



T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ



DOKTORA TEZİ

YENİ NESİL BİNALARDA DERİN ÖĞRENMEYLE ENERJİ ANALİZİ

Nevzat Yağız TOMBAL

DANIŞMAN
Dr. Öğr. Üyesi Tarık Veli MUMCU

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği, Doktora Programı

Ağustos, 2025

TEZ KABUL VE ONAYI

Nevzat Yağız TOMBAL tarafından, Dr. Öğr. Üyesi Tarık Veli MUMCU danışmanlığında hazırlanan "YENİ NESİL BİNALARDA DERİN ÖĞRENMEYLE ENERJİ ANALİZİ" başlıklı bu çalışma, jürimiz tarafından 12/08/2025 tarihinde yapılan sınav sonucunda oy birliği ile başarılı bulunarak **Doktora Tezi** olarak kabul edilmiştir.

Tez Jürisi

	İmza	Sonuç
DANIŞMAN	Dr. Öğr. Üyesi Tarık Veli MUMCU İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Anabilim Dalı	<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Prof. Dr. Aysel ERSOY İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Anabilim Dalı	<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Doç. Dr. Altuğ BOZKURT Yıldız Teknik Üniversitesi Elektrik Mühendisliği Anabilim Dalı	<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Doç. Dr. Rana ORTAÇ KABAOĞLU İstanbul Üniversitesi-Cerrahpaşa Elektrik-Elektronik Mühendisliği Anabilim Dalı	<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret
ÜYE	Doç. Dr. Selin ÖZÇİRA ÖZKILIÇ Yıldız Teknik Üniversitesi Elektrik Mühendisliği Anabilim Dalı	<input checked="" type="checkbox"/> Kabul <input type="checkbox"/> Ret



Kıymetli eşime ve oğluma ithaf ediyorum...

BÜTÇE DESTEKLERİ

YENİ NESİL BİNALARDA DERİN ÖĞRENMEYLE ENERJİ ANALİZİ

Bu tez çalışması için herhangi bir kurumdan bütçe desteği alınmamıştır.



TEŐEKKÜR

Doktora alıőmam boyunca bana desteklerini sŸrdüren deęerli danıőmanım Dr. Öğr. Üyesi Tarık Veli MUMCU'ya yüksek teőekkŸrlerimi sunarım. Sadece tez sŸrecinde deęil tŸm lisansŸstŸ eęitim hayatım boyunca bana yol gŸstermiőtir ve baőarılarımda bŸyŸk katkısı bulunmaktadır. Ayrıca bu sŸrete engin bilgileriyle bana destek olan Prof. Dr. Aysel ERSOY'a da teőekkŸrlerimi sunarım.

Bu alıőmada kullanılan verileri saęlayan İstanbul Florence Nightingale Hastanesi Teknik Hizmetler Ekibine teőekkŸr ederim.

TŸm doktora sŸreci boyunca bana manevi desteklerini esirgemeyen eőim Nazan İFTİ TOMBAL'a ve tŸm aileme ŐŸkranlarımı sunarım.

Tez sŸrecimde, kŸŸklŸ bŸyŸklŸ birok katkıda bulunan tŸm alıőma arkadaőlarıma da teőekkŸrŸ bir bor bilirim.

Aęustos 2025

Nevzat Yaęız TOMBAL

İÇİNDEKİLER

Sayfa No

TEZ KABUL VE ONAYI.....	ii
BEYAN	iii
BÜTÇE DESTEKLERİ	v
TEŞEKKÜR.....	vi
İÇİNDEKİLER.....	vii
ŞEKİL LİSTESİ	ix
TABLO LİSTESİ.....	x
SİMGE VE KISALTMA LİSTESİ.....	xi
ÖZET	xiv
ABSTRACT	xvi
1. GİRİŞ.....	1
2. KAVRAMSAL ÇERÇEVE	4
2.1. YAPAY ZEKÂ, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME KAVRAMLARI .4	
2.2. ENERJİ ANALİZİ ÜZERİNE YAPILAN ÇALIŞMALAR	5
2.3. DENETİMLİ ÖĞRENME, SINIFLANDIRMA VE LSTM	7
2.4. YEŞİL BİNA	11
2.5. HASTANE VERİ ANALİZİ	13
3. YÖNTEM	15
3.1. ZAMAN SERİSİ TAHMİNİ İÇİN LSTM	16
3.2. ZAMAN SERİSİ TAHMİNİ İÇİN LSTM TÜRLERİ	16
3.3. ZAMAN SERİSİ TAHMİNİ İÇİN FARKLI LSTM TÜRLERİNDE KULLANILAN DENKLEMLER	17
3.4. HATALI VERİLERİN VERİ SETİNDEN KALDIRILMA SÜRECİ.....	20
4. BULGULAR	21
5. TARTIŞMA.....	32
6. SONUÇ VE ÖNERİLER	34
KAYNAKLAR.....	36
İNTİHAL RAPORU İLK SAYFASI	39

ETİK KURUL İZİN YAZISI	40
KURUM İZİNİ YAZILARI.....	41
ÖZGEÇMİŞ	42



ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: Yapay zeka, makine öğrenmesi ve derin öğrenme kavramları.....	5
Şekil 3.1: LSTM akış diyagramı	8
Şekil 4.1: Toplam güç faktörü (TPF) gerçek ve tahmin edilen değerleri.....	21
Şekil 4.2: Güç faktörü (PF) gerçek ve tahmin edilen değerleri.....	22
Şekil 4.3: Toplam harmonik bozulma gerilimi (THDV) gerçek ve tahmin edilen değerleri...	22
Şekil 4.4: Toplam harmonik bozulma akımı (THDC) gerçek ve tahmin edilen değerleri.....	23
Şekil 4.5: TPF verileri için farklı LSTM modellerinde oluşan MAE hata oranı.....	26
Şekil 4.6: TPF verileri için farklı LSTM modellerinde oluşan MSE hata oranı.	27
Şekil 4.7: TPF verileri için farklı LSTM modellerinde oluşan RMSE hata oranı.	27
Şekil 4.8: TPF verileri için Vanilla LSTM modeli ile elde edilen tahmin değerleri.....	28
Şekil 4.9: TPF verileri için Vanilla LSTM modeli ile elde edilen tahmin değerleri (sınırlı zaman aralığı).....	29
Şekil 4.10: PF verileri için farklı LSTM modellerinde oluşan MAE hata oranı.	32
Şekil 4.11: PF verileri için farklı LSTM modellerinde oluşan MSE hata oranı.....	32
Şekil 4.12: PF verileri için farklı LSTM modellerinde oluşan RMSE hata oranı.	33

TABLO LİSTESİ

	Sayfa No
Tablo 2.1: Makine öğrenmesi üzerine yapılan çalışmaların içerik ve model bilgileri	6
Tablo 2.2: Denetimli ve denetimsiz öğrenme yöntemlerinin karşılaştırılması.....	8
Tablo 4.1: Farklı parametrelere ait MAE, MSE, RMSE hata oranları	23
Tablo 4.2: TPF kestirimi için ana veri seti	24
Tablo 4.3: TPF verileri için farklı LSTM modelleriyle oluşturulan gerçek ve tahmin edilen değerler	25
Tablo 4.4: TPF verileri için farklı LSTM modellerinde oluşan MAE, MSE, RMSE hata oranları	25
Tablo 4.5: Vanilla LSTM, SVM ve Random Forests yöntemleri için MAE hata oranları	29
Tablo 4.6: PF kestirimi için ana veri seti	30
Tablo 4.7: PF verileri için farklı LSTM modelleriyle oluşturulan gerçek ve tahmin edilen değerler	31
Tablo 4.8: PF verileri için farklı LSTM modellerinde oluşan MAE, MSE, RMSE hata oranları	31
Tablo 5.1: Literatür çalışmalarıyla bu tez çalışmasının karşılaştırılması	34

SİMGE VE KISALTMA LİSTESİ

Simgeler	Açıklama
t	: Zaman
x_t	: t anındaki giriş vektörü
h_t	: t anındaki gizli durum
h_{t-1}	: Önceki zaman adımındaki gizli durum
c_t	: t anındaki hücre durumu
c_{t-1}	: Önceki zaman adımındaki hücre durumu
i_t	: Giriş kapısı
f_t	: Unutma kapısı
o_t	: Çıkış kapısı
σ	: Sigmoid aktivasyon fonksiyonu
\tanh	: Hiperbolik tanjant aktivasyon fonksiyonu
W_i	: Girişle ilgili ağırlık matrisi
W_h	: Gizli durumla ilgili ağırlık matrisi
Z_i	: Konvolüsyon çıktısı
Conv	: Konvolüsyon işlemi
X	: Zaman serisi verisi
y_t	: t anındaki model çıktısı
softmax	: Sınıflandırma fonksiyonu
h_t'	: Gizli durum çıktısı
n	: Gözlem sayısı
y_i	: Gerçek değer
\hat{y}_i	: Tahmin değeri

Kısaltmalar	Açıklama
LSTM	: Uzun Kısa Süreli Bellek
SVM	: Destek Vektör Makineleri
RF	: Rastgele Orman
HEPA	: Yüksek Verimli Partikül Hava
MR	: Manyetik Rezonans
PET MR	: Pozitron Emisyon Tomografisi – Manyetik Rezonans
THD	: Toplam Harmonik Bozulma
K-Means	: Küme Ortalamalar
DBSCAN	: Gürültü İçeren Uygulamalar için Yoğunluk Tabanlı Mekânsal Kümeleme
PCA	: Temel Bileşen Analizi
UMAP	: Birleşik Çok Yüzey Yaklaşımı ve Projeksiyonu
SVR	: Destek Vektör Regresyonu
DT	: Karar Ağaçları
k-NN	: K-En Yakın Komşu
NB	: Basit Bayes Sınıflandırıcısı
ANN	: Yapay Sinir Ağı
FNN	: İleri Beslemeli Sinir Ağı
CNN	: Evrişimli Sinir Ağı
RNN	: Tekrarlayan Sinir Ağı
RBNN	: Radyal Tabanlı Sinir Ağı
SOM	: Kendini Düzenleyen Haritalar
AE	: Otokodlayıcılar
GRU	: Kapılı Tekrarlayan Birim
ESN	: Yankı Durum Ağı
CW-RNN	: Saat Kontrollü Tekrarlayan Sinir Ağı
NTM	: Sinirsel Turing Makinesi
USGBC	: Amerikan Yeşil Binalar Konseyi
LEED	: Enerji ve Çevresel Tasarımda Liderlik
LEED-NC	: LEED-Yeni Yapılar ve Büyük Onarımlar
LEED-EB	: LEED-Mevcut Yapılar
LEED-CI	: LEED-Ticari İç Mekânlar
LEED-S	: LEED-Okullar
LEED-ND	: LEED-Mahalle Kalkındırma Projeleri

LEED-Homes	: LEED-Konutlar
LEED-Retail	: LEED-Alışveriş Merkezleri
LEED-HC	: LEED-Sağlık Yapıları ve Laboratuvarlar
Stacked-LSTM	: Yığılmış LSTM
BiLSTM	: Çift Yönlü LSTM
CNN-LSTM	: Evrişimli Sinir Ağı LSTM
Seq2Seq-LSTM	: Kodlayıcı-Kod Çözücü LSTM
MAE	: Ortalama Mutlak Hata
MSE	: Ortalama Karesel Hata
RMSE	: Kök Ortalama Karesel Hata



ÖZET

[DOKTORA TEZİ]

[YENİ NESİL BİNALARDA DERİN ÖĞRENMEYLE ENERJİ ANALİZİ]

[Nevzat Yağız TOMBAL]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

Elektrik- Elektronik Mühendisliği Anabilim Dalı

Elektrik-Elektronik Mühendisliği, Doktora Programı

[Danışman : Dr. Öğr. Üyesi Tarık Veli MUMCU]

İnsanların aydınlatma, ısınma ve konfor ihtiyaçlarının artmasıyla birlikte dünya çapında elektrik enerjisine olan ihtiyaç da artmaktadır. Mesken olarak kullanılan konutlarda ve ortak kullanım alanı olarak hizmet veren binalarda, teknoloji geliştikçe farklı elektronik cihaz çeşitleri konfor talebine cevap vermekte ve bu durumla birlikte elektrik tüketimi de yıldan yıla artmaktadır. Elektrik tüketimiyle ilgili yapılan çalışmalarda, dünyadaki toplam elektrik tüketiminin yarıya yakın kısmının binaların yaptığı elektrik sarfiyatından oluştuğu görülmektedir. Kamu hizmeti yapan binalar, alışveriş merkezleri, hastaneler ve oteller bu tür yüksek enerji tüketen yapılara tipik örneklerdir. Bu binalar içerisinde hastaneler, çok çeşitli özellikte, yüksek yük çeken cihazlar barındırması ve insan sağlığı için kritik değerde olması nedeniyle ayrıca önem kazanan bir bina tipidir.

Otel ve alışveriş merkezleri gibi mekânlarda enerji tüketimi, konfor isteği üzerinden değerlendirilebilirken hastanelerde ise konfor isteğinden ziyade bir zorunluluktur. Bu nedenle hastanelerin tükettiği enerjinin analizi, elektrik tüketiminin çevreye verdiği zararı azaltmak için yapılması gereken başlıca şeylerden biridir.

Bu çalışmada, İstanbul'daki 55.000 metrekare kurulu alana sahip yeşil bina statüsündeki bir hastanenin enerji analizi yapılmıştır. Yapılan analiz çalışmalarında derin öğrenme teknikleri kullanılmıştır.

Bina enerji analizinde kullanılan birçok yöntemle mevcut veri seti analiz edilerek sınıflandırma ve tahmin işlemleri gerçekleştirilmiştir. Veri setinde öne çıkan parametreler üzerinden yapılan analizlerde, uzun kısa süreli bellek (LSTM) modeli başta olmak üzere birçok yöntemle çalışma tamamlanmıştır. Yöntemler arasından hangisinin yeşil bina tipi hastanelerde analiz için daha yararlı olacağı tartışılmıştır. Her yöntem için hata oranları karşılaştırılmıştır. Elde edilen sonuçlar, vanilla LSTM modelinin bina enerji analizinde kabul edilebilir çıktılar verdiğini göstermiştir. Tez kapsamında önerilen model, literatürde daha önce yapılan çalışmalarla karşılaştırılmıştır. Bu karşılaştırmaya göre yeşil bina tipi için önerilen yöntemin geçerli olduğu gösterilmiştir. |

Ağustos 2025 , [59] sayfa.

Anahtar kelimeler: | Enerji analizi, Makine öğrenmesi, Uzun kısa süreli bellek, Yeşil bina |

ABSTRACT

[Ph.D. THESIS]

**[ENERGY ANALYSIS WITH DEEP LEARNING IN NEXT GENERATION
BUILDINGS]**

[Nevzat Yağız TOMBAL]

İstanbul University-Cerrahpaşa

Institute of Graduate Studies

Department of Electrical and Electronics Engineering

Electrical-Electronics Engineering, PhD Programme

[Supervisor : Assist. Prof. Dr. Tarık Veli MUMCU]

[As people's needs for lighting, heating, and comfort increase, so does the global demand for electricity. As technology advances in residential buildings and buildings serving as common areas, various types of electronic devices respond to this demand for comfort, and electricity consumption is increasing year by year. Studies on electricity consumption indicate that nearly half of the world's total electricity consumption comes from buildings. Public service buildings, shopping malls, hospitals, and hotels are typical examples of these high-energy-consuming structures. Hospitals are a particularly important building type because they house a wide variety of high-load devices and are critical to human health.

While energy consumption in spaces like hotels and shopping malls can be assessed based on comfort requirements, in hospitals, it is a necessity rather than a desire for comfort. Therefore, analyzing the energy consumed by hospitals is a key step toward reducing the environmental impact of electricity consumption.

This study conducted an energy analysis of a 55,000-square-meter green building in Istanbul. Deep learning techniques were used in the analysis.

The existing dataset was analyzed using various methods used in building energy analysis, and classification and prediction were performed. Analyses of prominent parameters in the dataset were conducted using several methods, primarily the long short-term memory (LSTM) model. It was discussed which of these methods would be more useful for analysis in green building hospitals. Error rates for each method were compared. The results showed that the vanilla LSTM model yielded acceptable results in building energy analysis. The model proposed in this thesis was compared with previous studies in the literature. This comparison demonstrated that the proposed method is valid for green building types. |

August 2025, [59] pages.

Keywords: | Energy analysis, Machine learning, Long short-term memory, Green building|

1. GİRİŞ

Son yıllarda sıkça gündeme gelen iklim krizinin önüne geçebilmek amacıyla enerji üretim ve tüketim alanlarında, bir dizi önlem alınmaya başlanmıştır. Sürekli değişen ortalama sıcaklıklar, enerji üretim işlemleri esnasında doğaya salınan farklı tiplerde atıklar, doğal enerji kaynaklarının sınırlılığı ve benzeri koşullar; enerji sektöründe geleceğe dair önlem amacıyla bazı standartların oluşturulmasını beraberinde getirmiştir. Bu nedenle çevre dostu sistemler ön plana çıkmış ve yeşil bina kavramı literatüre girmiştir. Yeşil binalar; sürdürülebilir binalar, ekolojik binalar veya enerji verimli binalar olarak da adlandırılan yeni nesil binalara denir. Bu terimler, binaların kullanım ömürleri boyunca yüksek performans göstermesi ve çevreye çok az zarar vermesi anlamına gelmektedir. Dünyada kullanılan enerjinin %40'tan fazlası binalarda harcanmaktadır. Dolayısıyla yeşil bina sayısının yükselmesi, dünyadaki iklim kriziyle mücadelede önemli bir yer tutmaktadır [1].

Yeşil binalar; genellikle hastane, alışveriş merkezi, otel gibi gün içinde birçok insanın girip çıktığı, sirkülasyonun yüksek olduğu, konfor talebinin karşılandığı yaşam alanlarıdır. Bu alanlar, enerji verimliliği gözetilerek ve otomasyon sistemlerinden yardım alınarak oluşturulur. Yeşil binalarda ısıtma, soğutma, aydınlatma vb. ihtiyaçlar karşılanırken enerji giderinin optimize edilmesi gerekmektedir. Bunun için bu tarz binalarda iklimlendirme sistemlerinin otomatik ve insan eliyle kontrol edilebildiği otomasyon panelleri, aydınlatma kontrolü sağlayan sistemler ve yeri geldiğinde kendi enerjisini kendi üreten makineler bulunabilmektedir. Bütün bu sistemler, gün içinde birçok insana hizmet veren yeşil binanın enerji tasarrufunu en uygun şekilde yapabilmesi için tesise entegre edilir. Özetle bu sistemler, yeşil binalarda enerji optimizasyonu ile görevlidir.

Bir binada; enerji değerlerindeki dalgalanmayı optimize etmek, enerji tüketimini azaltmak ve sarfiyat kontrolünü sağlamak için yapılacak en önemli çözümlerden biri enerji analizidir. Son yıllarda binalarda enerji analizinde veri bilimi ve makine öğrenmesi ön plana çıkmıştır [2]. Bina enerji yüklerini tahmin etmek, büyük veri biliminin bir uygulamasıdır. Bina yük tahmini ve enerji yükü ile tüketim arasındaki ilişkinin belirlenmesi gibi analizler, büyük veri biliminin uygulamalarına örnek olarak verilebilir. Yapılacak analiz türüne bağlı olarak

sınıflandırma, regresyon veya kümeleme gibi seçenekler kullanılabilir. Bu işlemler için kullanılabilecek birçok makine öğrenmesi yöntemi bulunmaktadır.

Veri bilimi ve makine öğrenmesi, bina enerjisi alanında giderek daha fazla kullanılan bir optimizasyon yöntemi haline gelmiştir. Bina enerji yüklerini tahmin etmek, bir büyük veri bilimi uygulamasıdır. Bu uygulamada, aydınlatma ve diğer bina ekipmanları gibi dâhili yükler ile güneş, hava ve nem gibi çevreden kaynaklanan harici yükler dikkate alınabilir. Makine öğrenmesi; prensip olarak alınan sayısal verileri yorumlayarak arzu edilen çıktıya uygun şekilde sınıflandırma, regresyon veya kümeleme gibi çalışmalar yapar. Bu çalışmalar; bina uygulamasının koşullarına bağlı olarak bina yüklerini tahmin etmek, tasarım süreçlerine yardımcı olmak, bina bileşenlerinin etkisini görmek, enerji yükleri ve enerji tüketimi arasındaki ilişkiyi belirlemek gibi altyapı analizleri için kullanılabilir [3].

Makine öğrenmesi, daha önceki deneyimlerden öğrenebilen sistemler ve algoritmalarla ilgilenir. Makine öğrenmesi, denetimli öğrenme ve denetimsiz öğrenme olmak üzere iki temel kategoriye ayrılır. Denetimli öğrenme, algoritmaları eğitmek veya denetlemek için manuel olarak etiketlenmiş veri kümeleri gerektiren algoritmaları içerirken denetimsiz öğrenme, etiketlenmiş verileri gerektirmez. Özetle, eğer bir veri setinde verilerin hangi girdi başlığı altında olduğu belirliyse bu veri seti için denetimli öğrenme kullanılabilir. Ancak verilerin hangi özelliğe ait olduğu belirsizse denetimsiz öğrenme kullanılmalıdır.

Sınıflandırma, bir nesnenin özelliklerine göre ait olduğu kategoriyi tahmin etmeyi içeren bir denetimli öğrenme türüdür. Denetimli öğrenmenin başka bir kategorisi olan regresyon, girdi özelliklerine dayalı olarak sayısal bir değer tahmin edilmesini içerir. Denetimsiz öğrenme kategorisi olan kümeleme ise elemanların birbirine ne kadar benzer veya farklı olduğuna göre farklı gruplara ayrılması işlemidir. Bu tezde kullanılan veri setinde, tüm veri sütun başlıkları belirli olduğu için denetimli öğrenme yöntemi daha uygundur.

Bina enerji alanında hem regresyon hem de sınıflandırma için çeşitli makine öğrenmesi algoritmaları kullanılmaktadır. Bu alanda en yaygın kullanılan makine öğrenmesi algoritmaları; uzun kısa süreli bellek [Long Short-Term Memory (LSTM)], destek vektör makineleri [Support Vector Machines (SVM)] ve rastgele orman [Random Forests (RF)] yöntemidir.

Çalışmamızda yer alan hastane 55.000 metrekarelik alana sahip 19 katlı bir binadır. İçerisinde birçok farklı poliklinik ve sağlık ünitesi bulunmaktadır. Hastanede enerji ve

iklimlendirme amaçlı kullanılan 1 adet absorpsiyonlu soğutucu ve 3 adet santrifüjlü soğutucu bulunmaktadır. Ayrıca 40'tan fazla klima santrali, belirli mahallerde yüksek verimli partikül hava [High Efficiency Particulate Air (HEPA)] filtresi içeren klima sistemleri, 19 farklı ünitelerden ve uyutma-uyandırma odasından oluşan tam donanımlı ameliyathane, yangın pompa sistemleri ve acil durumlarda kullanılmaya hazır jet-fanlar; hastanenin yüksek tüketim değerlerine ulaşmasını sağlayan faktörlerden bazılarıdır. Ayrıca hastanenin bazı bölümlerinde -özellikle radyolojide- röntgen cihazları, manyetik rezonans (MR) cihazları ve pozitron emisyon tomografisi - manyetik rezonans (PET MR) cihazları gibi kullanıldığında yüksek enerji çeken üniteler bulunmaktadır. Bu tür cihazlar ve üniteler, gerektiğinde kullanılıp gerektiğinde kapatıldığı için enerji seviyeleri gün boyunca sürekli değişmektedir. Bu durum, harmonik bozulmalara ve dolayısıyla hastane ana dağıtım panosundaki toplam harmonik bozulma [Total Harmonic Distortion (THD)] değerinin artmasına neden olmaktadır. Sorunun çözümünü kolaylaştırmak amacıyla hastanede bir kompanzasyon odası bulunmaktadır.

Çalışmaya konu olan hastanede, enerji tüketim seviyelerini etkileyen birçok faktör bulunmaktadır. İnsan yoğunluğu, genellikle hafta içi artarken hafta sonu veya resmi tatillerde azalmaktadır. Öte yandan hasta ve ziyaretçi yoğunluğu, gün içinde değişmektedir. Hastane; bazı saatlerde çok doluyken, diğer saatlerde nispeten boş olabilmektedir. Ayrıca enerji tüketimindeki artış ve azalışın en önemli nedenlerinden biri, hastanede kullanılan cihazlardır. Özellikle yüksek yükler çeken ve sadece belirli saatlerde çalışan cihazlar, sistemde dalgalanmalara ve harmonik bozulmalara neden olan başlıca etmenlerdir.

Bu tez çalışmasında söz konusu hastanenin enerji değerleri, derin öğrenme yöntemleriyle analiz edilmiştir. Sonuç olarak yeşil binalarda enerji analizi için hangi yöntemin daha tutarlı sonuçlar verdiğinin belirlenmesi hedeflenmiştir.

2. KAVRAMSAL ÇERÇEVE


Dünyada enerji tüketiminin önemli bir kısmını binalar gerçekleştirmektedir. Enerji optimizasyonunu iyileştirmek adına son senelerde yeşil bina uygulaması hayata geçirilmiştir. Bu çevre dostu binalarda, akıllı şebeke altyapısının yanı sıra otomasyon sistemleri kullanılarak enerji verimliliğinin artırılması amaçlanmaktadır. Enerji verimliliği optimizasyonu için de yapay zekâ, makine öğrenmesi, derin öğrenme gibi kavramlar son yıllarda önemli bir hale gelmiştir.

2.1. YAPAY ZEKÂ, MAKİNE ÖĞRENMESİ VE DERİN ÖĞRENME KAVRAMLARI

Yapay zekâ, Turing testinde makinelerin insan olmadıklarını ortaya koymadan insanlarla iletişim kurabilme yeteneği olarak tanımlanır. Yapay zekânın öncülerinden Marvin Minsky; yapay zekâyı, makinelerin insan zekâsı gerektiren şeyleri yapabilmesini sağlamak olarak tanımlamıştır. İnsan zekâsını simüle etmek, genişletmek ve yaygınlaştırmak için araştırma teorileri, yöntemleri, teknolojileri ve uygulamaları geliştiren sistemlere yapay zekâ denir. Günümüzde yapay zekâ kavramı, insan yaşamı üzerinde giderek daha derin bir etkiye sahip olmaktadır [4].

Yapay zekâ, makineleri insan beyni kadar zeki hale getirmeyi ifade eder. Yapay zekâ terimi, bir makinenin öğrenme ve problem çözme gibi insan zihniyle ilişkilendirilen işlevleri yerine getirebilmesi durumuna denir. Öğrenme, makinelerin hayati bir yönüdür. Bu nedenle makine öğrenmesi, yapay zekânın bir alt kümesidir. Bilgisayar bilimcileri, 1950'lerden beri makine öğrenmesi alanında çalışmalar yürütmektedir. Bu çalışmalarla makinelerden daha yüksek beklentiler meydana gelmektedir. Derin öğrenme, bu yönde bir girişimdir. Makine öğrenmesinin bir alt kümesidir. Derin öğrenme, çok sayıda katman ve parametreye sahip bir sinir ağıdır. Derin öğrenmede, özellik çıkarma ve dönüştürme için doğrusal olmayan işlem birimlerinden oluşan çok katmanlı bir basamaklama kullanılır. Veri girişine yakın alt katmanlar, basit özellikleri öğrenirken üst katmanlar, alt katman özelliklerinden türetilen daha karmaşık özellikleri öğrenir. Bu, derin öğrenmenin hem büyük miktarda hem de farklı kaynaklardan toplanarak elde edilen verilerden faydalı bilgiler analiz etmek ve çıkarmak için uygun olduğu

anlamına gelir [5]. Yapay zekâ, makine öğrenmesi ve derin öğrenme kavramlarının birbiriyle ilişkileri Şekil 2.1’de gösterilmiştir.



Şekil 2.1: Yapay zekâ, makine öğrenmesi ve derin öğrenme kavramları.

2.2. ENERJİ ANALİZİ ÜZERİNE YAPILAN ÇALIŞMALAR

Son yıllarda enerji analizi üzerine birçok çalışma yayımlanmıştır. Gan ve diğ., yeşil binalarda enerji verimliliği üzerine simülasyon çalışmalarından oluşan bir kolaj oluşturmuştur [6]. Elnabawi, enerji analizi yoluyla verilerin elde edildiği yeşil binalarda veri aktarımının kalitesini araştırmıştır [7]. Pham ve diğ., enerji verimliliğini ve sürdürülebilirliği iyileştirmek için makine öğrenmesini kullanarak çeşitli binalardaki enerji tüketimini tahmin etmiştir [8]. Shao ve diğ., bir SVM enerji tüketimi tahmin modeli kurarak otel binalarının enerji tüketimini incelemiş ve analiz etmiştir [9]. Bu çalışma, SVM modelinin yüksek bir tahmin doğruluğu göstermesine rağmen modelleme sürecinde binaların enerji tüketiminin insan akışı gibi faktörlerden büyük ölçüde etkilendiğini ortaya çıkarmıştır. Liu ve diğ., Çin'deki kamu binalarındaki enerji tüketimini tahmin etmiştir [10]. Son ve diğ., SVM ile bir binanın maliyet performansını tahmin etmek için bir çalışma yayımlamıştır [11]. Paudel ve diğ., düşük maliyetli bir binadaki enerji tüketimini tahmin etmek için bir çalışma yapmıştır [12]. Li ve diğ.,

çalışmasında bir binanın saatlik soğutma yükünü tahmin etmiştir [13]. Zhao ve Magoules, enerji tüketimini tahmin etmek için paralel SVM kullanmıştır [14]. Ek olarak, literatürde SVM kullanan çeşitli analiz çalışmaları da mevcuttur [15].

SVM yönteminin genellikle binalarda enerji analizi ve tahmini için kullanıldığı görülebilir. Bu çalışmada, LSTM yöntemi kullanılacaktır. Binalarda enerji analizinde LSTM yöntemini içeren çalışmalar da mevcuttur. Wang ve diğ., makalelerinde LSTM tabanlı uzun vadeli bir enerji tahmini gerçekleştirmiştir [16]. Le ve diğ., LSTM kullanarak enerji tüketimi tahminini iyileştirmek için bir çalışma yayımlamıştır [17]. Jiang ve diğ., LSTM üzerinde endüstriyel robotların enerji tahmini üzerinde çalışmıştır [18]. Kim ve Cho, makalelerinde LSTM ile konut enerji tüketimini tahmin etmiştir [19]. Farklı makine öğrenmesi modelleri kullanılarak çeşitli tahminler, karşılaştırmalar ve benzer çalışmalara ilişkin bir özet Tablo 2.1'de listelenmiştir.

Tablo 2.1: Makine öğrenmesi üzerine yapılan çalışmaların içerik ve model bilgileri.

Çalışma	Yer	Yıl	Model	İzleme Süresi	Hata Oranı
[8]	Amerika B.D.	2020	RF	12 ay	0.612
[10]	Çin	2020	SVM	3 ay	0.0503
[13]	Çin	2009	SVM	6 ay	0.02365
[14]	Fransa	2010	SVM	5 ay	0.0023
[16]	Çin	2020	LSTM	5 ay	0.197
[17]	Fransa	2019	LSTM	5 yıl	0.065
[19]	Fransa	2019	LSTM	4 yıl	0.3738

Modelleme çalışmalarında büyük veri söz konusu olduğunda klasik yöntemler yeterli olmayabilir. Bu nedenle bu çalışmada, makine öğrenmesi yöntemlerini kullanılmıştır. Yeşil bina statüsündeki bir hastanedeki enerji verilerinin, makine öğrenmesi tekniklerinden biri olan LSTM ile yorumlanarak analiz edilmesi amaçlanmaktadır. İlgili konularda literatürde birçok benzer çalışma bulunmaktadır. Ancak bu tez çalışması sırasındaki deneyimlere dayanarak yeşil binalarda enerji analizi için LSTM yöntemine dayalı bir araştırmaya rastlanmamıştır. Yeşil binalarda enerji analizi konusunda birçok çalışma bulunmaktadır [20, 21, 22, 23, 24, 25, 26]. Ancak bu çalışmalar, yapay zekâ veya makine öğrenmesi teknikleri dışındaki yöntemlerle

analiz içermektedir ve bu çalışmadaki hastane örneğinden uzak bina tiplerini ele almaktadır. Çalışmamızda üç ana başlık öne çıkmaktadır. Bunlar; LSTM, yeşil bina ve enerji analizidir. Genellikle bu alandaki çalışmalar, üç alanı da kapsamamaktadır. Birçok çalışmada, makine öğrenmesi ile gerçekleştirilen enerji analizi; şehirleri, banliyöleri veya belirli bir bölgeyi ele almaktadır. Bazı çalışmalar, yeşil binalarda enerji analizine odaklanmış ancak bu çalışmalarda makine öğrenmesi teknikleri kullanılmamıştır. Ayrıca yeşil binalarla ilgili makaleler; genellikle binanın yapısına, yalıtımına ve malzeme türüne odaklanmaktadır. Bu tez çalışmasının diğer çalışmalardan farkı; makine öğrenmesi yöntemi LSTM, yeşil bina ve enerji analizi konularını tek bir yerde toplaması ve uygun bir çalışma sunmasıdır.

2.3. DENETİMLİ ÖĞRENME, SINIFLANDIRMA VE LSTM

Makine öğrenmesi; denetimli öğrenme, denetimsiz öğrenme, pekiştirmeli öğrenme ve yarı denetimli öğrenme olmak üzere 4 kola ayrılır ancak bunların içinden denetimli ve denetimsiz öğrenmenin iki temel kol olduğunu söyleyebiliriz.

Denetimsiz öğrenme; kümeleme, boyut azaltma ve anomali tespiti gibi işlemler için kullanılır. Bu işlemlerden kümeleme için küme ortalamalar (K-Means), hiyerarşik kümeleme ve gürültü içeren uygulamalar için yoğunluk tabanlı mekânsal kümeleme [Density-Based Spatial Clustering of Applications with Noise (DBSCAN)] gibi yöntemler bulunmaktadır. Boyut azaltma işlemi için temel bileşen analizi (Principal Component Analysis (PCA) ve birleşik çok yüzey yaklaşımı ve projeksiyonu [Uniform Manifold Approximation and Projection (UMAP)] yöntemleri öne çıkarken anomali tespiti için ise izolasyon ormanı yöntemi örnek verilebilir.

Denetimli öğrenmede ise çok daha çeşitli modeller önümüze çıkmaktadır. Denetimli öğrenme, genel olarak regresyon ve sınıflandırma olmak üzere iki ana işlem için kullanılır. Regresyon işlemi için lineer regresyon, sırt regresyonu ve destek vektör regresyonu [Support Vector Regression (SVR)] gibi çeşitler bulunmaktadır. Bu tez çalışmasında yapacağımız işlem olan sınıflandırma için ise seçenekler daha fazladır. Aşağıda sınıflandırma işleminde sıklıkla kullanılan başlıca yöntemler listelenmiştir:

- Karar ağaçları [Decision Trees (DT)]
- Rastgele Orman [Random Forests (RF)]

- K-En Yakın Komşu [K-Nearest Neighbors (k-NN)]
- Basit Bayes Sınıflandırıcısı [Naive Bayes Classifier (NB)]
- Destek Vektör Makineleri [Support Vector Machines (SVM)]
- Yapay Sinir Ağı [Artificial Neural Network (ANN)]

Bu yöntemlerden ANN, özellikle son dönemlerde birçok makine öğrenmesi çalışmasında ön plana çıkmaktadır. ANN modellerinin de birçok alt modeli bulunmaktadır. Bunlardan başlıcaları aşağıda listelenmiştir:

- İleri Beslemeli Sinir Ağları [Feedforward Neural Networks (FNN)]
- Evrişimli Sinir Ağları [Convolutional Neural Networks (CNN)]
- Tekrarlayan sinir ağları [Recurrent Neural Networks (RNN)]
- Radyal Tabanlı Sinir Ağları [Radial Basis Neural Networks (RBNN)]
- Kendini Düzenleyen Haritalar [Self-Organizing Maps (SOM)]
- Otokodlayıcılar [Autoencoders (AE)]

Bu yöntemlerden ön plana çıkanlardan biri olan RNN'nin de farklı modelleri bulunmaktadır. Bunlara temel RNN olan vanilla RNN, LSTM, kapılı tekrarlayan birim [Gated Recurrent Unit (GRU)], yankı durum ağı [Echo State Network (ESN)], saat kontrollü tekrarlayan sinir ağı [Clockwork Recurrent Neural Network (CW-RNN)] ve sinirsel Turing makinesi [Neural Turing Machine (NTM)] örnek olarak verilebilir. Bu yöntemlerin arasından LSTM, uzun dönemli korelasyonları incelemesi açısından bu çalışmaya uygundur ve bu tez çalışmasında bu yöntemlere ağırlık verilmiştir.

Bu yöntemlerin model, mimari yapı, bilgi akışı, bilgi hatırlama, parametre sayısı, hesaplama maliyeti açısından ayrıntılı karşılaştırılması Tablo 2.2'de verilmiştir.

Tablo 2.2: Denetimli ve denetimsiz öğrenme yöntemlerinin karşılaştırılması.

Model	Mimari Yapı/Yöntem	Veri Hatırlama	Parametre	Hesaplama Maliyeti
K-Means	Merkezi kümeleme	Yok	Düşük	Düşük
Hiyerarşik Kümeleme	Ağaçsal kümeleme	Yok	Düşük	Orta
DBSCAN	Yoğunluk kümeleme	Yok	Düşük	Orta
PCA	Boyut indirgeme	Yok	Orta	Düşük
UMAP	Grafik indirgeme	Yok	Orta	Orta
İzolasyon Ormanı	Rastgele bölme	Yok	Orta	Orta
Lineer Regresyon	Doğrusal model	Yok	Düşük	Düşük
SVR	Kernel regresyon	Yok	Orta	Orta yüksek
Karar Ağacı	Ağaç tabanlı	Yok	Düşük orta	Orta
Rastgele Orman	Birçok karar ağacı	Yok	Yüksek	Orta yüksek
k-NN	Mesafeye dayalı	Yok	Bağımlı	Yüksek
Naive Bayes	Olasılıksal	Yok	Düşük	Düşük
SVM	Kenar maksimizasyon	Yok	Orta	Orta yüksek
ANN	Çok katmanlı NN	Yüzeysel	Orta yüksek	Orta yüksek
FNN	İleri beslemeli NN	Yok	Orta	Orta
CNN	Evrişim katmanlı NN	Yok	Yüksek	Yüksek
RNN	Tekrarlayan hücre	Orta	Orta	Orta
Vanilla RNN	Temel RNN	Zayıf	Orta	Orta
LSTM	Hücre + kapılar	İyi	Yüksek	Yüksek
GRU	LSTM alternatifi	İyi	Orta	Orta
ESN	Sabit RNN	Orta	Düşük	Düşük
CW-RNN	Zamansal RNN	İyi	Orta	Orta
NTM	Sinirsel Turing	Çok iyi	Çok yüksek	Çok yüksek
RBNN	Radyal bazlı NN	Yok	Orta	Orta
SOM	Özörgütlenen harita	Yok	Orta	Orta
Otokodlayıcı	Encoder+decoder	Orta	Orta yüksek	Yüksek

LSTM, bir tür RNN çeşididir. Binlerce zaman adımı sürebilen kısa süreli bir bellek sağlamayı amaçlar ve bu nedenle "uzun kısa süreli bellek" ismini almıştır [27]. Bu isim, 20. yüzyılın başlarından beri bilişsel psikologlar tarafından incelenen uzun süreli bellek ile kısa süreli bellek arasındaki ilişkiye benzetilerek verilmiştir.

Bir LSTM modeli; genellikle bir adet hücreyle giriş, çıkış ve unutma kapısı olmak üzere 3 adet kapıdan oluşur [28, 29]. Hücre, verileri rastgele zaman aralıklarında kontrol eder. Kapılar da hücreye giriş ve hücreden çıkış yapan veri akışını düzenler. Unutma kapıları; önceki durumu ve mevcut girişi 0 ile 1 arasında bir değere eşler ve hangi verilerin eleneceğini, hangilerinin devam edeceğini saptar. Giriş kapıları da benzer bir şekilde, yeni durumunda hangi yeni bilgilerin tutulacağını kararlaştırır. Çıkış kapıları, eski ve yeni durumları göz önüne alarak bilgilere 0 ile 1 arasında bir değer verir; hangi verilerin çıkış olarak işaretleneceğini kontrol eder. Böylelikle, LSTM modelinin şu anki ve gelecekteki zaman aralıklarında kestirim işlemi yapabilmesi için gerekli korelasyonu sürdürmesini sağlar.

LSTM modelinin sınıflandırma, veri işleme, zaman serisi analiz görevleri, konuşma tanımlama, makine çevirisi, sesli ortam tespiti, robotik, video tabanlı sistemler ve sağlık alanlarında geniş uygulamaları vardır [30, 31, 32, 33, 34, 35].

Klasik RNN'ler, veri kümelerindeki rastgele uzun vadeli ilişkileri takip edebilir. Fakat bir RNN eğitilirken bazı sonuç kümelerinde, sağlıklı çıktı üretilmeyebilir. Hesaplamalarda 0'a çok yakın sayılar dahil olduğunda sonuç çıktıları sifıra doğru eğilim gösterebilir ve bu da modelin öğrenmeyi iptal etmesiyle sonuçlanır. LSTM kullanan RNN modelleri ise verilerin hiç hata olmadan okunabilmesine izin verdiği için bu sorunu çözer. Ancak LSTM ağları yine de belirsiz veri sorunundan dolayı hata verebilir.

LSTM mimarisinin yöntemi, bir sinir ağındaki verilerin yeri geldiğinde unutulup hatırlanmasını öğretmek amacıyla bir modül oluşturmaktır [29]. Başka bir deyişle sistem, hangi bilgilerin ne zaman işine yarayacağını ne zaman ise kullanılmayacağını saptamak üzerinedir. Veri kaybına eğilimli temel bir yapıya sahip RNN modellerinin aksine, LSTM birbiriyle haberleşen hücre ve kapılardan oluşur.

Sıralı veri kümelerinin modellenmesi ve büyük veri gruplarının işlenebilmesi yetenekleri sayesinde LSTM modelleri, birçok alanda kullanılmaktadır. Dil modelleme, metin sınıflandırma ve duygu analizi gibi doğal dil işleme görevlerinde sıklıkla kullanılmaktadır. Dil

modellemede LSTM sayesinde, daha önceki kelimeler temel alınarak cümlenin devamı tahmin edilebilir. Konuşma tanıma sistemlerinde, verilerin zaman ve frekansa göre aldığı değerlerin özellikleri modellenerek konuşmaların doğru bir şekilde tanınması ve yazıya geçirilmesi sağlanabilir. Bu, günümüzdeki sanal asistanların temel bir bileşeni olmuştur. LSTM modeli; zaman aralıklarında değişen verileri saptamadaki etkililikleri nedeniyle finans, meteoroloji ve enerji tüketimi tahmininde kullanılmaktadır. Geçmiş verilerden öğrenme işlemiyle gelecekteki değerleri tahmin edebilir. Tıp alanında LSTM modelleri; anormallikleri fark etmek, olası hastalıkları tahmin etmek veya uygun tedaviyi saptamak için hastalara ait verileri analiz edebilir ve zaman içinde hayati fonksiyonları takip edebilir. Giyilebilir sağlık cihazlarında da LSTM modelinin kullanımı artmaktadır.

LSTM modelinin, hem diğer RNN modelleriyle hem de diğer makine öğrenmesi modelleriyle karşılaştırıldığında avantajları ve dezavantajları bulunmaktadır. LSTM, standart RNN modellerine göre daha uzun süreli belleğe sahiptir. Ayrıca kaybolan veri sorununu hafifleterek büyük veri kümelerinde eğitimi mümkün kılar. Çok çeşitli ve çok katmanlı ardışık veri kümelerinde uygulanabilir. Ancak karmaşık yapısı ve hücre-kapı yapısı sebebiyle LSTM modelleri, diğer modellere göre daha fazla hesaplama gerektirir. Bu da eğitim süresini artırmaktadır. Buna rağmen LSTM, özellikle eğitim verilerinin sınırlarının ve tanımlarının belirli olduğu veya veri kümesi özelliklerinin ayrıştırılmasının kritik önem taşıdığı problemlerde önemini korumaktadır. İlerleyen zamanlarda daha yeni modeller ortaya çıksa da LSTM modelindeki temel kavramlar, modern derin öğrenme teknikleri üzerinde etki yaratmaya devam etmektedir.

2.4. YEŞİL BİNA

Dünya çapında son yıllarda ön planda olan iklim krizi; yapı sektöründe çevreye zarar vermeyen, ekolojik, yeşil enerji üreten binaların yapılmasını gündeme getirmiştir. Bu tarz binaların oranı artarken kavramsal olarak yeşil bina tabiri literatüre girmeye başlamıştır. Zamanla oluşturulan standartlarla birlikte gelen sertifikasyon sistemleriyle birlikte yeşil binalar; doğa dostu, ekolojik ve toplam enerji sarfiyatının önüne geçen binalar olarak sektörde yeni bir tarz oluşturmuştur [36].

Gerek ülkemizde gerekse tüm dünyada toplam enerji tüketiminin içinde; binaların ısıtılması, soğutulması, havalandırılması, aydınlatılması ve sıcak su ihtiyacı için kullanılan

enerjinin yaklaşık %30 olduğu tahmin edilmektedir. Ayrıca, binaların yapımında kullanılan ekipmanların harcadığı enerji de dikkate alındığında binalar için harcanan enerjinin toplam harcanan enerjiye oranı %40'ı geçmektedir. Bu durum, sürdürülebilir bir enerji sektörü için yeşil binaların öneminin gözler önüne sermektedir. Yeni nesil binalar içinde yeşil binalar, iç mekânda insana sağlanan konfordan vazgeçmeden enerji tüketimini ve atık miktarını azaltmayı amaçlar [37, 38].

Amerikan Yeşil Binalar Konseyi [United States Green Building Council (USGBC)] tarafından 1998 yılında Enerji ve Çevresel Tasarımda Liderlik [Leadership in Energy and Environmental Design (LEED)] programı uygulamaya geçirilmiştir. Bu uygulamanın hedefi; yapı sektörünün ortaya çıkardığı çevresel etkileri gündeme getirmek ve bu etkileri azaltmak için gerekli önlemleri almaktır. LEED sisteminde, tanımlanan standartlara bağlı bir sertifikalandırma süreci yürütülmektedir. LEED, yapıların çevresel etkilerini sekiz farklı kategoride ele almaktadır [39]. Bu kategoriler aşağıda listelenmiştir:

- Yeni Yapılar ve Büyük Onarımlar [New Construction&Major Renovations (LEED-NC)]
- Mevcut Yapılar [Existing Buildings (LEED-EB)]
- Ticari İç Mekânlar [Commercial Interiors (LEED-CI)]
- Okullar [Schools (LEED-S)]
- Mahalle Kalkındırma Projeleri [Neighborhood Development (LEED-ND)]
- Konutlar [Homes (LEED-Homes)]
- Alışveriş Merkezleri [Retail (LEED-Retail)]
- Sağlık Yapıları ve Laboratuvarlar [Healthcare and Laboratories (LEED-HC)]

Bu tez çalışmasına konu olan hastane, LEED-HC kategorisine girmektedir. Bu kategorideki sertifikasyon sistemi; tasarım, erişilebilirlik, yerel ekosistem, su verimliliği, geri dönüşüm, atık yönetimi, malzeme, iç hava kalitesi, gün ışığı, ses yalıtımı, kimyasal maruziyet, enfeksiyon kontrolü ve hasta güvenliği gibi özelliklerin yanı sıra enerji verimliliği ve yenilenebilir enerji kullanımını gibi özellikleri de göz önüne alarak kredilendirme yapmaktadır.

2.5. HASTANE VERİ ANALİZİ

Bu tez çalışmasında, enerji verileri kullanılan hastaneden çekilen veri dosyasında 103 birbirinden farklı parametre mevcuttur. Bu veri dosyası; başta gerilim, akım, güç, enerji, THD, harmonik gerilim (1., 3., 5., 7., 9., 11.), harmonik akım (1., 3., 5., 7., 9., 11.) ve benzeri değerler olmak üzere tüm parametreleri içeren bir veri setidir. İlgili değerler, 10 saniyede bir olacak şekilde 1 yıl boyunca çekilmiştir. Dolayısıyla kullanılan veri seti, 3.162.240 satır ve 103 sütundan oluşmaktadır. Gerekli hesaplama yapıldığında çalışmada kullanılan 325.710.720 adet veriden oluşan bir veri kümesi olduğu görülebilir. 103 adet parametrenin sınıflandırıldığı kategoriler aşağıda listelenmiştir:

- Temel Akım ve Gerilim Değerleri:

Üç faz hattı (L1, L2, L3) ve nötr hattı (N) arasındaki temel akım, temel gerilim, ortalama akım, ortalama gerilim, hat frekansı parametreleri bu kategoride değerlendirilir.

- Harmonik Akım ve Gerilim Bileşenleri:

Üç faz hattının her birine ait harmonik akım ve gerilim parametreleri, faz hatları ile nötr arası harmonik akım ve gerilim parametreleri bu kategoride değerlendirilir. Çekilen harmonik değerleri, 3. harmonik değerinden başlayarak 11. harmonik değerine kadar gitmektedir.

- Enerji Miktarları (Aktif, Reaktif, Görünür):

Aktif enerji ihracat ve ithalat, görünür enerji, reaktif enerji ihracat ve ithalat parametreleri ile sürece ait aktif, reaktif, görünür enerji parametreleri bu kategoride değerlendirilir.

- Güç (Aktif, Reaktif, Görünür):

Üç faz hattının üzerindeki aktif güç, görünür güç, reaktif güç parametreleri ile toplam aktif güç, toplam görünür güç, toplam reaktif güç parametreleri bu kategoride değerlendirilir.

- Güç Kalitesi ve Bozulmalar:

Üç faz hattının üzerindeki bozulma akımı, toplam harmonik bozulma akımı, toplam harmonik bozulma gerilimi parametreleri ile güç faktörü, toplam güç faktörü parametreleri bu

kategoride değerlendirilir. Özellikle güç faktörü ve toplam güç faktörü değerleri, enerji optimizasyonunun izlenmesi açısından öne çıkan parametrelerdir.

- Dengesizlik ve Nötr:

Genlik dengesizliği akımı, genlik dengesizliği gerilimi, dengesiz akım, dengesiz gerilim, nötr akımı parametreleri bu kategoride değerlendirilir.

Bu çalışmada, yüzün üzerinde başlık ve milyonlarca veri bulunmaktadır. Mevcut veri kümesinin, büyük bir küme oluşturduğu ve büyük veri bilimine ihtiyaç duyulduğu görülmüştür. Bu veri seti üzerinde yapılan analiz çalışmaları ile hastanenin harmonik değerlerindeki değişim gözlemlenmiştir. Toplam Güç Faktörü [Total Power Factor (TPF)], Güç Faktörü [Power Factor (PF)], Toplam Harmonik Bozulma Gerilimi [Total Harmonic Distortion Voltage (THDV)] ve Toplam Harmonik Bozulma Akımı [Total Harmonic Distortion Current (THDC)] değerleri bu yöntemlerle tahmin edilmiştir.

3. YÖNTEM

Bu çalışmada, yeşil bina statüsündeki bir hastanedeki enerji verileri makine öğrenmesi teknikleri ile yorumlanarak analiz edilecektir. Hastanenin ana dağıtım panosunda bulunan Siemens Sentron PAC4200 enerji analizörü ile alınan veriler yorumlanacaktır. Sentron PAC4200, düşük gerilimle çalışan enerji ana dağıtım panolarındaki temel elektriksel büyüklükleri kaydeden bir ölçüm cihazıdır. Cihaz, 1 ile 3 fazlı ölçüm yapabilmektedir. 690 V'luk gerilim değerine kadar olan alçak gerilim şebekelerine bağlanabilen cihazın grafik ekranında, tüm ölçüm değerleri okunabilmekte ve cihazın genel ayarları değiştirilebilmektedir. Çalışmaya konu olan hastanede, entegre Ethernet arabirimi ile otomasyon odasındaki bilgisayardan tüm veriler anlık olarak okunabilmektedir.

Veri seti; gerilim, akım, güç, enerji, THD, TPF, harmonik gerilim (1., 3., 5., 7., 9., 11.) ve harmonik akım (1., 3., 5., 7., 9., 11.) başta olmak üzere 103 farklı parametreden oluşmaktadır. İlgili değerler, bir yıl boyunca her günün her saati için her 10 saniyede bir alınmıştır. Çalışmada kullanılan veriler, 14.03.2023 saat 00.00.00 ile 13.03.2024 saat 23.59.50 arasındaki zaman aralığını kapsamaktadır. Veriler ayıklanıp basitleştirildikten ve hatalar giderildikten sonra geriye 3.162.240 satır ve 103 sütundan oluşan bir veri kümesi kalmıştır. Veri kümesinin matris boyutları, 103x3.153.600'dür. Bu kümede, toplam olarak 325.710.720 adet kullanılabilir veri bulunmaktadır.

Günümüzde büyük veri kümeleri, birçok alanda farklı amaçlarla kullanılmaktadır. Bu verilerin manuel olarak işlenmesi, büyük zaman kaybına ve belki de hatalara yol açmaktadır. Bu nedenle büyük veri kümelerini hızlı ve doğru bir şekilde yorumlayabilmek için makine öğrenmesi, hayatımızda önemli bir yer edinmiştir. Makine öğrenmesi yöntemleri ile sınıflandırma ve regresyon görevleri uygulanabilir.

Sınıflandırma, verilen bir giriş verisinin doğru etiketini tahmin etmeye çalışan bir denetimli makine öğrenme yöntemidir. Sınıflandırmada bir model oluşturulur. Oluşturulan model, eğitim verileri kullanılarak tamamen eğitilir. Daha sonra model, test verileri üzerinde değerlendirilir ve tahmin için kullanılır. Sınıflandırmada SVM, ANN gibi modeller

kullanılabilir. LSTM ağı, ANN modelinin bir alt türü olan bir yöntemin adıdır. Bu çalışmada, veri kümesi LSTM modeli ile eğitilecektir.

3.1. ZAMAN SERİSİ TAHMİNİ İÇİN LSTM

LSTM ağı, bir RNN türüdür. Birçok zaman adımının birleşiminden oluşan kısa süreli bir bellek görevi görür. Veri analizi işlemlerinde, sınıflandırma ve tahmin amaçları için işlenir. LSTM, girdinin ardışık bilgilerden oluştuğu ve önceki bilgilerin kullanımının işlem doğruluğunu etkileyebileceği uygulamalarda kullanılan bir yöntemdir. LSTM, bir önceki adımdan gelen çıktıyı, bir sonraki adımda yeniden kullanır. Bu modelde, düğüm girdileri kullanılarak bir çıktı değeri oluşturulur. Bu çıktı değeri, bir sonraki adımda girdi değerlerinden biri olarak kullanılır. Sonuçlar, yalnızca çıktı değerine katkıda bulunmak için kullanılmaz. Ortaya çıkan bilgiler, durum güncelleme işlemleri için de kullanılabilir.

LSTM, oturum açma bilgilerinin nasıl kullanılacağına ilişkin verileri içeren parametrelere sahiptir. Ayrıca, bu bilgilerin ne kadarının kullanılacağını kontrol eden parametreler içerir. Bu parametrelere, kapılar denir. LSTM düğümleri, genellikle yinelemeli düğümlerden daha karmaşıktır ancak bu nedenle karmaşık korelasyonları öğrenmede bir avantaja sahiptir. LSTM ağının, diğer sinir ağlarıyla benzerlikleri ve farklılıkları göz önüne alındığında yöntem ve süreçte farklılıklar olmasına rağmen bu ağ, genellikle eğitim sırasında öğrenilen parametrelerden oluşur.

3.2. ZAMAN SERİSİ TAHMİNİ İÇİN LSTM TÜRLERİ

LSTM modelinin birçok farklı türü vardır. Bunlardan bazıları vanilla LSTM, yığılmış LSTM [Stacked LSTM (Stacked-LSTM)], çift yönlü LSTM [Bidirectional LSTM (BiLSTM)], evrimsel sinir ağı LSTM [Convolutional Neural Network LSTM (CNN-LSTM)], kodlayıcı-kod çözücü LSTM [Encoder-decoder LSTM (Seq2Seq-LSTM)] türleridir. Giriş, unutmama, çıkış kapıları, hücre durumu ve gizli durum dâhil olmak üzere bir LSTM modelinin temel denklemleri, farklı varyantlarında aynı kalır. Ancak bu denklemlerin düzenlenme veya genişletilme şekli, belirli varyanta veya mimariye göre değişebilir.

Stacked-LSTM modeli, birden fazla LSTM katmanının üst üste yığılmasını içerir. Bu modeldeki her katman, alttaki katmandan girdi alır ve çıktısını üstteki katmana iletir. Bu, katmanlar arasındaki etkileşimler için ek denklemler sunar ancak her LSTM hücresindeki

denklemleri temelde deęiřtirmez. Benzer řekilde BiLSTM, temel LSTM mimarisine yeni deęiřiklikler veya uzantılar sunar ancak hepsi, ek özellikler veya işlemlere uyum sağlamak için denklemlerde deęiřikliklerle aynı temel ilkelere dayanır. Bu nedenle çekirdek denklemler, farklı LSTM varyantları arasında tutarlı kalırken belirli uygulamalar, ek özellikler eklemek veya model mimarisinin belirli gereksinimlerini karşılamak için farklılık gösterebilir.

3.3. ZAMAN SERİSİ TAHMİNİ İÇİN FARKLI LSTM TÜRLERİNDE KULLANILAN DENKLEMLER

Vanilla LSTM, LSTM tipleri arasında temel tip olarak kabul edilir. Vanilla LSTM hücresi için denklemler, bilgileri güncellemek ve çıktı vermek için çeřitli hesaplamalar içerir. Bu denklemler; denklem 3.1, denklem 3.2, denklem 3.3, denklem 3.4 ve denklem 3.5'te görülebilir. Bu denklemlerde; i giriş kapısı, f unutma kapısı, c hücre durumu, o çıkış kapısı ve h gizli durumdur. Giriş kapısı, geçerli girdiden gelen bilginin ne kadarının hücre durumunda saklanacağını kontrol eder. Unutma kapısı, önceki hücre durumunun ne kadarının unutulacağını kontrol eder. Hücre durumu denklemi, unutma kapısından ve giriş kapısından gelen bilgileri birleştirir. Çıkış kapısı, hücre durumunun ne kadarının çıkış olarak açığa çıkarılması gerektiğini kontrol eder. Gizli durum denklemi, hücre durumunun filtrelenmiş bir versiyonu olan LSTM hücresinin çıktısını hesaplar [40].

$$i_t = \sigma(W_{ix}x_t + W_{ih}h_{t-1} + b_i) \quad (3.1)$$

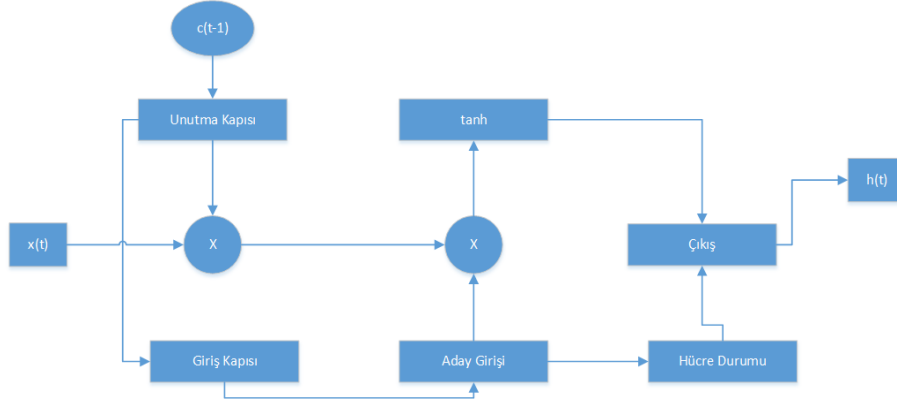
$$f_t = \sigma(W_{fx}x_t + W_{fh}h_{t-1} + b_f) \quad (3.2)$$

$$c_t = f_t * c_{t-1} + i_t * \tanh(W_{cx}x_t + W_{ch}h_{t-1} + b_c) \quad (3.3)$$

$$o_t = \sigma(W_{ox}x_t + W_{oh}h_{t-1} + b_o) \quad (3.4)$$

$$h_t = o_t * \tanh(c_t) \quad (3.5)$$

Burada, x_t zaman adımındaki girdidir, h_{t-1} bir önceki zaman adımının gizli durumudur, c_{t-1} bir önceki zaman adımının hücre durumudur, W deęişkenleri ağırlık matrisleridir, b deęişkenleri önyargı vektörleridir ve σ *sigmoid* fonksiyondur. (*) eleman bazında çarpımı temsil eder. İlgili sürece dair akış diyagramı Şekil 3.1'de verilmiştir.



Şekil 3.1: LSTM akış diyagramı.

Stacked-LSTM için denklemler neredeyse aynı kalır. Hücre durumu denkleminde yalnızca küçük bir değişiklik vardır. Bu, denklem 3.6'da görülebilir.

$$c_t = f_t * c_{t-1} + i_t * \tanh(W_c \cdot [h_{t-1}, h_t] + b_c) \quad (3.6)$$

Bu türdeki en önemli fark, her katman için denklemlerin yeniden hesaplanması ve birleştirilmesidir. Denklemlerdeki küçük değişiklik de bu farklılığa bir referanstır.

BiLSTM, girdi dizilerini hem ileri hem de geri yönlerde işleyen standart LSTM modelinin bir uzantısıdır. Bu, modelin geçmiş ve gelecekteki bağlamdan gelen bağımlılıkları yakalamasını sağlar. Bu türde, iki farklı çıktı oluşur. Bunlar ileri LSTM ve geri LSTM olarak adlandırılır. BiLSTM, her zaman adımı için ileri ve geri LSTM ağlarının çıktılarını birleştirerek nihai çıktı dizisini elde eder. BiLSTM için matematiksel denklemler, vanilla LSTM ile aynıdır. Tek değişiklik, denklemlerdeki t-1 değerlerine sahip parçaların t+1 olmasıdır. BiLSTM modelinin hücre durum denklemi denklem 3.7'de görülebilir.

$$c_t = f_t * c_{t+1} + i_t * \tanh(W_{cx}x_t + W_{ch}h_{t+1} + b_c) \quad (3.7)$$

Bu şekilde, işlemler ters yönde devam ettirilerek hüküm verilmiş olur. Tüm denklemlerde t-1 yerine t+1 kullanılarak ters hesaplama yapılır.

CNN ve LSTM ağlarının birleşimi, genellikle giriş verilerinin hem uzamsal hem de zamansal bağımlılıklara sahip olduğu görevlerde kullanılır. Mimari, genellikle giriş verilerinden uzamsal özellikleri çıkarmak için CNN kullanmayı ve ardından CNN tarafından çıkarılan özellik gösterimlerindeki zamansal bağımlılıkları yakalamak için bir LSTM katmanını içerir. Bu modele CNN-LSTM denir.

CNN-LSTM modelinde, nihai çıktıyı üretmek için üç adım vardır. Bu adımlar; CNN, LSTM ve nihai çıktı katmanı adımlarıdır. CNN katmanları, evrişimler ve birleştirme işlemlerini içerir. CNN ile çıktı özellik haritası, denklem 3.8'deki gibi hesaplanabilir. Burada X girdi, W ise filtredir ve b , girdiyi bir veya daha fazla evrişim katmanından geçirmek için konulan ön şartlardır.

$$Z_i = \text{Conv}(X, W_i) + b_i \quad (3.8)$$

Bu denklemde, Z çıktı özelliği haritasıdır ve “Conv” evrişim işlemini temsil eder. CNN-LSTM modeli için LSTM adımı, temel vanilla LSTM ile aynıdır. Son olarak sınıflandırma veya regresyon görevlerine bağlı olarak uygun aktivasyon fonksiyonlarının izlediği tam bağlı bir katman, nihai çıktıyı üretmek için LSTM katmanının üstüne eklenebilir. Bu denklemler birleştirilerek giriş verilerinden hem mekânsal hem de zamansal özellikleri etkili bir şekilde yakalayabilen CNN-LSTM mimarisi oluşturulabilir.

Bir Seq2Seq-LSTM için denklemler, iki ana bileşene ayrılabilir. Bu bileşenler, kodlayıcı LSTM ve kod çözücü LSTM'dir. Kodlayıcı LSTM, bir giriş dizisi alır ve onu tüm giriş dizisinin bilgilerini kapsülleyen sabit boyutlu bir gösterime işler. Kodlayıcı LSTM için denklemler, vanilla LSTM ile aynıdır. Kod çözücü LSTM, kodlayıcı tarafından oluşturulan sabit boyutlu gösterimi alır ve bir çıkış dizisi oluşturur. Kod çözücü LSTM, kodlayıcı LSTM ile aynı denklemlere sahiptir. Ancak bu aşama, aynı zamanda aşağıda denklem 3.9'da verilen son denkleme de içermektedir.

$$y_t = \text{softmax}(W_{sy}h_t' + b_y) \quad (3.9)$$

Burada y son çıktı, W_{sy} ve b_y çıkış katmanı için ağırlık matrisi ve önyargı terimidir; “softmax” ise softmax aktivasyon fonksiyonudur. Ek olarak h_t' kod çözücü LSTM için gizli bir durumdur.

LSTM çıktıları alındıktan sonra hata oranı hesaplaması yapılmalıdır. Hata oranını hesaplamak için birçok farklı yöntem kullanılır. Bu çalışmada, hata oranını belirlemek için en belirgin üç yöntem kullanılmıştır. Bu yöntemler; ortalama mutlak hata [mean absolute error (MAE)], ortalama karesel hata [mean squared error (MSE)] ve kök ortalama karesel hata [root mean squared error (RMSE)] yöntemleridir. Bu hata hesaplama yöntemleri, sırasıyla denklem

3.10, denklem 3.11 ve denklem 3.12'de görülebilir. Bu denklemlerde, y_i gerçek değer, \hat{y}_i ise tahmin edilen değerdir ve n örnek adedidir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.10)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.11)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (3.12)$$

3.4. HATALI VERİLERİN VERİ SETİNDEN KALDIRILMA SÜRECİ

Kullanılacak veri setinde, değer olarak alınamayacak bir veya birden fazla aralık olabilir. Bu değerleri analize dâhil etmek, yanlış sonuçlara neden olabilir. Bu nedenle bu değerleri veri setinde filtrelemek gerekir. Bu amaçla veri seti ilk olarak yazılıma tanıtıldıktan sonra aşağıdaki kod eklenmiştir.


```
df_new = df.loc[(df['Temel_akım_L1'] != 0) & ... & (df['Gerilim_L3_N'] != 0)]
df = df_yeni
```

Bu kod, her bir parametre için değer 0'a eşit olmadığı hücreleri ayırır. Böylelikle veri alınamayan belirli aralıklardaki 0 değeri, hesaba katılmamış olur. Bu yöntemle veri setinde doğru bilgi içeren hücrelerin kalmasıyla hatasız bir veri kümesi oluşturulmuştur.


4. BULGULAR

Hastaneden çekilen enerji değerlerini içeren veri setiyle birlikte analiz çalışmasına başlanmıştır. Veri seti; çok yüksek sayıda ve mutlak veri içerdiğinden, parametre sınırları belirli olduğundan, verilerde belirsizlik bulunmadığından dolayı çalışmada LSTM modeli kullanılmıştır.

Öncelikle tahmin sürecinde hangi parametrenin kullanılacağını belirlemek için, temel LSTM yöntemi olan vanilla LSTM ile bina enerji analizinde önemli olan 4 parametre için bir tahmin çalışması yapılmıştır. Bunlar; TPF, PF, THDV, THDC parametreleridir. Bu parametreler, özellikle binalarda kompanzasyon işlemlerinde önemli bir yer tutmaktadır. Bu verilerin sağlıklı olması, enerji optimizasyonu açısından son derece önemlidir. Bu sebeplerle kritik veri sütunları olarak bu 4 parametre seçilmiştir. Seçilen parametrelerin gerçek değerleri ile tahmin edilen değerlerinin karşılaştırılması; TPF için Şekil 4.1'de, PF için Şekil 4.2'de görülebilir.




Şekil 4.1: Toplam güç faktörü (TPF) gerçek ve tahmin edilen değerleri.




Şekil 4.2: Güç faktörü (PF) gerçek ve tahmin edilen değerleri.

Seçilen parametrelerin gerçek değerleri ile tahmin edilen değerlerinin karşılaştırılması, THDV için Şekil 4.3'te, THDC için Şekil 4.4'te görülebilir.



Şekil 4.3: Toplam harmonik bozulma gerilimi (THDV) gerçek ve tahmin edilen değerleri.



Şekil 4.4: Toplam harmonik bozulma akımı (THDC) gerçek ve tahmin edilen değerleri.

Söz konusu 4 parametre için gerçek değerler ile tahmin edilen değerler arasındaki farkın kalitesini ölçen hata oranı hesaplanmıştır. Sonuç olarak tahmin sonuçları ile gerçek veriler arasındaki ilişkiyi inceleyen MAE, MSE ve RMSE hata oranı yöntemleri kullanılarak hesaplamalar yapılmıştır. Bu hata oranları Tablo 4.1'de sunulmaktadır.

Tablo 4.1: Farklı parametrelere ait MAE, MSE, RMSE hata oranları.

Hata Oranı	TPF	PF	THDV	THDC
MAE	0.00049273	0.00407066	0.01423912	0.06381466
MSE	0.00000045	0.00003065	0.00057725	0.01767848
RMSE	0.00067232	0.00553694	0.02402605	0.13296045

Elde edilen sonuçlarda, en düşük hata oranının TPF parametresinde olduğu görülmüştür. Bu nedenle ilk olarak bu parametrenin kullanılması ve farklı LSTM yöntemlerinin TPF kestirimine etkisinin karşılaştırılması kararlaştırılmıştır. Bu karara yönelik olarak yapılan simülasyonlarda, LSTM yönteminin avantajlarını görmek için bazı işlemler yapılmıştır. TPF değeri bir tahmin çıktısı olarak, diğer 102 değişken bir giriş veri kümesi olarak işaretlenmiş ve böylelikle işleme alınmıştır. Sonuç olarak oluşan veri kümesinin belirli bölümleri Tablo 4.2'de görülebilir.

Tablo 4.2: TPF kestirimi için ana veri seti.

Time	Funda mental Current L1	Fundame ntal Current L2	Fundame ntal Current L3	Fundame ntal Voltage L1 N	...	Voltage L2 L3	Voltage L2 N	Voltage L3 L1	Voltage L3 N
14/03/23 00:00:00	794.153 87	829.6683 96	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:10	794.153 87	829.6683 96	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:20	794.153 87	826.3915 41	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:30	794.153 87	826.3915 41	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.419 769	235.818 710
14/03/23 00:00:40	794.153 87	826.3915 41	838.0681 15	236.0140 99	...	407.282 501	235.618 973	409.419 769	235.818 710
...
13/04/24 23:59:10	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:20	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:30	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:40	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:50	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78

Tablo 4.2’de görülen veri seti kullanılarak oluşturulan LSTM modeliyle bir eğitim çalışması yürütülmüştür. Eğitim sonucunda, tahmin edilen değerler ve gerçek değerler karşılaştırmalı olarak incelenmiştir. Bu çalışmada, 5 farklı LSTM türüyle veri kümesi üzerinde bir tahmin çalışması yürütülmüştür. Bu LSTM türleri; vanilla LSTM, Stacked-LSTM, BiLSTM, CNN-LSTM ve Seq2Seq-LSTM’dir. Bu sonuçların bir özeti Tablo 4.3’te görülebilir. Tablodan da anlaşıldığı üzere, bu LSTM modellerinden elde edilen gerçek değerler ile tahmin edilen değerler arasındaki farklar son derece düşüktür.

Tablo 4.3: TPF verileri için farklı LSTM modelleriyle oluşturulan gerçek ve tahmin edilen değerler.


Gerçek Değerler	Vanilla LSTM	Stacked-LSTM	BiLSTM	CNN-LSTM	Seq2Seq- LSTM
0.989418	0.989703	0.989936	0.989856	0.989017	0.989758
0.989418	0.989789	0.989983	0.989926	0.989048	0.989863
0.989418	0.989888	0.990264	0.989917	0.989163	0.989981
...
0.992353	0.992545	0.992633	0.992589	0.992106	0.992625
0.992353	0.992535	0.992621	0.992652	0.992058	0.992611
0.992353	0.992521	0.992608	0.992634	0.992073	0.992598

Tablo 4.3'te TPF değeri, 5 farklı LSTM türü kullanılarak tahmin edilmiştir. Bu tahminlerden ve gerçek değerlerden bazıları sergilenmektedir. Gerçek değerler ile tahmin edilen değerler arasındaki farkın kalitesini ölçen hata oranı hesaplanmıştır. Böylelikle her LSTM yönteminin bir sonucu olarak elde edilen tahmin sonuçları ile gerçek veriler arasındaki ilişkiyi inceleyen MAE, MSE ve RMSE hata oranı yöntemleri kullanılarak hesaplamalar yapılmıştır. Hata oranlarını içeren veriler Tablo 4.4'te sunulmuştur.


Tablo 4.4: TPF verileri için farklı LSTM modellerinde oluşan MAE, MSE, RMSE hata oranları.

Hata Oranı	Vanilla LSTM	Stacked-LSTM	BiLSTM	CNN-LSTM	Seq2Seq-LSTM
MAE	0.00049273	0.00050961	0.00058058	0.0005544	0.00054516
MSE	0.00000045	0.00000047	0.00000052	0.00000048	0.00000049
RMSE	0.00067232	0.000685565	0.00072111	0.00069282	0.00070089

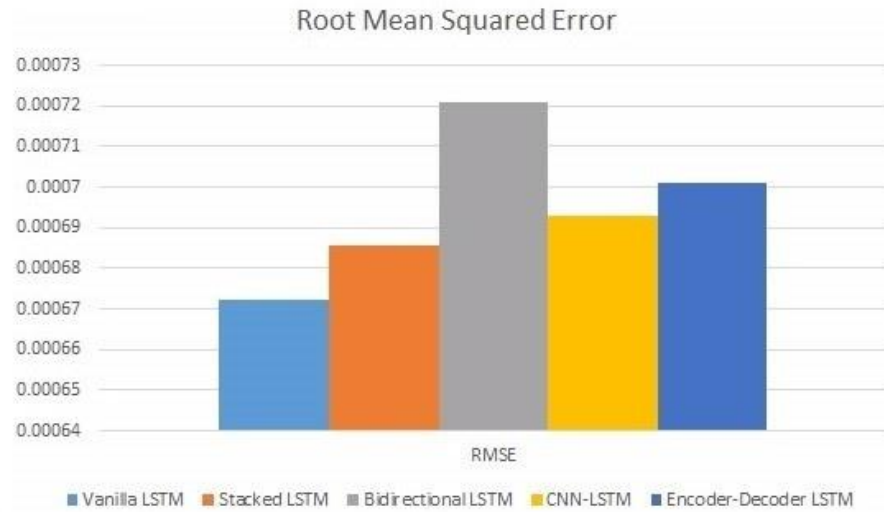
Bu çıktılara göre, vanilla LSTM diğer yöntemlere kıyasla daha düşük hata oranıyla öne çıkmaktadır. Vanilla LSTM yönteminin düşük hata oranı, 3 hata oranı hesaplama yönteminin tamamında görülmüştür. Bu nedenle bu çalışmada kullanılan yöntemlerden biri olan vanilla LSTM'nin, bu tür veri kümeleri için en iyi LSTM yöntemi olarak öne çıktığı söylenebilir. Vanilla LSTM yönteminde, MAE hata oranı 0,00049273 olarak ölçülürken diğer tahmin yöntemlerinde hata oranının biraz daha yüksek olduğu gözlemlenmiştir. Bu hata oranlarından MAE Şekil 4.5'te, MSE Şekil 4.6'da, RMSE Şekil 4.7'de grafiksel olarak görülebilir.



Şekil 4.5: TPF verileri için farklı LSTM modellerinde oluşan MAE hata oranı.




Şekil 4.6: TPF verileri için farklı LSTM modellerinde oluşan MSE hata oranı.




Şekil 4.7: TPF verileri için farklı LSTM modellerinde oluşan RMSE hata oranı.

Bu hata oranlarından, çalışmamıza konu olan binada enerji analizi için kullanılacak en verimli yöntemin vanilla LSTM olduğu görülebilir. Şekil 4.8, vanilla LSTM modelinin tahmin sonuçlarını göstermektedir. Değerler, vanilla LSTM ile elde edilen sonuçlar ile gerçek değerler arasındaki benzerliği daha iyi gözlemleyebilmek için çizilmiştir. Bu şekilde, gündüz ve gece saatleri arasındaki TPF değişimi açıkça görülebilmektedir. Aynı zamanda, veriler çok sık olduğundan gerçek ve tahmini çizgiler birbirine karışmaktadır. Ancak bu karışıklık, tahminin gerçeğe ne kadar yakın olduğunun da bir göstergesidir.



Şekil 4.8: TPF verileri için Vanilla LSTM modeli ile elde edilen tahmin değerleri.

Şekil 4.9, biraz daha dar bir zaman aralığı için aynı sonuçları göstermektedir. Bu şekilde, TPF değerinin tahmin edilen ve gerçek değerleri arasındaki yakınlık daha rahat gözlemlenebilir. Bu çalışmada, hata oranı MAE yöntemi ile 0,00049273 olarak hesaplanmıştır.



Şekil 4.9: TPF verileri için Vanilla LSTM modeli ile elde edilen tahmin değerleri (sınırlı zaman).

Bu çalışmada, önceki araştırmalardan edindiğimiz bilgi sayesinde, yeşil bina enerji analiz süreci için LSTM modellerini karşılaştırmak uygun görülmüştür. Ancak ilk etapta yapılan analizle tespit edilen en iyi LSTM modeli olan vanilla LSTM modelinin, diğer makine öğrenmesi modelleriyle karşılaştırılması da hedeflenmiştir. Bu amaçla yapılan karşılaştırmada, sık kullanılan yöntemler olan SVM, RF modelleri ve vanilla LSTM modeli karşılaştırılmış ve hata oranları hesaplanmıştır. İlgili karşılaştırma verileri Tablo 4.5'te görülebilir. Hesaplamalar, MAE hata oranı yöntemi kullanılarak yapılmıştır. Bu karşılaştırma sonucunda da LSTM modelinin çalışmaya daha uygun olduğu görülmüştür.

Tablo 4.5: Vanilla LSTM, SVM ve Random Forests yöntemleri için MAE hata oranları.

Hata Oranı	Vanilla LSTM	SVM	RF
MAE	0.00049273	0.00126247	0.00389523

Tablo 4.1'deki tahmin sonuçlarına göre en düşük ikinci hata oranını veren PF parametresi üzerinde de aynı işlemlerin tekrar edilmesine karar verilmiştir. Çalışmanın devamında bu kez PF değeri bir tahmin çıktısı olarak işaretlenmiş, diğer 102 değişken bir girdi veri kümesi olarak işaretlenmiştir. Veri kümesinin belirli bölümleri Tablo 4.6'da görülebilir.

Tablo 4.6: PF kestirimi için ana veri seti.

Time	Funda mental Current L1	Fundame ntal Current L2	Fundame ntal Current L3	Fundame ntal Voltage L1 N	...	Voltage L2 L3	Voltage L2 N	Voltage L3 L1	Voltage L3 N
14/03/23 00:00:00	794.153 87	829.6683 96	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:10	794.153 87	829.6683 96	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:20	794.153 87	826.3915 41	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.844 940	236.237 823
14/03/23 00:00:30	794.153 87	826.3915 41	847.5138 55	235.9149 63	...	407.441 772	235.386 368	409.419 769	235.818 710
14/03/23 00:00:40	794.153 87	826.3915 41	838.0681 15	236.0140 99	...	407.282 501	235.618 973	409.419 769	235.818 710
...
13/04/24 23:59:10	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:20	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:30	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:40	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78
13/04/24 23:59:50	784.233 652	845.7590 12	812.7022 18	234.6439 32	...	403.455 296	231.609 388	406.187 252	232.153 78

Tablo 4.6’da verilen veri seti üzerinde, LSTM modeli kullanılarak bir eğitim çalışması yürütülmüştür. Eğitim sonucunda tahmin edilen değerler ve gerçek değerler karşılaştırmalı olarak incelenmiştir. Bu sonuçların bir özeti Tablo 4.7’de görülebilir. Görüldüğü gibi, bu LSTM modellerinden elde edilen gerçek değerler ile tahmin edilen değerler arasındaki farklar son derece düşüktür.

Tablo 4.7: PF verileri için farklı LSTM modelleriyle oluşturulan gerçek ve tahmin edilen değerler.

Gerçek Değerler	Vanilla LSTM	Stacked-LSTM	BiLSTM	CNN-LSTM	Seq2Seq-LSTM
0.990869	0.991252	0.991662	0.992251	0.991943	0.993982
0.990387	0.990713	0.991253	0.991776	0.991424	0.992104
0.990387	0.990713	0.991253	0.991776	0.991424	0.992104
...
0.994306	0.994602	0.994889	0.995621	0.995016	0.996173
0.994306	0.994602	0.994889	0.995621	0.995016	0.996173
0.994306	0.994602	0.994889	0.995621	0.995016	0.996173


Tablo 4.7’de, PF değeri 5 farklı LSTM türü kullanılarak tahmin edilmiştir. Bu tahminlerden ve gerçek değerlerden bazıları sergilenmektedir. Gerçek değerler ile tahmin edilen değerler arasındaki farkın kalitesini ölçen hata oranı hesaplanmıştır. Böylelikle her LSTM yönteminin bir sonucu olarak elde edilen tahmin sonuçları ile gerçek veriler arasındaki ilişkiyi inceleyen MAE, MSE ve RMSE hata oranı yöntemleri kullanılarak hesaplamalar yapılmıştır. Hata oranlarını içeren veriler Tablo 4.8’de sunulmuştur.

Tablo 4.8: PF verileri için farklı LSTM modellerinde oluşan MAE, MSE, RMSE hata oranları.

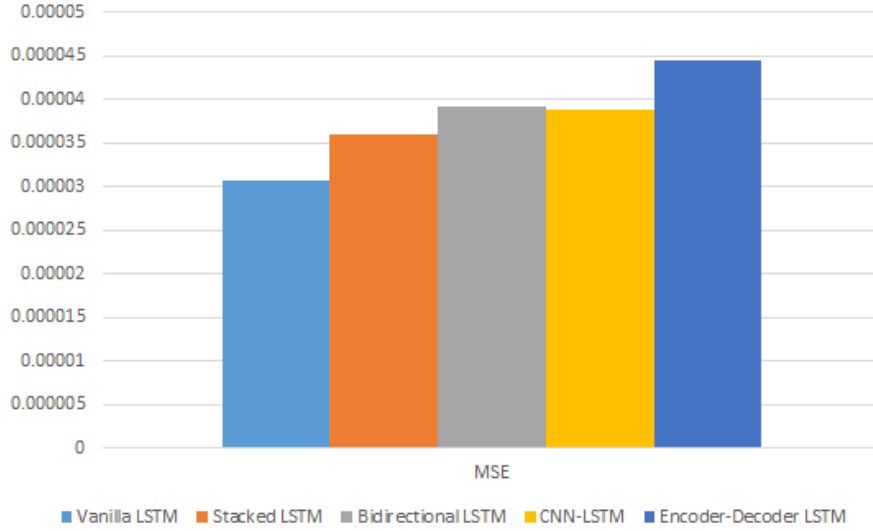
Hata Oranı	Vanilla LSTM	Stacked-LSTM	BiLSTM	CNN-LSTM	Seq2Seq-LSTM
MAE	0.00407066	0.00469613	0.00522387	0.00484321	0.00545284
MSE	0.00003065	0.00003608	0.00003912	0.00003874	0.00004442
RMSE	0.00553694	0.00581273	0.00619842	0.00601147	0.00653010

Bu çıktılara göre vanilla LSTM, diğer yöntemlere kıyasla daha düşük hata oranıyla yine öne çıkmaktadır. Bu yöntemin düşük hata oranı da aynı şekilde, 3 hata oranı hesaplama yönteminin tamamında görülmüştür. Bu nedenle bu çalışmada kullanılan yöntemlerden biri olan vanilla LSTM'nin bu tür veri kümeleri için, en iyi LSTM yöntemi olarak öne çıktığı bir kere daha söylenebilir. Vanilla LSTM yönteminde, MAE hata oranı 0,00040034 olarak ölçülürken diğer tahmin yöntemlerinde, hata oranının biraz daha yüksek olduğu


gözlemlenmiştir. Bu hata oranlarından MAE Şekil 4.10'da, MSE Şekil 4.11'de, RMSE Şekil 4.12'de grafiksel olarak görülebilir.



Şekil 4.10: PF verileri için farklı LSTM modellerinde oluşan MAE hata oranı.



Şekil 4.11: PF verileri için farklı LSTM modellerinde oluşan MSE hata oranı.



Şekil 4.12: PF verileri için farklı LSTM modellerinde oluşan RMSE hata oranı.

Bu tez çalışmasında incelenen bina, birçok optimizasyon sistemine sahip bir yeşil bina olduğundan dolayı beklendiği gibi her model için düşük hata oranları hesaplanmıştır. Ancak Tablo 4.4 ve Tablo 4.8’de görüldüğü gibi, ilgili veriler belirtilen yöntemlerle analiz edildiğinde en düşük hata oranı yine vanilla LSTM modelindedir.

5. TARTIŞMA

Yeşil bina özelliği sağlayan hastaneler, yüksek güç çeken cihazlara sahip olmasının yanı sıra bu özelliklerin etkilerini azaltan sistemlere de sahiptir. Bu nedenle bu tür binalarda hassas ölçüm ve analiz, son derece önemlidir. Önceki çalışmalarda, farklı makine öğrenmesi teknikleriyle birlikte farklı LSTM yöntemlerinin enerji analizine olan etkileri incelenmiştir. En uygun analiz yöntemi, incelenecek yerin bina mı yoksa ev mi olduğuna göre değişmektedir. Binalar söz konusu olduğunda binanın kamusal veya özel bina olması, üretim merkezi veya kullanıcı merkezi olması, kalabalık veya seyrek olması ve içindeki cihazların niteliği gibi farklı durumlar; farklı tahmin tekniklerini ön plana çıkarmıştır.

LSTM, yüksek enerji tüketen binalarda ön plana çıkmaktadır. Önceki çalışmalarda, incelenen farklı binalar için farklı LSTM tekniklerinin daha uygun olduğu gösterilmiştir. Bu çalışmada ilgili yapı için uygun, hassas bir enerji analiz yöntemi olan LSTM modeli kullanılmıştır. Bir hastanenin enerji verileri 5 farklı LSTM modeli ile analiz edilmiştir. Bunlar; vanilla LSTM, Stacked-LSTM, BiLSTM, CNN-LSTM, Seq2Seq-LSTM'dir. Eldeki parametreler üzerinde farklı LSTM teknikleri uygulanmıştır. Bu parametreler arasında en düşük hata oranına sahip olan TPF ve PF, analiz parametresi olarak seçilmiştir. Analizde, TPF ve PF değerinin günlere ve saatlere göre değişimi gözlenmiştir. Ayrıca veri seti üzerinden TPF ve PF üzerinde bir kestirim çalışması yapılmıştır.

Tahmin edilen ve gerçekleşen sonuçların iyi derecede tutarlı olduğu görülmüştür. Çalışmada, LSTM ve diğer yöntemler karşılaştırılmış; bunun sonucunda LSTM modelinin daha uygun olduğu sonucuna varılmıştır. Sonuçlar üzerinde 5 farklı LSTM modelinin etkisi gözlemlenmiştir. Vanilla LSTM modelinin en yüksek doğruluk ve en düşük hata oranına sahip olduğu bulunmuştur. Hata oranı üç farklı yöntemle hesaplanmıştır. Vanilla LSTM yöntemi için MAE hata oranı 0,00049273, MSE hata oranı 0,00000045 ve RMSE hata oranı ise 0,00067232 olarak hesaplanmıştır. Elde edilen bu düşük hata oranları ile vanilla LSTM modelinin yüksek tüketimli yeşil binalar için uygun olduğu sonucuna varılabilir.

Literatürde daha önce yapılan benzeri çalışmalar ile bu tez çalışmasının karşılaştırılması yapılmıştır. Daha önceki kısımlarda değinilen ilgili çalışmalar [8, 10, 13, 14, 16, 17, 19] ile bu tez çalışmasının hata oranları ve diğer parametreleri Tablo 5.1’de karşılaştırılmıştır.

Tablo 5.1: Literatür çalışmalarıyla bu tez çalışmasının karşılaştırılması.

Çalışma	Yer	Yıl	Model	İzleme Süresi	Hata Oranı
[8]	Amerika B.D.	2020	RF	12 ay	0.612
[10]	Çin	2020	SVM	3 ay	0.0503
[13]	Çin	2009	SVM	6 ay	0.02365
[14]	Fransa	2010	SVM	5 ay	0.0023
[16]	Çin	2020	LSTM	5 ay	0.197
[17]	Fransa	2019	LSTM	5 yıl	0.065
[19]	Fransa	2019	LSTM	4 yıl	0.3738
*	Türkiye	2025	LSTM	12 ay	0,00049273

* Bu tez çalışmasını gösterir.

6. SONUÇ VE ÖNERİLER

LSTM modeli, zaman serisi tahminlerinde sıklıkla kullanılan bir modeldir. Uzun dönemli zaman bağımlılıklarını tespit etmede ön plana çıkmakta ve ardışık verilerle iyi performans göstermektedir. SVM modeli ise genellikle küçük-orta büyüklükteki veri kümeleri için uygundur. Veri kümeleri küçüldükçe doğruluk oranı artmaktadır. Ancak veri başlıkları arttıkça hata oranı da artmaktadır. RF modeli ise genellikle regresyon işlemlerinde kullanılmaktadır. Eksik ve yanlış verilerde bile çalışabilme avantajına rağmen veri başlıkları arttıkça SVM gibi hata oranı artmaktadır. Bu çalışmada, çok yüksek ölçekli bir veri kümesi kullanılmıştır. Bu çalışmada, 3.162.240 satır ve 103 sütundan oluşan bir veri kümesi kullanılmış olup sonuçlardan da görüldüğü üzere LSTM modeli daha verimli sonuçlar elde etmiştir. Ayrıca SVM ve RF modelleri yüksek veri kümelerinde yavaş çalışması sebebiyle yine LSTM modelinin gerisinde kalmaktadır.

Vanilla LSTM, genellikle basit zaman serisi tahminlerinde ve küçük sıralı veri problemlerinde kullanılır. Yani veri setinin büyüklüğünden ziyade karmaşıklığı, hatalara yol açabilecek nedenlere örnek olarak verilebilir. Birden fazla katmana sahip veri setlerinde Stacked-LSTM tercih edilir. Finansal zaman serisi tahmini ve konuşma tanıma gibi karmaşık veri setleri, bu model için uygundur. BiLSTM modelinde ise veriler iki şekilde okunabilir. Veri değerlendirmesi geri bildirimle bağlıdır. Doğal dil işleme ve metin sınıflandırması gibi önceki tahminlere geri dönülmesi gereken süreçlerde kullanılmaya uygundur. CNN-LSTM modeli ise harita verileri üzerinde video sınıflandırması ve hava durumu tahmini gibi görsel içerikli veri setleri için uygundur. Gürültülü verilerle çalışabilir ancak eğitim süresi uzundur. Seq2seq-LSTM modeli ise dil çevirisi ve otomatik altyazı gibi teknolojiler için kullanılır. Yukarıda açıklandığı gibi her LSTM alt modelinin ayrı bir kullanım alanı vardır. Bunlar arasında vanilla LSTM, en uygun model olarak görülmektedir çünkü çalışmada kullanılan veri seti tek katmanlıdır, çok sayıda veri içerir ancak her veri hücresi basit sayılardan oluşur ve zaman tabanlı bir veri seti özelliği gösterir. Çalışmada elde ettiğimiz sonuçlar da vanilla LSTM modelinin bu veri seti için uygun olduğunu göstermiştir.

Yüksek enerji tüketen makinelere sahip binalarda, enerji dalgalanması nedeniyle güç faktörü değerleri ideal değerden sapmaktadır. Bu durum, elektrik sisteminin düzgün çalışmasını

engellemektedir. Güç faktörünü ideale yakın değerlere getirmek için binalarda farklı teknikler kullanılmaktadır. Söz konusu binada, şu anda bu sorunu düzeltmek için enerji depolama cihazları ve kompanzasyon panelleri gibi bileşenler bulunmaktadır. Bu çalışmada elde edilen değerler, kabul edilebilir değerler olmakla birlikte sistemi iyileştirmek için aşağıdaki işlemler uygulanabilir:

Bölgesel enerji analizi yapılabilir, hangi ünitelerin hangi saat aralıklarında yoğunluk yaşadığı belirlenerek özel önlemler için ilgili bölgelere lokal kompanzasyon cihazları entegre edilebilir. Toplam harmonik bozulma değerleri dikkate alınarak filtreleme yapılabilir. Söz konusu binanın yük çeşitliliği göz önüne alındığında basit pasif endüktör-kondansatör filtrelemesi yerine aktif filtreleme seçeneği tercih edilebilir. Güç faktörü düzeltme kondansatörleri eklenerek, düzenli kontrol ve koruyucu bakım sağlanarak endüktif akım değerleri dengelenebilir. Söz konusu binadaki enerji izleme sistemi; ayrıntılı değerleri sadece ana panodan, temel değerleri ise sadece bölgesel panolardan almaktadır. Bölgelere göre doğru çözümler üretebilmek için, hastanedeki her farklı poliklinik panosunda ayrıntılı veri alan bir enerji analizörü bulundurulabilir. Belirtilen önlemler alındığı takdirde, bölge bölge değişen yüklere göre özel önlem alınabilecek ve enerji optimizasyonu daha iyi bir seviyeye çıkartılabilecektir.

KAYNAKLAR

- [1]. Cao, X., Dai, X. ve Liu, J., 2016, Building energy-consumption status worldwide and the state-of-the-art technologies for zero-energy buildings during the past decade, *Energy and Buildings*, 128, 198-213.
- [2]. Tien, P. W., Wei, S., Darkwa, J., Wood, C. ve Calautit, J. K., 2022, Machine learning and deep learning methods for enhancing building energy efficiency and indoor environmental quality—a review, *Energy and AI*, 10, 100198.
- [3]. Molina-Solana, M., Ros, M., Ruiz, M. D., Gómez-Romero, J. ve Martín-Bautista, M. J., 2017, Data science for building energy management: A review, *Renewable and Sustainable Energy Reviews*, 70, 598-609.
- [4]. Jiang, Y., Li, X., Luo, H., Yin, S. ve Kaynak, O., 2022, Quo vadis artificial intelligence?, *Discover Artificial Intelligence*, 2(1), 4.
- [5]. Shinde, P. P. ve Shah, S., 2018, A review of machine learning and deep learning applications, *4th International Conference on Computing Communication Control and Automation (ICCUBEA)*, 30-31 August 2018 Pune, India, Pune, IEEE, 1-6.
- [6]. Gan, V. J., Lo, I. M., Ma, J., Tse, K. T., Cheng, J. C. ve Chan, C. M., 2020, Simulation optimisation towards energy efficient green buildings: Current status and future trends, *Journal of Cleaner Production*, 254, 120012.
- [7]. Elnabawi, M. H., 2020, Building information modeling-based building energy modeling: Investigation of interoperability and simulation results, *Frontiers in Built Environment*, 6, 573971.
- [8]. Pham, A. D., Ngo, N. T., Truong, T. T. H., Huynh, N. T. ve Truong, N. S., 2020, Predicting energy consumption in multiple buildings using machine learning for improving energy efficiency and sustainability, *Journal of Cleaner Production*, 260, 121082.
- [9]. Shao, M., Wang, X., Bu, Z., Chen, X. ve Wang, Y., 2020, Prediction of energy consumption in hotel buildings via support vector machines, *Sustainable Cities and Society*, 57, 102128.
- [10]. Liu, Y., Chen, H., Zhang, L., Wu, X. ve Wang, X. J., 2020, Energy consumption prediction and diagnosis of public buildings based on support vector machine learning: A case study in China, *Journal of Cleaner Production*, 272, 122542.
- [11]. Son, H., Kim, C. ve Kim, C., 2012, Hybrid principal component analysis and support vector machine model for predicting the cost performance of commercial building projects using pre-project planning variables, *Automation in Construction*, 27, 60-66.
- [12]. Paudel, S., Elmitri, M., Couturier, S., Nguyen, P. H., Kamphuis, R., Lacarrière, B. ve Le Corre, O., 2017, A relevant data selection method for energy consumption prediction of

- low energy building based on support vector machine, *Energy and Buildings*, 138, 240-256.
- [13]. Li, Q., Meng, Q., Cai, J., Yoshino, H. ve Mochida, A., 2009, Predicting hourly cooling load in the building: A comparison of support vector machine and different artificial neural networks, *Energy Conversion and Management*, 50(1), 90-96.
- [14]. Zhao, H. X. ve Magoulès, F., 2010, Parallel support vector machines applied to the prediction of multiple buildings energy consumption, *Journal of Algorithms & Computational Technology*, 4(2), 231-249.
- [15]. Adıgüzel, E., Subaşı, N., Mumcu, T. V. ve Ersoy, A., 2023, The effect of the marble dust to the efficiency of photovoltaic panels efficiency by SVM, *Energy Reports*, 9, 66-76.
- [16]. Wang, J. Q., Du, Y. ve Wang, J., 2020, LSTM based long-term energy consumption prediction with periodicity, *Energy*, 197, 117197.
- [17]. Le, T., Vo, M. T., Vo, B., Hwang, E., Rho, S. ve Baik, S. W., 2019, Improving electric energy consumption prediction using CNN and Bi-LSTM, *Applied Sciences*, 9(20), 4237.
- [18]. Jiang, P., Wang, Z., Li, X., Wang, X. V., Yang, B. ve Zheng, J., 2023, Energy consumption prediction and optimization of industrial robots based on LSTM, *Journal of Manufacturing Systems*, 70, 137-148.
- [19]. Kim, T. Y. ve Cho, S. B., 2019, Predicting residential energy consumption using CNN-LSTM neural networks, *Energy*, 182, 72-81.
- [20]. Cheng, K., Yao, J. ve Zheng, R., 2023, Energy performance of occupant behaviors on windows: A green building based study, *Energies*, 16(5), 2209.
- [21]. Abdullah Halim, A. Z., Talkis, N. A., Wan Ali, W. N. ve Majid, M. F., 2022, Energy efficiency in building an analysis study of K-Value and U-Value application through green building material, *Malaysian Journal of Sustainable Environment (MySE)*, 9 (2), 1-20.
- [22]. Guo, K., Li, Q., Zhang, L. ve Wu, X., 2021, BIM-based green building evaluation and optimization: A case study, *Journal of Cleaner Production*, 320, 128824.
- [23]. Ng, W. L., Chin, M. Y., Zhou, J., Woon, K. S. ve Ching, A. Y., 2022, The overlooked criteria in green building certification system: Embodied energy and thermal insulation on non-residential building with a case study in Malaysia, *Energy*, 259, 124912.
- [24]. Liu, Y., Pedrycz, W., Deveci, M. ve Chen, Z. S., 2024, BIM-based building performance assessment of green buildings-A case study from China, *Applied Energy*, 373, 123977.
- [25]. Pan, Y., Zhu, M., Lv, Y., Yang, Y., Liang, Y., Yin, R., ... ve Yuan, X., 2023, Building energy simulation and its application for building performance optimization: A review of methods, tools, and case studies, *Advances in Applied Energy*, 10, 100135.
- [26]. Wang, Q., Chen, G., Khishe, M., Ibrahim, B. F. ve Rashidi, S., 2023, Multi-objective optimization of IoT-based green building energy system using binary metaheuristic algorithms, *Journal of Building Engineering*, 68, 106031.

- [27]. Hochreiter, S. ve Schmidhuber, J., 1997, Long short-term memory, *Neural Computation*, 9 (8), 1735-1780.
- [28]. Hochreiter, S. ve Schmidhuber, J., 1996, LSTM can solve hard long time lag problems, *Advances in Neural Information Processing Systems*, 9.
- [29]. Gers, F. A., Schmidhuber, J. ve Cummins, F., 2000, Learning to forget: Continual prediction with LSTM, *Neural Computation*, 12 (10), 2451-2471.
- [30]. Graves, A., Fernández, S., Gomez, F. ve Schmidhuber, J., 2006, Connectionist temporal classification: labelling unsegmented sequence data with recurrent neural networks, *23rd International Conference on Machine Learning Proceedings*, 3-6 Haziran 2006 Pittsburgh, ACM, New York, 369-376.
- [31]. Karim, F., Majumdar, S., Darabi, H. ve Chen, S., 2017, LSTM fully convolutional networks for time series classification, *IEEE Access*, 6, 1662-1669.
- [32]. Schmidhuber, J., Wierstra, D. ve Gomez, F. J., 2005, Evolino: Hybrid neuroevolution /optimal linear search for sequence prediction, *Proceedings of the 19th International Joint Conference on Artificial Intelligence (IJCAI)*, 30 Temmuz-5 Ağustos 2005 Edinburgh, Morgan Kaufmann, San Francisco.
- [33]. Sak, H., Senior, A. W. ve Beaufays, F., 2014, Long short-term memory recurrent neural network architectures for large scale acoustic modeling, *Interspeech*, Eylül 2014 Singapur, ISCA, 338-342.
- [34]. Li, X. ve Wu, X., 2015, Constructing long short-term memory based deep recurrent neural networks for large vocabulary speech recognition, *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Nisan 2015 Brisbane, IEEE, 4520-4524.
- [35]. Mayer, H., Gomez, F., Wierstra, D., Nagy, I., Knoll, A. ve Schmidhuber, J., 2008, A system for robotic heart surgery that learns to tie knots using recurrent neural networks, *Advanced Robotics*, 22 (13-14), 1521-1537.
- [36]. Erdede, S.B. ve Bektaş, S., 2014, Ekolojik açıdan sürdürülebilir taşınmaz geliştirme ve yeşil bina sertifika sistemleri, *Harita Teknolojileri Elektronik Dergisi*, 6(1), 1-12.
- [37]. Özbalta, T. ve Çakmanus, İ., 2008, *Binalarda Sürdürülebilirlik: Ömür boyu maliyete ilişkin yaklaşımlar*, Doğa Sektörel Yayınları, İstanbul.
- [38]. Sert, S., 2010, *Bina Yaşam Döngüsünde Enerji Analizi ve Yeşil Binalar*, Yüksek Lisans, Ege Üniversitesi.
- [39]. Yalçın, G., 2013, *Yeşil Bina Sertifika Programları ve Türkiye'deki Uygulanabilirliğinin Araştırılması*, Yüksek Lisans, İstanbul Üniversitesi.
- [40]. Kwak, G. H., Park, C. W., Ahn, H. Y., Na, S. I., Lee, K. D. ve Park, N. W., 2020, Potential of bidirectional long short-term memory networks for crop classification with multitemporal remote sensing images, *Korean Journal of Remote Sensing*, 36 (4), 515-525.

İNTİHAL RAPORU İLK SAYFASI

Yeni Nesil Binalarda Derin Öğrenmeyle Enerji Analizi

ORJİNALLİK RAPORU

% 20 BENZERLİK ENDEKSİ	% 18 İNTERNET KAYNAKLARI	% 12 YAYINLAR	% 11 ÖĞRENCİ ÖDEVLERİ
----------------------------------	------------------------------------	-------------------------	---------------------------------

BİRİNCİL KAYNAKLAR

1	www.mdpi.com İnternet Kaynağı	% 3
2	acikbilim.yok.gov.tr İnternet Kaynağı	% 3
3	Submitted to The Scientific & Technological Research Council of Turkey (TUBITAK) Öğrenci Ödevi	% 3
4	www.pronit.com.tr İnternet Kaynağı	% 1
5	docplayer.biz.tr İnternet Kaynağı	% 1
6	Submitted to Istanbul Bilgi University Öğrenci Ödevi	% 1
7	acikerisim.gelisim.edu.tr İnternet Kaynağı	% 1
8	pt.scribd.com İnternet Kaynağı	% 1
9	Submitted to Karadeniz Teknik University Öğrenci Ödevi	% 1

KURUM İZİNİ YAZILARI

Uyarı: Canlı ve cansız deneklerle yapılan tüm çalışmalar için kurum izin belgelerinin eklenmesi zorunludur. Gizlilik ve mahremiyet içeren durumlarda kurum adı kapatılmalıdır.

- Kurum izni gerekmektedir.
- Kurum izni gerekmemektedir.

Nevzat Yağız TOMBAL
(İmza)

