforunun tahmin edilebileceğini öne sürülmüştür. Fakat öncesinde LS-SVM'de kullanılan düzenleme ve çekirdek parametreleri, Particle Swarm Optimization (PSO) algoritması ile optimize edilir. Öncelikle simülasyon ile 1000 veriden oluşan bir küme oluşturulmuş, bunun 800'ü LS-SVM'in eğitimi kalan 200'ü de modelin doğrulanması için kullanılmıştır. Önerilen yöntemin PMV'ye göre %1 ile %12 arasında daha tutarlı sonuçlar ürettiği gözlemlenmiştir (Bin ve Ke, 2010).

Termal konforun gerekliliklerini karşılamak için başka bir çalışmada ise iç ortam sıcaklığının dinamik ve otomatik olarak düzenlenmesini hedefleyen kombine bir neuro-bulanık modelin uygulanması sunulmuştur. Yapay sinir ağı, HVAC sisteminin açık/kapalı anahtarlamasını ve giriş havası hızının düzenlenmesini yapan bulanık mantık kontrol ünitesine iç ortam sıcaklık tahminlerini beslemek için kullanılmıştır. Kapalı ve açık ortam hava sıcaklıkları, rüzgâr hızı ve iç ortam nem oranı sensörler vasıtası ile Sinir Ağı-Otoregresif Harici Giriş (Neural Network Auto Regressive External Input – NNARX) yapay sinir ağı modeline kapalı ortam termal konforunun

tahmin edilmesi için iletilmiştir. Vaka analizi için bir yıl boyunca toplanan veri üzerinde çalışılmış, analiz yaz ve kış dönemleri için ayrı ayrı gerçekleştirilmiştir. NN modelleri, termal konforda oldukça karmaşık veri kümeleriyle başa çıkmak için güçlü bir yöntem olarak kullanılmıştır (Chen ve Deng, 2018). Bina sakinlerinden gelen geri bildirimlerle de NN'deki üyelik fonksiyonları her defasında yeniden düzenlenmiştir. Kullanıcının geri bildirimini bulunan ortamdaki termal hissiyatın sıcak ya da soğuk olmasından ibarettir. Bu da yine ortamdaki bu işlem için tasarlanmış prototip bir cihaz yardımı ile yapmaktadır. Bulanık kontrol için belirlenen dilsel değerler, Fanger'in ortaya koyduğu yedi noktalı termal hissiyat ölçeğindedir ve her biri yaz ve kış mevsimleri için ayrı ayrı °C cinsinden sayısal değer aralıklarına sahiptir. Tahmin edilen sıcaklık, Gaussian Üyelik fonksiyonundan geçirilerek son çıktıya ulaşılır. Bu tahmin kullanıcı geri bildirimleri ile karşılaştırılarak üyelik fonksiyonu yeniden düzenlenir. Daha sonra Mizumoto (Li vd. 2009) fonksiyon yardımı ile bulanık mantıktan çıkarma işlemi yapılarak net mantık kararları alınır, yani HVAC sisteminin nasıl çalışacağına karar verilir. Geleneksel yöntemlerde fan hızı yaz aylarında en yüksek hıza 1 gün içinde ortalama 8 kez çıkarken, önerilen yöntem ile ortalama 2 defa çıkmıştır. Aynı değer kış aylarında ise geleneksel yöntemde 9 iken önerilen yöntemde 6'dır (Collotta vd. 2014).

Isıtma ve soğutma sistemlerindeki verimsiz kontrol stratejilerinin, büyük miktarda enerji israfına ve binalardaki termal çevre ile ilgili şikayetlerin artmasına neden olmasından yola çıkılan bir başka çalışmada SVM tabanlı zeki bir kontrol stratejisi önerilmektedir. Modeli mümkün olduğunca basit tutmak adına sadece bir girdi ile bina içindeki termal hissiyatı tahmin edilmeye çalışılmış ve bunun için de cilt sıcaklığından faydalanılmıştır. Öncelikle giyilebilir teknoloji yardımı ile farklı kişilerden veri topladıkları iki farklı test ortamı oluşturulmuştur. Yapılan birinci deneyde 11 kişi yer almış ve yapılan 70 deney sonucunda 969 oy toplanmıştır. Deneklerin vücutlarına yerleştirilen 13 farklı noktadaki sensörden her 5 saniyede bir ölçüm yapılmış ve her 1-3 dakika arasında karşılarındaki bilgisayar vasıtası ile termal hissiyatları ASHRAE'nin yedi noktalı ölçeğe göre oylamaları sağlanmıştır. Toplanan oylar daha sonrasında IBM'in SPSS aracı kullanılarak 5 kümeye bölünmüştür. Fakat çalışmanın çıktısının sadece ısıtma ihtiyacı, doğal ve soğutma ihtiyacı olacak şekilde üç farklı talepten birinin olması gerekmektedir. Bu nedenle öncelikle beş küme içe düşürülmüştür. Daha sonra da cilt sıcaklıkları ve oylarla birlikte SVM eğitilmiştir. Bu sırada amaç vücudun 13 farklı noktasından toplanan cilt sıcaklığının bir tanesinin ne kadar tutarlı talep tahmini üretebildiğini bulmaktır. Testler, kaval kemiğinden alınan verinin %80'den fazla tutarlılıkla doğru sonuç ürettiğini göstermiştir. Birden fazla noktadan toplandığı durumlarda ise %94,4 tutarlılığa göğüs, üst kol ve kaval kemiğinden alınan verilerin kombinasyonu ile ulaşılmıştır. Yapılan ikinci deneydeki

amaç ise bir grup insan yerine bir denekten veri alındığındaki durumda oluşan tahmin tutarlılığını bulmaktır. Yedi gün boyunca bir denekten cilt sıcaklığı verisi ile iç ve dış ortam sıcaklık ve nem oranı ve giyilen kıyafet miktarı da toplanmıştır. Bu deneyde ise sırt, kaval kemiği ve elden alınan sıcaklıklar ile %94,1 oranında doğru tahmin üretmeyi başarmışlardır. SVM kullanıldığında dikkat edilmesi gereken en önemli nokta kernel fonksiyonunun seçilmesidir. Bu nedenle de yaptıkları çalışmada Doğrusal Çekirdek (Linear Kernel) ve Gauss Çekirdeği (Gaussian Kernel) karşılaştırılmıştır. Ayrıca yapılan iki deney de göstermiştir ki Gauss Çekirdeği daha iyi sonuçlar üretmektedir (Dai vd. 2017).

Termal rahatlığın sağlandığı iç ortamın hem sağlık hem de üretkenliği olan etkisine her geçen gün daha fazla dikkat çekildiğini belirten başka bir çalışmada ise Geri Yayılımlı Sinir Ağı (Back Propagation-Neural Network – BPNN) tabanlı bireysel bir termal konfor modeli ortaya koymaya çalışılmıştır. Çalışmada, uygun bir kapalı ortam termal ortamı oluşturmak için, her şeyden önce, bir ortamdaki insan termal konforu doğru bir şekilde değerlendirilmesi gerektiği belirtilir ve mevcut değerlendirme modellerinin bireysel değerlendirme için uygun olmadığı öne sürülmektedir. Daha önceden de belirtildiği gibi termal konfor üzerinde ASHRAE'nin belirlediği iki adet kişisel faktör ile dört adet çevresel faktörün etkisi mevcuttur. Çevresel faktörlere ait veriler sensörler yardımı ile toplanmıştır. Altmış beş erkek ve 48 kadın olmak üzere 113 denek ile çalışılmıştır. Bir odada 30 dakika geçirdikten sonra farklı hava akımı ve sıcaklıklar için ASHRAE'nin yedi nokta ölçeği ile uygun olacak şekilde termal hissiyat geri bildirim alınmıştır. Bununla birlikte deneklerden her durum için farklı fiziksel aktivite de yapmaları da talep edilmiştir. Her denek 20 ile 40 farklı teste tabi tutulmuştur. Toplanan bu veriler BPNN'nin eğitiminde ve optimizasyonunda kullanılmıştır. Yapılan testlere göre önerilen yöntem %80 oranında tutarlı tahmin yürütebilmektedir (Lian vd. 2007).

Yüksek enerji verimliliği, daha yüksek termal konfor ve daha iyi iç ortam hava kalitesi sağlamayı amaçlayan başka bir çalışmada ise yapay öğrenme algoritmalarıyla birleştirilmiş, akıllı öğrenen nesnelerin interneti (Internet of Things – IoT) sistemi geliştirilmeye çalışılmıştır. İç ortam sıcaklığı ve nem oranı sensörler, dış ortam sıcaklığı ve nem oranı verileri internet servisleri yardımı ile her 5 dakikada bir 25 gün boyunca toplanmıştır. Kullanıcının istediği sıcaklık değeri de mobil uygulama aracılığıyla toplanmıştır. Toplanan veriler her 30 dakikada bir regresyon denetimli öğrenme algoritması (regression supervised learning algorithm) olan M5P algoritmasında değerlendirilip, bina içinde bulunanların ortalama termal konforu tahmin edilmeye, ve uygun bir iç ortam sıcaklığı önerilmeye çalışılır. Yapılan testler göstermiştir ki önerilen yöntem %15 göreceli mutlak hata (Relative Absolute Error –

RAE) değeri üretmektedir ki bu değer aynı veriseti için doğrusal regresyon (Linear Regression) kullanıldığında %92'ye yakındır (Tin vd. 2017).

Gelecekteki iç ortam sıcaklığını tahmin ederek, HVAC ayarlarını değiştirip, termal konforu artırmayı hedeflemek ise farklı bir yaklaşımdır. Yapay öğrenme modülü olarak NNARX kullanan bir başka çalışmada dış ortam faktörlerini (dış sıcaklık, havaya bağlı nem ve rüzgar hızı) ve önceki zamanlarda kaydedilen iç sıcaklığı kullanarak iç ortam sıcaklığının 1 saat sonraki değerini tahmin etmeye çalışılmış ve çıktısını bulanık mantık (Fuzzy Logic – FL) kontrol ünitesine aktarılmıştır. FL kullanılarak HVAC sisteminin açık ya da kapalı olma durumunu veya içeri giren hava hızını değiştirerek çeşitli simülasyonlar yapılmıştır. Öncesinde, uygun sayının tespiti için nöron sayıları 10'dan 70'e kadar onar-onar olacak şekilde artırılarak testler yapılmıştır. Testlerin yapılması için iç ve dış ortamlardaki sensörlerden her beş dakikada bir olacak şekilde bir yıl boyunca veri toplanmıştır. Toplanan verinin %70'i yapay öğrenme modülünün eğitimi, %15'i doğrulanması ve %15'i de test edilmesi için kullanılmıştır. Yapılan testler sonucunda en iyi tahminlerin kış mevsimi için gizli katmandaki 30 nöron ile üretildiği, yaz ayları içinse 10 nöron ile ortalama 0,3 derecelik hata ile üretildiği tespit edilmiştir (Messineo vd. 2014).

Termal konforun gerçek zamanlı olarak belirlenmesi olmadan, HVAC sistemlerinin insanın rahatı için kontrollü hava koşulları sağlaması her zaman mümkün olmayabilir. Bu önermeden ve PMV'nin gerçek zamanlı olarak hesaplanmasının kullanışlı bir çözüm olmamasından yola çıkarak yapılan bir çalışmada, İleri Doğru Sinir Ağları (Feed Forward Neural Network – FFNN) kullanılarak bu sorunlar aşılmaya çalışılmıştır. Öncelikle odaya yerleştirilen sensörler ile iç ortam sıcaklık, nem, hava akımı ve duvar sıcaklıkları bilgileri dokuz saat boyunca her on dakikada bir toplanmıştır. Daha sonra bu veriler sekiz ve beş nörona sahip iki gizli katmana sahip NN'in eğitiminde kullanılmıştır. Yapılan testler göstermiştir ki gerçek PMV ve önerilen NN modeli arasındaki karesel yanılğı toplamı (Sum of Squared Error – SSE) değeri sadece 0,11'dir (Leephakpreeda ve Atthajariyakul, 2005).

Yine PMV'nin kullanımının hem yüksek işlem gücü gerektirmesinden hem de göreceli olarak geniş çaplı sensör ağı yardımıyla yapılan ölçüm gerektirmesi zorluğundan yola çıkan başka bir çalışmada araştırmacılar yapay sinir ağları ve polinom genleşmelerinden faydalanarak bu sorunu çözmeye çalışmışlardır. Bunun için de test ortamına yerleştirdikleri sıcaklık, nem, hava akımı, radyan sıcaklık ve kuru küre sıcaklık sensörlerinden yaz ve kış aylarından 44.568 satır veri toplamış ve bu veriler iki yöntemin karşılaştırılması için hem model eğitimi hem doğrulanması hem de test edilmelerin kullanılmıştır. ANN için tercih edilen algoritma Levenberg-

Marquardt'dır. ANN'nin yapısı ise her bir katmanında sekiz ve dört nöron olacak şekilde iki gizli katmandan oluşmaktadır. Yapılan testler sonucunda görülmüştür ki ANN, polinom modele göre ortalama hatanın kare kökü (Root Mean Squared Error – RMSE) değeri %30 ile %40 arasında olacak şekilde daha iyi termal konfor tahmini üretmektedir (Álvarez vd. 2013).

Başka bir çalışmada ise termoelektrik hava kanalı (thermoelectric air duct – TE-AD) soğutma sistemlerinde de ANN'in termal hissiyat tahmininde kullanılabileceği gösterilmiştir. Yapılan çalışmada onlu termal hissiyat ölçeği (-5 ile +5 arasında değişecek şekilde) kullanılmış, ve hissiyatın tahmin edilmesinde için de Levenberg-Marquardt algoritması temelli üç farklı ANN modeli oluşturulmuştur. Farklı yaş, boy ve kilolarda olan 10 kadın ve 10 erkekte oluşan 20 kişiden termal hissiyat, metabolik hız ve kıyafet izolasyonu bilgileri toplanırken bir yandan da sensörler aracılığıyla iç ve dış ortam koşulları verisi beş hafta boyunca kaydedilmiştir. Verisetinin farklı bölümlerinden üç farklı eğitim ve test setleri oluşturulmuş ve bu üç set için 5, 10 ve 15 nöron içeren üç ANN yapısı oluşturularak toplam dokuz deney gerçekleştirilmiştir. Yapılan deneylere göre PMV değerinin hesaplanmasındaki en az hata (MSE) 0,07956 ile 10 nöron kullanan ve verisetinin birinci %75'lik bölümünü kullanan model ile sağlanmıştır. Öte yandan PPD'nin tahmin edilmesinde ise en düşük hata (MSE) 5,1789 ile yine 10 nöron kullanarak ve verisetinin son %75'lik bölümü ile eğitilen model ile sağlanmıştır (Irshad vd. 2020).

Doğru bir termal konfor modelinin iç ortam sakinlerinden büyük miktarda termal konfor verisinin gereksiniminin araştırmacılar için bir zorluk olduğuna bir başka çalışmada dikkat çekilmiş ve buna bir çözüm bulmaya çalışılmıştır. Aynı iklim kuşağında bulunan farklı şehirlerden elde edilen sensör verisinden öğrenme aktarması tabanlı çok katmanlı algılayıcı (Transfer Learning-Based Multi Layer Perceptron – TL-MLP) modeli kullanarak termal konfor örüntüleri elde edilmesi hedeflenmiştir bu çalışmada. Elde edilen bu örüntüler daha sonra başka şehirlere aktarılmıştır. Bunu başarmak için de modelin eğitiminde ASHRAE'nin erişime açık olan RP-884 termal konfor veriseti kullanılmıştır. Verisetinde 26 şehirden toplanmış 25.000'den fazla gözlem bulunmaktadır. Yapılan deneyler göstermiştir ki önerilen yöntem termal hissiyatı 5'li ölçekte %54,5 tutarlılıkla tahmin edebilmektedir. Buna en yakın değeri %51 ile RF sağlarken, geleneksel PMV yöntemi %33,35 ile doğru tahmin yürütebilmektedir (Salim vd. 2021).

Termal hissiyatın doğru olarak ölçülebilmesi için önemli faktörlerden biri de doğru değişkenlerin ANN modeline girdi olarak sağlanmasıdır. Bu yaklaşımdan yola çıkan bir çalışmada farklı ANN yaklaşımları farklı parametrelerle test edilmiştir. Modellerin eğitimi için bizim de çalışmamızda yer alan, açık erişime sahip

ASHRAE'nin küresel termal konfor veri tabanının ikinci versiyonu kullanılmıştır. Çeşitli filtreler sonrası elde edilen verisetinde 10,618 satır veri bulunmaktadır. RF, LR, SVM ve KNN gibi bilinen yöntemler aynı veriseti ve aynı değişken setleri kullanılarak eğitilmiş ve test sonuçları karşılaştırılmıştır. Klasik PMV hesaplamasında kullanılan değişkenlerin yanı sıra, mevsim, binada kullanılan havalandırma yöntemi, binanın kullanım amacı ve deneğin cinsiyeti değişkenleri de karşılaştırılan modellere girdi olarak sağlanmıştır. Yapılan testler göstermiştir ki en iyi performansı %66,3 tutarlılıkla sağlayan yöntem, tüm parametreleri kullanarak termal hissiyatı üçlü ölçekte tahmin etmeye çalışan RF'dir. Aynı şekilde eğer ölçek yedi ile sınırlandırılırsa, tahmin tutarlılığı da %61,1 olarak yine RF en iyi performansı sağlamaktadır (Zhang vd. 2020).

## 2.7. Yapay Öğrenme ile Enerji Tasarrufu Sağlanması

Ülkemizde 2017 verilerine göre enerji üretiminin 2017 yılında elektrik üretimimizin, %37'si doğal gazdan, %33'ü kömürden, %20'si hidrolik enerjiden, %6'sı rüzgârdan, %2'si jeotermal enerjiden ve %2'si diğer kaynaklardan elde edilmiştir. Ayrıca 2018 yılı ilk yarısı sonunda kurulu gücümüzün kaynaklara göre dağılımı; %32'si hidrolik enerji, %26,4'ü doğal gaz, %21,4'ü kömür, %7,7'si rüzgâr, %5,4'ü güneş, %1,3'ü jeotermal ve %5,8'i ise diğer kaynaklar şeklindedir (EB, 2018). Türkiye Cumhuriyeti Çevre ve Şehircilik Bakanlığının yayımladığı rapora göre 2018 yılında toplam üretimin %23'ü meskenler tarafından tüketilirken, %25'i de sanayi tarafından tüketilmektedir (CSB, 2019). Özellikle, yenilenebilir kaynaklardan faydalanma oranındaki azlık, doğal gazın ithal edilmesi ve kömürün çevre ve insan sağlığına verdiği zararlar göz önüne alındığında tüketimde tasarruf sağlamak elzemdir. Uzun yıllardır bilinen bir gerçek vardır ki o da bir binadaki dinamik iklimlendirme yükünün öngörülmesi, HVAC sistemi tasarımı için kilit bir noktadır. Dahası, başlatılma esnasında oluşacak yükün karşılanması, en yüksek elektrik talebinin en aza indirilmesi veya sınırlandırılması, maliyet ve enerji kullanımının optimize edilmesi için soğutmanın başlangıç zamanının ayarlanması da dahil olmak üzere HVAC sisteminin işletilmesinde çok kullanışlıdır (Bida ve Kreider, 1987).

Bina yönetim sistemlerinin HVAC için önceden belirlediği çalışma saatleri dahilinde ticari binalarda her zaman insanlar bulunmayabilir. Bu durum, ofis sakinlerinin davranışları ile ilişkili, HVAC sistemlerinin gereksiz enerji taleplerini azaltma fırsatı sunar. Bu durumu göz önünde bulunduran bir çalışmada, ofis sakinlerinin rastgele davranışlarının gerçek zamanlı olarak incelenmesinin HVAC sistemlerinin verimliliğini artırmadaki etkisini araştırılmıştır. Çalışmada, enerji tüketimini azaltmak için enerji kaynaklı davranışlara otomatik olarak yanıt veren ve

statik soğutma gibi benzer performanslara sahip, kişiler için oda sıcaklığını koruyan, talep odaklı bir kontrol stratejisi önerilir. Bu denetim stratejisinde, ofis sakinlerinin davranışlarını öğrenmek için iki tür yapay öğrenme yöntemi (denetimsiz ve denetimli öğrenme) uygulanmıştır. Algoritmalar tarafından öğrenilen dolulukla ilgili bilgiler, ofisin soğutma sistemini kontrol etmek için gerçek zamanlı ayar noktalarını bulmak için kurallar dizisi tarafından kullanılır. Bu öğrenme temelli yaklaşım, soğutma sisteminin kontrolünde insan müdahalesi ihtiyacını azaltmayı amaçlamaktadır. Araştırmacılar, önerdikleri stratejiyi, gerçek dünya koşulları altında kendi ofis binalarının soğutma sistemini kontrol etmek için uygulamışlar ve bunu tek kişilik ve çok kişilik ofislerle toplantı odalarını da kapsayan 11 farklı noktada test etmişlerdir. Daha önceden bina yönetim sistemi tarafından toplanan 7,5 aylık mevcut veri üzerinden sistemi eğitmek için geniş kullanım alanına sahip, sağlanan veriden belirli sayıda kümeler çıkarmaya çalışan bir denetimsiz öğrenme yöntemi olan, k-merkezli kümeleme kullanılmıştır. Daha sonrasında ise ofis sakinlerinin bir sonraki davranışlarını tahmin etmek için, denetimli öğrenme yöntemlerinden biri olan KNN tercih edilmiştir. Ofis ve toplantı odalarındaki doluluğun algılanmasında hareket sensörlerinden, iklimlendirme koşullarının algılanması için (sıcaklık, nem ve CO<sub>2</sub> miktarı) iklim sensörlerinden, önerilen yöntemin sağladığı tasarrufun ölçülmesinde ise enerji ölçerlerden faydalanmışlardır. Toplanan veriler MATLAB ile işlenmiştir. Deney sonuçları göstermiştir ki geleneksel olarak planlanan soğutma sistemlerine kıyasla %7 ile %52 arasında enerji tasarrufu sağlanmıştır (Peng vd. 2018).

Enerji tasarrufunun tanınımının yapıldığı bölüm 2.4'te bahsedildiği gibi enerji tüketimini azaltmanın yöntemlerinden biri de eskiyen parçaları ya da sistemin tamamını yenilemektir. Bu konu üzerinde yoğunlaşan bir çalışmada Singapur'daki 56 ofisteki bina özelliklerine ait verileri ve enerji tüketimine dair verileri incelenmiştir. Çalışmanın amacı, iyileştirme öncesi ve sonrasındaki tüketim göz önünde bulundurularak, hangi değişkenlerin daha etkin olduğunu tespit eden bir model çıkarmaktır. Bu başarmak için de ANN ve Çoklu Doğrusal Regresyon (Multiple Linear Regression – MLR) karşılaştırılmıştır. Modelin eğitimi için 40 binadan, geçerliliğinin onaylanması için 16 binadan toplanan veriler kullanılmıştır. 14 değişken ile en tutarlı modeli ortaya koymak için 819.150 tekrar yapılmıştır. Her bir değişkenin birbiri ile olan ilişkisini anlamak için 16.383 farklı kombinasyon oluşturulmuş, tüm kombinasyonlar da 50 farklı model ile denenmiştir. %14,8 Ortalama Mutlak Yüzde Hatası ile (Mean Absolute Percentage Error – MAPE) en tutarlı modeli 4 gizli katmanı bulunan ANN ile elde etmişlerdir. Modelin tutarlılığında en büyük öneme sahip değişkenler; brüt kat alanı, iklimlendirme enerji tüketiminin toplam tüketime oranı, çalışma süresi, ortalama soğutma tesis verimliliği ve kurulmuş olan soğutucuların toplam kapasitesidir. Bundan

sonra o bölgede yapılacak olan HVAC yenilemelerinde hangi değişkenin enerji tasarrufu üzerinde ne kadar etkisi olacağını tahmin edilmesi için bu modelden faydalanmak mümkündür (Deb vd. 2018)

HVAC'ın kullandığı enerji tüketimini azaltmanın bir başka yöntemi de mevcut koşulları korumaktır. Valencia'da yapılan bir çalışmaya göre belli bir sıcaklığı devam ettirmek için gereken enerji, onu elde etmek için ortam sıcaklığını artırmak ya da azaltmaktan daha az enerji gerektirmektedir. Yapılan bu çalışmada çevrimiçi öğrenme tekniklerini uygulayarak tamamen bilinmeyen bir çevre için öngörü sistemlerinin geliştirilmesi ve uygulanabilirliğini incelenmiştir. Çalışmaya göre model parametreleri tamamen bir rastgele modelden veya tarafsız bir önsel bilgiden başlayarak tahmin edilmektedir. Bu tahmin ölçümleri, ev otomasyonunu enerji verimli bir şekilde kullanarak evin gelecekteki sıcaklık koşullarına uyum sağlamasına olanak sağlar. Amaç, dört ya da beş günlük kısa eğitim süresi ve daha basit model kullanarak daha tutarlı tahminlerde bulunmaktır. Bayes çevrimiçi ve Gradyan İnişi (Gradient Descent – GD) çevrimiçi algoritmaları karşılaştırılmıştır. Bu karşılaştırma için beş farklı tipteki 88 sensörden her 15 dakikada bir toplanan 4136 satır veri kullanılmıştır. Modelin performansını ölçebilmek için bu veri kümesi, 2764 örnek eğitim (yaklaşık 28 günlük veri) ve 1373 örnek test (yaklaşık 14 günlük veri) olacak şekilde ikiye ayrılmıştır. Buna göre en iyi sonuç, model 2 gizli katman ve 24 ya da 16 nöron ile tasarlandığında ve 5 günlük eğitim ile elde edilmiştir ki ortalama hata 1 °C derecenin altındadır (Martínez vd. 2014).

Benzer bir amaçla yola çıkan başka bir çalışmada mevcut ortam koşullarını korumanın daha az enerji tüketimine yol açacağı ifade edilmiştir. Kısa ve çok kısa vadede sistemde oluşacak soğutma yükünü tahmin etmeye çalışarak, önlem alma yöntemi ile enerji tasarrufu ve termal konforu hedeflenmiştir. Bir gün ve bir saat sonra oluşacak soğutma yükü doğru tahmin edilip, bina yönetimine haber verilirse, HVAC önceden istenen koşullar için ayarlanabilir. Bunu sağlamak için ihtiyaç duyulan veriler arasındaki en önemli olanı hava durumu tahminidir. Kısa ve çok kısa vadedeki oluşacak yükün tahmin edilmesi için Genetik Algoritma (GA) – Destek Vektör Regresyon (Support Vector Regression – SVR) ve Genetik Algoritma (Genetic Algorithm – GA) – Dalgacık Ayrışımı (Wavelet Decomposition –WD) – SVR iki farklı yöntem kullanılmıştır. Bu çalışmada SVR'in görevi, soğutma yükü ile onun tahmin edilmesinde kullanılacak olan girdi parametreleri arasındaki ilişkiyi modellemektir. Bu işlem öncesinde parametreler GA kullanılarak optimize edilir. Bina soğutma yükü verileri periyodik ve rastgele koşulları içeren bir sinyal dizisi olarak kabul edilebilir. WD ise soğutma yük sinyalini işlemek; doğal varyasyon kurallarını ve özelliklerini çıkarmak için kullanılmıştır. Bu model Çin'deki 200 kişilik bir ofiste test edilmiştir. Dış

ortamdan sıcaklık, nem, güneş ışması ve rüzgar hızı sensörler vasıtası ile toplanmıştır. İç ortamdan ise sıcaklık, nem ve binanın doluluk oranı bilgileri toplanmıştır. Modelin girdilerinden diğeri de önceki saatte oluşmuş olan soğutma yüküdür. Modelin eğitimi için 21, doğrulanması için de 21 olmak üzere toplam 42 günlük veri toplanmıştır. Test sonuçları göstermiştir ki kısa vadeli tahminlerde GA-SVR %6,5 ortalama hata oranı ile başarılı sonuçlar üretirken, çok kısa vadeli tahminlerde GA-WD-SVR %4,6 ortalama hata oranı ile 1 saat sonraki soğutma yükünü tahmin edebilmiştir. Daha sonra yaptıkları başka bir vaka çalışmasında ise model üzerinde en büyük etkiye sahip değişkenlerin ortalama %7 hata oranı ile dış etkenler olduğunu tespit etmişlerdir. Sadece iç etkenler ile yapılan deneylerde bu değer %17 olarak saptanmıştır (Ding vd. 2018).

Yine aynı araştırma grubu tarafından yapılan başka bir çalışmada ise bina soğutma yükü tahminleri, enerji taleplerini daha iyi anlamak ve HVAC sistemlerinin enerji verimliliğini arttırmak için kullanılabilirliği vurgulanmıştır. Kısa ve çok kısa vadeli tahminlerde bulunacak iki farklı model ortaya konmuştur. Amaç bir sonraki gün (kısa vadede) ve bir sonraki saat (çok kısa vadede) oluşacak soğutma yüklerini tahmin ederek HVAC operasyonun önceden ayarlanması için bina yönetimine haber vermektir. Modele girdi olarak kullanılan parametreler dış ortam sıcaklığı, nem oranı, güneş ışması ve soğutma yüküdür. Bir buçuk ay boyunca 30 dakikada bir kayıt alınmıştır. Bu verinin 21 günlük bölümü modelin eğitilmesinde, geri kalanı ise test edilmesinde kullanılmıştır. Önerilen modelde kullanılan yöntemler, SVR, WD ve GA. Bina soğutma yükünün doğrusal olmayan, yüksek boyutlu ve küçük örneklem adedi özelliklerinden dolayı SVR tercih edilmiştir. WD algoritması, soğutma yükü numunesi üzerinde çok frekanslı bir analiz yapmak ve ardından farklı frekans bantları için SVR tahmin modelleri oluşturmak için tercih edilmiştir. GA ise SVR'in çekirdek fonksiyonu parametrelerinin optimizasyonunda kullanılmıştır. Yapılan testler göstermiştir ki GA-SVR kısa vadeli tahminlerde daha tutarlı sonuç üretirken, GA-WD-SVR çok kısa vadeli tahminlerde daha tutarlı sonuçlar üretmektedir (Ding vd. 2017).

HVAC'ın tükettiği enerjiyi azaltmanın bir yöntemi de sistemin kurulumu öncesi, binanın tasarım aşamasından sonra oluşabilecek ısıtma ve soğutma yüklerini mümkün olduğu kadar doğru tahmin ederek, mühendislere yardım etmektir. Önceden kapasitesi doğru hesaplanmamış HVAC sistemleri, binaların işletim maliyetlerini artırmaktadır. Fakat gerçek zamanlı verinin olmaması tahmin etme sürecinin en büyük kısıtlarından biridir. Bu fikirden yola çıkarak yapılan çalışmada tahmin yürütülürken kullanılan parametreler, binadaki yüzey alan hacim oranı; duvar, zemin ve çatı yüzey alanları; tavan yüksekliği, binanın konumu ve yönü, cam alanları ve bina içindeki dağılımı gibi mimari tasarım sırasında belli olanlardır. Veriler bir simülasyon programı

aracılığı ile oluşturulmuştur. İnşaat malzemesi ve bina hacmi sabit tutulurken, diğer değişkenler farklılaştırılmıştır. Oluşturulan verisetinin %70'i modelin eğitimi, %30'u da doğrulanması için kullanılmıştır. Tahmin etme sürecinde kullanılacak her bir parametrenin önemi Çok Değişkenli Uyarlanabilir Regresyon Eğrileri (Multivariate Adaptive Regression Splines – MARS) ile hesaplanmıştır. Bu hesaba göre yüzey-hacim oranı, çatı alanı, toplam pencere alanları ve toplam yüzey alanı (Catalina vd. 2011) en önemli dört parametredir. Bu parametreler önem bilgisi ile ELM algoritmasında kullanılarak yük tahminlerinin üretildiği melez bir model geliştirilmiştir. Bu sayede tahminlerin tutarlığı artarken, hesaplama süresi de kısalmıştır. Önerilen bu melez model sayesinde hem ısıtma hem de soğutma yüklerinin tahmin edilme süresi yaklaşık %60 oranından azalırken, ısıtma tahmininde yapılan hatalarda %50, soğutma tahmininde yapılan hatalar %15 azalmıştır. Gauss Süreçleri, ANN, LR ve RBF Network gibi geleneksel yöntemlere göre de hem işlem süresi hem de hata oranı olarak daha iyi sonuçlar üretmiştir (Roy vd. 2018).

Yine aynı fikirden yola çıkan bir başka çalışmada ise bu kez sadece soğutma yükünü doğru tahmin etmeye odaklanılmıştır. Gözlemsel Mod Ayrıştırma (Empirical Mode Decomposition – EMD), Derin İnanç Ağı (Deep Belief Network – DBN) ve Topluluk Tekniği (Ensemble Technique) bir arada kullanılarak melez bir yöntem önerilmiştir. Çalışmada soğutma yükü bir zaman serisi olarak kabul edilmiş ve DBN'in katmanlı ve ön eğitim gerektiren yapısı, soğutma yükünün üst seviye doğrusal olmayan özelliklerinin ve gizli yapısının etkin bir şekilde çıkarım yapılması için kullanılmıştır. Fakat öncesinde orijinal girdi sinyali EMD kullanılarak taslağı çıkarılıp, davranışı anlaşılabilir diye birden fazla bileşene bölünmüştür. Hataların etkisinin azaltılması için de işlem boyunca topluluk tekniğinden faydalanmışlardır. Vaka analizi için 15 dakika aralıklarla toplanmış bir yıllık veri kümesi üzerinde çalışılmıştır. Veri kümesinde yer alan parametreler, soğutma yükü, kızıl ötesi kameralar vasıtası ile algılanan ortamda bulunan kişi sayısı, dış ortam sıcaklığı ve nem oranıdır. Her ayın 1'i ve 25'i arası modelin eğitimi, kalan günler ise modelin testi için kullanılmıştır. Bir ve sekiz saat sonrası tahmin edilmeye çalışılmıştır. Tüm sezonlar için bakıldığında önerilen yöntemin BP ve SVM'e göre %25 ila %50 arasında daha tutarlı sonuçlar ürettiği gözlemlenmiştir. Tahmin edilmesi istenen süre arttıkça tutarlılığında arttığı gözlemlenmiştir (Fu, 2018).

Binalardaki enerji tasarrufu stratejileri için yük tahmininin önemine dikkat çeken bir başka çalışmada dış ortam hava şartları ve bina içi aktiviteleri değerlendirerek soğutma yükünü tahmin etmeye çalışan Bayes Ağı (Bayesian Network – BN) tabanlı bir model ortaya konulmuştur. Çalışmaya göre enerji tasarrufu yapmanın üç yöntemi vardır;

1. Oluşan talebe verilecek yanıt stratejileri
2. Tüketilen enerjinin denetlenme stratejileri
3. İleri kontrol stratejileri

Her üç strateji için de başarılı bir uygulama olup, olmadığının onaylanması için yük tahminine ihtiyaç duyulmaktadır (Huang ve Li, 2013). Örneğin denetleme stratejilerine gerçeğe en yakın yük tahminleri girdi olarak sağlanmalıdır ki uygulanacak tasarruf yöntemlerinin ne kadar doğru çalışacağı tespit edilebilsin. Vaka analizi için 7 aylık veri toplanmıştır. Toplanan veriler ise saatlik olarak sistemde oluşan soğutma yükü, dış ortam sıcaklık ve nemi ile davranışların tespiti için test ortamının kurulduğu üniversitenin akademik takvimidir. Farklı kalite ve miktara sahip 14 farklı eğitim veriseti üzerinde yapılan vaka incelemesine göre önerilen BN, SVM ve ANN'e göre daha tutarlı tahminler üretirken, ANN'e göre 58 kat daha az eğitim süresi gerektirdiği tespit edilmiştir. 10 hafta barındıran bir verisetine göre önerilen yöntemin standart sapması %23 civarında iken SVM'in en yakın değeri %34'dür. Hava durumu tahminlerindeki belirsizlikler, incelenen vaka için soğutma yükü tahmininin doğruluğunu önemli ölçüde etkilemiş ve SVM'in, diğer iki modele kıyasla bu belirsizliklere daha duyarlı olduğu tespit edilmiştir. Karmaşık matematiksel modeller içermediği için de halihazırdaki binalara kolaylıkla uygulanabileceği iddia edilmektedir. Çalışmada göze çarpan bir başka nokta da her üç yöntemde de eğitim veriseti ile test veriseti arasında olan farklılık arttığında çıkarılan sonuçlardaki çeşitliliğin arttığıdır (Zuo vd. 2018).

Başka bir çalışmada ise en büyük enerji kaybının ticari binalardaki insan varlığını gözetmeksizin statik olarak bir takvim ile çalıştırılan HVAC sistemlerinden kaynaklandığına dikkat çekilmiştir. Singapur'daki ticari bir binanda bulunan altı farklı ofiste yapılan bir çalışmada tam da bu konu üzerinde yoğunlaşmıştır. Toplanan yedi aylık eğitim verisi ile kullanıcı davranışları analiz edilmiş ve sonraki iki ay boyunca da aktif olarak kullanılmıştır. Deneklerin bir gün sonra ofiste olup, olmayacakları ve gün içinde ne kadar zamanı ofiste geçirecekleri tahmin edilerek sıcaklık ayarı yapılmıştır. Çalışmada sıcaklık, nem, CO<sub>2</sub> ve hareket değişkenleri sensörler ile her dakikada bir yedi ay boyunca toplanmıştır. Belirlenen yöntemde üç katman vardır. Birinci katmanda kullanıcı davranışlarının analizi için denetimli öğrenme yöntemi olan KNN tercih edilmiştir. Buradan elde edilen veriler ikinci olan kural tabanlı kontrol katmanına iletilmiş, önceden belirlenmiş kurallara göre de HVAC'ın nasıl çalışması gerektiğine karar verilmiştir. Üç ayar noktası belirlenmiştir; konforlu: 22,5 °C, boşta: 23,5 °C ki bu ayar noktası ofistekilerin kısa bir süre rahatsız olmadan kalabilecekleri bir sıcaklıktır ya da ofis boş bile olsa her an birilerinin gelme ihtimalinin yüksek olduğu durumdur ve ekonomi: 35 °C yani ofiste kimsenin olmadığı durumlarda kullanılır. Daha sonra da bu karar üçüncü katman olan bina yönetim sistemine iletilmiştir. Enerji tasarrufunun tespit

edilebilmesi için de her bir ofise enerji ölçer yerleştirilmiştir. Yapılan vaka analizi göstermektedir ki geleneksel statik yöntemle göre %20,3 enerji tasarrufu sağlanmıştır (Peng vd. 2017).

Öte yandan bazı binalardaki HVAC sistemleri mevsimsel olarak ayarlanır ve bu ayar günlük olarak değiştirilmez. Bu durumu göz önünde bulunduran başka bir çalışmada ise RF yapay öğrenme tabanlı bir kara kutu kontrol yöntemini HVAC'in aç/kapat ve mekanik havalandırma operasyonlarının optimizasyonunda kullanarak enerji tasarrufu sağlanmaya çalışılmıştır. Bunu yaparken de ortamda bulunanların termal konforunun bozulmaması için sıcaklığın 21 °C ile 26 °C arasında kalmasını bir kısıt olarak alınmıştır. *Next 24 h-Energy* adını verdikleri bu yöntem, sensörler vasıtası ile toplanan önceki günlere ait iç ve dış ortam sıcaklık, nem oranı ve binada bulunan kişi sayısı ile birlikte önümüzdeki 24 saatin hava durumu tahminini RF ile değerlendirerek sonraki gün için HVAC sisteminin nasıl işletileceğine karar verir. Bir sonraki 24 saat boyunca, her saat için HVAC'in ısıtma veya soğutma operasyonu ile tam olarak mı, mekanik havalandırma ayarında mı çalışacağına yoksa tamamen kapalı mı kalması gerektiğine konfor şartlarına (sıcaklık 21 °C ile 26 °C arasında olmalı) bakarak karar verir. Bunun için ön görülmek istenen saat aralığındaki iç ortam sıcaklığının ne olacağını bu üç seviye için de RF ile tahmin eder. Bu çalışma ile mekanik havalandırmanın, özellikle dış ortam sıcaklığının binanın iç sıcaklığının altında olduğu yaz döneminde gün boyunca binada oluşan sıcaklığın önceki geceden düşürülmesi için son derece yararlı olduğu görülmüştür. HVAC sistemi ısıtma veya soğutma yerine sadece havalandırma sağlayacağından enerji tüketimi tam operasyona göre daha düşüktür. Önerdikleri yöntem ile İspanya'daki test ortamında, 110 gün boyunca toplanan verilerle yapılan testler süresince, ısıtma için harcanan enerjide %48, soğutma için ise %39 oranında tasarruf sağlanmıştır (Manjarres vd. 2017).

Yapılan başka bir çalışmada ise enerji tüketimi, kontrol ayarları (iç ortama gönderilen havanın sıcaklığı ve statik basıncı) ve kontrol dışı parametre kümesi arasındaki ilişkiyi en iyi tanımlayan sınıflandırıcının tespiti için sekiz farklı algoritma denenmiştir. Vaka çalışmasının yapıldığı ortama ait sıcaklık, nem ve hava akımı gibi veriler sensörler ile toplanırken, iklim kontrol ünitelerinin (Air Handling Unit – AHU) içindeki pompa ve fanların ne kadar enerji tükettiği de kaydedilmiştir. Sisteme 15 gün boyunca dakikada bir yaklaşık 500 veri girişi sağlanmıştır. Daha sonra bu veriler arasındaki ilişkinin tespit edilebilmesi için Sınıflandırma ve Regresyon Ağacı (Classification and Regression Tree – C&RT), Ki-kare Otomatik Etkileşim Algılama (Chi-squared Automatic Interaction Detector – CHAID), Artırma Ağacı (Boosting Tree – BT), RF, MARS, Çok Katmanlı Algılayıcı (Multi-layer Perceptron – MLP), MLP

Topluluğu ve SVM algoritmaları ile testler yapılmıştır. MLP Ensemble %3,77 ortalama hata oranı ile en iyi sonucu üretmiştir. Daha sonrasında bu algoritma soğutma, yeniden ısıtma, fan ve pompa sistemlerinin enerji modellerinin kurulmasında kullanılmıştır. Burada da yapılan testler göstermiştir ki MLP topluluk algoritması, enerji tüketimi, kontrol edilebilir değişkenler ve kontrol edilemeyen parametreler arasındaki ilişkinin tanımlanmasında başarılıdır. MLP topluluk algoritmasından elde edilen bu alt modeller, tüm optimizasyon modelinin kurulmasında kullanılmıştır. Enerji tüketiminin azaltılması için tüm alt modellerde uygulanacak tek amaçlı bir fonksiyon oluşturulmuştur. Karar değişkenleri besleme havası sıcaklık ayar noktası ve statik basınç ayar noktasıdır. Bu amaç fonksiyonun verilen kısıtlar doğrultusunda çözülmesinde ise Parçacık Sürüsü Optimizasyonu (Particle Swarm Optimization – PSO) algoritması kullanılmıştır. Sonuçlar, önerilen yöntemin HVAC sisteminin enerji tüketiminde %7,66 enerji tasarrufu sağladığını, ortam sıcaklığı korunurken CO<sub>2</sub> miktarının da azaldığını göstermiştir (Kusiak vd. 2010).

Gelecekte oluşabilecek HVAC'a bağlı enerji tüketimini tahmin etmeye çalışan bir başka çalışmada bir ofisteki soğutma yükü saatlik olarak SVM yapay öğrenme yöntemi kullanılarak tahmin edilmeye çalışılmış ve bu yöntemin sonuçları Back-BPNN sonuçları ile karşılaştırılmıştır. Yaz dönemine ait altı aylık dış ortam sıcaklığı ve nemi ile solar ışıma verileri şehir veri tabanından alınmıştır. Model sonuçlarının doğrulanması için Tsinghua Üniversitesi tarafından 10 yıllık bir araştırma ile geliştirilen *DeST (Designer's Simulation Toolkit)* isimli simülasyon programından faydalanılmıştır. Ofisin benzeri bu programda oluşturulmuş ve altı ay için saatlik soğutma yükü hesaplatılmıştır. Bu çıktının temmuz ayı için olanı SVM ve BPNN'in eğitiminde; Mayıs, Haziran, Ağustos, Eylül ve Ekim ayları için olanları da yöntemlerin ürettiği sonuçların doğrulanmasında kullanılmıştır. Yapılan testlerin sonucundan görülmüştür ki girdi parametreleri olan sıcaklık ve nem tahmin yürütülürken sadece geçmiş iki saatin dikkate alınması, solar ışımada ise sadece son bir saatin dikkate alınması tutarlılık ve basitlik açısından en idealidir. Ayrıca SVM'nin farklı ceza parametreleri  $C$  parametresi,  $\epsilon$  yarıçapı ve Gaussian çekirdeğinin  $\delta^2$  genişlik parametresi ile performansı araştırılmış ve uygulama için en uygun parametre ayarı elde edilmiştir. Göreceli olarak ortalama hata oranında ise SVM, BPNN'e göre %50 daha başarılıdır (Li vd. 2009).

Soğutmada olduğu gibi bina ısıtma sistemi için de enerji talebi tahmini, operasyon optimizasyonu, arıza tespit ve teşhisi ve talep tarafı yönetimi açısından oldukça faydalıdır. Bu konu özelinde yapılan bir çalışmada önerilen tahmin etme stratejisinin amacı sistemin açma ve kapanma zamanlarını belirlemektir. Bunu başarabilmek için de girdi değişkenlerini korelasyon analizi ile optimize ettikleri bir

yapay öğrenme yöntemi kullanılmıştır. Öncelikle meteorolojik parametreler, iç ortam sıcaklığı, zaman ve ısı pompası ünite parametreleri olmak üzere dört tip veri 5 dakikada bir olmak kaydı ile 15 gün boyunca toplanmıştır. Toplanan verinin bir bölümü modelin eğitilmesinde kullanılmıştır. Geri kalanı da ELM, MLR, SVR ve BPNN yapay öğrenme yöntemlerinin performans değerlendirilmesi amacı ile kullanılır. Daha sonra binanın sıcaklık değişikliklerine olan tepki süresinin 40 dakika olduğu tespit edilmiştir. İlk veri kümesinde 11 farklı değişken yer vermişler ve yaptıkları korelasyon analizine göre günün zamanı ve enerji tüketimi arasındaki korelasyon nispeten yüksek bulunmuştur. Bu analiz doğrultusunda ikinci versetinde 6 özellik seçilmiştir. 40 dakika sonraki 5 dakikalık enerji tüketimini tahmin etmek için o an tüketilen enerji miktarını bilmek de büyük öneme sahiptir. Bu nedenle ilk ve ikinci veri setlerine bu veri eklenerek üçüncü ve dördüncü veri setleri de elde edilmiştir. Yapılan testler göstermiştir ki en iyi sonuç dördüncü veriseti kullanılarak gizli katmanında 11 nöron bulunan ELM ile elde edilmiştir (Chen vd. 2017).

Kapalı ortam sıcaklık tahminini doğru yapmanın hem termal konfor hem de enerji tasarrufu için büyük öneme sahiptir. Bunu başarmak için de zaman serileri ile baş etmedeki üstünlüklerinden dolayı ANN kullanmayı tercih eden bir çalışmanın odak noktası ise doğru tahmin için gereken girdilerin seçilmesi ve doğru network mimarisinin oluşturulmasıdır. Modelin geliştirilmesi sırasında üç farklı ANN eğitim algoritması test edilmiş ve bu eğitim algoritmalarının performansı, tahmin doğruluğu, genelleme kabiliyeti ve çalışma süresi esas alınarak değerlendirilmiştir. İlk olarak her 5 dakikada bir, 13 gün boyunca, 25 farklı değişken değeri toplanmıştır. Toplanan verilerin %70'i eğitim, %15'i doğrulama ve %15'i de test için kullanılmıştır. Daha sonra Neural Fitting aracı ile tek-tek tüm değerlerin network performansı ve tahmin tutarlığı üzerindeki etkisi ölçülmüştür. Test edilen ANN algoritmaları Levenberg-Marquardt, Bayesian Regularization ve Scaled Conjugate Gradient'dir. Yapılan testler göstermiştir ki modelin doğru tahminde bulunması için gereken en önemli değişkenler HVAC sisteminin çalışması için ayarlanan sıcaklık ve dış ortam sıcaklığıdır. Bunları sırası ile rüzgâr hızı, rüzgâr yönü, çiğlenme noktası sıcaklığı, barometrik basınç, bağıl nem ve güneş ışıması takip etmektedir. Bu parametrelerin herhangi birinin eksikliğinde model istenilen tutarlılık seviyesinde tahmin üretememiştir. Modeller hem yaz hem de kış ayları için teste tabi tutulduğunda ise hem çalışma süresi açısından hem de tahminlerdeki hata miktarları göz önünde bulundurularak değerlendirildiğinde en iyi sonucu Levenberg-Marquardt üretmiştir (Afroz vd. 2017).

Yük tahmini için yapılan bir çalışmada ise amaç, bina otomasyon sistemindeki (Building Automation System – BAS) trend verisinden (hava sıcaklığı ve soğutulmuş su sıcaklığı vb.) yola çıkarak önce AHU'nun sağladığı hava akımı, daha sonra

soğutma bobinindeki yük ve bu veri kullanılarak da tüm binanın soğutma yüküne ulaşmak ve en sonunda da sonraki üç saat içinde 15 dakikalık zaman dilimlerinde HVAC'ın ne kadar enerji tüketeceğini tahmin etmektir. Bunu başarabilmek için de tahmin edilmek istenen her bir değişken için farklı bir SVR modeli geliştirmişlerdir. SVR'in üç önemli üst değişken ( $\epsilon$ ,  $C$ ,  $\gamma$ ) için farklı aralıklar belirlenmiş ve bu 3 parametrenin farklı kombinasyonları için 10 gün boyunca 15 dakikada bir toplanan veri üzerinden model eğitilip, sonraki altı saatlik veri ile de test edilmiştir. Tüm testler ve eğitimler yaz dönemine ait 10 farklı alt veri kümesinde tekrarlanmıştır. 15 dakika sonraki tüketimin tahmin edilmesi için tahmin edilecek değişkene ait o andaki ve bir saat 45 dakika önceki durumu BAS'dan alınmaktadır. 2014 yılında üç aylık yaz döneminde yapılan testler sonucunda görülmüştür ki önerilen yöntem RMSE değeri %14,2 ile %22,5 olacak kadar düşük seviyede hata ile tahmin üretebilmektedir (Zmeureanu vd. 2017).

Değişken akışkan debili sistemlerinin (Variable Refrigerant Flow – VRF) farklı ayar noktalarındaki enerji tüketimini ANN kullanarak tahmin etmeye çalışmak da enerji tasarrufu için farklı bir yöntemdir. Buna göre değişken akışkan debili sistemlerde, çevresindeki arka plan koşulları ve sistem değişkenlerinin ayarı olmak üzere enerji tüketim miktarını belirleyen iki faktör vardır. Çevredeki arka plan koşulları, dış ortam hava sıcaklığı, nem, güneş radyasyonu, iç ortam hava sıcaklığı ve alan soğutma yükünü belirleyen iç yük gibi dış ve iç çevresel faktörlerdir ki bunların arasında dış ortam hava sıcaklığı, nem, güneş radyasyonu ve iç ortam hava sıcaklığı yapılan bir çalışmada ANN'e girdi parametresi olarak alınmıştır. İç yükün dışarda bırakılmasının sebebi de bina tipine ve programına göre değişiklik göstermesi ve gerçek binalarda gerçek zamanda ölçülmesinin zorluğudur. Önce ANN modeli geliştirilmiş, daha sonra girdi değişkenleri seçilmiş, bu doğrultuda model optimize edilmiş ve son olarak da modelin performansı değerlendirilmiştir. Model geliştirilirken öğrenme algoritması olarak Levenberg-Marquart kullanılmıştır. İlk geliştirilen modelde bir gizli katman, her gizli katmanda 17 nöron olacak şekildedir. Dış ortam sıcaklık ve nem oranı ve iç ortam sıcaklığı parametrelerinin son bir saatteki ortalamaları dikkate alınırken, güneş radyasyonu, soğutma yükü, besleme havası ayar sıcaklığı, yoğunlaştırıcı akışkanı sıcaklık ayarı, yoğunlaştırıcı akışkanı basınç ayarı parametreleri dakikada bir olarak 5 aylık bir periyod için toplanmış daha sonrada bu sekiz parametre ile sonuç arasındaki ilişkinin saptanması için istatistik çalışması yapılmıştır. Determinasyon katsayısına göre sadece son bir saatteki dış ortam ortalama sıcaklığı, son bir saatteki dış ortam ortalama nem oranı, son bir saatteki iç ortam ortalama sıcaklığı, güneş radyasyonu, soğutma yükü parametrelerini ANN'e girdi olarak kullanmaya karar verilmiştir. Oluşturulan ilk model, iki gizli katman, her

gizli katmanda 15 gizli nöron olacak şekilde optimize edilmiştir. ASHRAE Kılavuzu 14- Enerji ve Talep tasarruflarının ölçülmesi (ASHRAE, 2002), tahmin modelinin tahmin doğruluğu varyasyon katsayısı kök ortalama kare hatası (Coefficient of Variation Root Mean Square Error – CVRMSE) değerinin %30'un altında ve ortalama yanlılık hatası (Mean Bias Error – MBE) değerinin %10'un altında olduğu durumları doğrulanabilir olarak kabul etmektedir ki önerilen sistem bunu sağlamaktadır (Moon vd. 2017).

Enerji tasarrufu ile termal konforu artırmayı aynı anda hedefleyen çalışmalar da mevcuttur. Bunlardan birinde, ANN ve optimizasyon yöntemlerinden faydalanarak ısıtma ayar noktası programlayıcısını kontrol etmeyi denemiş ve %4,93 oranında enerji tasarrufu sağlanırken bir yanda da PPD değerinin %0,76 oranında iyileştirilmesi başarılmıştır. Öncelikle *EnergyPlus* simülasyon programında içinde üç ofis alanı, mutfak, toplantı odası ve resepsiyonu olan altı termal bölgeye sahip 30 kişilik bir bina modellenmiş ve 12 °C ile 24 °C arasında değişen farklı ısıtma ayar noktalarını da içeren saatlik çözünürlüğe sahip üç aylık veri üretilmiştir. Daha sonra bu veri, hava durumu, günün saati, doluluk durumu ve daha önceki kapalı ortam sıcaklık bilgileri ile birlikte ANN'in eğitiminde kullanılmıştır. Çalışmada Bayesian Regularization Backpropagation eğitim fonksiyonu olarak seçilmiş ve iki gizli katmanı olan ve her bir katmanda 20 nöron içeren bir yapı kullanılmıştır. ANN'den sonraki 24 saatin toplam enerji tüketimi ve ortalama PPD değeri elde edilmiştir. Üretilen sonuç sayısı birden fazladır. Burada mümkün olan en az enerji tüketimi ve en az PPD'nin bulunması için optimizasyon metodu olan GA kullanılarak en uygun olan iki sonuçtan yeni bir sonuç seti oluşturulur ve yeniden ANN'e verilerek yeni tahminler yürütmesi sağlanır. Bu işlem ta ki durma kriteri sağlanana kadar tekrar eder. Beş günlük veri ile yapılan doğrulama testlerine göre önerilen yöntem, *EnergyPlus* simülasyonuna göre hem daha iyi hem de daha hızlı sonuçlar üretmeyi başarmış ve kara kutu modelleme yöntemlerinin fizik tabanlı yöntemlere göre üstünlüğünü ortaya koymuştur (Reynolds vd. 2017).

Aynı yöntemle başvuran bir başka çalışmada ise sistem başlatıldığında, meta-sezgisel bileşen (k-Nearest Neighbor Stochastic Hill Climbing), benzer tarihsel veri noktalarına dayanan bir gradyanı hesaplayarak daha fazla enerji verimli ayar noktaları seçmek için kontrol parametresi alanı (yani ayar noktaları) aramaya başlar. Bu sırada, yapay öğrenme bileşeni Regresyon Karar Ağacı (Regression Decision Tree – RDT) benzer tarihsel veri noktalarının komşularına matematiksel bir modele uygun olacak şekilde ve komşuluklarda lokal olarak en uygun olanı bulur. Vaka analizi *EnergyPlus* yazılımı üzerinde kurgulanan simülasyon ile gerçekleştirilmiştir. Paralelde ise iki bileşenin performansı sürekli olarak kendi kendine ayarlanan başka bir bileşen (Recursive Brute-Force Search) tarafından iyileştirilmeye çalışılmıştır. Sisteme girdi

olarak üç tip veri sağlanmaktadır; bina enerji kullanım verisi ve dış ortam sıcaklığı ve bina sakinlerinin bulunma şablonu gibi bağımsız değişkenlerdir. Yapılan testler göstermiştir ki geleneksel kontrol stratejisine göre %31,17 oranından enerji tasarrufu sağlamayı başarmışlardır (Becerik-Gerber vd. 2017).

Aynı hedeften yola çıkan bir başka çalışmada ise hem veri güdümlü modellerden hem de optimizasyon algoritmalarından faydalanılmıştır. İlk olarak, HVAC enerji tüketimini ve çevre koşullarını tahmin etmek için veri odaklı modeller geliştirilmiş; daha sonra da enerji tüketimi minimize edilirken önceden belirlenmiş çevresel koşulların devamlılığı sağlamak amacı ile optimum işletme stratejisini oluşturmak için enerji optimizasyon problemi formüle edilip, çözülmüştür. Bunu başarmak için de sistemin çıktı olarak sadece HVAC'ın besleme havası sıcaklığını ve statik basıncı üretmesi sağlanmıştır. Çevresel koşullardaki kısıtlar ise oda sıcaklığı ve nemdir. Vaka çalışması için 300 farklı sensörden 19 gün boyunca dakikada bir veri toplanmıştır. Daha sonra bu veriler 30 dakikalık ortalamalar halinde gruplanmıştır. Gruplama sonrası geriye kalan 911 veri noktasının %85'i veri güdümlü modelin eğitiminde %15'i de doğrulanmasında kullanılmıştır. Modelin geliştirilmesi için Multi Layer Perceptron (MLP)'den yararlanılmıştır. Gizli katmadaki nöron sayısı 3 ile 25 arasında rastgele olacak şekilde atanarak optimum sayı bulunmaya çalışılmıştır. En iyi çıktıyı ise %90 tutarlılık ile beş nöron kullanıldığında üretmiştir. Enerji optimizasyonu için ise GA, PSO ve Ateş Böceği Algoritması (Firefly Algorithm – FA) karşılaştırılması yapılmıştır. PSO ve GA testler sırasında lokal optimumlarda sıkışıp kalırken FA'da hem bu durum gözlemlenmemiş hem de daha kısa sürede sonuca ulaşabilmiştir. Yapılan testler sonucunda görülmüştür ki önerilen sistem sayesinde %2,23 ile %17,24 arasında enerji tasarrufu sağlanmaktadır (Zhang vd. 2015).

Bir binanın 24 saat sonraki soğutma yükünü tahmin edilmesini konu alan bir başka çalışmada ise büyük verilerdeki doğrusal olmayan ve karmaşık desenleri açığa çıkarmakta güçlü olan yapay öğrenme algoritmaları koleksiyonunu derin öğrenme (Deep Learning – DL) yöntemine başvurulmuştur. Yapılan çalışmanın temel odağını denetimsiz derin öğrenme oluşturmaktadır ve bu modeller, üst düzey veri soyutlamalarını özellik olarak almak için geliştirilmiştir. Daha sonra bu özellikler DL ve MLR, Elastik Ağ (Elastic Net – ELN), RF, GBM, SVR ve Aşırı Gradyanlı Arttıran Ağaçlar (Extreme Gradient Boosting Trees – XGB) olmak üzere altı farklı tahmin tekniğine performanslarının karşılaştırılması amacı ile girdi olarak verilmiştir. Çalışmada denetimli derin öğrenme yöntemi mimarisi olarak en çok kullanılan Derin Sinir Ağı (Deep Neural Network – DNN) tercih edilmiştir. Çalışmada bir yıl boyunca toplanmış veriseti kullanılmıştır ki toplam 15.792 adet gözlem içermektedir. Ay, gün, saat, dakika, günün türü, dış sıcaklık, dış bağıl nem, temin edilen ve geri dönen

soğutulmuş suyun sıcaklığı ve soğutulmuş su sıcaklığının akış hızı veri olarak 30 dakikada bir kaydedilmiştir. Verinin tamamının %70'i modelin eğitimi için, %15'i doğrulanması, %15'i de test edilmesi için kullanılmıştır. Yukarıda bahsedilen yedi farklı tahmin yöntemi yine yukarıda bahsedilen 4 farklı özellik çıkarımı yönteminden elde edilen girdilerle denenmiştir. Çıkan sonuçlar şunu göstermiştir ki en iyi tahmini denetimsiz derin öğrenme yöntemi ile elde edilen özellikleri kullanan XGB ile elde edilmiştir (Xiao vd. 2017).

Veri güdümlü yöntemler sadece tekil binaların enerji tüketiminin optimizasyonunda değil, şebekesel ölçekteki ısıtma sistemlerinde de kullanılabilir. Bunu ispatlamayı hedefleyen bir çalışmada bölgesel ısıtmadan faydalanan beş mesken ve beş ofisten oluşan İsveç'teki 10 farklı binadan 7 haftalık alan ve su ısıtma yükü verisi toplamışlardır. Amaç, sonraki 48 saatte oluşacak ısıtma yükünü saatlik çözünürlükte tahmin etmektir. Bunu başarmak için de denetimli yapay öğrenme yöntemlerinden SVM, Regresyon Ağacı (Regression Tree – RT), FFNN ve MLR karşılaştırılması yapılmıştır. Toplanan veriler; zaman, birincil kaynağın sağladığı ve geri dönüş sıcaklıkları, hava akımı hızı, birincil kaynağın tükettiği enerji, haftanın hangi günü, günün hangi saati olduğu ve dış ortam sıcaklığıdır. Öncelikle verilere Pearson product-moment korelasyon katsayısı analizi uygulanarak tüketim miktarı ve diğer değişkenler arasındaki korelasyon bulunmaya çalışılır. Buradan bütün değişkenlerin (zamanla ilişkili olanlar dışında) tüketim miktarı üzerinde yüksek oranda etkisi olduğu bulunmuştur. Yapılan testler göstermiştir ki RT haricindeki tüm yöntemler bu veriseti ile tahmin yürütmek için uygundur. SVM sonraki 24 saat için en az hata ile tahmin üreten yöntemdir (Idowu vd. 2016).

Yine aynı yöntem ile ısıtma sağlanan bir bölge için Ameirka'da yürütülen bir başka çalışmada termal konforun artırılması ve en yüksek enerji talebinin düşürülmesi için akıllı yöntemlerin kullanılabilirliği araştırılmıştır. Çalışmada önerilen modeli aynı bölgesel ısıtma sistemine sahip dört farklı binada test ettiler ve modellerini geleneksel açma/kapama sistemleriyle karşılaştırılmıştır. Oluşturulan ANN modeli 20 nörona sahip, tek gizli katmanlı bir MLP'dir. Modelin eğitimi ve testi için kullanılan veriseti 8.700 adet gözlem bulunmaktadır. Model 0.64 hata payı (RMSE) ile doğru tahmin yürütmektedir ki bu konfor seviyesini %27 artırırken enerji tüketimini %30 seviyesinde düşürmüştür (Ahn ve Cho, 2017).

Binalardaki enerji tüketimini doğrudan etkileyen değişkenlerin değerlerinin önceden tahmin edilmesinin enerji yöntemindeki önemine dikkat çeken bir başka çalışmada ise farklı odalardaki sıcaklık farklı yapay öğrenme yöntemleri ile tahmin edilmeye çalışılmıştır. Modellerin eğitimi için 18 farklı değişkenin değerleri dört farklı odadan, bir yıl boyunca ve birer saat aralıklarla olacak şekilde TeKton 3D adlı

simülasyon programında oluşturulmuştur. Kaydedilen değişkenler; ay, ayın günü, haftanın günü, zaman, dış ortam sıcaklık ve nem oranı, odanın sıcaklık ayarı, odanın toplam termal gücü ve odanın o anki sıcaklığıdır. Daha sonra bu veriler, ay ve günler tam sayı değeri alacak şekilde, oda sıcaklık ayarı da hep sabit bir değer aldığı için çalıştığı zamanlarda ikili sistem olacak şekilde ve son olarak da zaman, kosinüs transformasyonu ile bir ön işlemden geçirilmiştir. Karşılaştırılan yapay öğrenme yöntemleri, Otoregresif Model (Autoregressive Model – AR), MLR, MLP, ELM, Doğrusal Olmayan Otoregresif Dışsal (Non-linear Autoregressive Exogenous – NARX) ve çeşitli kümeleme yöntemleridir. Yapılan testler göstermiştir ki en iyi performansa sahip yöntem MLP-NARX'dır. Bu yöntem, MLP'nin doğrusal olmayan kestirim yetenekleriyle, günlük periyodikliğin izini süren modeli oluşturmak için otoregressive bir yaklaşım kullanmanın faydasını ekler. Yıllık tahmindeki ortalama hatası 0,11 °C'dir. ELM'in ilk başta ürettiği sonuçlar hayal kırıklığı yaratırken daha sonradan RReliefF yöntemi ile değişkenlerin sonuç üzerindeki etki değerine göre bir sıralama yapılmıştır ve bu sıralamaya göre ilk 10 değişken yapılan deneylerde ELM daha iyi sonuçlar üretmeye başlamıştır (Mateo vd. 2013).

Enerji tasarrufu için termostatlar geceleri kapatılır ki buna gece modu (ayarı) denir ve çalışma saatlerinin başlamasından önce bu ayardan çıkılarak termostat yeniden aktif edilir. Termostat gece ayarının sonlanacağı zamanın doğru tahmin edilmesi hem enerji tasarrufu hem de bina sakinlerinin termal konforu için önemlidir. Öncelikle geçmiş beş yıllık verinin üretilmesi için ESP-r adındaki bir simülasyon programı kullanılmıştır. Ayrıca o yıllardaki Kuveyt'in hava koşulları da sisteme dahil edilmiştir. İlk iki yıllık veri önerilen yöntemin eğitimi için, geri kalan üç yıl da test için kullanılmıştır. Yapay öğrenme yöntemi olarak Genel Regresyon Sinir Ağları (General Regression Neural Networks – GRNNs) tercih edilmiş ve altı farklı şekilde yapay ağ tasarlanmıştır. İçlerinden en optimum sonucu üreten model Şehir Blok (City Block Distance) adındaki genetik algoritmayı, girdi verileri için de doğrusal ölçekleme fonksiyonu (Linear Scaling Function) kullanan modeldir. Yapılan testler göstermiştir ki determinasyon katsayısı (coefficient of multiple determination –  $R^2$ ) 0,939'a kadar başarıyla doğru tahminde bulunmaktadır (Mahmoud ve Ben-Nakhi, 2002).

HVAC kontrol algoritması geliştirmek için iki farklı ANN yöntemi kullanan bir çalışmada ise yöntemlerden biri ile binanın boş olduğu zamanlarda farklı gerileme sıcaklıkları için soğutmada ne kadar enerji tüketimine sebep olacağını tahmin etmeye çalışılmış; diğeri ile de ortamı normal sıcaklığına getirmek için gereken zaman hesaplanmıştır. Çalışmada kullanılması için seçilen veriler iç ve dış ortam sıcaklıklarıdır ve bu veriler de TRNSYS simülasyon programında toplamda 241 satırlık olacak şekilde üretilmiştir. Öncelikle bu veriler üç gizli katmanı ve 19 nöronu

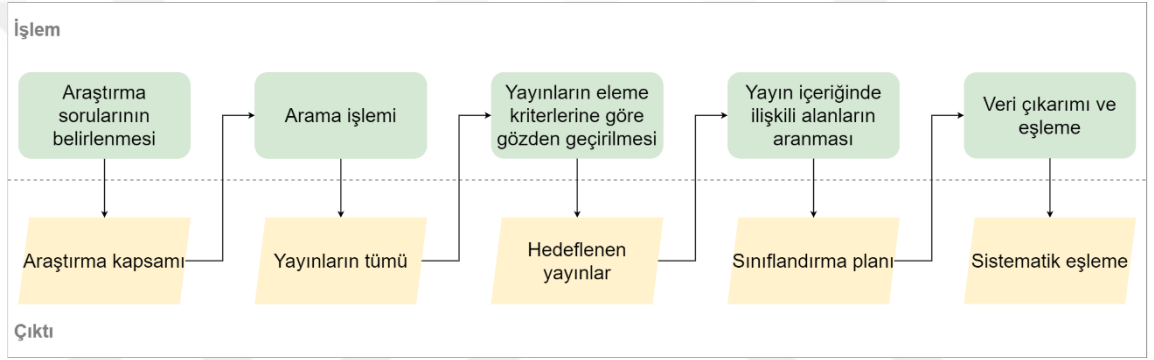
olan ANN'de uygun gerileme sıcaklığı bulmak için kullanılır. Daha sonra bu sıcaklık, sistemin ne zaman başlaması gerektiğini bulmak için yine üç gizli katmanı ve dört nöronu olan ikinci ANN modelinde kullanılır. Çalışma zamanı geldiğinde de iç ortam sıcaklığının kabul edilebilir aralıkta olup, olmadığına bakılarak soğutmanın devreye alınıp, alınmayacağına karar verilir. Yapılan simülasyonlar göstermiştir ki önerilen yöntem ile %40'a kadar enerji tasarrufu sağlamak mümkün olduğu gözlemlenmiştir (Jung ve Moon, 2016).

Minimum değişken hava hacmi (Variable Air Volume – VAV) ile termal konfor arasında doğrudan bir ilişki önceden de tespit edilmiştir (Anand vd. 2019). Bu tespitten yola çıkılarak yapılan bir çalışmada geri yayımlı Gradient Descent ANN ile hava akımını kontrol eden vana açıklığını tahmin ederek enerji tasarrufu sağlanmaya çalışılmıştır. HVAC sistemi içerisine yerleştirilen sensörler aracılığıyla toplanan hava basıncı, hava akımı hızı ve sıcaklık verilerinden oluşan bir veriseti oluşturulmuş. Bu veriseti üzerinde farklı katman ve nöronlarla oluşturulan modeller eğitilmiş ve uygun ortam koşulları için en az hataya (MSE) sahip modelin 0.05 değeri ile ilk gizli katmanda 4 ikinci gizli katmanda da 8 nöron içeren yapının olduğu tespit edilmiştir (Feng vd. 2021).

Bizim çalışmamızda önceki çalışmalardan farklı olarak yedi noktalı ısı hissiyatının daha yüksek tutarlılıkla tahmin edilmesi hedeflenmiş; bu hedefe ulaşmak için de DNN yöntemlerinden faydalanılmıştır. Bir diğer farklı nokta ise mümkün olduğu kadar az değişken kullanılarak bu hedefe ulaşılmaya çalışılmıştır. Detaylar bir sonraki bölümde anlatılmaktadır.

### 3. YÖNTEM

Araştırmanın başında öncelikle daha önceden bu alanda yapılmış araştırmaları incelemek amacıyla bir sistematik eşleme çalışması (Systematic Mapping Study – SMS) yapılmıştır. Bu öncül araştırmanın yapılması için izlenen yöntemin adımları Şekil 3.1’de gösterilmiştir. Bu akışa göre Tablo 1.1’de yer alan RS1, RS2 ve RS3’e cevap aranmaktadır.

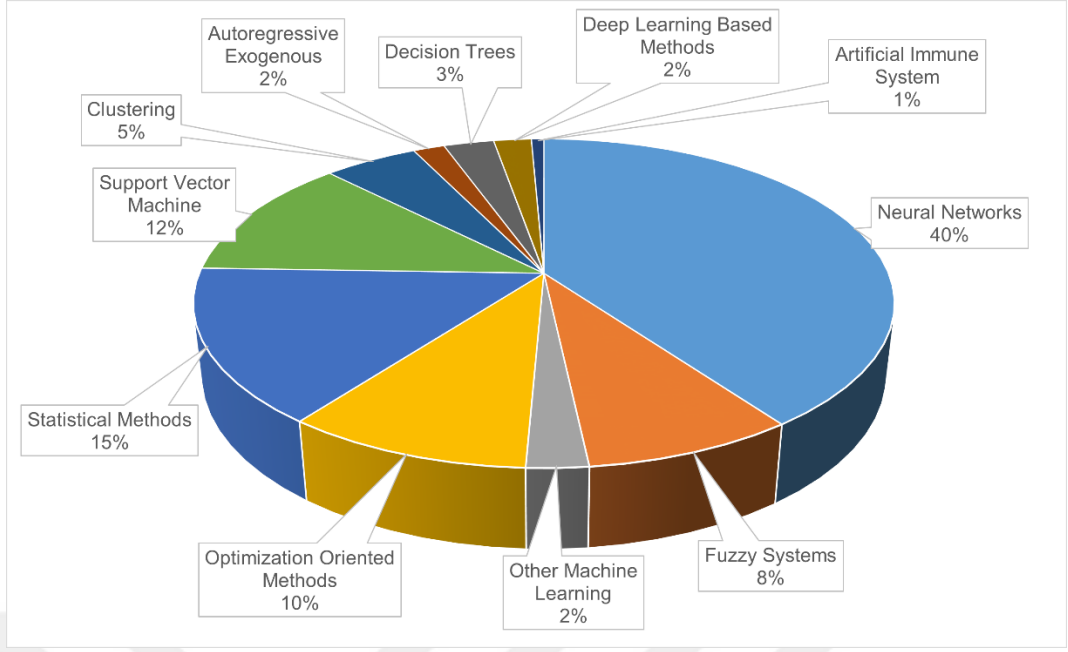


Şekil 3.1. Sistematik eşleme çalışmasında izlenen yöntem

Daha sonrasında aşağıdaki arama cümlecği ile Institute of Electrical and Electronics Engineers (IEEE), Association for Computing Machinery (ACM) Digital Library, ScienceDirect, SpringerLink, ve Wiley Online Library veri tabanlarında arama yapılmıştır. Elde edilen çalışmaların içinden PMV gibi hesaplama dayalı yöntemler, araçlarda kullanılan HVAC ile ilgili yapılan araştırmalar ve ikincil çalışmalar çıkarılmıştır. Filtreleme sonrasında toplam 289 çalışma incelenmiştir.


*(HVAC AND ("thermal comfort" OR energy OR efficiency OR saving)) AND (forecasting OR prediction OR classification)*

İnceleme sonunda Şekil 3.2’den de görülebileceği gibi derin öğrenme, destek vektör makinesi, karar ağaçları, yapay sinir ağları ve diğer yapay öğrenme yöntemleri de dahil edildiğinde incelenen çalışmaların yaklaşık %59’u yapay zeka yöntemleri kullanarak enerji tasarrufu ya da ısı konfor problemlerine çözüm aradığı tespit edilmiştir.



Şekil 3.2. İncelenen çalışmalardaki kullanılmış olan akıllı yöntemler

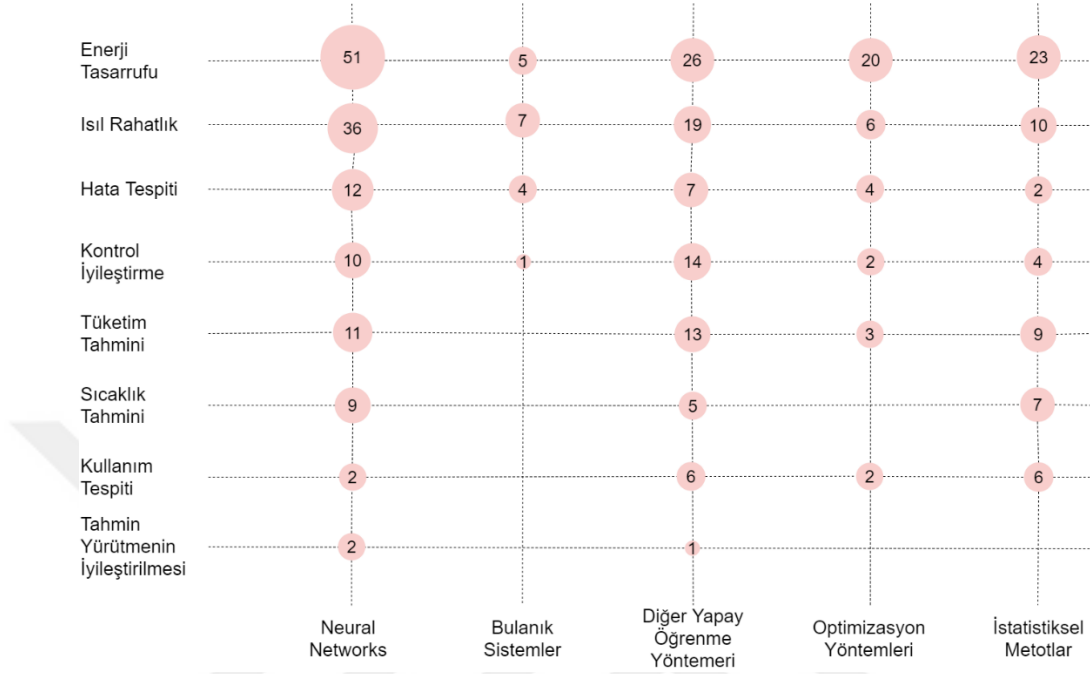
İncelenen çalışmalarda kullanılan veri toplama yöntemleri ise Şekil 3.3'de görülmektedir. Çalışmaların çoğunda sensörler ile veri toplansa da yadsınamayacak miktarda çalışmada önceki çalışmalarda toplanan veriler üzerinde araştırmalar yapılmış ve başarılı sonuçlara ulaşılmıştır.



Şekil 3.3. İncelenen çalışmalarda kullanılan veri toplama yöntemleri

Yine incelenen çalışmalarda hangi problemin çözümünde hangi yöntemin tercih edildiği bir balon grafiği olarak Şekil 3.4'de verilmiştir. Bu grafiğe göre problemin türünden bağımsız olarak akıllı yöntemler arasında en çok tercih edilen yapay sinir ağlarıdır. Derin öğrenmenin de bir anlamda yapay öğrenme yöntemleri arasında

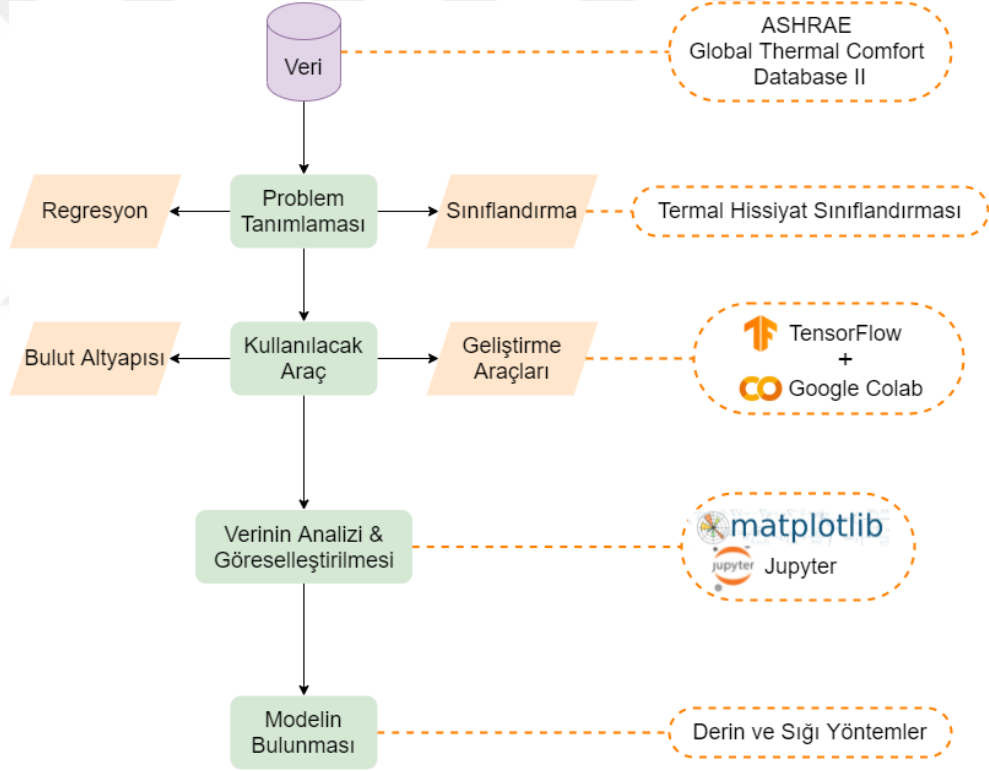
olduğu düşünülürken (Şekil 2.5) hem enerji tasarrufu hem de ısı rahatlık tahmininde yüksek oranda tercih edildiği kolaylıkla görülmektedir.



Şekil 3.4. SMS çalışmasının bulgularının balon grafiği

Veriye dayalı tahmin problemlerinin genel çözüm süreci beş adımdan oluşmaktadır. Bu sürece göre ilk olarak veri toplanmalıdır. Veri toplamanın birkaç farklı yolu vardır; gerçek zamanlı çevresel verileri toplamak için sensörler tercih edilebilir veya veriler iyi bilinen simülasyon araçları kullanılarak oluşturulabilir. Aynı zamanda kişisel verilerin toplanması için kontrollü ortamlarda bulunan deneklerden çevirim içi araçlar yardımı ile ya da kâğıt üzerindeki anketler yardımı ile faydalanılabilir. Bu iki tip verinin toplanması için bir başka yöntem ise daha önceki çalışmalarda elde edilmiş olan verilerden faydalanmaktır. Bizim çalışmamızda veriler, ASHRAE'nin 2018'de yayınlanan küresel termal konfor veri tabanının ikinci versiyonundan elde edildi. Verilerle ilgili daha fazla ayrıntı bir sonraki alt bölümde bulunabilir. Sürecin ikinci adımında problemin tipine karar verilmesi gerekir. Fanger'in modeline göre, Şekil 2.4'te de görüldüğü gibi, termal hissiyat tahmini sadece aralarında birer fark olacak şekilde değerleri alabildiği için bir sınıflandırma problemi olarak ele alınmalıdır. Bu, iç ortam koşulları ile öznel termal duyum arasındaki ilişkiyi tanımlamanın bir yoludur. Konforun değerlendirilmesi için 'soğuk' veya 'serin' gibi muğlak duyum ifadeleri oluştursa da tanımlandığı günden bu yana yaygın olarak

kullanılmaktadır (Schweiker vd. 2017). Üçüncü adımda, verileri analiz etmek ve makine öğrenmesi modelini geliştirmek için kullanılacak araç belirlenmelidir. Çalışmamızda uçtan uca açık kaynak kodlu bir platform olan *TensorFlow* ve yine bu platform üzerinde çalışan bulut altyapısına sahip *Google'ın Colab* servisinden faydalanılmıştır. Daha sonra, veriseti üzerinde daha detaylı bilgi elde etmek ve özellikle sayısal değişkenlerin dağılımı hakkında bir fikir edinmek için veriler görselleştirilmelidir. Son olarak da farklı en iyi tahmin sonucunu üreten modelin yani veri hazırlama yöntemi, üst değişkenler ve girdi değişken kombinasyonunun bulunması adımı yer alır. Verilen problem için en uygun modeli bulmak deneysel bir süreçtir. Bu adım mevcut seçeneklerin bitimine ya da en iyi modelin bulunduğu karar verilene kadar tekrarlanmalıdır. Şekil 3.5, bu süreci ve araştırmamız sırasında her adıma yanıt olarak yapılan faaliyetleri göstermektedir. Tanımlanan akış, veriye dayalı tahmin problemlerine uygulanabilir.




Şekil 3.5. Veriye dayalı tahmin problemleri için metodoloji. Noktalı şekiller, metodolojideki her bir soru için çalışmamızdaki cevaplardır.

Bizim araştırmamızda, önceden de belirtildiği gibi modelin eğitilmesinde ASHRAE'nin 66 farklı çalışmadan elde ettiği küresel ısı rahatlık veri tabanının ikinci versiyonu kullanılmıştır. Doğru modelin bulunması için farklı veri işleme teknikleri, derin ve sığ modellerde denenmiştir.

### 3.1. Veriseti

Berkeley, California Üniversitesi; Dayton Vakfı; Sidney Üniversitesi; Yonsei Üniversitesi; ve British Columbia Üniversitesi'nin ortak çalışması olarak, veriler anketler, mobil uygulamalar ve sensörler aracılığıyla toplanmıştır (Földvary Licina vd. 2018). Veriseti, 1995-2015 yılları arasında farklı mevsimlerde ve çeşitli bina tipleriyle yapılmış farklı lkelerden 66 çalışmayı kapsamaktadır. Belirli bir özelliğın farklı metriklerinden bağımsız olarak 51 değışkene ve 107.583 veri noktasına sahiptir. Detaylar Ek 1'de mevcuttur. Bazı çalışmalarda sayısal değışkenlerin birkaçı deney için hazırlanan ortamların zemininden 0,1 metre, 0,6 metre ve 1,1 metre yükseklięe yerleřtirilmiř ç sensör kullanılarak toplanırken, dięerlerinde aynı değışken bir sensör kullanılarak verilerin toplandıęı tespit edilmiřtir. Bir çalışmada veri toplamak için birden fazla sensör kullanılmıřsa, sensör deęerlerinin ortalaması gerçek değışken deęeri olarak kabul edilmiřtir. Bu tip sensör deęerlerinin birleřtirilmesinden sonra, kalan değışkenlerin sayısı 29'dur. Aıkçası, her çalışma tüm değışkenleri saęlamadıęı ve bu, veriseti içinde birçok boş deęer (null) yarattıęı için çok sayıda eksik deęere sahip değışkenler de göz ardı edilmiřtir. Boş deęere sahip değışkenlerin oranları, ki bu durum Őekil 3.6'de aık renkli alanlar olarak görlebilmektedir, göz önüne alındıęında çıkarılan değışkenler: sistemin çalışma sıcaklıęı (operative temperature); radyan sıcaklık (radiant temperature); deneğın boyu (subject height); deneğın kilosu (subject weight); perdelerin kapalı ya da aık olma durumu (blind – curtain); fanın aktif olup, olmama durumu (fan); pencerelerin aık olup, olmama durumu (window); kapının aık olup, olmama durumu (door) ve ısıtıcının çalışıp, çalışmama durumu (heater) olmak üzere dokuz adettir.



Şekil 3.6. Değişkenlerdeki boş (null) değerleri gösteren ısı haritası. Açık renk alanlar boş değerleri ifade etmektedir.

Bina sakinlerinin termal algısını etkileyen iki ana faktör grubu vardır: kişisel ve çevresel faktörler. Kişisel faktörler, bireyin metabolizma hızı ve giysisinin yalıtım özellikleridir. Çevresel faktörler, ortam sıcaklığı, bağıl nem ve hava akımı hızıdır. Çalışmamızda, standart efektif sıcaklık ve dış ortam sıcaklığını da çevresel faktörlerin unsurları olarak ele alınmıştır. Bununla birlikte aylık ortalama sıcaklıklar da modele girdi olarak verilmiştir. Değişkenlerin açıklamalar ve birimleri Tablo 3.1’de görülmektedir. Bu tabloda gösterilen sekiz değişkenden altısı, Şekil 2.3’de de gösterildiği gibi PMV’nin hesaplanmasında kullanılan değişkenlerdir (Fanger, 1970). Ek olarak SET ve dış ortama ait aylık ortalama sıcaklıklar modele girdi olarak sağlanmıştır. SET, katılımcının içinde bulunduğu ortam koşulu hakkında daha fazla bilgi sağladığı için; Binanın ısıtma/soğutma stratejisine bağlı olarak iç ve dış sıcaklığın doğrusal veya eğrisel bir ilişkiye sahip olması (Nicol vd. 2020) nedeniyle modele dış ortam aylık hava sıcaklığı özelliğini de girdi parametresi olarak ekledik. Bu değişkenler modelin eğitilmesinde kullanılırken diğerleri demografik bilgi edinmek amacı ile verisetinden çıkarılmamıştır.

Tablo 3.1. Girdi değişkenleri ve açıklamaları

	<b>Girdi Adı</b>	<b>Açıklama</b>	<b>Veri Tipi</b>	<b>Birim</b>
<i>Kişisel</i>	Kıyafet İzolasyonu	Katılımcının üzerindeki kıyafetlerin oluşturduğu ısı yalıtımı.	Sayısal	Clo
	Hareketlilik Seviyesi	Katılımcının son bir saat içerisindeki aktivitelerinden kaynaklı ortalama metabolik hızı.	Sayısal	Met
<i>İç Ortam</i>	Sıcaklık	İç ortamın ölçülen hava sıcaklığı.	Sayısal	°C
	SET	Standart Etkin Sıcaklık	Sayısal	°C
	Bağıl Nem	İç ortamın bağıl nemi.	Sayısal	%
	Kuru Küre	İç ortamın ölçülen küre sıcaklığı.	Sayısal	°C
	Hava Akımı Hızı	İç ortamdaki ölçülen hava akımı hızı.	Sayısal	m/s
<i>Dış Ortam</i>	Aylık ortalama sıcaklık	Veriler toplandığında dış ortam aylık ortalama sıcaklık.	Sayısal	°C


Ayrıca probleme bir sınıflandırma problemi olarak yaklaşıldığı için termal hissiyat değerleri içinden sadece tam sayı olanlar ve bu tam sayıların 0,1 oranında altında ya da üstünde olanlar dahil edildi. Yukarıda bahsedilen değişkenler içinde yer alan boş gözlemler de çıkarıldıktan sonra deneylerin yapılmasında kullanılan verisetinde 40.988 adet gözlem yer almıştır. Daha sonra bu gözlemlerden birebir aynı olanlar yani tekrar eden 1.478 adedi çıkarıldıktan sonra geriye 39.510 gözlem kalmıştır. Bu değişkenlerin alabileceği en yüksek ve en düşük değerlerle ortalamaları Tablo 3.2'de görülebilir. Bu tabloya göre ölçülen en yüksek sıcaklık yaklaşık 49 °C iken en düşüğü 0,6 °C'dır. Öte yandan dış ortam sıcaklığı farklı iklim kuşaklarından veri toplandığı için ise -8,4 °C ile 38 °C arasında geniş bir aralıkta değişmektedir.

Tablo 3.2. Sayısal girdi değişkenlerinin verisetinde aldığı en düşük, en yüksek ve ortalama değerler

	<b>En Düşük</b>	<b>En Yüksek</b>	<b>Ortalama</b>
Kıyafet izolasyonu	0,03	2,77	0,72
Hareket seviyesi	0,7	3,8	1,23
Sıcaklık	0,6	48,8	24,4

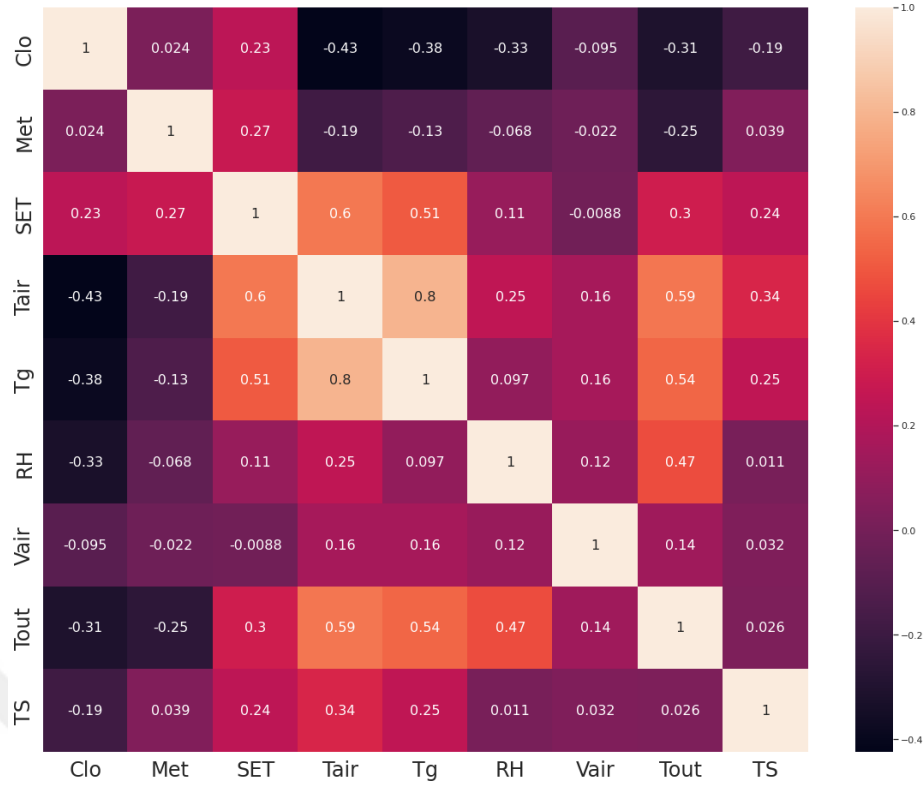
Küre sıcaklığı	0,5	100	24,69
Bağıl nem	0,03	89	44,62
Hava akımı hızı	0	56,17	0,13
Dış ortam sıcaklığı	-8,4	38,1	17,13
SET	6,55	61,53	26,19

Şekil 3.7’te örnek veriseti oluşturulurken verilerin toplandığı test ortamlarının kullanım amaçları ve o binalarda kullanılan soğutma yöntemlerinin dağılımı yer almaktadır. Şekilden de görülebileceği gibi verilerin çok büyük bir çoğunluğu ofislerden elde edilmiştir. Bu ofislerde kullanılan soğutma yöntemi ise genellikle iklimlendirme sistemleridir. Bunu doğal havalandırma yöntemleri takip etmektedir. En son olarak da ikisinin de bir arada bulunduğu karışık sistemler tercih edilmiştir. Öte yandan evlerin sayısı az olmasına rağmen çoğunlukla doğal havalandırma yöntemleri tercih edilmiştir. Mekanik havalandırma yöntemleri ise neredeyse hiç tercih edilmemiştir.




Şekil 3.7. Verisetinde bulunan binaların kullanım amaçları ve o binalarda kullanılan soğutma yöntemleri

Şekil 3.8’teki değişkenlerin kendi aralarındaki ve termal hissiyat ile olan ilişki gücünü gösteren korelasyon haritasına bakıldığında çok da güçlü ilişki içinde olmadıkları kolayca görülebilmektedir. Modelin eğitilmesinde kullanılacak olan sekiz değişkenden, termal hissiyat ile 0,34 korelasyon katsayısı ile en güçlü ilişki içinde olan, tahmin edilebileceği gibi, iç ortam sıcaklığıdır. En düşük katsayı ise 0,0077 ile bağıl nemdir. Kıyafet izolasyonu ise termal hissiyat ile ters orantılıdır.



Şekil 3.8. Değişkenlerin korelasyon haritası

Son olarak da Şekil 3.9'ten termal hissiyat oylarının dağılımı görülebilir. Bu grafiğe göre toplamda elde olan 39.510 gözlemden sadece 958'sinde içinde bulunulan ortam çok soğuk olarak nitelendirilirken, 1.983'ünde çok sıcak olarak nitelendirilmiştir. Doğal olarak nitelendirilen durumlarda ise 16.178 oy ile en çok gözlemlenen durum olmuştur. Şekilden de görülebileceği gibi dağılım bir hayli dengesiz durumdadır. Bu durumla nasıl baş edildiği bölüm 3.3'te açıklanmıştır.

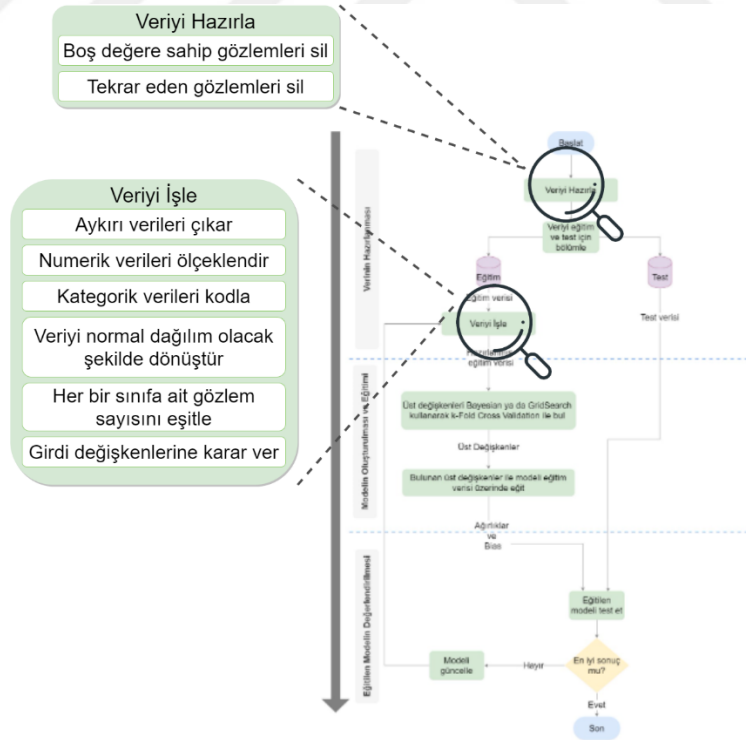


Şekil 3.9. Termal hissiyatın verisetindeki dağılımı

### 3.2. Verisetinin Önışlemesi

Bölüm 3.1’de bahsedildiđi gibi modelin eğitimi için kullanılacak olan verisetindeki boş verilerin temizlenmesinden sonra, verinin öncelikli olarak eğitim ve eğitilen modelin performans değeriendirilmesi için ikiye bölünmesi gerekmektedir. Böylelikle model daha önceden hiç görmediđi veri üzerinde test edilmiş olacaktır. Bizim senaryomuzda bu oran %80 eğitim, %20 de test verisi olarak belirlenmiştir. Daha sonrasında eğitim ayrılan verinin bu amaçla hazırlanması gerekmektedir. Genellikle bu hazırlama süreci beş aşamadan oluşmaktadır ve her aşamada o aşamadaki amaca ulaşmak için birden farklı yöntem bulunmaktadır. Her bir yöntemin model üzerinde etkisi farklı olacağından aşama ve yöntemler için farklı kombinasyonlarla model tekrar-tekrar denenmelidir. Bu beş aşama, Şekil 3.10’da gösterildiđi gibi, model oluşturma sürecinin bir parçasıdır ve sırası ile aşağıdaki adımlardan ibarettir.

- 1- Aykırı verilerin çıkarılması
- 2- Ölçeklendirme
- 3- Dönüşürme
- 4- Örneklem oluşturma

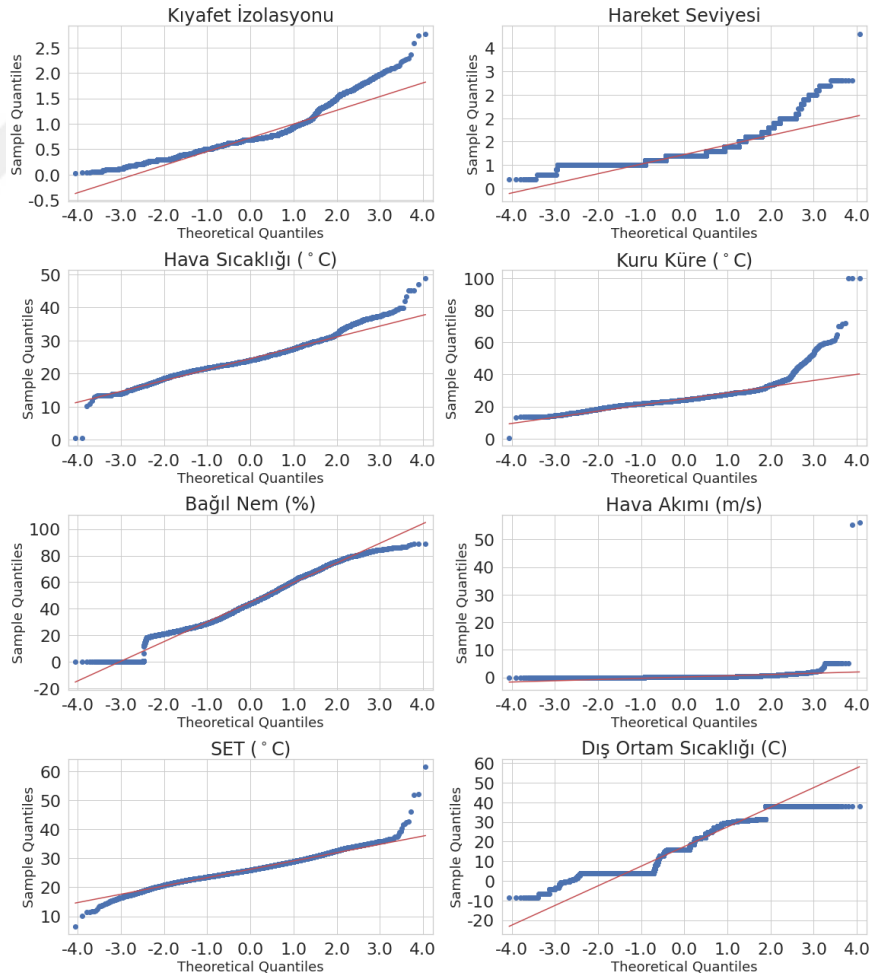


Şekil 3.10. Veri hazırlığı aşamaları ve genel süreçteki yeri

Bu aşamalarda yapılan işlemler alt başlıklarda detaylı olarak anlatılmıştır.

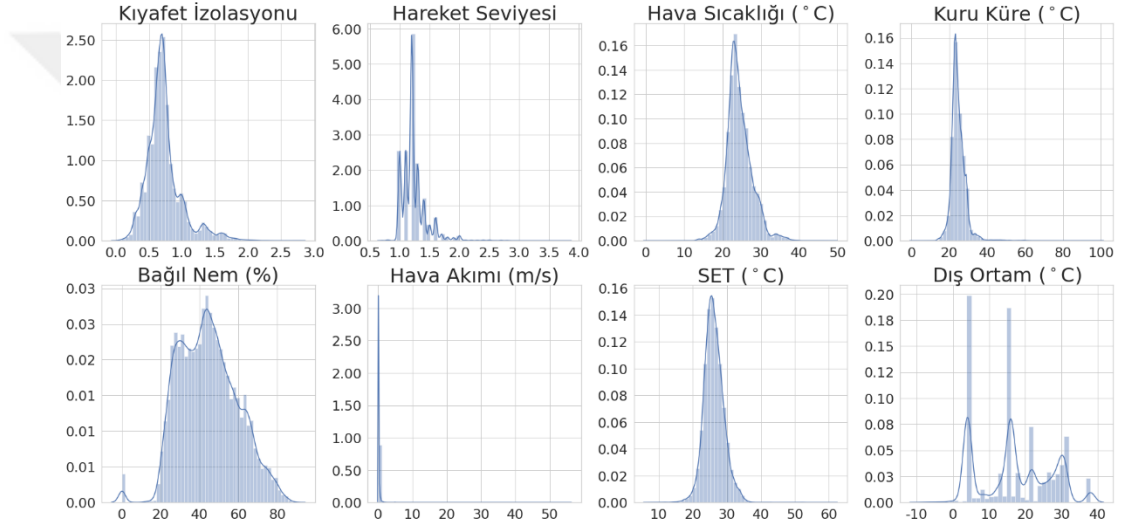
### 3.2.1. Aykırı Verilerin Çıkarılması

Modelleme yaparken, gözlemlerin sorunu en iyi şekilde temsil ettiğinden emin olmak için verisetini temizlemek önemlidir. Bazen bir veri kümesi, diğer verilerden farklı olarak, beklenen aralığın dışında olan uç değerler içerebilir ki bu değerlere aykırı veriler adı verilir. Yapay öğrenme modelinin tutarlılığı bu aykırı verilerin verisetinden çıkarılmasıyla iyileştirilebilir (Brownlee, 2020). Bunun için de her bir değişken için aykırı değerlerin tespit edilmesi gerekmektedir. Bu yöntemi uygulamadan önce sayısal değişkenlerin normal (Gaussian) dağılıma sahip olup, olmadığına bakılmalıdır. Bunu anlamamanın iki yöntemi vardır. Ya her bir değişken için QQ grafiğindeki normal çizgisini takip edip, edilmediğine bakılmalı, ya da veriler normallik testine tabi tutulmalıdır. Bu test, verilen bir değer kümesinin normal dağılıma sahip olup olmadığını  $p$  değerinin 0,05'in altına kalıp kalmadığına bakarak tespit etmektedir. Şekil 3.11'den de görülebildiği gibi değişkenlerin hiçbiri normal dağılıma sahip olmadığı değerlerin (mavi noktalar) grafikler üzerinde yer alan kırmızı çizgiyi takip etmemesinden anlaşılabilir.



Şekil 3.11. Verisetindeki değişkenlerin Q-Q grafiği

Aynı şekilde yapılan normallik testinde tüm değişkenler için  $p$  değeri 0,05'in altında kalmıştır. Şekil 3.12'den de değişkenlerin dağılımlarının çan eğrisine tam olarak benzemediği görülebilir ki bu aynı zamanda Şekil 3.11'de görünen grafikleri desteklemektedir. Normal dağılıma sahip bir veri kümesinin grafik üzerinde yer alan kırmızı çizgiye mümkün olduğu kadar yakın koordinatlarda verilerinin yer alması gerekmektedir. Bu bilgiye göre normal dağılıma en çok yakın değişken SET'tir ki bu Şekil 3.12'de de rahatça görülebilmektedir. SET'i daha sonra hava sıcaklığı ve kuru küre değişkenleri takip etmektedir. Öte yandan hava akımı değişkenindeki değerlerin dağılımı her ne kadar kırmızı çizgiye yakın görünse de bunun sebebi biraz da değerlerin çoğunluğunun bir yerde toplanmış olmasıdır ki bu durum da Şekil 3.13'de görülebilmektedir.



Şekil 3.12. Değişken dağılımları

Eğer değişken normal dağılıma sahipse aykırı değerler standart sapma yöntemiyle, değil ise çeyrekler arası aralık yöntemi (Interquartile Range Method – IQR) ile tespit edilebilir. Bizim durumumuza hiçbir değişken normal dağılıma sahip olmadığı için hepsinde IQR yöntemi kullanılarak her bir değişken için alt ve üst limitlerini belirlenmesi ile aykırı değerlerin tespiti yapılmıştır. Şekil 3.13'da değişkenlerin dağılımı kutu grafiği olarak görülmektedir. Kutuların ortasındaki çizgi o değişken için ortalama değeri gösterirken kutuların alt ve üst sınırları ise o değişkinin alt ve üst dörtte birlik sınırlarını göstermektedir. Aykırı değerler ise noktalarla temsil edilmektedir.

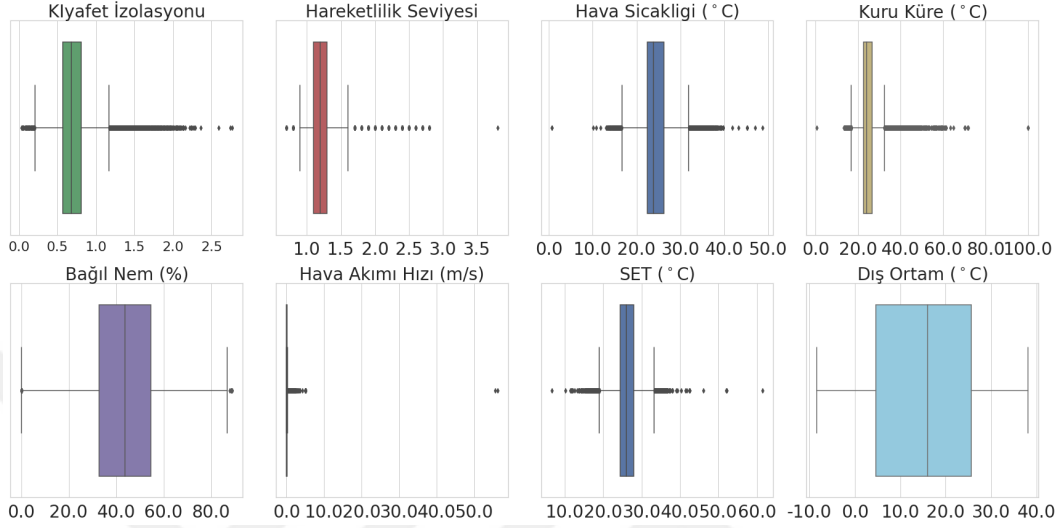
$$Q_1 = (N + 1) \times \frac{1}{4}$$

$$Q_3 = (N + 1) \times \frac{3}{4}$$

$$IQR = Q_3 - Q_1$$

$$lower = Q_1 - (IQR \times 1,5)$$

$$upper = Q_3 + (IQR \times 1,5)$$



Şekil 3.13. Değişkenlerdeki aykırı değerlerin görülebileceği kutu grafiği

Bu işlemden sonra eğitim verisinde bulunan 8.621 gözlemin aykırı değere sahip olduğu tespit edilmiş ve eğitim verisetinden çıkarılmıştır.

### 3.2.2. Ölçeklendirme

Birçok yapay öğrenme algoritması, sayısal girdi değişkenleri standart bir aralığa ölçeklendiğinde daha iyi performans gösterir (Brownlee, 2020). Tablo 3.2'de görülebildiği gibi kullanılan verisetindeki sayısal değişkenler aynı aralıkta değildir. Tüm değişkenleri aynı aralığa getirmenin üç yöntemi vardır. Bunlarda ilki MinMax adındaki yöntemdir ki bu yöntem mevcut değerden o değişken için en küçük değeri çıkarıp, daha sonra da o değişkenin en büyük ve en küçük değeri arasında ki değere bölerek yeni bir değer elde eder. Elde edilen bu yeni değer 0 ile 1 arasında değişmektedir.

$$m_i = \frac{(x_i - x_{min})}{(x_{max} - x_{min})}$$

$m_i$  yeni değer

$x_i$  orjinal değer

$x_{min}$  o değişken için en küçük değer

$x_{\max}$  o deęişken için en büyük deęer

Bir dięer yöntem ise standartlaştırmadır. Bu yöntemde mevcut deęerden o deęerin ait olduęu deęişkenin ortalaması çıkarılır ve daha sonra o deęişkenin standart sapmasına bölünerek yeni bir deęer elde edilir.

$$m_i = \frac{(x_i - \mu)}{\sigma}$$

$m_i$  yeni deęer

$x_i$  orjinal deęer

$\mu$  tüm  $x$ 'lerin aritmetik ortalaması

$\sigma$  tüm  $x$ 'lerin standart sapması

Son olarak da aykırı deęerlerin olduęu durumlarda daha iyi sonuçlar ürettięi düşünölen Robust ölçeklendirmedir. Bu ölçeklendirme türünde mevcut deęerden o deęerin ait olduęu deęişkenin medyan deęeri çıkarılır ve sonuç üçüncü çeyrek ile birinci çeyrek farkına bölünür.

$$m_i = \frac{(x_i - x_{med})}{(x_{75} - x_{25})}$$

$m_i$  yeni deęer

$x_i$  orjinal deęer

$x_{med}$  tüm  $x$ 'lerin medyan deęeri

$x_{75}$  üçüncü çeyrek deęeri

$x_{25}$  birinci çeyrek deęeri

### 3.2.3. Dönüştürme

Lineer Regresyon ve Gauss Naive Bayes gibi makine öğrenimi algoritmaları, sayısal deęişkenlerin Gauss olasılık dağılımına sahip olduęunu varsayar. Bu nedenle, girdi deęişkenlerini daha fazla Gauss dağılımına sahip olacak şekilde dönüştürerek çok çeşitli makine öğrenimi algoritmalarında daha iyi performans elde edilebilir (Brownlee, 2020). Bu sebeple de güç dönüşümü yöntemlerinden Box-Cox dönüşümü ve Yeo-Johnson ile birlikte nicelik (quantile) dönüşümü olmak üzere üç farklı dönüşüm yöntemi bizim çalışmamızda kullanılmak amacıyla incelenmiştir.

Box-Cox dönüşümünün aşağıdaki formülünde  $w$  değişkenin değerinin dönüşeceği yeni değeri;  $y$  ilk değeri,  $\lambda$  ise dönüşüm için kullanılan optimal değeri temsil etmektedir.

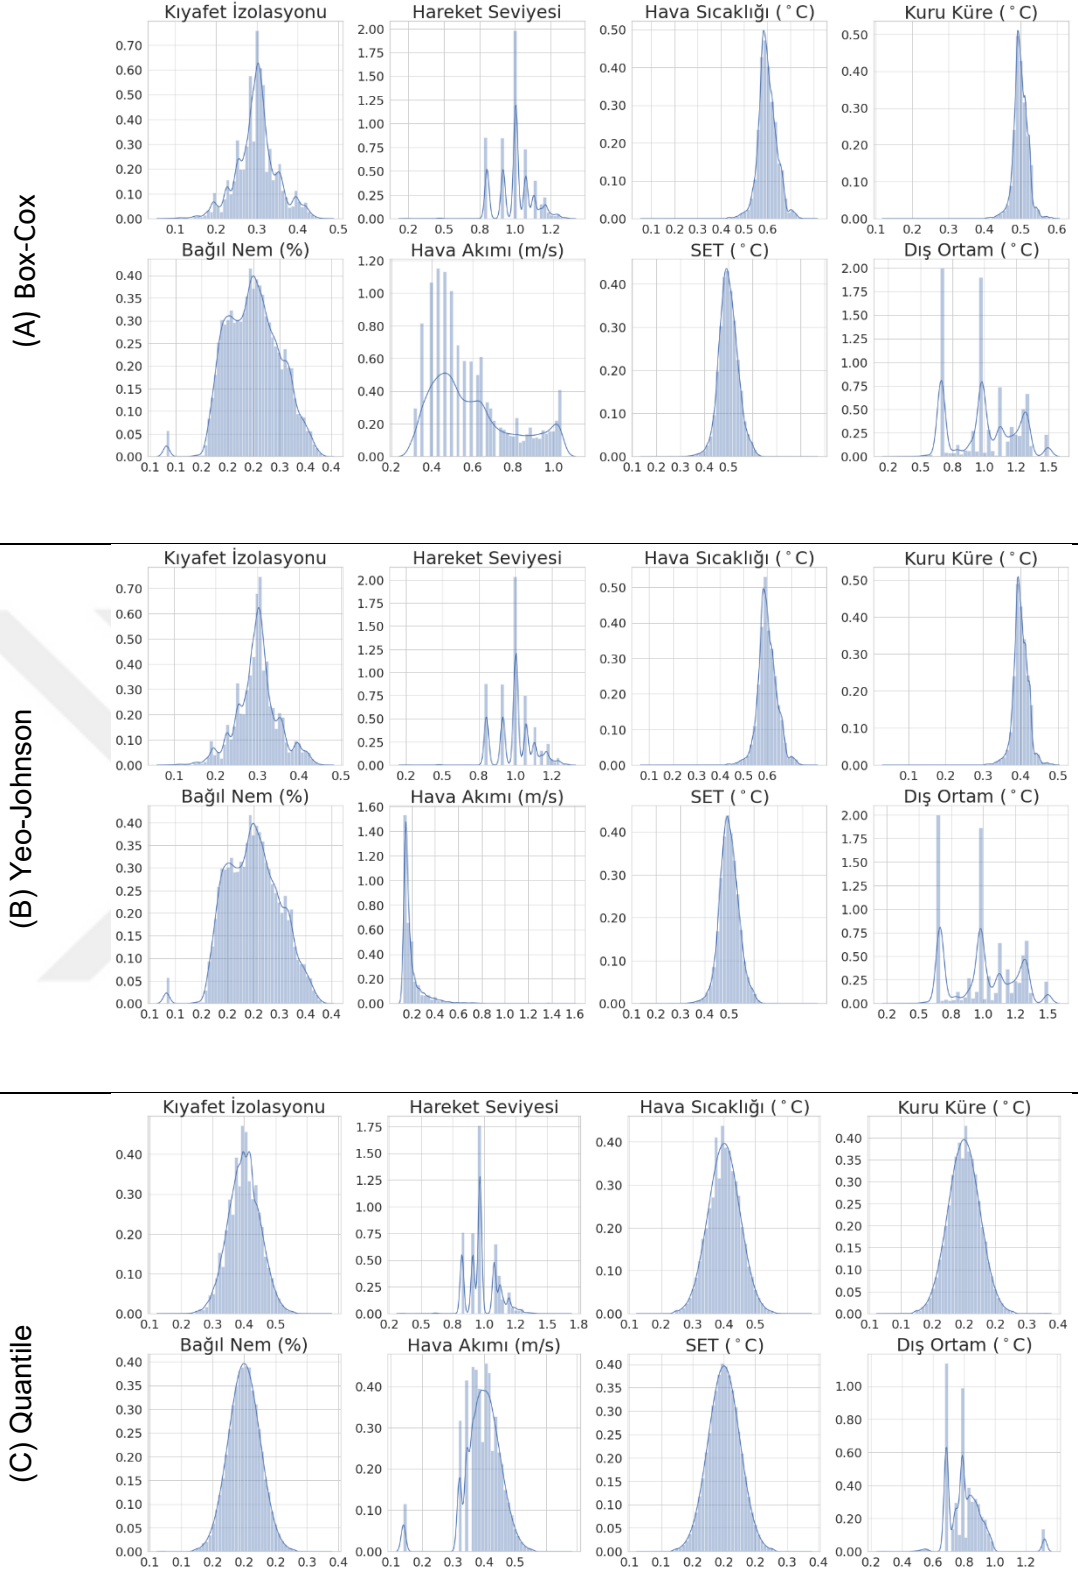
$$w = \begin{cases} \log(y) & \text{eğer } \lambda = 0; \\ \frac{y^\lambda - 1}{\lambda} & \text{eğer } \lambda \neq 0 \end{cases}$$

Burada dikkat edilmesi gereken bir nokta, Box-Cox dönüşümünün sadece positive sayılara uygulanabiliyor olması. Bu nedenle değişkenlere, aralığın 1 ile 2 olacağı şekilde MinMax ölçeklendirilmesi uygulanmıştır. Daha sonra diğer iki dönüşüm yöntemi öncesinde de bu ölçeklendirme yöntemi uygulanmıştır ki yöntemler arası karşılaştırma doğru olarak yapılabilir.

Yeo-Johnson dönüşümünün formülü ise aşağıdaki gibidir ve semboller Box-Cox ile aynı değişkenleri temsil etmektedir.

$$w = \begin{cases} \log(y + 1) & \text{eğer } \lambda = 0, y \geq 0; \\ \frac{(y + 1)^\lambda - 1}{\lambda} & \text{eğer } \lambda \neq 0, y \geq 0; \\ \frac{-((-y + 1)^{(2-\lambda)} - 1)}{(2 - \lambda)} & \text{eğer } \lambda \neq 2, y < 0; \\ -\log(-y + 1) & \text{eğer } \lambda = 2, y > 0 \end{cases}$$

Şekil 3.14'da görüldüğü gibi bu üç dönüşüm yöntemi değişkenlere uygulanarak dağılımları üzerindeki etkiler karşılaştırılmıştır. Yine şekilden anlaşılacağı gibi Gauss dağılımına en yakın dağılımı nicelik dönüşüm yöntemi sağlamıştır.



Şekil 3.14. Değişkenlerin farklı dönüşüm yöntemleri sonrasındaki dağılımları

Modelin oluşturulması sırasında nicelik dönüşümünün performansa olan etkisi incelenmiş, çıktıları sonuçlar bölümünde değerlendirilmiştir.

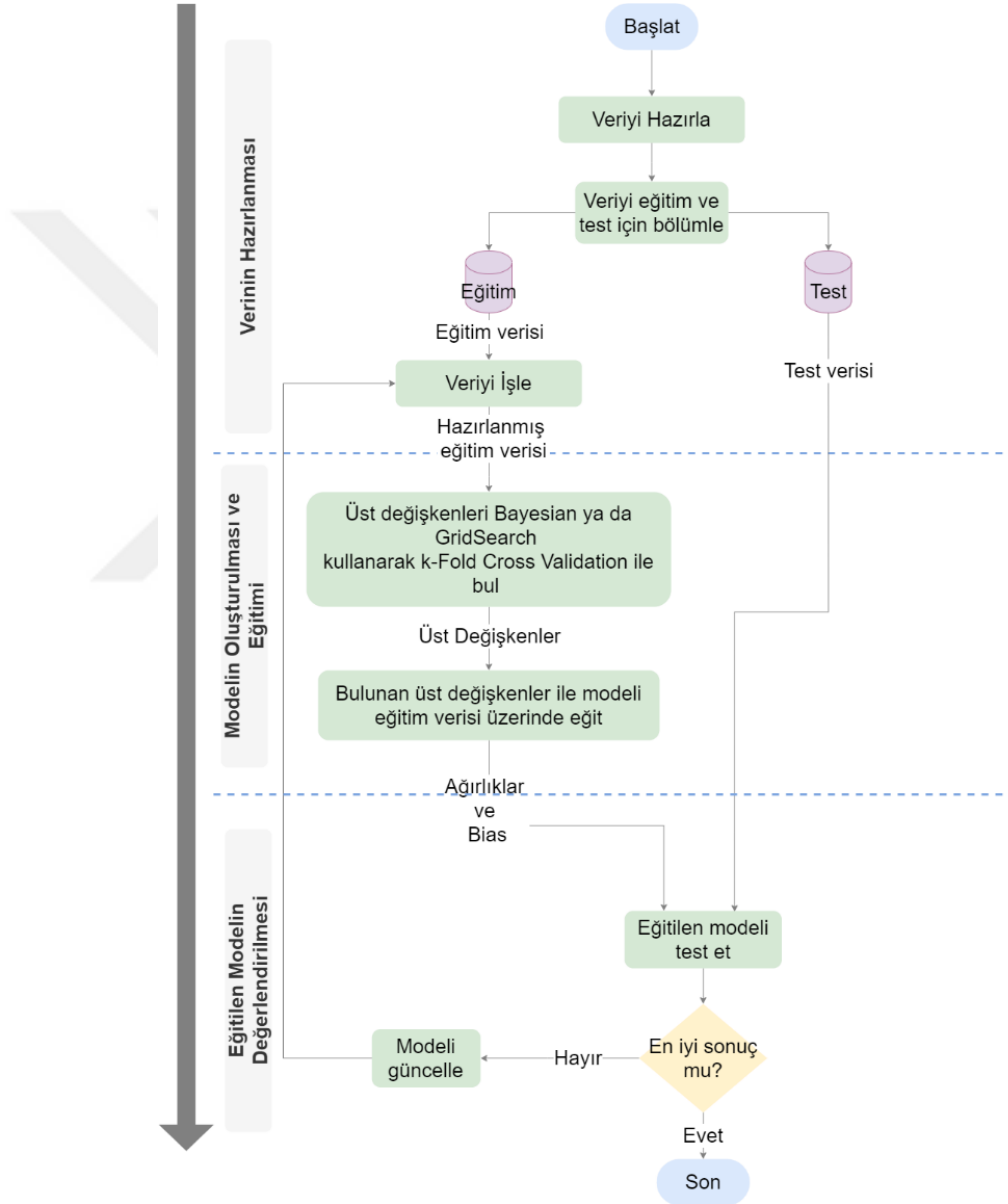
### 3.2.4. Örneklem Oluşturma

Veriseti hakkında bölüm 3.1’de bilgi verirken de değindiğimiz gibi hedef değişken yani termal hissiyat dağılımı dengede değildir. Şekil 3.9’ten de görülebileceği gibi oyların çok büyük bir çoğunluğunu 0 yani “Doğal” hissiyat oluşturmaktadır ve bu durum sınıflandırıcının performansında sapsmalara sebep olacaktır. Kullanılan veriseti için sınıflandırıcı her durum için 0 değerini verse dahi yaklaşık %40 tutarlılıkla doğru tahminde bulunmuş olacaktır ki bu gerçeği yansıtmayacaktır. Bunun önüne geçmek için iki yöntem mevcuttur; ya en az gözleme sahip sınıf sayısına gelene kadar her bir sınıftan gözlem miktarlarını azaltmak ya da tüm sınıflar için gözlem sayısını en yüksek gözlem sayısına sahip sınıfa eşitleyinceye kadar sentetik gözlemler oluşturmak. Kullanılan verisetinde en az gözleme sahip olan sınıf 958 gözlemle -3 yani “Çok Soğuk” hissiyatıdır ki bu sayı tüm gözlemler içinde %2,4 oranına sahiptir. Gözlem sayılarının azaltılması durumunda yaklaşık olarak 7.000 gözlem ile modelin eğitilmesi gerekmektedir fakat bu çok da tercih edilen bir durum değildir. Bu nedenle verilerin artırılması yöntemi tercih edilmiştir. Verisetini dengeye getirmek için Synthetic Minority Over-Sampling (SMOTE) yöntemi tercih edilmiştir. SMOTE, az gözleme sahip olan sınıfın verilen veri noktasına en yakın  $k$  komşularını göz önünde bulundurarak verisetini dengeli hale getirir (Konstantakopoulos vd. 2019). Bizim çalışmamızda da SMOTE her bir sınıfa ait gözlem sayısını yaklaşık 16.000’e yaklaştırarak modeli toplamda 100.000’den fazla örneklem ile eğitmemizi sağlamıştır.

### 3.3. Model Geliştirme

Verilen problem için en uygun modeli bulmak deneysel bir süreçtir. Bu nedenle de farklı veri hazırlama yöntemleri ve farklı üst değişkenler ile modelin doğrulanması, daha sonra içlerinden en iyi sonucu veren üst değişkenler ile modelin eğitilmesi ve son olarak da eğitilen modelin test amaçlı ayrılmış olan veri kullanılarak tahmin performansının ölçülmesi gerekmektedir. Bu süreç en iyi sonucu bulana kadar Şekil 3.15’de gösterildiği gibi tekrarlanmalıdır. Modelin performansının gerçeğe en yakın koşulda ölçüldüğünden emin olmak için ölçümünün daha önceden hiç eğitime girmemiş veriseti üzerinden yapılması gerekmektedir. Bu denklemlerle öncelikle veriseti, eğitim ve test olmak üzere ikiye ayrılır. Yeteri kadar veri olması sebebiyle bizim çalışmamızda toplam verisetinin %20’si test amaçlı ayrılmıştır. Daha sonra veri işlenir ve işlenen veri üzerinde modelin eğitilmesi için kullanılacak üst değişkenlerin bulunması işlemi başlar. Verisetinin işlenmesi için mevcut yöntemlerden 3.1’de bahsedilmiştir. Bunlardan hangisinin en iyi sonucu üreteceği de deneysel bir süreçtir.

Dolayısıyla veri işleme yöntemi belirlenir, işlenir ve son olarak üst değişken arama işlemi başlatılır. Ve bu akış veri işleme yöntemi her defasında güncellenerek en iyi sonuca ulaşana kadar tekrarlanır. Bizim çalışmamızda Robust, Standard ve MinMax ölçeklendirme yöntemleri, ayrı verilerin çıkarılıp, bırakılma durumları ve Quantile dönüştürme yönteminin uygulanıp, uygulanmaması seçenekleri değerlendirilerek veri farklı kombinasyonlar kullanılarak işlenmiş ve üst değişken arama işlemine tabi tutulmuştur.



Şekil 3.15. Model oluşturma süreci

Bu konuda daha fazla bilgi vermeden önce bazı kavramların netleştirilmesi gerekmektedir. 2.5'te anlatıldığı gibi oluşturulan modelin eğitimi sonrasında elde

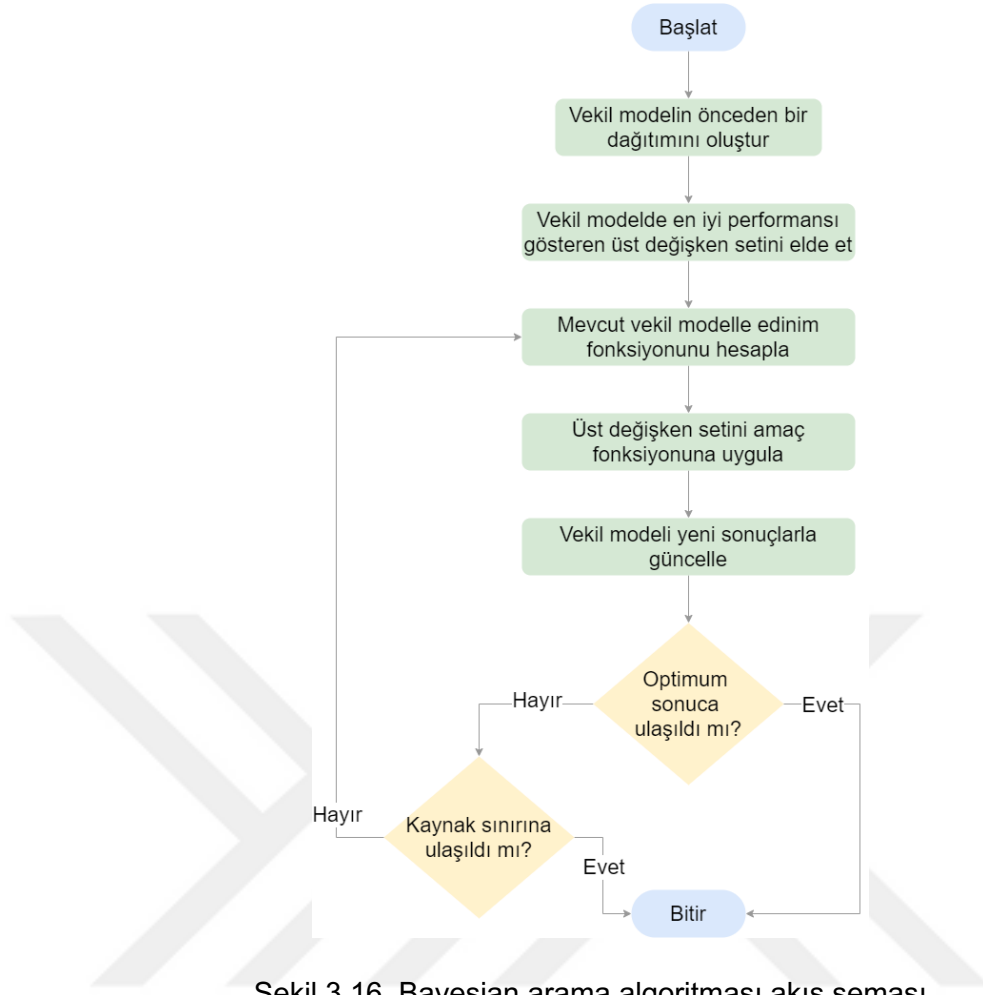
edilen ağırlık ve ek girdiler model değişkenleri olarak adlandırılmaktadır. Modelin eğitimi öncesinde belirlenmesi gereken, katman ve nöron sayısı, ağırlıkların optimizasyon algoritması ya da aktivasyon fonksiyonu gibi değişkenlere ise üst değişkenler adı verilmektedir. Bunlara ek olarak ağırlıkların her güncellenmesinde ne kadarlık bir farkla güncelleneceğini belirleyen öğrenme oranı (learning rate) ve ağırlıkların ilk atanması sırasında hangi yönteme göre atanacağını belirlenmesi de üst değişkenler arasındadır. Üst değişkenlere ek olarak bir de verinin farklı yöntemlerle işlenip, model üzerindeki etkisinin ölçülmesi durumu da söz konusu olduğundan, en iyi sonucu veren modelin bulunması için arama yapılması gereken uzay bir hayli geniştir. Bizim çalışmamızda kullanılan üst değişkenler ve her birinin alabileceği değerleri Tablo 3.3'den görmek mümkündür. Bu deneyler hem DNN hem de CNN tekniği kullanılarak tekrarlandığı için yukarıdaki tabloda yer alan üst değişkenlere ek olarak CNN için fitre ve örneklem büyüklükleri de iki ek üst değişken olarak değerlendirilmiştir.

Tablo 3.3'den de anlaşılabilceği gibi uygun kombinasyonun bulunması için çok sayıda deney yapmak gerekmektedir. Geleneksel olarak, üst değişken optimizasyonu şimdiye kadar insanların işi olmuştur çünkü sadece birkaç denemenin mümkün olduğu sistemlerde insanlar çok verimli olurlar. Fakat bu kadar geniş ve fazla boyuta sahip bir uzayda istenilen sonuca ulaşmak için yapısal bir yöntem kullanarak doğru kombinasyonu aramak gerekir. Günümüzde bilgisayar kümeleri ve grafik işlemcileri (GPU) daha fazla deneme yapmayı mümkün kıldığı için algoritmik yaklaşımların daha iyi sonuçlar bulması mümkündür (Bergstra vd. 2011). Bu noktada önerilen üç yöntem mevcuttur (Altun ve Talu, 2021). Bunlardan ilki bütün üst değişken kombinasyonlarının tek-tek denendiği ızgara aramasıdır (grid search) ki yukarıdaki tabloda bulunan değişkenlerin tüm kombinasyonlarının toplam sayısının yaklaşık on milyon olduğu düşünülürse uygun parametrelerin bulunmasının çok uzun zaman alacağı yani yüksek maliyete sahip olduğu aşikardır. İkinci yöntem ise rastgele aramadır ki bu arama yöntemi üst değişken kombinasyonlarını rastgele oluşturarak önceden belirlenmiş olan yineleme sayısı tamamlana kadar rastgele kombinasyonları denemeye devam eder ve içlerinden en iyi sonucu vereni seçer. Izgara arama yöntemine göre çok daha az maliyetli olmasına rağmen ızgara arama yöntemindeki gibi en iyi sonucu veren üst değişken kombinasyonunu yakalayamama ihtimali vardır. Son yöntem ise sıralı modele dayalı optimizasyon yöntemi olarak da bilinen Bayesian arama yöntemidir ki bu yöntem her boyutun önemini ağırlıklandırmaya yönelik yaklaşım sunduğu için en iyi sonuç üreten üst değişken kombinasyonu en kısa sürede bulmayı sağlamaktadır (Bergstra ve Bengio, 2012).

Tablo 3.3. Arama yapılan uzaydaki üst deęişkenler ve alabilecekleri deęerler

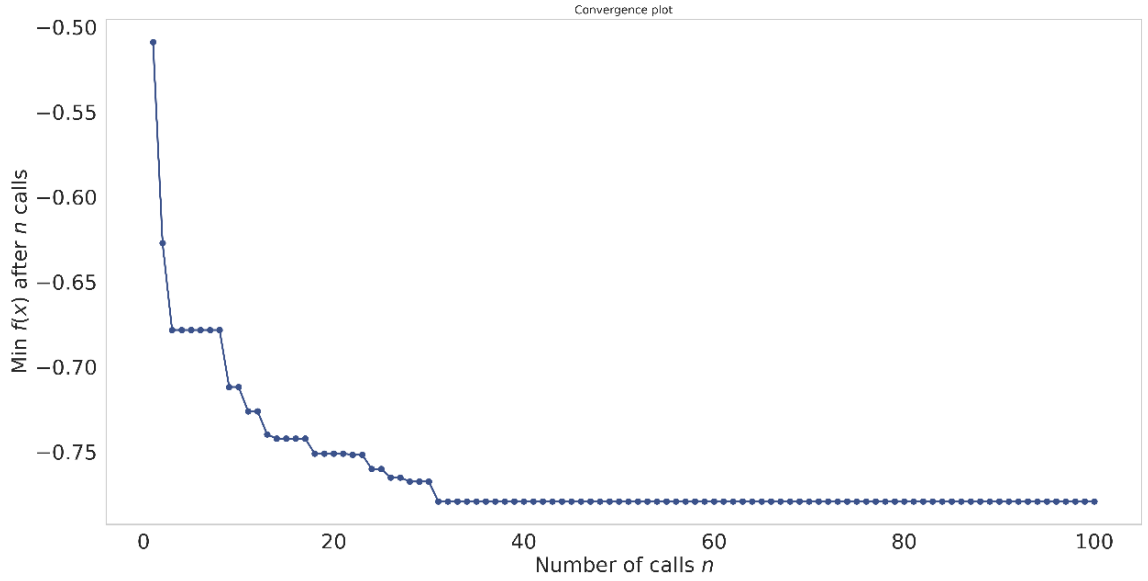
Üst Deęişken	Alabileceęi Deęerler
Aęırlık optimizasyon algoritması	Adam, AdaMax, Nadam
Parça büyüklüęü	16, 32, 64, 128
Katman sayısı	2, 3, 4, 6
Katmanlardaki nöron sayısı	40, 80, 160, 320, 640
Aęırlık başlatıcı	glorot_normal, glorot_uniform, he_normal, he_uniform
Öęrenme oranı	0,1 – 0,0001

Bayesian arama yöntemi, ki özünde mutlak en iyiyi bulmada kullanılan bir optimizasyon algoritmasıdır, neredeyse tüm küresel optimizasyon türleri için tipik bir yöntemdir ve daha fazla veriyle daha az hatayı amaçlar (Yu ve Zhu, 2020). Bu yöntem son zamanlarda, görüntü sınıflandırması, konuşma tanıma ve farklı problemler için sinirsel dil modellemesi için derin sinir aęlarında üst deęişkenlerin ayarlanmasında geniş uygulanabilirlik göstererek ciddi ilgi görmeye başlamıştır (Hutter vd. 2019). İki temel bileşenden oluşur: amaç fonksiyonunu modellemek için bir Bayes olasılık vekil modeli ve bir sonraki örnekleme noktasını belirlemek için bir edinme fonksiyonu. Algoritma akışı ise Şekil 3.16'de kısaca gösterilmiştir. Izgara ya da rastgele aramadaki gibi arama alanına deęil de şu anki durum bilgisine bakarak en iyi kararı vermeye odaklandıęı için bu iki arama yöntemine göre daha iyi sonuç elde etmektedir.



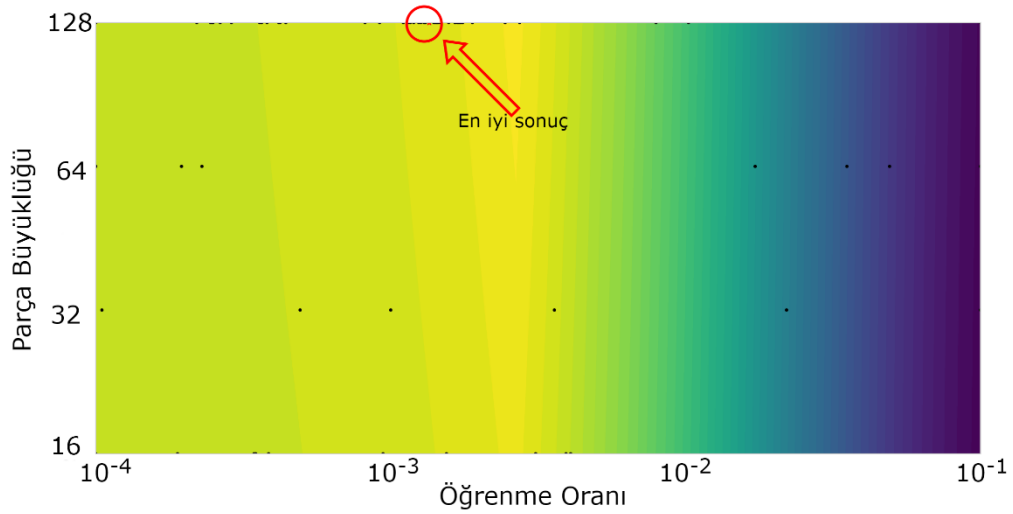
Şekil 3.16. Bayesian arama algoritması akış şeması

Bizim çalışmamızda Bayesian arama algoritmasına 100 deneme yapma şansı verilmiştir ve sonuç olarak bu 100 denemenin içerisinde en yüksek tutarlılıkla tahmin yürütebilen üst parametreler çapraz doğrulamaya tabi tutulur. Şekil 3.17’de her denemeden sonra elde edilen tutarlılık değerleri görülebilmektedir. Grafikten de anlaşılacağı gibi en yüksek tutarlılık değerine 31’inci adımda ulaşılmıştır. Daha sonrasında Bayesian algoritmasına göre türetilerek oluşturulan üst değişken kombinasyonları ile yapılan 69 denemede bu değer üzerine çıkılamamıştır. Burada Bayesian tutarlılığın bulunmasına bir minimizasyon problemi olarak yaklaştığı için grafiğin y ekseninde görülen değerler negatife dönüştürülmüştür.



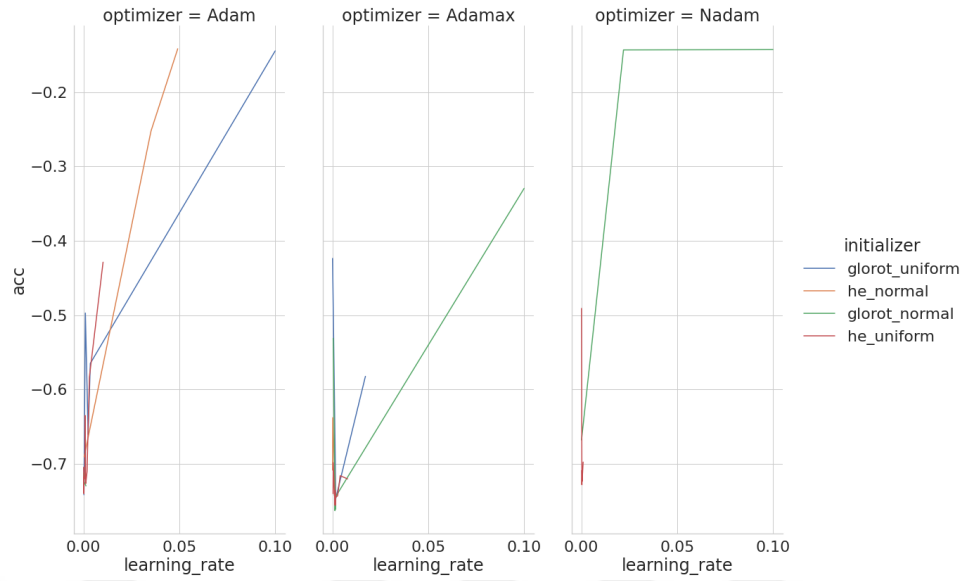
Şekil 3.17. Bayesian adımlarında DNN’de elde edilen tutarlılık değeri

Bayesian arama algoritmasının parça büyüklüğü ve öğrenme oranı boyutları uzayında arama sırasında denediği koordinatlar Şekil 3.18’de siyah noktalar olarak görünmektedir. Bu şekle göre en iyi sonucu üreten parça büyüklüğü 128 iken öğrenme oranı da  $1.10^{-3}$  civarındadır.



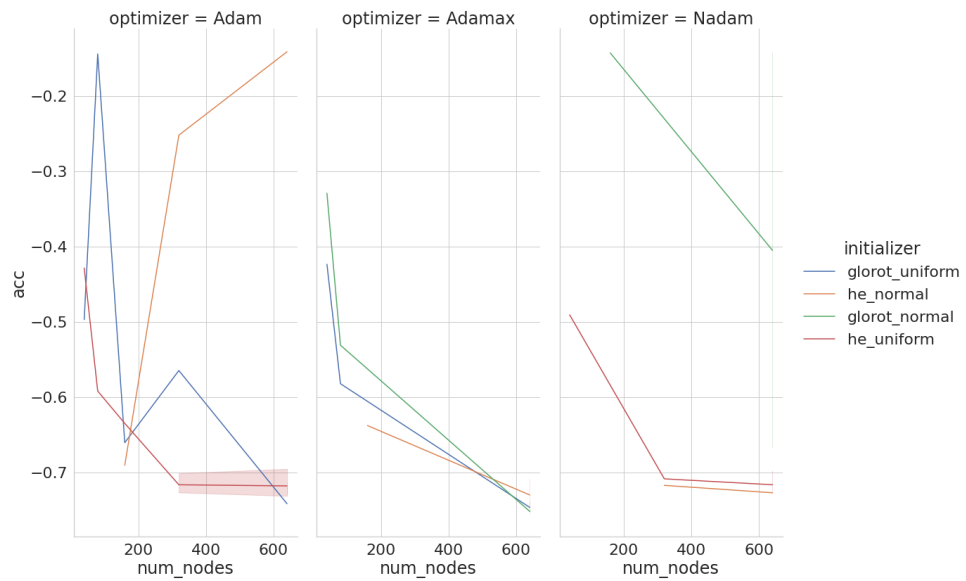
Şekil 3.18. Bayesian üst değişken tarama alanı: parça büyüklüğü ve öğrenme oranı

Öğrenme oranının, ağırlık başlatıcı ile olan ilişkisini incelediğimizde de Şekil 3.19’den faydalanmamız gerekir. Bu şekle göre ağırlık başlatıcı ve optimizasyon algoritmasından bağımsız olarak öğrenme oranı sıfıra yakınsadıkça modelin daha iyi tutarlılıkla sonuç ürettiği görülebilmektedir. Yine şekle göre AdaMax algoritması en yüksek tutarlılık değerine ulaşabilmekte ve bunu da glorot\_normal ağırlık başlatıcı ile sağlamaktadır.




Şekil 3.19. Öğrenme oranı, ağırlık başlatıcı ve ağırlık optimizasyon algoritması ilişkisi

Benzer bir ilişkiyi nöron sayısı üzerinden incelediğimizde ise Şekil 3.20'da da görülebileceği gibi nöron sayısı arttıkça tutarlılığın da arttığını gözlemleyebiliriz. Şekil 3.8'den de görülebileceği gibi verisetindeki değişkenlerin birbiri içindeki korelasyonunun zayıf oluşu göz önünde bulundurulduğunda bu durum gayet normaldir. Buna rağmen Adam optimizasyon algoritması ve he\_normal ağırlık başlatıcı üst değişken kombinasyonunda durum tersidir. Fakat buna rağmen model en iyi sonucu her bir katmanında 600'den fazla nörona sahip olduğu koşullarda üretebilmiştir.



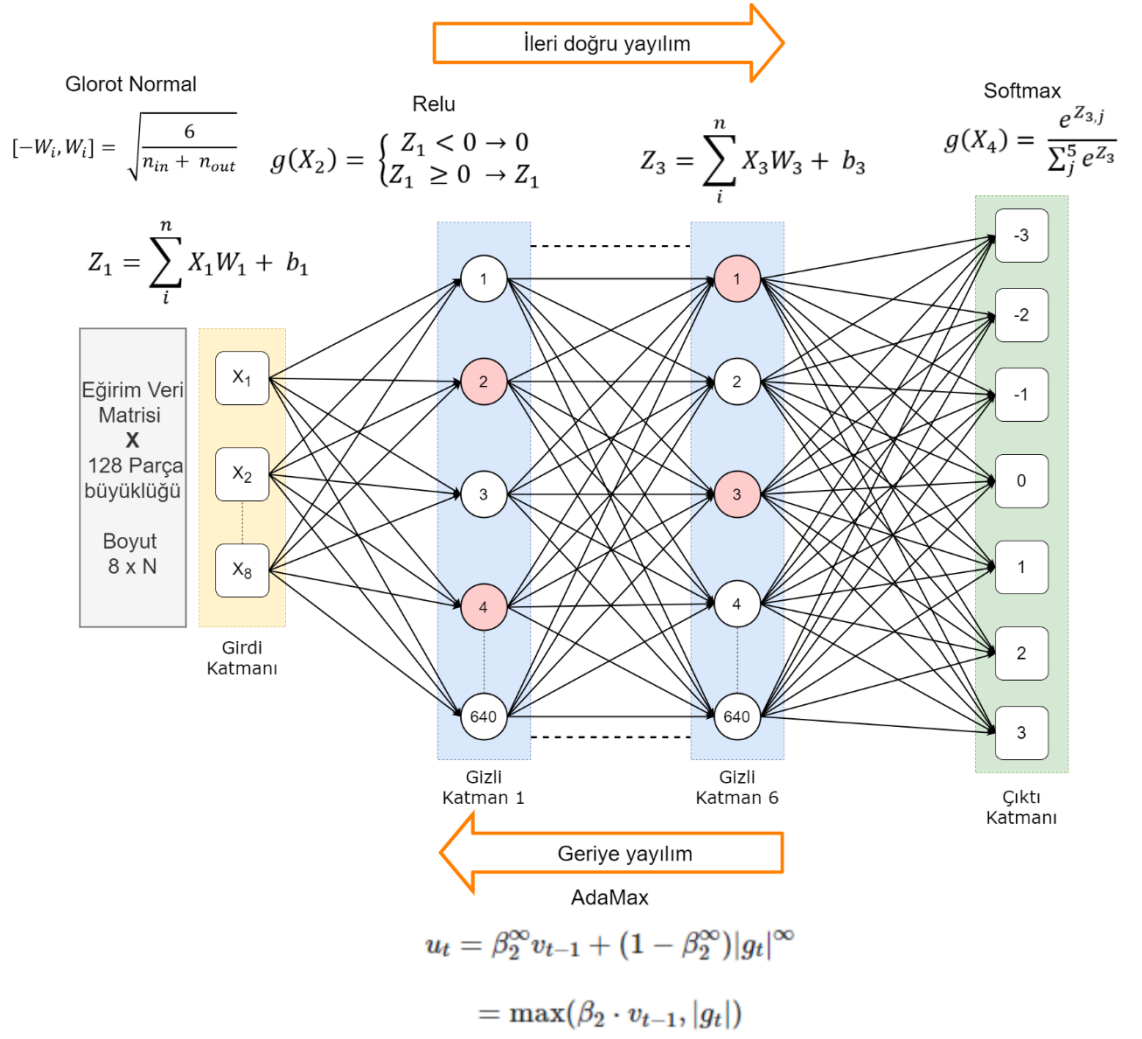
Şekil 3.20. Nöron sayısı, ağırlık başlatıcı ve ağırlık optimizasyon algoritması ilişkisi

CNN için aynı incelemeler yapıldığında ise durum çok az farklıdır. Şekil 3.21'de Bayesian arama algoritmasının hangi adımda ne kadar tutarlılıkla tahmin yürüten bir CNN modeli ürettiği görülmektedir. Bu şekle göre 55'inci adımdan sonra bir iyileşme kaydedememiştir.

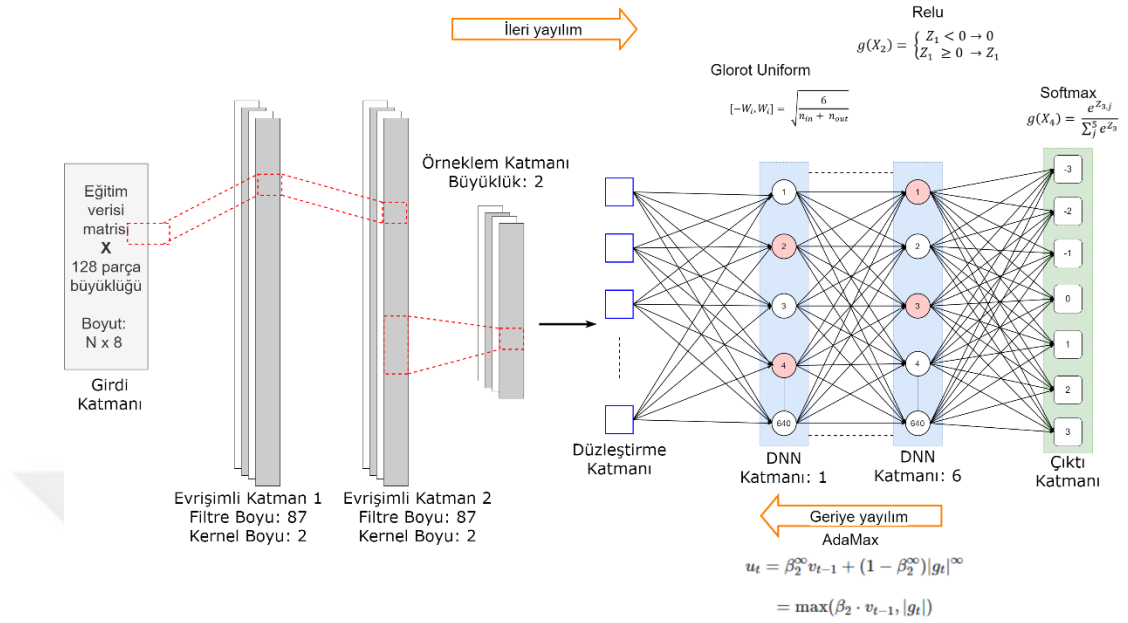


Şekil 3.21. Bayesian adımlarında CNN'de elde edilen tutarlılık değeri

Nöron sayısı, ağırlık başlatıcı, ağırlık optimizasyon algoritması parça büyüklüğü için benzer üst değişkenlerde karar kılmıştır Bayesian algoritması. Deneylerde en iyi sonucu veren DNN ve CNN modelleri Şekil 3.22 ve Şekil 3.23'te görülmektedir. Her iki model için de en iyi sonucu aykırı verilerin çıkarılıp, Robust ölçeklendirme sonrasında Quantile dönüşümü yapılan ver işleme süreci sağlamıştır. Şekillere göre arama algoritmasının seçtiği üst değişkenler de Tablo 3.4'de listelenmiştir. Şekiller ve tabloya göre DNN için altı gizli katmanı, her bir katmanında 640 adet nöron olan, ağırlıkları gloriot\_normal ile başlatıp, daha sonra AdaMax ve 0,0013 öğrenme oranı ile optimize eden ve verileri eğitim için 128'lik parçalar halinde veren bir model ortaya çıkmıştır.



Şekil 3.22. DNN Modeli Mimarisi



Şekil 3.23. CNN Modeli Mimarisi


CNN’de ise öğrenme oranı 0,0019 olarak belirlenmiş, diğer parametreler aynı kalmıştır. Ek olarak girdi değişkenleri çıkarım katmanı için filtre boyu 87 olurken örnekleme büyüklüğü ise 2 olarak bulunmuştur.

Tablo 3.4. DNN ve CNN modelleri için Bayesian arama algoritması tarafından seçilen üst değişkenler

Üst Değişken	DNN Değeri	CNN Değeri
Ağırlık optimizasyon algoritması	AdaMax	AdaMax
Parça büyüklüğü	128	128
Katman sayısı	6	6
Katmanlardaki nöron sayısı	640	640
Ağırlık başlatıcı	glorot_normal	glorot_normal
Öğrenme oranı	0,0013	0,0019
Filtre boyu	-	87
Örnekleme büyüklüğü	-	2

Yukarıda da bahsedildiği gibi Bayesian algoritması ile karar verilen üst değişkenler kullanılarak, temel anlamda, model eğitime tabi tutulur. Şekil 2.11’de de gösterildiği gibi aslında bu ağırlıkların ve ek girdinin (bias) bulunması işlemidir. Bu

işlem sırasında modele veri 128'erlik gruplar halinde verilmiştir ve 500 adımda en iyi tahmin sonucunu üreten ağırlık ve ek girdiyi hesaplaması beklenmiştir. Şekil 3.24'de eğitim süreci ve bu süreçte elde edilen tutarlılık değerlerine ait grafik görülmektedir. Bu grafik en iyi sonucu üreten üst değişkenler ile oluşturulan modele ait eğitim grafiğidir.

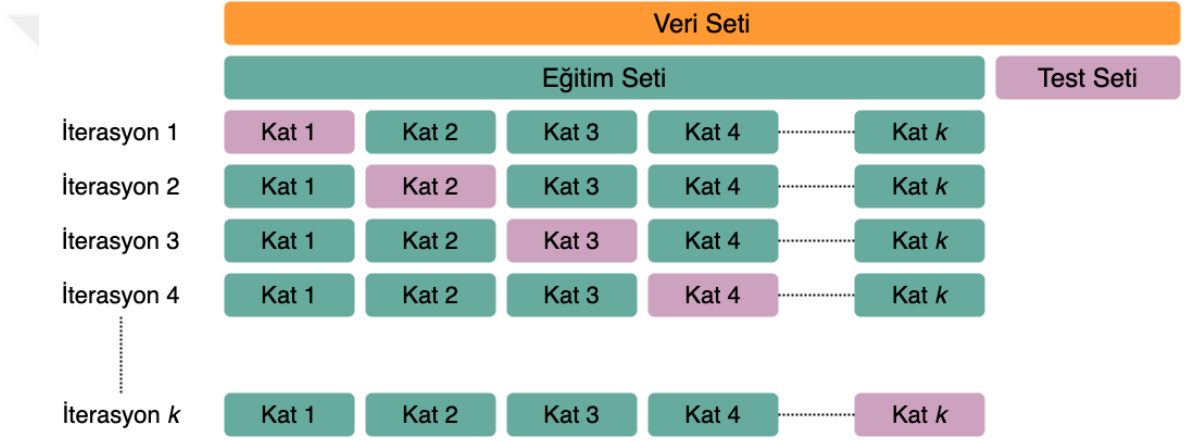


Şekil 3.24. DNN eğitim ilerlemesi grafiği

Eğitim için ayrılan verinin %10'u eğitimin doğrulanması için ayrılmıştır. Bu ayrılan veri test için ayrılan ve modelin daha önceden hiç görmediği veriden farklıdır. Burada iki amaç söz konusudur. Bunlardan ilki eğitimde bulunan ağırlıkların gerçeği ne kadar yansıttığı ikincisi ise eğitimde elde edilen performans ile karşılaştırarak modelin aşırı öğrenme hatasına düşüp düşmediğini anlamaktır. Şekil 3.24'de eğitime ait tutarlılık değerleri kırmızı çizgi ile gösterilirken, doğrulamaya ait tutarlılık ise yeşil ile gösterilmektedir. Eğer model aşırı öğrenme hatasına düşerse eğitimde çok iyi performans sergilerken, testte ve gerçek veri ile tahmin yürütmeye çalışıldığında performansı düşük olacaktır. Bu durumu engellemenin birden fazla yöntemi mevcuttur. Bizim çalışmamızda bunlardan ikisi tercih edilmiştir. İlk olarak doğrulama performansı sürekli takip edilerek belirli bir tekrar sayısından sonra ilerleme gözlemlenmediği takdirde eğitimin durdurulmasını sağlayan erken durdurma (early stopping). Bizim çalışmamızda gözlemlenen performans kriteri doğrulama kaybıdır. Artarda 25 defa kayıp değerinde düşüş gözlemlenmediği takdirde Bayesian algoritması tarafından seçilen üst parametrelerle başlatılan eğitim, henüz 500 adımı tamamlamadan durdurulmuştur. İkinci yöntem ise her bir katmandaki nöronların belirli oranda seyreltilmesidir (dropout). Burada amaç eğitim sırasında her katmandan belirli oranda nöronun rastgele olarak işlevlerini durdurarak modelin karmaşıklığını azaltmak

yoluyla aşırı öğrenmenin önüne geçmektir. Seyreltme oranı olarak %20 olarak farklı oranlarda denemeler yapılarak belirlenmiş ve Şekil 3.22’de kırmızı nöronlar olarak ifade edilmiştir.

Şekil 3.15’te de belirtildiği gibi daha sonra bulunan üst değişkenlerle model çapraz doğrulamaya tabi tutulmuştur. Şekil 3.25’ten de görülebileceği gibi eğitim veriseti  $k$  eşit parçaya bölünür ve her bir parçaya “Kat” adı verilir. Katların  $k-1$  adedinde model eğitilirken geri kalan son parçada modelin performansı kontrol edilir. Burada dikkat edilmesi gereken nokta, sınıflandırma problemlerinde veriseti bölümlere ayrılırken her bölümde her bir sınıftan eşit miktarda olması gerekliliğidir. Aksi taktirde 3.2.4’de bahsi geçen durum söz konusu olacak ve performans doğru değerlendirilemeyecektir.



Şekil 3.25. Çapraz doğrulama

Tekrarların tamamlanmasının ardından  $k$  adet performans ölçütü elde edilir ve bunların ortalaması alınır. Model farklı veriler üzerinde birden çok kez eğitilip değerlendirildiği için sonuç daha güvenilir bir tahminidir (Brownlee, 2016). Bizim çalışmamızda  $k$  değeri 10 olarak belirlenmiştir. Son olarak da eğitilip, çapraz doğrulamaya tabi tutulan modelin daha önceden hiç görmediği veriler ile nasıl başa çıkabildiği hakkında bilgi sahibi olmak için, bölümün başında da belirttiğimiz gibi, test için ayrılmış veriseti üzerinde tahmin yürütmesi sağlanır. Üzerinde çalıştığımız veriseti herhangi bir şekilde zaman serisi özelliği barındırmadığı için özyineli sinir ağları (Recurrent Neural Networks – RNN), uzun-kısa vadeli bellek (long short term memory – LSTM) vb. zaman serilerinde daha iyi performans gösteren ANN modelleri değerlendirilmemiştir. Çıkan sonuçların nasıl değerlendirildiği ise bir sonraki alt bölümde detaylı olarak aktarılmıştır.

### 3.4. Modelin Değerlendirilmesi

Bölüm için başında da belirtildiği gibi, bu çalışmada termal hissiyat tahminine çoklu sınıflandırma problemi olarak yaklaşılmış ve örnek verisetindeki yedi nokta ölçeği üzerinden tahmin yürütülmeye çalışılmıştır. Bu nedenle de oluşturulan modellerin değerlendirilip en iyi olanın seçilmesinde kullanılan ölçüm yöntemleri tutarlılık (accuracy), kesinlik (precision), duyarlılık (recall), F1 puanı (F1 score) ve alıcı işletim karakteristiği (Receiver Operating Characteristic – ROC) eğrisi – eğrinin altında kalan alandır (Area Under the Curve – AUC). Bu ölçüm yöntemlerinin nasıl hesaplandığına değinmeden önce, sınıflandırıcıların performansını ölçmeye yarayan hata matrisi (confusion matrix) kavramından bahsetmek gerekir. Hata matrisi, sınıflandırıcı eğitildikten sonra test veriseti ile elde edilen tahminlerin ve gerçek sınıfların bir arada gösterildiği Şekil 3.26'de bir örneği olan tablodur. Bu tabloya bakarak önerilen modeli değerlendirenler, olması gereken sınıfın kaç farklı sınıf olarak tahmin edildiğini görebilir. Bu tablodan da yukarıda bahsedilen ölçüm yöntemlerinin hesaplanmasında kullanılan aşağıdaki dört değer elde edilir.

- **Doğru Pozitif (True Positive – TP)** : Sınıflandırıcının gerçek termal hissiyatı doğru bir şekilde tahmin ettiği toplam tahmin sayısı.
- **Yanlış Pozitif (False Positive – FP)** : Sınıflandırıcının diğer termal hissiyat sınıflarına ait bir termal sınıfı, başka bir sınıf olarak tahmin ettiği toplam tahmin sayısı.
- **Doğru Negatif (True Negative – TN)** : Bir sınıfa ait olmadan o sınıf olarak tahmin edilmeyen toplam tahmin sayısı.
- **Yanlış Negatif (False Negative – FN)** : Sınıflandırıcının belirli bir termal hissiyat sınıfı için yaptığı yanlış tahminlerin toplam sayısı.

		Gerçek Sınıf	
		Pozitif	Negatif
Tahmin Edilen Sınıf	Pozitif	TP	FP
	Negatif	FN	TN

Şekil 3.26. Hata matrisi örneği

### 3.4.1. Tutarlılık

Her bir sınıf için tutarlılık ayrı-ayrı olarak gerçek pozitif ve gerçek negatif değerlerin toplamının tüm doğru ve yanlış, pozitif ve negatif değerlere bölünmesi ile aşağıdaki gibi hesaplanır;

$$Tutarlılık = \frac{TP + TN}{TP + TN + FP + FN}$$

Tüm modelin tutarlılık performansı ise aşağıdaki gibi hesaplanır;

$$Toplam\ Tutarlılık = \frac{Toplam(TP)}{Toplam(FP) + Toplam(FN)}$$

### 3.4.2. Kesinlik

Kesinlik, herhangi bir sınıf için doğru tahminlerin diğer tüm tahminlere oranını ölçen bir ölçüdür ve Şekil 3.4'te görüldüğü gibi sınıfların dengesiz olduğu durumlarda faydalı bir ölçüdür. Kesinlik, her bir sınıf için aşağıdaki gibi hesaplanır;

$$Kesinlik = \frac{TP}{TP + FP}$$

### 3.4.3. Duyarlılık

Doğru tahmin edilen sınıfların, o sınıfa ait olmayan diğer tüm sınıflara oranıdır ve aynı zamanda, hassasiyete benzer şekilde, sınıflar dengesiz olduğunda kullanmak için iyi bir ölçüttür. Bu ölçüt de her bir sınıf için aşağıdaki gibi hesaplanır;

$$Duyarlılık = \frac{TP}{FN + FP}$$

### 3.4.4. F1 Puanı

Kesinlik ve hatırlamanın harmonik ortalamasıdır. Kesinlik ve geri çağırma arasında seçim yapmanın, modelin yanlış pozitifleri ve yanlış negatifleri açısından değerlendirilmesini sağlar. F1 puanı da her bir sınıf için hesaplanmalıdır ve aşağıdaki gibi formül kullanılarak elde edilir;

$$F1 \text{ Puanı} = 2 \times \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}}$$

Normal şartlar altında oluşturduğumuz modelin kesinlik ve duyarlılık ölçütlerinin mümkün olduğu kadar 1'e yakın sonuçlar üretmesini isteriz ki bu F1 puanının aynı şekilde 1'e yakın olmasını hatta tutarlılığın da %100'e yakın olmasını sağlar. Fakat ne yazık ki yapay öğrenme modelleri için bu sıkça karşılaşılmayan bir durumdur. Bu nedenle de kesinlik ve tutarlılığın mümkün olduğunca yüksek olduğu modeller tercih edilmelidir.

### 3.4.5. ROC – AUC

Son olarak da ROC – AUC'den bahsetmeden önce üzerinde durulması gereken doğru pozitif oranı (True Positive Rate – TPR) ve yanlış negatif oranı (False Positive Rate – FPR) adında iki ölçüt daha mevcuttur.

$$TPR = \frac{TP}{TP + FN}$$

$$FPR = \frac{FP}{FP + TN}$$

ROC eğrisi ve AUC, bir sınıflandırıcının tüm sınıflar arasında ayırt etme yeteneğinin grafiksel temsil yöntemidir. AUC ne kadar yüksekse, model sınıfları doğru bir şekilde tahmin etmede o kadar başarılıdır. ROC ise FPR'a karşı TPR çizen bir olasılık eğrisidir. Tüm bu değerlendirme kriterlerine ait sonuçlardan hem DNN hem de CNN modeli için


SONUÇ kısmında detaylı olarak bahsedilmiştir.



#### 4. SONUÇLAR


Elde edilen sonuca ulaşabilmek için 100'den farklı deney yapılmıştır. Bu deneyler yapay öğrenme için oluşturulmuş açık kaynak kodlu TensorFlow platformu kullanılarak yapılmıştır. Bu platformun ikinci versiyonunun tercih edilmesinin sebebi ise daha hızlı işlem gücü sağlaması sebebiyle GPU hesaplama olanak sağlamasıdır. Deneylerin yapıldığı bilgisayar Intel(R) Core(TM) i7-9750H 6 Core @2.60 GHz işlemci, 16GB DDR4 4.5 GHz RAM hafıza ve NVIDIA GeForce RTX 2060 6GB grafik kartına sahiptir. Bu bilgisayara ek olarak deneyler ikinci bir kaynak olması adına Google'ın ücretsiz olarak sağladığı bulutta yer alan Colab platformunda da ek olarak gerçekleştirilmiştir. Modellerin oluşturulup eğitilmesi için Python programlama dilinden, verilerin incelenmesinde de Python'un Matplotlib ve Seaborn istatistiksel veri görselleştirme kütüphaneleri kullanılmıştır. Programlama editörü olarak da hem Colab hem de bilgisayardan faydalandığı için kod taşıma kolaylığı olması için Jupyter tercih edilmiştir.

Yapılan deneyler sonucunda elde edilen en yüksek tutarlılık değeri DNN tarafından sağlanmaktadır ve %78'dir. Tutarlılığın yanında %77 kesinlik, %78 duyarlılık ve %77 F1 puanı elde edilmiştir. Bu değeri sağlayan üst değişkenler ise Tablo 3.4'te gösterildiği gibidir. Önceki bölümde de değinildiği gibi bu değerın hesaplanabilmesi için öncelikle hata matrisine bakılması gerekir. Şekil 4.1'de sol tarafta gösterilen sınıflar tahmin edilenleri, alta gösterilenler ise gerçek sınıf değerlerini temsil etmektedir. Şekilde hücrelerde yer alan sayı ne kadar büyükse o hücreyi dolduran renk o kadar açıktır. Dolayısıyla iyi performansa sahip bir modelin kolon ve satırlarında aynı değere sahip hücrelerdeki renklerin çok açık renge sahip olması beklenmektedir. Bu şekle göre örneğin -3 yani "Çok Soğuk" olarak yapılan oylamaların toplamına ulaşmak için o kolonda bulunan bütün değerlerin toplanması gerekmektedir. Yani, kullanılan veri tabanında bu toplam  $2 + 9 + 32 + 60 + 40 + 31 + 2.735 = 2.878$ 'dir. Öte yandan modelin aynı sınıf için tahminlerinin toplamına ulaşmak için de o satırda bulunan tüm değerlerin toplanması gerekir. Bu da  $2.735 + 8 + 9 + 8 + 8 + 4 + 3 = 2.775$ 'dir. Bu örneğe göre model aslında 2.878 "Çok Soğuk" sınıfından 2.735'ini doğru tahmin ederken; 8 adet "Soğuk" sınıfını, 9 adet "Serin" sınıfını, 8 adet "Doğal" sınıfını, 8 adet "Hafif Sıcak" sınıfını, 4 adet "Sıcak" sınıfını ve son olarak da 3 adet "Çok Sıcak" sınıfını "Çok Soğuk" olarak tahmin etmiştir.




Şekil 4.1. En iyi sonucu üreten DNN modelinin hata matrisi

Şekil 4.2’de önerilen modelin sınıfları birbirinden ayırt etmedeki başarısını gösteren hem ROC eğrisini hem de AUC değerleri görülebilmektedir. Grafikteki eğri y ekseninde ne kadar yüksekte geçiyorsa o sınıf için modelin tahminindeki TP değeri FN değerinden o kadar büyük demektir. 3.4.5’te de açıklandığı gibi AUC değeri ne kadar yüksekse yani 1’e ne kadar yakınsa modelin sınıfları ayırt etme yeteneği de o kadar yüksektir. Bu grafiğe göre model en yüksek değerlere 1 ile “Çok Soğuk” ve 0,99 ile “Çok Sıcak” sınıfları için ulaşmaktadır. Öte yandan en düşük değeri ise 0,84 ile “Doğal” sınıfı için üretmiştir. Mikro ve makro ortalamalarında 0,96 ve 0,95 değeri de oldukça yüksek tutarlılıkla tahmin üretme yeteneğine sahip olduğunun bir göstergesidir.

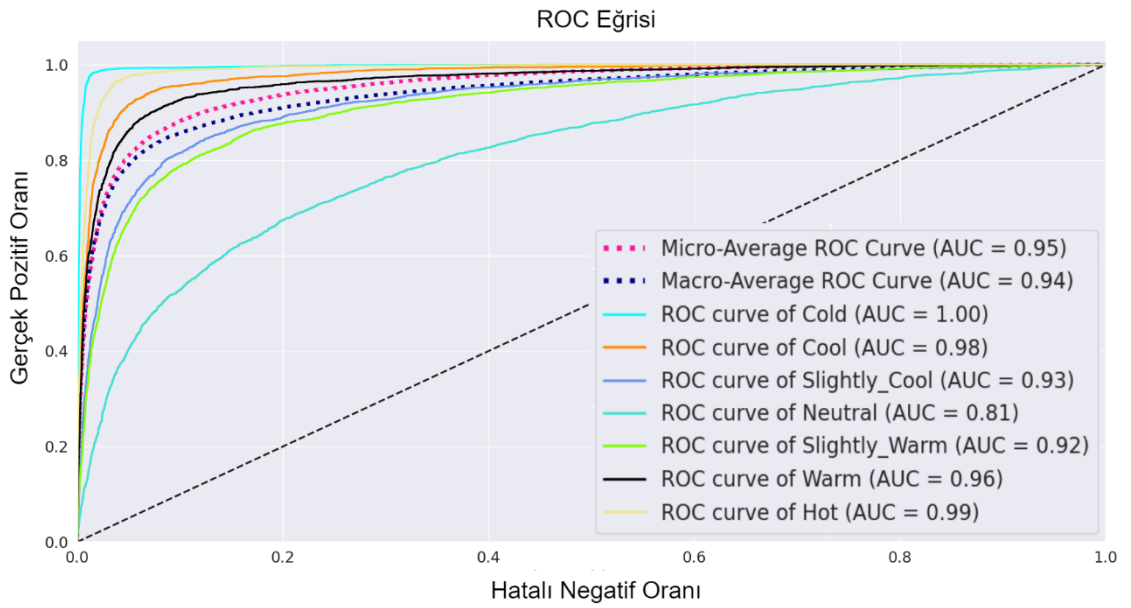


Şekil 4.2. Önerilen DNN modelinin ROC eğrisi ve AUC değerleri

Aynı değerlendirmeyi CNN için yaptığımızda üretilen sonuç biraz daha düşük %1'lik bir farkla %77'dir. Aynı modelin kesinlik değeri %76, duyarlılık değeri %77 ve F1 puanı ise %77'dir. Yine bu değeri sağlayan üst değişkenler Tablo 3.4'ten görülebilmektedir. Bu sayı yine de PMV ve sığı yöntemlere göre daha iyi bir tutarlılık değeri ile tahmin yürütebildiğini göstermektedir modelin. Şekil 4.3 ve Şekil 4.4 incelediğimizde DNN ile çok benzer sonuçları görmekteyiz. Burada ilk göze çarpan farklılık DNN'e göre "Doğal" sınıfı için AUC değerinin 0,03; "Sıcak" sınıfının 0,01 daha düşük olduğudur ki bu da makro ve mikro ortalama hesaplamalarında ve dolaylı olarak da genel tutarlılıktaki 0,01 daha düşük değer üretmesinin sebebi olarak açıklanabilmektedir.



Şekil 4.3. En iyi sonucu üreten CNN modelinin hata matrisi



Şekil 4.4. Önerilen CNN modelinin ROC eğrisi ve AUC değerleri

Diğer sınıflar için aynı karşılaştırma yapıldığında ise değerlerin aynı olduğu kolaylıkla görülebilmektedir.

## 5. TARTIŞMA VE ÖNERİLER


Bu bölümde önerilen model kullanılarak elde edilen sonuçların güçlü ve zayıf yönleri değerlendirilmiş, ısı hissiyatın tahmin edilmesinde kullanılan diğer yöntemlerle karşılaştırılmış ve gelecekte hangi yönde araştırmanın devam ettirilebileceği yönünde tavsiyelerde bulunulmuştur. Şekil 4.1 ve Şekil 4.3'ün orta kısımlarına tekrar bakılacak olursa renklerin koyuya doğru gittiği yani sayıların küçüldüğü rahatlıkla görülebilmektedir ki bu da modelin “Doğal” ve ona yakın sınıfları tahmin etmedeki performansının uç noktadaki sınıfları tahmin etmesine göre daha düşük olduğunu göstermektedir. ROC grafiklerindeki AUC değerleri de bu durumu doğrular niteliktedir. Örneğin Şekil 4.2'deki “Çok Soğuk” sınıfı için AUC değerinin 1 olması, “Çok Sıcak” sınıfı için elde edilen AUC değerinin de 0,99 olması öte yandan da “Doğal” sınıfı yani 0 için bu değer 0,84 olması da bu sebepten dolayıdır ki modelin diğer sınıflardan ayırt etmekte en çok zorlandığı sınıf budur. Yine, hata matrisi grafiklerin de görülebileceği gibi “Serin”, “Doğal” ve “Hafif Sıcak” sınıflarına ait tahminleri gösteren hücrelerde rengin koyuya yaklaşması da bu durumu doğrular niteliktedir. Bu sınıfın bu kadar kolay ayrıştırılamamasının sebeplerinden biri denekler tarafından verilen ısı hissiyat oylarının çoğunluğunun subjektif koşullardan etkilenmiş olmalarıdır. 2.3'de bahsedildiği gibi kıyafet izolasyonu ve hareketlilik seviyesi gibi kişisel etkenler ne kadar ölçülebilse de kişinin o anki ruh halinin ısı çevresini duyumsamaktaki etkisi bilinmemektedir (Wang ve Liu, 2020). Fakat yine de genel tutarlılık söz konusu olduğunda önerilen yöntem PMV ve diğer sığı yöntemleri aynı veri işleme teknikleri kullanıldıktan sonra bile geride bırakabilmektedir. Buna dair bir karşılaştırma Tablo 5.1'de görülebilmektedir. Dikkat edilirse önerilen yöntem en iyi sonuç üreten RF'e göre %4 oranında daha iyi tahmin yürütmektedir. 3.4.3'de bahsedildiği gibi verisetindeki sınıfların dağılımının dengesiz olduğu durumlarda modelin performansının değerlendirilmesinin için duyarlılık skoru daha önemlidir. Sadece bu ölçüm göz önünde bulundurulduğunda bile en yakın değere yine başka bir derin öğrenme yöntemi olan CNN ile ulaşılmaktadır.

Tablo 5.1. Farklı yöntemlerin ürettiği sonuçların karşılaştırması

Yöntem	Tutarlılık	Kesinlik	Duyarlılık	F1 Puanı
DNN	%78	%77	%78	%77
CNN	%77	%76	%77	%77
RF	%74,8	%74,1	%74,8	%74,4
SVC	%31	%28,7	%31	%28

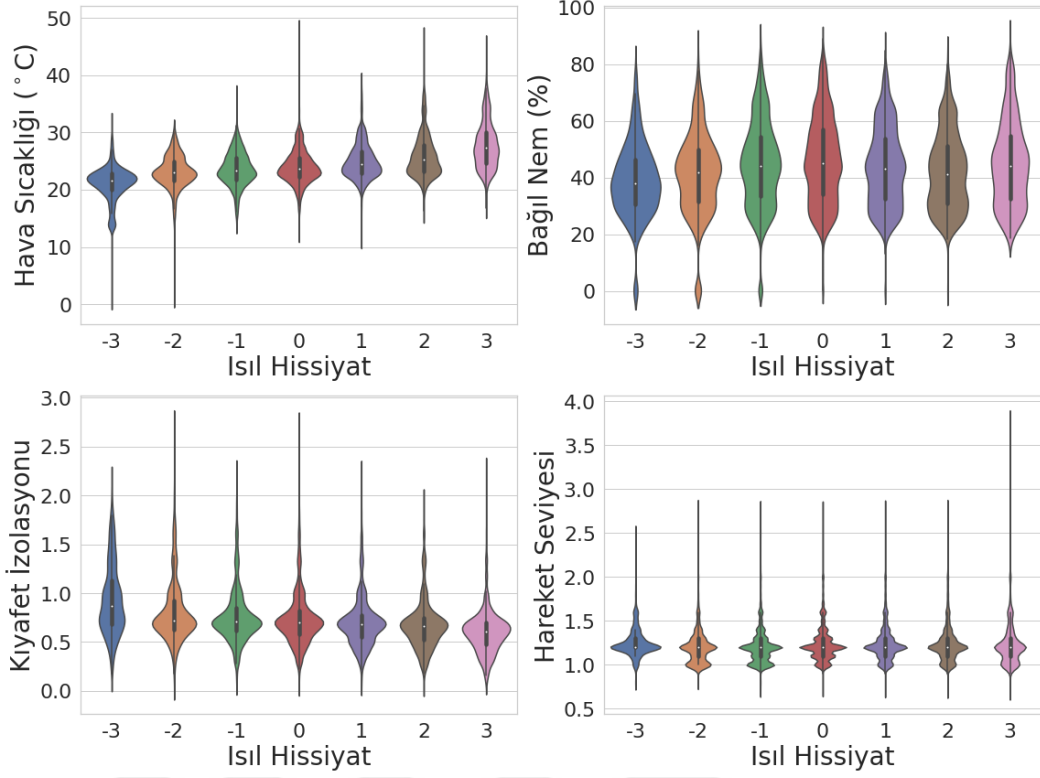
Karar Ağacı	%61,9	%61,6	%61,9	%61,7
Gradiend Boosting	%42	%40,4	%42,1	%40
kNN	%67	%61	%65	%65
PMV	%36	%16	%16	%15

Şekil 5.1'den de görülebileceği gibi PMV %36 ile SVC'ye göre daha yüksek tutarlılıkta tahmin yürütüyormuş gibi görünse de aslında %16 ile en düşük duyarlılık oranına sahiptir ve bu da dengede olmayan bir veriseti için tahmin yeteneğinin çok da iyi olmadığını göstermektedir. PMV'nin, değişken katsayıları önceden belirlendiği için bir anlamda katı kurallara sahip denilebilir. Bu nedenle bu model, esnek olmayan bir sistemi temsil eden kural-tabanlı bir model olarak değerlendirilebilir. Öte yandan, makine öğrenme modelleri değişken katsayılarını (veya kuralları) tümevarımsal bir şekilde öğrenmeyi amaçladıkları için daha esnektir ve bu durum araştırmacıların daha fazla veri ekledikçe sistem genelleme yeteneğini artırdığı için, araştırmacıların tek bir alan veya çeşitli alan türleri için daha doğru tahminler oluşturmasına olanak tanır. Bu sebeple de PMV'nin düşük duyarlılık elde etmesi anlaşılabilir.



Şekil 5.1. Aynı veriseti ile farklı algoritmaların değerlendirme metriklerinin karşılaştırılması

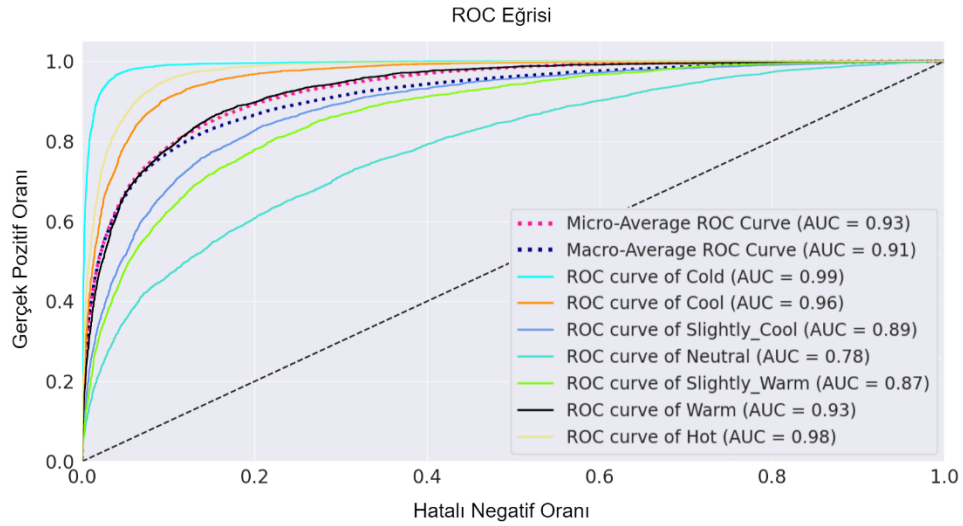
Şekil 5.2, kıyafet yalıtımı, hareketlilik seviyesi, iç ortam hava sıcaklığı, iç ortam bağıl nemi ve ısı hissiyat ölçeği arasındaki ilişkiyi tanımlar. Bu şekle göre kişisel faktörler, çevresel faktörler ve çıktı arasında doğrudan pozitif veya negatif bir ilişkinin olmaması nedeniyle bir bakışta çıkarım yapmanın zor olduğu açıktır. Verisetinin de Şekil 3.9'de de görüldüğü gibi sınıfları arasında dağılım bakımından dengesiz olduğu göz önünde bulundurulduğunda önerilen modelin oldukça iyi sonuç ürettiği düşünülmektedir.



Şekil 5.2. Bazı çevresel ve kişisel değişkenlerin ısı hissiyat ile olan ilişkisi

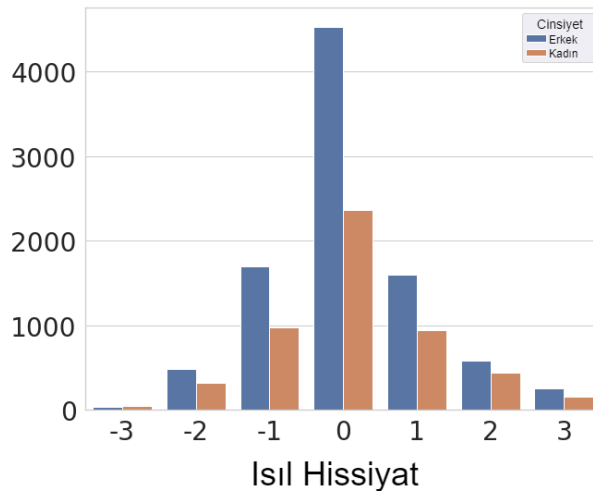
Çalışma sırasında veri işleme tekniklerinin genel tutarlılık üzerindeki etkisi de araştırılmıştır. Ölçeklendirme yapılmadığı takdirde tutarlılık %1 - %2 aralığında gerilerken, aykırı verilerin çıkarılmadığı durumlarda bu değer %7 - %8 aralığında olmaktadır. Fakat aynı durum Robust ölçeklendirme için geçerli değildir. Aykırı verilerin çıkarılmadığı ve Robust ölçeklendirmenin kullanıldığı durumlarda tutarlılıkta dramatik bir düşüş yaşanmamaktadır. Dönüşümün uygulanmadığı durumlarda ise model yine %1 - %2 oranında daha az tutarlılık ile tahmin yürütebilmektedir.

Veri herhangi bir işleme tabi tutulmadan doğrudan modelin eğitimi için kullanılırsa mevcut sonuçtan %11 daha kötü sonuç üretmektedir. **Error! Reference source not found.**'de de bu durumun ROC grafiği görülmektedir. AUC değerlerine bakılacak olursa en kötü değeri yine "Doğal" sınıfı için elde etmektedir fakat öncekine göre 0,06 daha düşüktür. Bu model için duyarlılık değeri %67'dir ve bu değer önerilen derin öğrenme modeline en yakın sonucu üreten sığı model olan Random Forest'dan neredeyse %8 daha düşüktür.

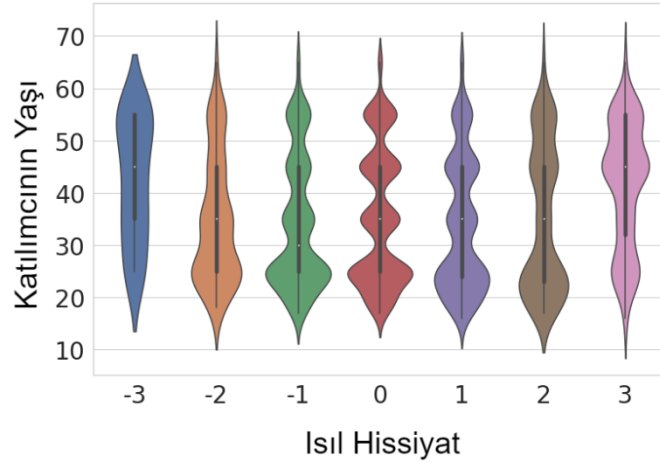


Şekil 5.3. Herhangi bir veri işleme olmadan önerilen DNN modelinin ROC grafiği

Araştırmamıza ek olarak, binada bulunanların cinsiyeti, yaşı, kilosunu ve boyu gibi diğer kişisel faktörlerin önemini belirlemek için daha fazla çalışmaya ihtiyaç vardır. Katılımcının cinsiyetinin termal duyu algısı ile çok zayıf bir korelasyona sahip olduğu Şekil 5.4'den görülmektedir (Zhang vd. 2020). Modelin eğitimi için kullanılan verisetinde yaş, cinsiyetten ısı hissiyat ile daha yüksek bir korelasyona sahip olmasına rağmen, bir faktör olarak analizimize dahil edilmemiştir. Şekil 5.5'ten de görülebileceği gibi yaş arttıkça "Doğal" ve ona yakın sınıfların hissedilme oranı da azalmaktadır. Buradan da yaşlıların uç sınıfları hissetme oranı daha yüksek denilebilir. Bu nedenle gelecekte araştırmaya kişisel etkenlerin dahil edilmesinde fayda olacaktır.



Şekil 5.4. Isıl hissiyatın cinsiyete göre histogramı



Şekil 5.5. Yaşın ısı hissiyat ile ilişkisini gösteren violin grafiği

Akıllı saatler gibi giyilebilir teknolojilerden yararlanmak, kullanıcıların hareketlilik seviyeleri hakkında daha doğru veriler elde etmek için gelecekteki bir araştırma konusu olarak düşünülebilir. Özellikle nabız, kandaki oksijen düzeyi veya uyku düzeni gibi fiziksel durum hakkında akıllı saatler kullanarak daha fazla bilgi sahibi olmak, kişinin duygusal durumu hakkında fikir vererek subjektif yargıların ortadan kalkmasında yardımcı olabilir. Önerilen modelin tutarlılığı, uygun şekilde etiketlenmiş değerlere sahip bir veri seti kullanılarak artırılabilir. Ek olarak gelecekte boyut azaltma yönteminin uygulanması veya değişkenlerin bir alt kümesinin seçilmesinin de modelin performansı üzerinde olumlu etki yaratıp, yaratmayacağı konusunda bir araştırma yapılabilir. Ayrıca, bina operatörlerine, bina sakinlerinin ısı hissiyatını tahmin ederek iklimlendirme sistemleri için açma/kapama zamanlarını planlamalarına yardımcı olacak bir öneri sistemi oluşturmak, enerji tasarrufu sağlamak için kullanılabilir. Dahası, Zigbee veya BACnet gibi iyi bilinen iletişim protokollerinden birini kullanarak modeli mevcut bir HVAC sistemiyle bütünleşmiş olarak gerçek zamanlı HVAC ayar noktası ayarının termal konfor ve enerji tasarrufu üzerindeki etkisini incelemek için bir araştırma da yapılabilir.

## 6. SONUÇ

Bina sakinlerinin ısı hissiyatlarını tahmin etmek, HVAC sistem operatörlerinin iç mekan termal konforunu sağlarken enerji tüketimini optimize etmesine olanak tanır. Bu araştırmada ısı rahatlığın tahmin edilmesinde hangi yöntemlerin kullanıldığı, verilerin nasıl toplandığı ve enerji tasarrufunun sağlanmasında doğrudan ya da dolaylı olarak hangi yöntemlerin kullanıldığı sorularına cevaplar bulunmuştur. Araştırmaya göre özellikle son yıllarda, bilgisayarların hesaplama güçlerinin artması ile yapay sinir ağları geniş çapta yer bulmaktadır. Yine araştırmalar göstermiştir ki önceki çalışmalarda çoğunlukla doğrudan enerji tasarrufu yerine ısı hissiyatın tahmininin iyileştirilmesi hem ihtiyaç dışı kullanımın önüne geçmesi hem de ofis benzeri ortamlarda çalışan performansını artırması sebebiyle tercih edilmiştir. Bunu başarmak için de kullanılan veri toplama yöntemleri açıklanmıştır. Azımsanamayacak miktarda çalışma önceden toplanan verileri kullanarak hedefe ulaşmayı başarmıştır. ASHRAE tarafından 66 farklı çalışmadan toplanan veriler üzerinde önerilen derin öğrenme modeli eğitilmiş ve test edilmiş, DNN tabanlı bir termal duyum tahmin modelini tanıtılmıştır. İlk olarak, yedi noktalı ölçekte termal hissiyat tahmini için kullanılacak değişken setine karar verilmiştir. Tüm boş, tekrar eden ve aykırı veri noktalarını silerek, DNN modelini eğitmek için 30.000'den fazla veri noktası elde edilmiştir. En iyi tutarlılıkla tahmin yürütecek üst değişkenlerin bulunması içinse Bayesian arama algoritması adapte edilmiştir. Tespit edilen üst değişkenlerin grafiksel sunumu sağlanmış ve modelin eğitiminden sonra, elde edilen genel tutarlılık %78 olarak tespit edilmiştir. Bu değer 1.2'de söz edilen  $H_0$  hipotezinin reddedilmesi için yeterlidir. Aynı veriseti ile üzerinde eğitilen diğer yöntemlerden ve geleneksel PMV modelinde daha yüksek bir puandır. Bu durum ayrıca, girdi özellikleri ve çıktı etiketinin doğrudan bir ilişkisi olmamasına ve veri kümesinin oldukça dengesiz olmasına rağmen, önerilen modelin termal duyum tahmini için uygun olduğunu göstermiştir. Fakat şu unutulmamalıdır ki ANN modelimizde eğittiğimiz verilerin güvenilirliği, insan algısı etkisi altındadır ve bu nedenle ısı hissiyat oylarının istatistiksel açıdan geçerli olduğu ön koşulu ile araştırmaya başlanmıştır. Önerilen derin öğrenme modeli “Çok Soğuk” ve “Çok Sıcak” gibi uç noktalardaki sınıfların yani memnun olunmayan durumların tahmin edilmesinde “Doğal” durumuna göre daha tutarlıdır. Bunun sebeplerine de

arařtırma deęinilmiřtir. Memnuniyetsizlięin tespit edilmesi de ortam kořullarının otomatik olarak dzenlenmesi iin nemlidir. Gelecekte arařtırmaya boyut azaltma algoritmalarının veya giyilebilir teknolojilerin nasıl dahil edilerek daha tutarlı tahminler retilbileceęi de arařtırmada tartiřılmıřtır.



## KAYNAKLAR

Ahmadi-Karvigh, S., Becerik-Gerber, B., ve Soibelman, L. "Intelligent adaptive automation: A framework for an activity-driven and user-centered building automation", *Energy and Buildings*, 188, 184-199, 2019

Chaudhuri, T., Zhai, D., Soh, Y. C., Li, H., ve Xie, L. "Thermal comfort prediction using normalized skin temperature in a uniform built environment", *Energy and Buildings*, 159, 426-440, 2018

Clements-Croome, D., ve Baizhan, L., "Productivity and indoor environment", *Proceedings of Healthy Buildings 1.1 (2000)*: pp. 629-634

Desideri, U., Proietti, S., ve Sdringola, P. "Solar-powered cooling systems: technical and economic analysis on industrial refrigeration and air-conditioning applications", *Applied Energy*, 86, 1376-1386, 2009

Liang, J., ve Du, R. "Design of intelligent comfort control system with human learning and minimum power control strategies", *Energy Conversion and Management*, 49, 517-528, 2008

Nemethova, E., Stutterecker, W., ve Schoberer, T. "Thermal Comfort and HVAC Systems Operation Challenges in a Modern Office Building-Case Study", *Selected Scientific Papers: Journal of Civil Engineering*, 11(2), 2016

Pérez-Lombard, L., Ortiz, J., ve Pout, C. "A review on buildings energy consumption information", *Energy and Buildings*, 40, 394-398, 2008

Qi, R., Lu, L., ve Yang, H. "Investigation on air-conditioning load profile and energy consumption of desiccant cooling system for commercial buildings in Hong Kong", *Energy and Buildings*, 40, 509-518, 2012

Standard, ASHRAE. 2004. "Standard 55-2004 (2004) Thermal environmental conditions for human occupancy", American Society of Heating, Refrigerating and Air-Conditioning Engineers Inc., Atlanta

Standard, ANSI/ASHRAE. 2017. "Standard 55-2017: Thermal Environmental Conditions for Human Occupancy", American Society of Heating, Refrigerating and Air-Conditioning Engineers Inc., Atlanta

Vakiloroaya, V., Samali, B., Fakhar, A., ve Pishghadam, K. "A review of different strategies for HVAC energy saving", *Energy conversion and management*, 77, 738-754, 2014

Robert McDowall, *Fundamentals of HVAC Systems: SI edition*. Atlanta: Academic Press, 2007.

Samuel C. Sugarman, *HVAC Fundamentals, Second Edition*. Lilburn: The Fairmont Press, Inc., 2007

Preller, L., Zweers, T., Brunekreef, B., ve Boleij, J. S. M., "Sick leave due to work-related health complaints among office workers in The Netherlands". *In Proc. 5th Int. Conf. Indoor air quality and climate*, Toronto. Vol. 1 (1990): pp. 227-230.

Avaltroni, R., Constantinides, C., Dipaolo, G., Fields, R., Gallo, L., ve Glorie, D., "Indoor air quality and sick building syndrome in health care facilities and commercial buildings", Environmental Advisory Council, 2015

Yang, W., Elankumaran, S., ve Marr, L. C., "Relationship between humidity and influenza A viability in droplets and implications for influenza's seasonality", PLOS ONE, 2012

Wyon, D. P., "The effects of indoor air quality on performance and productivity", *Indoor air*, 14, 92-101, 2004

Fanger, P. O., "Thermal comfort. Analysis and applications in environmental engineering" *Thermal comfort. Analysis and applications in environmental engineering*, 1970

Wong, J. K., Li, H., & Wang, S. W., "Intelligent building research: a review", *Automation in construction*, 14(1), 143-159, 2005

Hensen, J. L. M., "Application of modelling and simulation to HVAC systems", *In Proc. 30th Int. Conf. MOSIS Vol. 96*, 1996

Afram, A., ve Janabi-Sharifi, F., "Review of modeling methods for HVAC systems", *Applied Thermal Engineering*, 67(1-2), 507-519, 2014

Afram, A., ve Janabi-Sharifi, F., "Gray-box modeling and validation of residential HVAC system for control system design" *Applied Energy*, 137, 134-150, 2015

Afram, A., ve Janabi-Sharifi, F., "Black-box modeling of residential HVAC system and comparison of gray-box and black-box modeling methods", *Energy and Buildings*, 94, 121-149, 2015

Arendt, K., Jradi, M., Shaker, H. R., ve Veje, C., "Comparative analysis of white-, gray- and black-box models for thermal simulation of indoor environment: Teaching building case study" *In Proceedings of the 2018 Building Performance Modeling Conference*

and SimBuild co-organized by ASHRAE and IBPSA-USA, Chicago, IL, USA (pp. 26-28), 2018

Wang, S., ve Ma, Z., "Supervisory and optimal control of building HVAC systems: A review", *Hvac&R Research*, 14(1), 3-32, 2008

Kumar, R., Aggarwal, R. K., ve Sharma, J. D., "Energy analysis of a building using artificial neural network: A review", *Energy and Buildings*, 65, 352-358, 2013

Homod, R. Z., "Review on the HVAC system modeling types and the shortcomings of their application", *Journal of Energy*, 2013.

Afroz, Z., Shafiullah, G. M., Urmee, T., ve Higgins, G., "Modeling techniques used in building HVAC control systems: A review", *Renewable and sustainable energy reviews*, 83, 64-84, 2018

Wang, X., Xia, J., Zhang, X., Shiochi, S., Peng, C., ve Jiang, Y., "Modelling and experiment analysis of variable refrigerant flow air-conditioning systems", In *Proceedings of the IBPSA conference on building simulation*, pp. 361-368, 2009

Ma, Q., Wang, R. Z., Dai, Y. J., ve Zhai, X. Q., "Performance analysis on a hybrid air-conditioning system of a green building", *Energy and Buildings*, 38(5), 447-453, 2006

Aria, H., "A systematic approach of integrated building control for optimization of energy and cost", *Doctoral dissertation, Concordia University*, 2015

Fasiuddin, M., ve Budaiwi, I., "HVAC system strategies for energy conservation in commercial buildings in Saudi Arabia", *Energy and Buildings*, 43(12), 3457-3466, 2011

Alom, M. Z., Taha, T. M., Yakopcic, C., Westberg, S., Sidike, P., Nasrin, M. S., Hasan M., Van Essen B. C., Awwal A. S. A., ve Asari, V. K., "A state-of-the-art survey on deep learning theory and architectures", *Electronics*, 8(3), 292, 2019

Afram, A., ve Janabi-Sharifi, F., "Theory and applications of HVAC control systems—A review of model predictive control (MPC)", *Building and Environment*, 72, 343-355, 2014

Magoulès, F., ve Zhao, H. X., "Data mining and machine learning in building energy analysis", *John Wiley & Sons*, 2016

Levent, V. E., & Dirı, B., "Türkçe Dokümanlarda Yapay SinirAğları İle Yazar Tanıma", *Akademik Bilişim*, 14, 5-7, 2014

- Tezel, G., "Biyomedikal işaretlerin yeni bir adaptif aktivasyon fonksiyonlu yapay sinir ağı ile sınıflandırılması", Doktora Tezi, Selçuk Üniversitesi Fen Bilimleri Enstitüsü, 2007
- Afroz, Z., Shafiullah, G. M., Urmee, T., ve Higgins, G., "Prediction of indoor temperature in an institutional building", *Energy Procedia*, 142, 1860-1866, 2017
- Ghahramani, A., Castro, G., Karvigh, S. A., ve Becerik-Gerber, B., "Towards unsupervised learning of thermal comfort using infrared thermography", *Applied Energy*, 211, 41-49, 2018
- Katipamula, S., ve Brambley, M. R., "Methods for fault detection, diagnostics, and prognostics for building systems—a review, part I", *Hvac&R Research*, 11(1), 3-25, 2005
- Energy, U. S., ve Information Administration, "International Energy Outlook. Report No.: DOE/EIA-0484", 2009
- Guo, Y., Wall, J., Li, J., ve West, S., "Real-time HVAC sensor monitoring and automatic fault detection system", In *Sensors for everyday life* (pp. 39-54). Springer, Cham., 2017
- Li, D., Menassa, C. C., ve Kamat, V. R., "Personalized human comfort in indoor building environments under diverse conditioning modes", *Building and Environment*, 126, 304-317, 2017
- Javed, M., Li, N., ve Li, S., "Personalized thermal comfort modeling based on Support Vector Classification", In *2017 36th Chinese Control Conference (CCC)* (pp. 10446-10451). IEEE., 2017
- Kim, J., Zhou, Y., Schiavon, S., Raftery, P., ve Brager, G., "Personal comfort models: Predicting individuals' thermal preference using occupant heating and cooling behavior and machine learning", *Building and Environment*, 129, 96-106, 2018
- Chaudhuri, T., Soh, Y. C., Li, H., ve Xie, L., "Machine learning based prediction of thermal comfort in buildings of equatorial Singapore", In *2017 IEEE International Conference on Smart Grid and Smart Cities (ICSGSC)* (pp. 72-77). IEEE., 2017
- Bin, S., ve Ke, H., "Indoor thermal comfort pmv index prediction based on particle swarm algorithm and least square support vector machine", In *2010 International Conference on Intelligent System Design and Engineering Application* (Vol. 1, pp. 857-860). IEEE., 2010

Collotta, M., Messineo, A., Nicolosi, G., ve Pau, G., "A dynamic fuzzy controller to meet thermal comfort by using neural network forecasted parameters as the input", *Energies*, 7(8), 4727-4756, 2014

Deng, Z., ve Chen, Q., "Artificial neural network models using thermal sensations and occupants' behavior for predicting thermal comfort", *Energy and Buildings*, 174, 587-602, 2018

Li, Q., Meng, Q., Cai, J., Yoshino, H., ve Mochida, A., "Applying support vector machine to predict hourly cooling load in the building", *Applied Energy*, 86(10), 2249-2256, 2009

Guo, Y., Li, G., Chen, H., Wang, J., ve Huang, Y., "A thermal response time ahead energy demand prediction strategy for building heating system using machine learning methods", *Energy Procedia*, 142, 1003-1008, 2017

Dai, C., Zhang, H., Arens, E., ve Lian, Z., "Machine learning approaches to predict thermal demands using skin temperatures: Steady-state conditions", *Building and Environment*, 114, 1-10, 2017

Liu, W., Lian, Z., ve Zhao, B., "A neural network evaluation model for individual thermal comfort", *Energy and Buildings*, 39(10), 1115-1122, 2007

Tin, T. T., Yuan, C. Z., ve Selvaraj, K. R., "Smart-Learning Networked Controllers for Centralized Air-Conditioning Systems Using Model-View-Controller Model", In *International Visual Informatics Conference* (pp. 737-749). Springer, Cham, 2017

Marvuglia, A., Messineo, A., ve Nicolosi, G., "Coupling a neural network temperature predictor and a fuzzy logic controller to perform thermal comfort regulation in an office building", *Building and Environment*, 72, 287-299, 2014

Atthajariyakul, S., ve Leephakpreeda, T., "Neural computing thermal comfort index for HVAC systems", *Energy conversion and management*, 46(15-16), 2553-2565, 2005

Castilla, M., Álvarez, J. D., Ortega, M. G., ve Arahál, M. R., "Neural network and polynomial approximated thermal comfort models for HVAC systems", *Building and Environment*, 59, 107-115, 2013

CSB. 24 Nisan 2019. Türkiye Cumhuriyeti Çevre ve Şehircilik Bakanlığı. 8 Eylül 2021. <<http://cevreselgostergeler.csb.gov.tr/sektorlere-gore-toplam-enerji-tuketimi-i-85800>>

EB. 2018. Enerji ve Tabii Kaynaklar Bakanlığı. 13 Aralık 2018. <<http://www.enerji.gov.tr/tr-TR/Sayfalar/Elektrik>>

Peng, Y., Rysanek, A., Nagy, Z., ve Schlüter, A., "Using machine learning techniques for occupancy-prediction-based cooling control in office buildings", *Applied energy*, 211, 1343-1358, 2018

Deb, C., Lee, S. E., ve Santamouris, M., "Using artificial neural networks to assess HVAC related energy saving in retrofitted office buildings", *Solar Energy*, 163, 32-44, 2018

Zamora-Martínez, F., Romeu, P., Botella-Rocamora, P., ve Pardo, J., "On-line learning of indoor temperature forecasting models towards energy efficiency", *Energy and Buildings*, 83, 162-172, 2014

Ding, Y., Zhang, Q., Yuan, T., ve Yang, K., "Model input selection for building heating load prediction: A case study for an office building in Tianjin", *Energy and Buildings*, 159, 254-270, 2018

Ding, Y., Zhang, Q., ve Yuan, T., "Research on short-term and ultra-short-term cooling load prediction models for office buildings", *Energy and Buildings*, 154, 254-267, 2017

Catalina, T., Virgone, J., ve lordache, V., "Study on the impact of the building form on the energy consumption", In *Proceedings of building simulation* (pp. 1726-1729), 2011

Roy, S. S., Roy, R., ve Balas, V. E., "Estimating heating load in buildings using multivariate adaptive regression splines, extreme learning machine, a hybrid model of MARS and ELM", *Renewable and Sustainable Energy Reviews*, 82, 4256-4268, 2018

Fu, G., "Deep belief network based ensemble approach for cooling load forecasting of air-conditioning system", *Energy*, 148, 269-282, 2018

Li, Z., ve Huang, G., "Re-evaluation of building cooling load prediction models for use in humid subtropical area", *Energy and Buildings*, 62, 442-449, 2013

Huang, S., Zuo, W., ve Sohn, M. D., "A Bayesian Network model for predicting cooling load of commercial buildings", In *Building Simulation* (Vol. 11, No. 1, pp. 87-101). Springer Berlin Heidelberg, 2018

Peng, Y., Rysanek, A., Nagy, Z., ve Schlüter, A., "Occupancy learning-based demand-driven cooling control for office spaces", *Building and Environment*, 122, 145-160, 2017

Manjarres, D., Mera, A., Perea, E., Lejarazu, A., ve Gil-Lopez, S., “An energy-efficient predictive control for HVAC systems applied to tertiary buildings based on regression techniques”, *Energy and Buildings*, 152, 409-417, 2017

Kusiak, A., Li, M., ve Tang, F., “Modeling and optimization of HVAC energy consumption”, *Applied Energy*, 87(10), 3092-3102, 2010

Bida, M., ve Kreider, J. F., “Monthly-averaged cooling load calculations—residential and small commercial buildings”, 1987

Li, Q., Meng, Q., Cai, J., Yoshino, H., ve Mochida, A., “Applying support vector machine to predict hourly cooling load in the building”, *Applied Energy*, 86(10), 2249-2256, 2009

Le Cam, M., Zmeureanu, R., ve Daoud, A., “Cascade-based short-term forecasting method of the electric demand of HVAC system”, *Energy*, 119, 1098-1107, 2017

ASHRAE, A., “Ashrae guideline 14: measurement of energy and demand savings”, *American Society of Heating, Refrigerating and Air-Conditioning Engineers*, 35, 41-63, 2002

Chung, M. H., Yang, Y. K., Lee, K. H., Lee, J. H., ve Moon, J. W., “Application of artificial neural networks for determining energy-efficient operating set-points of the VRF cooling system”, *Building and Environment*, 125, 77-87, 2017

Reynolds, J., Hippolyte, J. L., ve Rezgui, Y., “A smart heating set point scheduler using an artificial neural network and genetic algorithm”, In *2017 International Conference on Engineering, Technology and Innovation (ICE/ITMC)* (pp. 704-710). IEEE, 2017

Fan, C., Xiao, F., ve Zhao, Y., “A short-term building cooling load prediction method using deep learning algorithms”, *Applied energy*, 195, 222-233, 2017

Idowu, S., Saguna, S., Åhlund, C., ve Schelén, O., “Applied machine learning: Forecasting heat load in district heating system”, *Energy and Buildings*, 133, 478-488, 2016

Zeng, Y., Zhang, Z., ve Kusiak, A., “Predictive modeling and optimization of a multi-zone HVAC system with data mining and firefly algorithms”, *Energy*, 86, 393-402, 2015

Mateo, F., Carrasco, J. J., Sellami, A., Millán-Giraldo, M., Domínguez, M., ve Soria-Olivas, E., "Machine learning methods to forecast temperature in buildings", *Expert Systems with Applications*, 40(4), 1061-1068, 2013

Ben-Nakhi, A. E., ve Mahmoud, M. A., "Energy conservation in buildings through efficient A/C control using neural networks", *Applied Energy*, 73(1), 5-23, 2002

Moon, J. W., ve Jung, S. K., "Development of a thermal control algorithm using artificial neural network models for improved thermal comfort and energy efficiency in accommodation buildings", *Applied Thermal Engineering*, 103, 1135-1144, 2016

Irshad, K., Khan, A. I., Irfan, S. A., Alam, M. M., Almalawi, A., ve Zahir, M. H., "Utilizing artificial neural network for prediction of occupants thermal comfort: A case study of a test room fitted with a thermoelectric air-conditioning system", *IEEE Access*, 8, 99709-99728, 2020

Gao, N., Shao, W., Rahaman, M. S., Zhai, J., David, K., ve Salim, F. D., "Transfer learning for thermal comfort prediction in multiple cities" *Building and Environment*, 195, 107725, 2021

Anand, P., Sekhar, C., Cheong, D., Santamouris, M., ve Kondepudi, S., "Occupancy-based zone-level VAV system control implications on thermal comfort, ventilation, indoor air quality and building energy efficiency", *Energy and Buildings*, 204, 109473, 2019

Feng, G., Lei, S., Gu, X., Guo, Y., ve Wang, J., "Predictive control model for variable air volume terminal valve opening based on backpropagation neural network", *Building and Environment*, 188, 107485, 2021

Ahn, J., ve Cho, S., "Development of an intelligent building controller to mitigate indoor thermal dissatisfaction and peak energy demands in a district heating system", *Building and Environment*, 124, 57-68, 2017

Chaudhuri, T., Zhai, D., Soh, Y. C., Li, H., ve Xie, L., "Thermal comfort prediction using normalized skin temperature in a uniform built environment", *Energy and Buildings*, 159, 426-440, 2018

Luo, M., Xie, J., Yan, Y., Ke, Z., Yu, P., Wang, Z., ve Zhang, J., "Comparing machine learning algorithms in predicting thermal sensation using ASHRAE Comfort Database II", *Energy and Buildings*, 210, 109776, 2020

Földvály Ličina, Veronika; Cheung, Toby; Zhang, Hui; de Dear, Richard; Parkinson, Thomas; Arens, Edward; Chun, Chungyoon; Schiavon, Stefano; Luo, Maohui; Brager,

Gail; Li, Peixian ve Kaam, Soazig, "ASHRAE Global Thermal Comfort Database II", <https://doi.org/10.5683/SP2/GNVEM8>, Scholars Portal Dataverse, V1, 2018

Schweiker, M., Fuchs, X., Becker, S., Shukuya, M., Dovjak, M., Hawighorst, M., ve Kolarik, J., "Challenging the assumptions for thermal sensation scales", *Building Research & Information*, 45(5), 572-589, 2017

Brownlee, Jason. *Data Preparation for Machine Learning: Data Cleaning, Feature Selection and Data Transforms in Python*. Vermont Victoria: Machine learning Mastery Pty Ltd, 2020

Altun, S., ve Talu, M. F., "Derin Sinir Ağları için Hiperparametre Metodlarının ve Kitlerinin İncelenmesi", *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 12(2), 187-199, 2021

Bergstra, J., ve Bengio, Y., "Random search for hyper-parameter optimization", *Journal of machine learning research*, 13(2), 2012

Bergstra, J., Bardenet, R., Bengio, Y., ve Kégl, B., "Algorithms for hyper-parameter optimization", *Advances in neural information processing systems*, 24, 2011

Çakır, M., Akbulut, A., ve Hatay Önen, Y., "Analysis of the use of computational intelligence techniques for air-conditioning systems: A systematic mapping study", *Measurement and Control*, 52(7-8), 1084-1094, 2019

Guo, T., Dong, J., Li, H., ve Gao, Y., "Simple convolutional neural network on image classification", In *2017 IEEE 2nd International Conference on Big Data Analysis (ICBDA)* (pp. 721-724). IEEE., 2017, March

Sharma, A., ve Kumar, D., "Non-image data classification with convolutional neural networks", *arXiv preprint arXiv:2007.03218.*, 2020

Yu, T., ve Zhu, H., "Hyper-parameter optimization: A review of algorithms and applications", *arXiv preprint arXiv:2003.05689*, 2020

Hutter, F., Kotthoff, L., ve Vanschoren, J., *Automated machine learning: methods, systems, challenges*. Springer Nature., 2019

Konstantakopoulos, I. C., Barkan, A. R., He, S., Veeravalli, T., Liu, H., ve Spanos, C., "A deep learning and gamification approach to improving human-building interaction and energy efficiency in smart infrastructure" *Applied energy*, 237, 810-821, 2019

Brownlee, J., *Machine learning mastery with Python: understand your data, create accurate models, and work projects end-to-end*. Machine Learning Mastery, 2016

Agarap, A. F., "Deep learning using rectified linear units (relu)", arXiv preprint arXiv:1803.08375, 2018

Ramachandran, P., Zoph, B., ve Le, Q. V., "Searching for activation functions", arXiv preprint arXiv:1710.05941, 2017

Bouchard, G., "Efficient bounds for the softmax function and applications to approximate inference in hybrid models", *In Proceedings of the Presentation at the Workshop For Approximate Bayesian Inference in Continuous/Hybrid Systems at Neural Information Processing Systems (NIPS)*, Meylan, France (Vol. 31), 2008 May

Wang, H., ve Liu, L., "Experimental investigation about effect of emotion state on people's thermal comfort", *Energy and Buildings*, 211, 109789, 2020

Alpaydin, Ethem, *Introduction to machine learning*. MIT press. 2020

Nicol, F., Rijal, H. B., Imagawa, H., ve Thapa, R., "The range and shape of thermal comfort and resilience", *Energy and Buildings*, 224, 110277, 2020

**EK-1 (ÖRNEK VERİ SETİNDEKİ DEĞİŞKENLER VE AÇIKLAMALARI)**

	Değişken	Açıklama	Veri Tipi	En Yüksek	En Düşük	Ortalama
1	Year	Verinin elde edildiği yıl.	Kategorik	1995	2015	-
2	Season	Verilerin toplandığı yılın mevsimi.	Kategorik	-	-	-
3	Koppen climate classification	Verilerin alındığı ülkenin bulunduğu iklim tipi.	Kategorik	-	-	-
4	Climate	Köppen iklim sınıflandırmasına göre iklim tipi adı.	Kategorik	-	-	-
5	City	Verinin toplandığı şehir.	Kategorik	-	-	-
6	Country	Verinin toplandığı ülke.	Kategorik	-	-	-
7	Building type	Binanın kullanım amacı.	Kategorik	-	-	-
8	Cooling startegy_building level	Binada kullanılan soğutma yöntemi.	Kategorik	-	-	-
9	Cooling startegy_operation mode for MM buildings	Karma modlu binalarda kullanılan soğutma yöntemi.	Kategorik	-	-	-
10	Heating strategy_building level	Binada kullanılan ısıtma yöntemi.	Kategorik	-	-	-
11	Age	Geri bildirimde bulunan katılımcının yaşı.	Sayısal	99	6	33
12	Sex	Geri bildirimde bulunan katılımcının cinsiyeti.	Kategorik	-	-	-
13	Thermal sensation	Katılımcının kişisel termal hissiyat oyu. -3 (soğuk) ile +3 (sıcak) arasında	Sayısal	3.0	-3.0	0.16
14	Thermal sensation acceptability	Termal hissiyatın kabul edilebilir olup olmadığına dair katılımcının kişisel oyu. 0 = kabul edilemez, 1 = kabul edilebilir	Kategorik	-	-	-
15	Thermal preference	Katılımcının termal tercihi. daha serin, değişikliğe gerek yok, daha sıcak	Kategorik	-	-	-

16	Air movement acceptability	İç ortamın hava hareketinin kabul edilebilir olup olmadığına dair katılımcının kişisel oyu. 0 = kabul edilemez, 1 = kabul edilebilir	Kategorik	-	-	-
17	Air movement preference	Katılımcının iç ortam için hava hareketi tercihi. daha az, değişikliğe gerek yok, daha fazla	Kategorik	-	-	-
18	Thermal comfort	Katılımcının termal konforu. 1'den (son derece rahatsız) 6'ya (çok rahat)	Sayısal	6.0	0.0	4.3
19	PMV	Predicted Mean Vote	Sayısal	3.0	-3.0	0,13
20	PPD	Predicted Percentage of Dissatisfied	Sayısal	99.1	5	20.9
21	SET	Standard Effective Temperature	Sayısal	61.5	6.5	25.7
22	Clo	Katılımcının giyim yalıtımı.	Sayısal	2.8	0.0	0.6
23	Met	Katılımcının ortalama metabolik hızı.	Sayısal	6.8	0.6	1.2
24	activity_10	Katılımcının son 10 dakikadaki metabolik aktivitesi.	Sayısal	0	3.8	1.1
25	activity_20	Katılımcının 10 ila 20 dakika önceki metabolik aktivitesi.	Sayısal	0.4	6.8	1.2
26	activity_30	Katılımcının 20 ila 30 dakika önceki metabolik aktivitesi.	Sayısal	0	3.8	1.2
27	activity_60	Katılımcının 30 ila 60 dakika önceki metabolik aktivitesi.	Sayısal	0.6	6.8	1.3
28	Air temperature (°C)	Santigrat derece cinsinden iç ortamın ölçülen hava sıcaklığı.	Sayısal	63.2	0.6	24.5
29	Ta_h (°C)	Yerden 1,1 m yüksekliğe yerleştirilen sensör ile santigrat derecesinde ölçülen hava sıcaklığı.	Sayısal	41.7	6.3	24.5
30	Ta_m (°C)	Yerden 0,6 m yüksekliğe yerleştirilen sensör ile	Sayısal	42.7	6	24.2

		santigrat derecesinde ölçülen hava sıcaklığı.				
31	Ta_l (°C)	Yerden 0,1 m yüksekliğe yerleştirilen sensör ile santigrat derecesinde ölçülen hava sıcaklığı.	Sayısal	36.2	5	23.4
32	Operative temperature (°C)	Santigrat derece olarak iç ortamın hesaplanan çalışma sıcaklığı.	Sayısal	44.7	6.8	24.5
33	Radiant temperature (°C)	İç ortamın santigrat derece cinsinden ölçülen radyan sıcaklığı.	Sayısal	148.1	1.2	24.6
34	Globe temperature (°C)	İç ortamın santigrat derece cinsinden ölçülen küre sıcaklığı.	Sayısal	0.5	100	24.6
35	Tg_h (°C)	Yerden 1,1 m yüksekliğe yerleştirilen sensör tarafından santigrat derecesinde ölçülen küre sıcaklığı.	Sayısal	6	43.6	24.7
36	Tg_m (°C)	Yerden 0,6 m yüksekliğe yerleştirilen sensör tarafından santigrat derecesinde ölçülen küre sıcaklığı.	Sayısal	3	46.5	24.3
37	Tg_l (°C)	Yerden 0,1 m yüksekliğe yerleştirilen sensör tarafından santigrat derecesinde ölçülen küre sıcaklığı.	Sayısal	5.9	36.3	22.9
38	Relative humidity (%)	Verinin toplandığı test ortamındaki bağıl nem.	Sayısal	100	0	47.5
39	Humidity sensation	Katılımcının iç ortamın nem hissi ile ilgili kişisel oyu. 3 = çok kuru, 2 = kuru, 1 = hafif kuru, 0 = ideal, -1 = hafif nemli, -2 = nemli, -3 = çok nemli	Kategorik	-	-	-
40	Air velocity (m/s)	Metre/saniye olarak ölçülen hava akımı hızı	Sayısal	56.1	0	0.1

41	Velocity_h	Yerden 1,1 m yüksekliğe yerleştirilen sensör tarafından metre/saniye olarak ölçülen hava akımı hızı.	Sayısal	6.5	0	0.1
42	Velocity_m	Yerden 0,6 m yüksekliğe yerleştirilen sensör tarafından metre/saniye olarak ölçülen hava akımı hızı.	Sayısal	29.8	0	0.1
43	Velocity_l	Yerden 0,1 m yüksekliğe yerleştirilen sensör tarafından metre/saniye olarak ölçülen hava akımı hızı.	Sayısal	2.8	0	0.1
44	Subject height (cm)	Katılımcı deneğin boyu	Sayısal	210	99.1	167.1
45	Subject weight (kg)	Katılımcı deneğin kilosu	Sayısal	150	24	65.2
46	Blind (curtain)	Verinin toplandığı test ortamındaki perdelerin açık ya da kapalı olması durumu. 0 = açık, 1 = kapalı	Kategorik	-	-	-
47	Fan	Verinin toplandığı test ortamındaki fanın çalışır durumda olup olmadığı. 0 = çalışır, 1 = kapalı	Kategorik	-	-	-
48	Window	Verinin toplandığı test ortamındaki pencerenin açık ya da kapalı olması durumu. 0 = açık, 1 = kapalı	Kategorik	-	-	-
49	Door	Verinin toplandığı test ortamındaki kapının açık ya da kapalı olması durumu. 0 = açık, 1 = kapalı	Kategorik	-	-	-
50	Heater	Verinin toplandığı test ortamındaki ısıtıcının çalışır durumda olup olmadığı. 0 = çalışır, 1 = kapalı	Kategorik	-	-	-

51	Outdoor monthly air temperature (C)	Veriler toplandıđında santigrat cinsinden dıř ortam aylık ortalama sıcaklık.	Sayısal	45.1	-18	17,4
----	-------------------------------------	--	---------	------	-----	------

