

KONYA GIDA VE TARIM ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

KISA DÖNEM ELEKTRİK TÜKETİM TAHMİNİ İÇİN
2D-CNN ve DERİN ÖĞRENME ALGORİTMALARI
KULLANILARAK HİBRİT BİR MODEL
GELİŞTİRİLMESİ

YÜKSEK LİSANS TEZİ

D*u A*****A**

KONYA

HAZİRAN, 2021

KONYA GIDA VE TARIM ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

YÜKSEK LİSANS TEZİ

**KISA DÖNEM ELEKTRİK TÜKETİM TAHMİNİ İÇİN 2D-CNN ve DERİN
ÖĞRENME ALGORİTMALARI KULLANILARAK HİBRİT BİR MODEL
GELİŞTİRİLMESİ**

D*u A*****A**

Danışman: Dr. Öğr. Üyesi B*k Y****Z**

Bilgisayar Mühendisliği Anabilim Dalı

Meram-KONYA

HAZİRAN, 2021

D***u A*****A tarafından hazırlanan “Kısa Dönem Elektrik Tüketim Tahmini İçin 2D-CNN ve Derin Öğrenme Algoritmaları Kullanılarak Hibrit Bir Model Geliştirilmesi” adlı bu çalışma, 18/06/2021 tarihinde aşağıdaki jüri tarafından oy birliği ile BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI’ nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman : Dr. Öğr. Üyesi B***k Y****Z
Konya Gıda ve Tarım Üniversitesi

Başkan : Doç. Dr. K***m Ö*****K
Konya Gıda ve Tarım Üniversitesi

Üye : Dr. Öğr. Üyesi B***k Y****Z
Konya Gıda ve Tarım Üniversitesi

Üye : Dr. Öğr. Üyesi O***r İ***N
Necmettin Erbakan Üniversitesi

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Doç. Dr. K***m Ö*****K
Anabilim Dalı Başkanı

Fen Bilimleri Enstitü Onayı

Prof. Dr. S*****r B*****L
Müdür

ÖZET

KISA DÖNEM ELEKTRİK TÜKETİM TAHMİNİ İÇİN 2D-CNN ve DERİN ÖĞRENME ALGORİTMALARI KULLANILARAK HİBRİT BİR MODEL GELİŞTİRİLMESİ

A*****A, D***u

Yüksek Lisans Tezi, Bilgisayar Mühendisliği Anabilim Dalı

Danışman: Dr. Öğr. Üyesi B***k Y*****Z

Haziran 2021, 67 sayfa

Enerji tüketim tahmini arz-talep dengesinin sağlanması açısından oldukça önemlidir. Bu dengenin sağlanabilmesi için doğru ve güvenilir tahminler yapılması gerekmektedir. Bu tez çalışmasında, kısa dönem saatlik yük tahmini için 2D-CNN ve derin öğrenme metotlarından farklı yaklaşımlar kullanılarak hibrit bir model geliştirilmiştir. Çalışmada farklı olarak bir boyutlu zaman serisi olan geçmiş 24 saatlik tüketim verisi iki boyutlu görüntü verisine dönüştürülerek kullanılmıştır. Ayrıca benzer günlerin tüketimi ile takvim etkisinin model üzerindeki etkisi de incelenmiş ve doğruluğu artırdığı gözlemlenmiştir. Amaçlanan model ve 1D-CNN ile oluşturulan model karşılaştırıldığında tahmin sonuçlarında iyileşme sağlandığı görülmüştür. Kullanılan derin öğrenme modellerinden RNN, LSTM ve GRU karşılaştırıldığında ise GRU' nun daha başarılı sonuç verdiği görülmüştür. Çalışma sonucunda, 2D-CNN-GRU hibrit modeli ile yapılan tahminlerin hata oranı %3.15 MAPE olarak hesaplanmıştır. Ayrıca klasik zaman serisi yöntemlerinden ARIMA ile karşılaştırıldığında derin öğrenme algoritmalarının tahmin modelleri üzerinde daha başarılı olduğu gözlemlenmiştir.

Anahtar kelimeler: Zaman serisi, tüketim tahmini, yük tahmini, derin öğrenme, gramian angular field

ABSTRACT

A HYBRID MODEL BY USING 2D-CNN and DEEP LEARNING ALGORITHMS FOR SHORT-TERM ELECTRICITY CONSUMPTION FORECASTING

A*****A, D***u

Master of Science Thesis, Department of Computer Engineering

Supervisor: Dr. Öğr. Üyesi B***k Y*****Z

Haziran 2021, 67 pages

Energy consumption forecasting very important in terms of maintaining supply-demand balance. Accurate and reliable forecasting are required to provide this balance. In this thesis study, a hybrid model has been developed using 2D-CNN and deep learning methods for the short-term load forecasting. Unlike other studies in the study, the past 24-hour consumption data, which is a one-dimensional time series, was converted into two-dimensional image data and used. In addition, the consumption of similar days and the effect of the calendar effect on the model were also examined and it was observed that it increased accuracy. However, the consumption of similar days and the effect of special days and holidays were examined, and it was observed that it increased model accuracy. Compared to the proposed model and the model created with 1D-CNN, the forecast results were improved. GRU, which is one of the deep learning models used, has been found to be more successful. As a result of the study, the error rate of the predictions made with the 2D-CNN-GRU hybrid model was calculated as 3.15% MAPE. In addition, it has been observed that deep learning algorithms are more successful on prediction models when compared to ARIMA, one of the classical time series methods.

Keywords: Time series, load forecasting, consumption forecasting, deep learning, Gramian Angular Field

TEŞEKKÜR

Çalışmalarım boyunca değerli katkılarıyla ve yardımlarıyla beni yönlendiren tez danışmanım Sayın Dr. Öğr. Üyesi B***k Y****Z' a teşekkür ederim. Tez konumun belirlenmesinde yardımcı olan ve çalışmam boyunca uzman görüşünü esirgemeyerek her konuda yardımcı olan Enerji Ticaret ve Portföy Yönetim Uzmanı Sayın Ş***a A**T' e teşekkürlerimi sunarım.

Hayatım boyunca hep yanımda olan ve desteklerini benden hiç esirgemeyen aileme ve tez aşamasında bana her konuda destek olan ve sabrını benden esirgemeyen eşim M***t A*****A' ya sonsuz teşekkürlerimi ve sevgilerimi sunarım.

D***u A*****A
Haziran-2021

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Kısa Dönem Elektrik Tüketim Tahmini İçin 2D-CNN ve Derin Öğrenme Algoritmaları Kullanılarak Hibrit Bir Model Geliştirilmesi” adlı çalışmanın tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

18/06/2021

D***u A*****A



İÇİNDEKİLER

	Sayfa
ÖZET.....	iii
ABSTRACT.....	iv
TEŞEKKÜR.....	v
YEMİN METNİ.....	vi
İÇİNDEKİLER	vii
SİMGELER VE KISALTMALAR.....	viii
ŞEKİLLER DİZİNİ.....	x
ÇİZELGELER DİZİNİ	xi
1. GİRİŞ	1
2. LİTERATÜR TARAMASI.....	4
2.1. Türkiye Kısa Dönem Tüketim Tahmini Literatür Taraması	4
2.2. Diğer Ülkeler Kısa Dönem Tüketim Tahmini Literatür Taraması.....	9
3. MATERYAL VE METOT	14
3.1. Gramian açısal alan (Gramian Angular Field -GAF).....	14
3.2. Yinelemeli Sinir Ağları (Recurrent Neural Network - RNN)	17
3.3. Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM).....	21
3.4. Geçitli Tekrarlayan Birim (Gated Recurrent Unit)	24
3.5. Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN).....	26
3.5.1. CNN Katmanları	27
3.5.1.1. Konvolüsyon Katmanı (Convolutional Layer)	27
3.5.1.2. Havuzlama Katmanı (Pooling Layer)	28
3.5.1.3. DropOut Katmanı.....	29
3.5.1.4. Düzleştirme Katmanı (Flattening Layer)	29
3.5.1.5. Tam Bağlı Katman (Fully Connected Layer).....	30
3.5.2. CNN Hiper Parametre Optimizasyonu.....	30
4. ARAŞTIRMA SONUÇLARI	32
4.1. Veri Ön İşlemesi.....	32
4.2. Özellik Seçimi	33
4.3. Parametre Optimizasyonu	34
4.4. Verilerin Bölünmesi	35
4.5. Performans Ölçütleri	36
4.6. GAF-CNN-GRU Model Mimarisi	37
4.7. Sonuçların Değerlendirilmesi.....	38
5. SONUÇ ve ÖNERİLER.....	47
6. KAYNAKÇA.....	50
ÖZGEÇMİŞ	53

SİMGELER VE KISALTMALAR

Simgeler

θ	Açı
b	Bias
t	Mevcut zaman
x_t	t anındaki giriş vektörü
h_{t-1}	Bir önceki zamanın çıkış vektörü
c_t	Geçmiş bilgileri içeren vektör
e_j	Gerçek ve tahmin değerleri arasındaki fark
A_j	Gerçek zaman
$\tilde{x}$	Ölçeklenmiş zaman serisi verileri
I	Birim vektör
r	Yarıçap
N	Polar koordinat düzlemi
w	Ağırlık matrisi
σ	Sigmoid aktivasyon fonksiyonu

Kısaltmalar

1D	Bir boyutlu
2D	İki boyutlu
AF	Activation Function
ANFIS	Adaptive-Network Based Fuzzy Inference Systems
ANN	Artificial Neural Network
ARMA	Autoregressive Moving Average
ARIMA	Autoregressive Integrated Moving Average
Bi-GRU	Bidirectional GRU
BS	Batch Size
CNN	Convolution Neural Network
EWMA	Exponentially Weighted Moving Average
GA	Genetik Algoritmalar
GADF	Gramian Angular Difference Field
GAF	Gramian Angular Field
GASF	Gramian Angular Summation Field
GKA	Görgül Kip Ayırışımı
GRU	Gated Recurrent Unit
GSMH	Gayri safi milli hasıla
FFT	Fast Fourier Transform
FOA	Fruit Fly Optimization
IEMD	Image Empirical Mode Decomposition
LR	Learning Rate
LSTM	Long Short Term Memory
MAPE	Mean Absolute Percentage Error
MLP	Multilayer Perceptron
MSE	Mean Square Error
MTF	Markov Transition Fields
PSO	Parçacık Sürü Optimizasyonu
ResNet	Residual Network

RMSE	Root Mean Square Error
RNN	Recurrent Neural Network
RTF	Radyal Tabanlı Fonksiyon
RP	Recurrence Plots
SA	Sinir Ağları
SGD	Stochastic Gradient Descent
SVR	Support Vector Regression
VMD	Variational Mode Decomposition
YSA	Yapay Sinir Ağları
WNN	Wavelet Neural Network



ŞEKİLLER DİZİNİ

Şekil	Sayfa
Şekil 3.1. Kartezyen ve Polar Koordinat Sistemi gösterimi	14
Şekil 3.2. Zaman serisinden görüntü elde edilmesi akış diyagramı	15
Şekil 3.3. Zaman Serisi GADF/GASF dönüşümü	17
Şekil 3.4. RNN yapısı	17
Şekil 3.5. RNN mimarisi (a) Jordan yinelemeli ağ mimarisi (b) Elman yinelemeli sinir ağı	18
Şekil 3.6. RNN açılmış hali	19
Şekil 3.7. Aktivasyon fonksiyonları. (a) Tanh fonksiyonu (b) ReLU fonksiyonu....	20
Şekil 3.8. (a) RNN Mimarisinin iç yapısı. Tekrar eden kısmı tek bir tanh katmanından oluşmaktadır. (b) LSTM Mimarisinin iç yapısı. Tekrar eden kısım dört katmandan oluşmaktadır.	21
Şekil 3.9. LSTM kapıları.....	22
Şekil 3.10. Unutma kapısı	22
Şekil 3.11. Giriş kapısı	23
Şekil 3.12. Çıkış kapısı	23
Şekil 3.13. GRU mimarisi.....	24
Şekil 3.14. GRU sıfırlama kapısı	25
Şekil 3.15. GRU güncelleme kapısı	25
Şekil 3.16. GRU hücresindeki son aşama	26
Şekil 3.17. CNN mimarisi.....	27
Şekil 3.18. Konvolüsyon işleminin görüntü üzerinde uygulanması	28
Şekil 3.19. Farklı filtrelerle uygulanmış havuzlama işlemi	28
Şekil 3.20. (a) Normal ağ yapısı (b) Dropout kullanılmış ağ yapısı	29
Şekil 3.21. Düzleştirme işlemi	29
Şekil 4.1. 2016 - 2021 yılları arasındaki yük verileri.....	32
Şekil 4.2. Modelin giriş parametreleri	32
Şekil 4.3. Özellikler arasındaki ilişki haritası	34
Şekil 4.4. Zaman serisi 5-katlı çapraz doğrulama	36
Şekil 4.5. CNN-GRU mimarisi	38
Şekil 4.6. RNN modeli gerçek tüketim ve tahmin grafiği	41
Şekil 4.7. LSTM modeli gerçek tüketim ve tahmin grafiği	41
Şekil 4.8. GRU modeli gerçek tüketim ve tahmin grafiği	41
Şekil 4.9. 01.01.2021 tarihli tahmin sonuçları grafiği	43
Şekil 4.10. GRU ile 1D ve 2D CNN kullanılarak yapılan 24 saatlik tahmin sonuçları	44
Şekil 4.11. Bazı zaman serilerinin GADF ve GASF ile görüntüye dönüştürülmesi..	45

ÇİZELGELER DİZİNİ

Çizelge	Sayfa
Çizelge 1.1. Tüketim tahminini etkileyen faktörler	1
Çizelge 2.1. Türkiye’ de yapılan çalışmalar	8
Çizelge 2.2. Diğer ülkelerde yapılan çalışmalar	13
Çizelge 4.1. Modelde kullanılan hiper parametre listesi.....	35
Çizelge 4.2. GRU ve ARIMAX metotlarının karşılaştırılması.....	39
Çizelge 4.3. RNN, LSTM ve GRU modelleri için minimum ve maksimum başarılı parametreler ve başarı oranları.....	39
Çizelge 4.4. Aylık MAPE oranları.....	40
Çizelge 4.5. 01.01.2021 tarihli 24 saatlik tüketim tahmini hata oranları (MAPE)	42
Çizelge 4.6. Kullanılan Özniteliklerin 2D-CNN-GRU Model Doğruluğu Üzerindeki Etkisi	43
Çizelge 4.7. Modele etkisi incelenen gün tipleri, özel günler ve tatiller	44
Çizelge 4.8. GADF ve GASF ile görüntü dönüşümü sonrası GRU model başarı sonuçları	46

1. GİRİŞ

Teknolojinin, sanayileşmenin, nüfusun ve yaşam standartlarının artmasından dolayı enerji ihtiyacı her geçen gün artmaktadır. Bu nedenle bazı sektörlerdeki arz-talep dengesinin sağlanması da büyük önem kazanmıştır. Artan enerji ihtiyacının karşılanması için enerji üretim, dağıtım ve iletim tesislerinde geleceğe dönük planlama yapılması gerekmektedir. Bu geleceğe yönelik planlamaların daha doğru ve güvenilir bir biçimde yapılabilmesi için şirketlerdeki birimler tarafından geçmiş ve mevcut veriler kullanılarak talep tahmini yapılmaktadır.

Talep tahmini, gelecekteki bir zaman için şirketin kullandığı ürünlerin talep düzeyini tespit etmeyi amaçlamaktadır. Elektrik dağıtım şebekelerinde talep tahmini ise dağıtım şirketleri tarafından belirli bir zaman aralığı için geleceğe dönük olarak yapılan dağıtılan elektrik enerjisi tahminidir. Talep tahmini birçok sektörde önemli olmasına rağmen elektrik enerjisinde daha çok önemlidir. Çünkü elektrik depo edilemeyen bir enerjidir ve üretimi ile tüketimi arasındaki denge çok iyi sağlanmalıdır. Yapılacak tahminin talepten az olması bölgesel bazlı elektrik kesintilerine yol açacaktır. Tahminin talepten fazla olmasında ise enerji kayıpları kaçınılmaz olacak ve bu da gereksiz maliyetlere yol açacaktır. Bu nedenle yapılan enerjinin daha verimli kullanılabilmesi için yük tahminlerinin gerçeğe en yakın şekilde yapılması gerekmektedir. İyi bir talep tahmini, güvenilir ve ekonomik olmalıdır.

Çizelge 1.1. Tüketim tahminini etkileyen faktörler

Nüfus	Şehirleşme oranı
Zaman	Teknolojik gelişmeler
Mevsimsel değişiklikler	Tüketici davranışları
İklim koşulları	Elektrik fiyatı
Ülkelerin coğrafi özellikleri	Kişi başına düşen milli gelir
Gayri safi milli hasıla (GSMH)	Hane halkı sayısı ve ortalama hane büyüklüğü

Talep tahminini etkileyen birçok parametre mevcuttur. Bu parametreler kullanıcılara, kullanım amacına ve maliyetine göre bölgeden bölgeye çeşitlilik göstermektedir. Bu nedenle %100 doğruluk ile tahmin yapılması mümkün olmamaktadır. Yapılan

tahminin türüne göre farklı parametreler kullanılır. Çizelge 1.1' de elektrik tüketim tahminini etkileyen bazı faktörler gösterilmiştir.

Yük tahmini, tahmin döneminin uzunluğuna göre genel olarak kısa, orta ve uzun dönem olarak üçe ayrılmaktadır. Kısa Dönem yük tahminleri genellikle bir saatten bir haftaya kadar olan tahminleri kapsamaktadır. Bu zaman aralığında yapılan tahminler ile gerçek zamanlı anlık yük değerleri görülebilir. Kısa dönem yük tahmininde kullanılan en önemli parametreler hava durumu verileridir. Bir saatten az olan tahminler ise genel olarak çok kısa dönem yük tahmini olarak geçmektedir. Orta dönem yük tahminleri, bir ay ile bir yıl arasında yapılan tahminlerdir. Orta dönem yük tahmini de uzun dönem yük tahmini gibi nüfus artışı ve büyüme hızı ile ülkenin ekonomik değerlerine bağlı olarak yapılmaktadır. Bu faktörlere ilaveten dönemsel etkinlikler, olaylarda orta dönem yük tahmininde etkili olmaktadır. Bir yıldan daha fazla yapılan tahminler ise uzun dönem yük tahminlerini kapsamaktadır. Uzun dönem yük tahmininde ülkelerin büyüme hızı, nüfus artışı, gayri safi milli hasıla (GSMH) ve milli gelir gibi değişkenler kullanılmaktadır. Bu tahminler daha çok enerji sistemlerinde yapılması gereken kapasite genişletilmesi, enerji kaynak stratejilerinin belirlenmesi, sermaye yatırımlarının belirlenmesi ve gelir analiz çalışmaları için gereklidir (Akman, Yılmaz ve Sönmez, 2018).

Talep tahmini yapılırken planlanan tahmin türüne göre farklı yöntemler kullanılmaktadır. Ayrıca talep tahmininin kendine has özellikleri, sürekli değişen faktörleri ve etkileyen özellikleri göz önüne alındığında tahmin modelini genelleştirmek çok uygun olmamaktadır. Çünkü tahmini etkileyen faktörler düşünüldüğünde her ülkenin, şehrin ve bölgenin kendine has özellikleri ve tüketim alışkanlıkları bulunmaktadır. Bu nedenle tahmin modeli geliştirilirken bunlar dikkate alınarak her bölge için farklı yaklaşımlar önerilmelidir.

Literatürde, tüketim tahmini için yapılan çalışmalar farklı şekillerde sınıflandırılmış olmakla birlikte genel olarak Nitel ve Nicel yöntemler olmak üzere iki grupta ele alınmaktadır. Nitel yöntemler daha çok uzman kişilerin görüşlerine ve deneyimlerine dayanırken nicel yöntemler sayısal verilerin analiz edilmesine ve matematiksel yöntemlere dayanmaktadır. Regresyon Analizi, Zaman Serisi Analizleri, Genetik Algoritmalar ve Yapay Sinir Ağları nitel yöntemlere örnektir.

Bu tez çalışmasında, 2D-CNN ve derin öğrenme algoritmaları kullanılarak kısa dönem yük tahmini için yeni bir model geliştirilmesi amaçlanmıştır. Çalışma kapsamında Meram Elektrik Perakende Satış A.Ş. (MEPAŞ)' nin faaliyet gösterdiği Konya, Aksaray, Niğde, Kırşehir, Nevşehir ve Karaman olmak üzere 6 ilin bulunduğu İç Anadolu Bölgesi için tahmin çalışmaları yapılmıştır. Yapılan analizlerde MEPAŞ tarafından temin edilen 2016-2021 yılları arasındaki saatlik tüketim verisi ve hava durumu verileri kullanılmıştır. Bu illere ait toplam saatlik tüketim tahmini yapılırken modele Konya iline ait hava durumu verileri ve geçmiş 24 saatlik tüketim verisi eklenmiştir. Ayrıca öznitelik seçme yöntemi ile sıcaklık, nem oranı, radyasyon gibi hava durumu parametrelerinin tüketim verisin üzerindeki etkisi incelenerek modeli olumsuz etkileyecek parametreler çıkartılmıştır.

Çalışmada, derin öğrenme algoritmalarından RNN, LSTM ve GRU algoritmaları ile CNN algoritması birleştirilerek melez bir model oluşturulmuştur. Diğer çalışmalardan farklı olarak geçmiş 24 saatlik tüketim verisi Gramian Angular Field (GAF) yöntemi kullanılarak 24x24'lük görüntüye dönüştürülmüş ve CNN mimarisine giriş olarak verilmiştir. Model sonuçları, 1D-CNN model sonuçları ile karşılaştırılmış ve görüntü olarak verilen geçmiş tüketim özelliğinin kullanılmasının daha başarılı sonuçlar verdiği gözlemlenmiştir.

Saatlik yük tahminindeki hassasiyetten dolayı çalışmada, az parametre ile genel bir tahmin yapmak yerine tüketimi etkileyen tüm parametreler göz önünde bulundurularak kesin ve doğru tahminler yapılması amaçlanmıştır. Bu nedenle hava durumu ve 24 saatlik geçmiş tüketim verilerine ilaveten benzer günlerin tüketimleri de modele ilave edilerek tüketim tahmini üzerindeki etkisi incelenmiş ve bu parametrenin model doğruluğunu büyük oranda artırdığı gözlemlenmiştir. Son olarak modele resmî tatil günleri, dini ve milli bayramlar ile Ramazan ayı parametreleri eklenerek model üzerindeki etkisi incelenmiştir. Bu günlerin eklenmesi hata oranı düşürerek tahmin sonuçlarının iyileşmesini sağlamıştır.

Önerilen modellerin doğruluğunun belirlenmesi ve kolay karşılaştırılabilmesi için MSE, RMSE, MAPE ve R-kare hata ölçüm yöntemleri kullanılmıştır. Tüketim tahmini gibi tahmin problemlerinde gerçekleşen ve tahmin değerlerindeki büyük farklılıklar bu değerler üzerinde ani değişimler gösterdiği için tek bir hata ölçüm metodu yerine hepsi birlikte yorumlanarak tahmin doğruluğu incelenmiştir.

2. LİTERATÜR TARAMASI

Bu bölümde, elektrik tüketim tahmini ile ilgili yapılan çalışmalar hakkında bilgi verilmesi amaçlanmıştır. Kaynak araştırması, Türkiye’deki tüketim tahmini ve diğer ülkelerdeki tüketim tahmini olmak üzere iki bölümde incelenmiştir. İlk bölümde Türkiye ve bölgeleri için kısa dönem yük tahmini ile ilgili daha önce yapılan çalışmalar ele alınmış ve kullanılan metotlar ile hata oranları anlatılmıştır. Diğer bölümde ise genel olarak kısa, orta ve uzun dönem tüketim tahmini üzerinde yapılan çalışmalar incelenmiş ve en çok başarılı sonuç veren modellerde hangi metotların kullanıldığı üzerine odaklanılmıştır.

2.1. Türkiye Kısa Dönem Tüketim Tahmini Literatür Taraması

Tüketim tahmini kısa, orta ve uzun vadeli olarak farklı şekillerde yapılabilir. Tezin amacı kısa dönem yük tahmini olduğundan dolayı bu bölümde geçmişten günümüze kadar Türkiye için yapılan tüketim tahmini çalışmalarından bazıları özetlenmiştir.

Toker ve Korkmaz (2011) çalışmasında üç alt modeli birleştirerek melez bir model kurmuş ve Türkiye elektrik talebinin günlük ve haftalık tahminini saatlik olarak yapmıştır. Veri olarak geçmiş tüketim verileri, sıcaklık, nem, ısıma ve haftanın günleri, dini ve milli bayramlar gibi takvim değerleri kullanılmıştır. Modelde tüketim verisindeki aylık sezonsallık bileşenini ayırmak için spektrum analiz yöntemi kullanılmış ve verinin kendi içindeki doğrusal bağlantısı da AR filtreleme yöntemi ile ortaya koyulmuştur. Son alt model olarak da YSA ile tahminleme yapılmıştır. Model test edildiğinde MAPE değeri %2 olarak bulunmuştur. Yine çalışmada 1 haftalık saatlik tahmin için saatlik meteorolojik tahminler yerine 7 günlük minimum ve maksimum sıcaklık değerleri kullanılmış ve %4 lük MAPE oranı ile tahmin gerçekleştirilmiştir.

Başka bir çalışmada Haliloğlu ve Tutu (2018) mevsimselliğin kısa dönem elektrik talebindeki önemini ortaya koymuştur. Bir gün önceki elektrik tüketimi, haftanın günleri ve resmi tatillere ait kukla değişkenlere ilaveten mevsimselliği daha dinamik şekilde modellemek için yeni bir eşik sıcaklık değişkeni kullanılmıştır. EKK yöntemi kullanılarak oluşturulan model sonucunda gerçekleşen ve tahmin edilen tüketim arasındaki ortalama sapma oranları %1,3 ve %1,6 arasında değişmektedir.

Başıoğlu ve Bulut (2017) kısa dönem yük tahmini için yapay sinir ağları ve uzman sistemleri birleştirerek yeni melez bir model geliştirmiştir. EPSİM-NN adı verilen bu model için günlük ortalama saatlik talep tahmini ve 24 saatlik talep tahmini için iki farklı yapay sinir ağı kullanılmıştır. Ortalama saatlik talep miktarını tahmin etmek için geçmiş veriler, sıcaklık, gayri-safı milli hasıla, sanayi üretim endeksi ve günün hususi özellikleri kullanılırken yirmi dört saatlik bazda günlük tahmin için sadece zaman bilgileri ile günün özellikleri kullanılmıştır. İlk aşama olarak girdiler YSA' ya verildiğinde %5-6 bandında hata oranı ile karşılaşılmıştır. Son aşamada ise zaman serisindeki rastlantısal öğeleri ve mevsimsel etkileri azaltmak için kullanılan uzman sistem modülü yardımı ile bu hata oranı %2 civarına düşürülmüştür.

Bozkurt, Tayşi ve Biricik (2015) çalışmasında Türkiye piyasasında elektrik yük tahmininde kullanılabilecek değişkenlerin modele etkisini gözlemlemek için ileri beslemeli bir YSA modeli oluşturmuştur. Model ile geçmiş yüklere ilave olarak diğer tüm özelliklerin çeşitli kombinasyonları test edilmiştir. Bu çalışma ile Bozkurt ve diğerleri (2015) sadece geçmiş yük bilgileri ile tahmin yapmanın mümkün olabileceğini fakat başarı oranını artırmak için diğer parametrelerinde modele eklenmesi gerektiğini ortaya koymuştur. Geçmiş yük bilgisi ve takvim bilgisinin birlikte modele girdi olarak verilmesi sonucu %3.2 MAPE oranı ile tahmin yapılırken, bu parametrelerle birlikte fiyat ve yük tahmin planı da eklendiğinde %1.76 MAPE ile tahmin yapılmıştır.

Biçer (2018) tez çalışmasında YSA kullanarak toplam yüke dayalı ve bölgesel yüke dayalı iki farklı model geliştirmiştir. Test için Urla bölgesindeki bir örnek mahalleye ait yük, sıcaklık ve nem verileri kullanılmış ve birinci model için %7.04 diğer model için ise %7.66 MAPE oranı ile tahmin yapılmıştır. Çalışma sonucunda bölgeye dayalı tahminlerde yüke dayalı modelin daha başarılı olduğu ortaya konulmuştur.

Başka bir tez çalışmasında, geriye yayılım algoritması ile eğitilen çok katmanlı yapay sinir ağı modeli ile ertesi günün 24 saatlik tahmini yapılmıştır (Ceylan, 2004). Veri olarak Gölbaşı Bölgesi'ne ait 24 saatlik gerçek güç verileri, tahmin yapılacak güne ait minimum ve maksimum sıcaklık değerleri, gün tipi ve benzer günlere ait değerler kullanılmıştır. Oluşturulan model Regresyon analizi ile karşılaştırıldığında süre olarak regresyonun daha kısa sonuç verdiği fakat YSA' nın hata oranının daha düşük olduğu tespit edilmiştir. Belirli günler için yapılan tahmin sonuçlarına göre en yüksek

hata oranı ile regresyon analizi %30.3 hata oranı ile tahmin yaparken YSA %13.6 oran ile sonuçları tahmin etmiştir. Test edilen günlere ait en küçük hata oranı ise regresyon analizi sonucunda %16.5 iken YSA ile tahminde %4.7 olmuştur.

Özen ve Gül (2015), toplam yüke ve bölgelere dayalı olarak eğitilen 2 farklı model oluşturularak İstanbul Avrupa yakası için kısa dönemli yük tahmini üzerine bir çalışma yapmıştır. Saatlik yük, saatlik sıcaklık, günlük nem verileri ile zaman değişkenleri kullanılmıştır. Haftanın farklı günleri için bir haftalık yapılan tahminler sonucunda birinci model için ortalama %9.74 MAPE hesaplanırken ikinci model için MAPE değeri %4.45 olarak bulunmuştur. Bu sonuçlara göre de bölgeye dayalı talep tahminlerin yapılmasının daha doğru sonuçlar vereceği görülmüştür.

Tokgöz ve Ünal (2018), RNN, LSTM ve GRU gibi derin öğrenme yöntemlerinin tüketim tahmini üzerindeki başarısını araştırmak için bir çalışma yapmıştır. Çalışmada geçmiş 24 saatin tüketim verisi, 24 saatin ortalama tüketimi, 1 hafta önceki aynı saatin tüketimi ve gün türü verileri kullanılmıştır. Tüketim tahmini için belirtilen üç algoritma ile farklı katman sayıları kullanılarak modeller oluşturulmuş ve sonuçlar karşılaştırılmıştır. En iyi sonuç veren modeller %1.67 MAPE ile 2 katmanlı RNN, %0.92 MAPE ile 4 katmanlı LSTM ve %0.71 MAPE ile 3 katmanlı GRU modeli olmuştur. Tokgöz ve Ünal (2018) bu çalışma ile GRU modelinin RNN ve LSTM modeline göre daha iyi başarımlar elde edilebileceğini ortaya koymuştur.

Hocaoğlu, Kaysal ve Kaysal (2015), küçük bir bölge olarak belirledikleri Güney ilçesinin yük tahmini için YSA ve Regresyon yöntemleri ile melez bir model oluşturmuşlardır. İlk olarak regresyon yöntemi ile bir saat önceki veriler kullanılarak bir sonraki saatin yükü tahmin edilmiştir. Daha sonra bu modelin tahmin sonuçları ile bir saat önceki veriler YSA modeline verilmiştir. Melez model sonucunda %5.3 bağlı hata oranı ile tahminler oluşturulmuş ve hibrit sistemin sadece regresyon veya YSA kullanılarak oluşturulan modellerden daha başarılı sonuç verdiği gözlemlenmiştir.

Topalli ve Erkmen (2003), günün her saati için ayrı bir sinir ağı oluşturularak hibrit öğrenmeye dayalı bir YSA modeli önermişlerdir. Çalışmada, o saatin bugünkü ve önceki iki günün aynı saatteki tüketim değerleri ağı verilerek önceki tüketim değerlerinin modele etkisi araştırılmıştır. Model, 2001 yılı verileri ile test edildiğinde %2.45 MAPE hata oranı ile tüketim tahmin edilmiştir.

Topalli, Erkmen ve Topalli (2006), ARMA ve Elman sinir ağı yöntemlerini kullanarak 24 saatlik kısa dönem tahmin modellerini karşılaştırmıştır. Veriler, Cumartesi, Pazar, Pazartesi erken saatleri, haftanın geri kalan günleri ve özel günlere göre kümelere ayrılmıştır. Kümeleme, korelasyon analizi, günlük ve mevsimsel değişimler, tatil davranışları gibi detaylı bir veri analizinden sonra gerçekleştirilmiştir. Daha sonra her bir küme için ayrı ayrı yapay sinir ağı uygulanmıştır. ARMA modeli ile %2.33 MAPE ile tahmin yapılırken, Elman sinir ağı ile yapılan tahminler %1.6 MAPE ile daha başarılı sonuçlar vermiştir.

Akarslan ve Hocaoglu (2018) daha az tüketime sahip olan bölgeler için ANFIS tabanlı yeni bir yük tahmin yaklaşımını amaçlamıştır. Bunun için Afyon Kocatepe Üniversitesi Çay Meslek Yüksek Okulu Kampüsü geçmiş yük verileri, ay ve saat giriş parametresi olarak kullanılmıştır. Ayrıca tüketimin birinci sıradaki türevi de giriş olarak eklenmiştir. Bu parametrenin kullanılmasının doğruluğu artırdığı gözlemlenmiş ve nRMSE oranı %28.4 olarak hesaplanmıştır.

Esener, Yüksel ve Kurban (2012) çalışmasında sıcaklık verisi olmadan Türkiye geneli 24 saatlik yük tahmini için melez modelleri incelemiştir. Ülke geneli bir tahmin yaparken sıcaklık verisini kullanmak zor olduğundan bu çalışmada sadece yük verisi kullanılarak tahmin doğruluğunu artırmak amaçlanmıştır. Çalışmada, Yapay Sinir Ağları (YSA), Dalgacık Dönüşümü ve Yapay Sinir Ağları (DD ve YSA), Dalgacık Dönüşümü ve Radyal Tabanlı Fonksiyon Sinir Ağları (DD ve RTF SA), Görgül Kip Ayrışımı ve Radyal Tabanlı Fonksiyon Sinir Ağları (GKA ve RTF SA) olmak üzere dört farklı hibrit model oluşturulmuştur. 2010 yılı için yapılan tahminler sonucunda en iyi sonuç veren modeller ortalama günlük %2.99 MAPE ile regülesiz DD ve RTF SA ve %2.6 MAPE ile regüleli GKA ve RTF SA olarak gözlemlenmiştir.

Çizelge 2.1’ de yukarda bahsedilen Türkiye’ de yapılan çalışmalar özetlenmiştir. Bu tabloda çalışmalarda kullanılan yöntemler ve değişkenler ile hata oranları yer almaktadır. Ayrıca yük tahmininin zaman bağımlılığı dikkate alınarak kullanılan verilerin yıl bilgisi de eklenmiştir.

Çizelge 2.1. Türkiye’ de yapılan çalışmalar

Çalışma	Tahmin Yöntemi	Tahmin Türü	Değişkenler	Veri Yılı	Tahmin Yılı	Hata Oranı (MAPE)
Toker ve Korkmaz (2011)	YSA, AR, Spectrum Analiz Yöntemi	Günlük ve haftalık(saatlik)	geçmiş tüketim, sıcaklık, nem, ısıma, yağış miktarı, rüzgar hızı ve yönü ve takvim günleri	2008-2009	2009	%2 (günlük) , %4 (haftalık)
Haliloğlu ve Tutu (2018)	EKK	Günlük	bir gün önceki elektrik tüketimi, haftanın günleri, resmi tatiller, eşik sıcaklık farkı	2012-2018	Ocak – Nisan 2018	%1,3-%1,6
Başoğlu ve Bulut (2017)	YSA ve Uzman Sistemler	Günlük (saatlik)	geçmiş veriler, sıcaklık, gayri-safi milli hasıla, sanayi üretim endeksi, günün özellikleri	2005-2016	Mayıs-2016 (1 hafta)	%2
Bozkurt vd. (2015)	YSA	Haftalık	geçmiş yük, takvim bilgisi, geçmiş elektrik fiyatı, yük planı	2013 -2014	2013-2014	%3,2, %1.76
Biçer (2018)	YSA	Günlük (saatlik)	yük, sıcaklık ve nem verileri, gün özelliği	2013-2017	Nisan-2017 (1 hafta)	%7.04 (Bölgeye dayalı), %7.66 (yüke dayalı)
Ceylan (2004)	YSA	Günlük (saatlik)	24 saatlik gerçek güç verileri, minimum ve maksimum sıcaklık, gün tipi ve benzer günlere ait değerler	2002-2003	2003 (günlük)	%4.66 - %13.58
Özen ve Gül (2015)	YSA	Günlük	saatlik yük, saatlik sıcaklık, günlük nem verileri ile zaman değişkenleri	2010-2013	(1 hafta)	%9.74(toplam yüke dayalı) %4.45 (bölgeye dayalı)
Tokgöz ve Ünal (2018)	RNN, LSTM ve GRU	Haftalık	geçmiş 24 saatin tüketimi, 24 saatin ortalama tüketimi, 1 hafta önceki aynı saatin tüketimi ve gün türü	2013-2014	2014 (1 hafta)	%0.71
Hocaoğlu vd. (2015)	YSA ve Regresyon	Saatlik	bir saat önceki gerçek ve tahmini tüketim	-	-	%5.26
Topalli ve Erkmen (2003)	YSA	Günlük (saatlik)	o saatin bugünkü ve önceki iki günün aynı saatteki tüketim değerleri	2000-2001	2001	%2.45
Topalli vd. (2006)	ARMA ve Elman sinir ağı	Günlük (saatlik)	geçmiş yük verisi	2001-2002	2002	%2.33 (ARMA) %1.6 (Elman)
Akarslan ve Hocaoglu (2018)	ANFIS	Saatlik	geçmiş yük verileri, ay ve saat, tüketimin birinci sıradaki türevi	2016-2017	2017	%28.4
Esener vd. (2012)	DD, YSA , RTF, GKA	Günlük (saatlik)	geçmiş yük verisi	2008-2010	2009-2010	%2.99 (regülesiz) , %2.6 (regüleli)

2.2. Diğer Ülkeler Kısa Dönem Tüketim Tahmini Literatür Taraması

Xu, Yang ve Huang (2020), kısa dönem yük tahmininin doğruluğunu artırmak için artık ağlarla yeni bir derin sinir ağı modeli önermiştir. Çalışma, ön tahmin sonucu almak için farklı tam bağlı katmanların birleştirilmesi ve son tahminleri almak için düzenlenmiş artık ağ (residual network) olmak üzere iki aşamadan oluşmaktadır. Böylelikle modelin genelleme yeteneği artırılmaya çalışılmıştır. 2010 ve 2011 yıllarındaki verilerle test edildiğinde sırasıyla MAPE %1.46 ve %1.54 olarak hesaplanmıştır.

Choi, Ryu ve Kim (2018), kısa dönem yük tahmini için ResNet ve LSTM tabanlı yeni bir model geliştirmişlerdir. ResNet günlük ve haftalık yük verisindeki gizli özellikleri çıkarmak için kullanılırken, LSTM ResNet modelinden elde edilen özellik vektörünün eğitilerek yük tahmini yapılması için kullanılmıştır. Kore Elektrik Güç Şirketi (KEPCO) tarafından sağlanan 15 dakika aralıklı yük verileri kullanılarak oluşturulan model sonucunda %24.4 MAPE ile tahminler elde edilmiştir.

Wu, Kong, Hao, Chen ve Chen (2020), GRU-CNN tabanlı melez bir yapay sinir ağı modeli geliştirmiştir. Önerilen modelde GRU ile zaman serisi dizisindeki öğrenme potansiyeli daha yüksek özellikler için geçmiş yük verisindeki dinamik değişkenler modellenmiştir. CNN modülü de zaman sırasına ve sensörlerin konumuna dayalı olan spatio-temporal matrislerini bulmak ve bu matrisleri özellik vektörüne işlemek için kullanılmıştır. Test için GRU, CNN ve önerilen GRU-CNN modelleri ile 24 saatlik yük tahmini yapıldığında MAPE oranları sırasıyla %4.63, %3.38 ve %2.88 olarak hesaplanmıştır.

N, Yelamali ve Byahatti (2010) kısa dönem yük tahmini için Elman Yinelemeli Sinir Ağı kullanarak hava koşullarına duyarlı ve duyarlı olmayan iki farklı modeli karşılaştırmıştır. Hava koşullarını kullanmadan oluşturulan model sonucunda MSE 0.0111 olarak hesaplanırken, rüzgâr hızı, nem ve minimum-maksimum sıcaklık bilgilerinin kullanıldığı model sonucunda MSE 0.0046 olarak bulunmuştur.

El-Hendawi ve Wang (2020) çalışmasında kısa dönem yük tahmini için tam dalgacık paket dönüşümü ve sinir ağını birleştiren bir model önermişlerdir. Bir gün ve bir hafta önceki yük, sıcaklık, nem, saat, gün ve gün tipleri tam dalgacık paket dönüşümü modeline giriş parametresi olarak verilmiştir. Bu model ile yük profili farklı frekanslara ait çeşitli bileşenlere ayrılır ve daha sonra bu bileşenler sinir ağı ile

eğitilerek tahmin elde edilir. Çalışma sonucunda önerilen yaklaşımın %1.52 MAPE ile düşük tahmin hatasına sahip olduğu görülmüştür.

Lv, Liu, Yu, Zheng ve Lv (2020), EGA-STLF adını verdikleri kısa dönem yük tahmin modeli geliştirmiştir. Giriş değişkenleri arasındaki korelasyonu daha iyi bir şekilde yansıtmak için one-hot encoding yerine dağıtılmış bir temsil (distributed representation) kullanılmıştır. Ayrıca giriş verisinden geçici ve doğrusal olmayan özellikleri çıkarmak için Bi-GRU modeli kullanılmıştır. Avustralya Victoria (VIC) ve Queensland Eyaleti'nden (QLD) alınan 2 farklı gerçek veri seti kullanılmıştır. Her bir veri seti geçmiş yük verisi, elektrik fiyatı, ay, hafta, saat ve tatil günleri gibi takvim bilgilerini içermektedir. Önerilen model SVR ve MLP modelleri ile karşılaştırıldığında daha başarılı sonuçlar verdiği gözlemlenmiştir. EGA-STLF ile yapılan tahminler sonucunda VIC verisi için %3.35 MAPE ve QLD verisi için %3.06 MAPE hesaplanmıştır.

Mbae ve Nwulu (2020), Kenya elektrik piyasası saatlik gün içi tahmini için yeni bir Gri Verhulst modeli önermiştir. Çalışmada, doğal logaritma ve üstel ağırlıklı hareketli ortalama (EWMA) veri dönüşüm yöntemleri kullanılarak Gri Verhulst modelinin doğruluğunu artırmak amaçlanmıştır. Homojen olmayan üstel zaman serisi yük tahmin verisini normalleştirmek için doğal logaritmik dönüşüm kullanılmış ve yük zaman serisi verilerinin ağırlıklı ortalamasını hesaplamak için EWMA' da yumuşatma işlemi olarak logaritmik dönüşümün gradyanı kullanılmıştır. Geliştirilmiş Gri Verhulst modeli, geleneksel yöntemle karşılaştırıldığında sırasıyla %7.82 ve %2.96 MAPE elde edilmiş ve önerilen model çok daha iyi tahmin sonuçları vermiştir.

Jiang, Zhu, Li ve Qing (2018), büyük ölçekli elektrik yük tahminine odaklanarak Estonya ülkesi için LSTM ile bir tahmin modeli geliştirmiştir. İlk olarak yük verileri denetimli öğrenme verilerine dönüştürülmüş ardından LSTM ile eğitilerek tahminler oluşturulmuştur. Önerilen model ile SVR karşılaştırılmış ve RMSE değerleri sırasıyla 38.74 ve 43.16 olarak hesaplanmıştır. LSTM modelinin yük verisinin özelliklerini daha doğru bir şekilde elde ettiği sonucu çıkarılmıştır.

Jiang, Li, Liu ve Gao (2020) çalışmasında, elektrik talep tahmini için Değişken Kip Ayrışım Yöntemi (VDM), Hızlı Fourier Dönüşümü (FFT) ve akıllı optimizasyon algoritması tabanlı SVR modelini birleştirilmiştir. VMD ile giriş verisinden gürültü bileşenlerini ayırılarak zaman serisi verisindeki doğrusal ve durağan olmayan

durumlar ortadan kaldırılmıştır. FFT ile yük verisindeki karmaşık mevsimsel desenler belirlenmiş ve bu mevsimsel faktörler ortadan kaldırılmıştır. Modelde kullanılan makine öğrenmesi algoritmasının parametrelerinin ayarlaması için ise akıllı optimizasyon algoritması kullanılmıştır. Önerilen model Şubat, Mayıs, Ağustos ve Kasım ayı için test edildiğinde sırasıyla MAPE oranları 0.1859, 0.1448, 0.1819 ve 0.1962 olarak hesaplanmıştır.

He (2017) gün içi saatlik yük tahmini için yeni bir derin sinir ağı modeli önermiştir. Bu çalışma ile yük tahminini etkileyen faktörlerin farklı tiplerini modellemek için sinir ağının farklı bileşenlerini kullanmak amaçlanmıştır. Geçmiş yük verisinin zengin özelliklerini çıkarmak için CNN bileşenleri kullanılırken belirsiz dinamikleri modellemek için RNN bileşenlerinden yararlanılmıştır. Model oluşturulurken yük verisi için üç adet paralel CNN kullanılmış, sıcaklık tatil gibi diğer özellikler ise dense bileşeni ile modele dahil edilmiştir. Test sonucunda %1,405 MAPE ile tahmin yapılmıştır.

Zhang, Wei, Li, Tan ve Zhou (2018) kısa dönem yük tahmin doğruluğunu artırmak için geliştirilmiş deneysel mod ayrıştırması (IEMD), otoregresif birleşik hareketli ortalama (ARIMA) ve meyve sineği algoritması (FOA) ile optimize edilmiş dalgacık sinir ağına dayanan yeni bir hibrit model geliştirmiştir. Çalışmada IEDM ile yük verisinin lineer bileşenlerin ayrıştırılması sırasında bilgi kayıplarının en aza indirilmesi amaçlanmıştır. Ayrıca yük verisinin doğrusal bileşenine daha iyi uyum sağlayabilmesi için ARIMA kullanılmıştır. FOA ile optimize edilmiş WNN ise elektrik yükünün doğrusal olmayan bileşenine daha güçlü uyum sağlayarak tahmin doğruluğunu artırmada önemli etkenlerden olmuştur. 2012 yılı sıcaklık ve yük verileri ile her ay için ayrı ayrı tahminler yapılmış ve MAPE ortalama %0.82 olarak hesaplanmıştır.

Centra (2011) çalışmasında, İtalyan demiryollarının saatlik yük tahmini için Holt-Winter üstel yumuşatma tekniği ve zaman serisi analizi uygulamıştır. Holt Winter ve ARIMA yöntemleri karşılaştırılmış ve MAPE oranları sırasıyla %5.2 ve %6.5 olarak hesaplanmıştır. Haftalık mevsimselliği daha iyi yakalamak için Holt-Winter metodunun daha uygun olduğu gözlemlenmiştir.

Bouktif, Fiaz, Ouni ve Serhani (2020) metropol bölgelerinde kısa dönem tüketim tahmini için LSTM modeli geliştirmiştir. Modelin performansını etkileyen optimizasyon problemi için iki evrimsel metasezgisel model uygulanmıştır. Çalışmada

LSTM modelinin başarısını artırmak ve gerekli olan uygun hiperparametrelerin seçilmesi için genetik algoritma (GA) ve parçacık sürü optimizasyonu (PSO) kullanılmıştır. SVR, ANN ve Random Forest gibi algoritmalar ile önerilen model karşılaştırıldığında optimizasyon algoritmalarının tahmin sonuçlarındaki etkisi olduğu gözlemlenmiştir. SVR, LSTM-PSO ve LSTM-GA modellerinin RMSE oranları sırasıyla 479.43, 342.57 ve 311.44 olarak hesaplanmıştır.

Estebansari ve Rajabi (2020) bireysel konut yük tahmini için derin öğrenme ve resim işleme teknikleri kullanarak bir model önermiştir. Önerilen modelde ilk olarak zaman serisi resim olarak kodlanmış daha sonra üretilen bu resimler CNN'e giriş olarak verilerek tahminler oluşturulmuştur. Zaman serisini resme dönüştürmek için GASF, GADF, MTF ve RP olmak üzere dört farklı metot test edilmiş ve en doğru sonucu %14.15 MAPE oranı RP ile yapılabileceği analiz edilmiştir. RP ve CNN ile oluşturulan model sonucunda %12.54 MAPE oranı ile tahminler oluşturulmuştur.

Çizelge 2.2' de yukarda bahsedilen diğer ülkelerde yapılan çalışmalar özetlenmiştir. Bu tabloda çalışmalarda kullanılan yöntemler, değişkenler, hata oranları ve kullanılan verilerin yıl bilgisi yer almaktadır.

Çizelge 2.2. Diğer ülkelerde yapılan çalışmalar


Çalışma	Tahmin Yöntemi	Tahmin Türü	Değişkenler	Veri Yılı	Tahmin Yılı	Hata Oranı (MAPE)
Xu et al. (2020)	DNN	24 saatlik	geçmiş 24 saatlik tüketim verisi, sıcaklık, zaman özellikleri, tatil günleri	2003-2014	2010,2011	%1.46 , %1.54
Choi et al. (2018)	ResNET ve LSTM	Günlük	geçmiş yük verisi	-	-	%24.4
Wu et al. (2020)	GRU ve CNN	24 saatlik	geçmiş yük verisi, sıcaklık, hava durumu verileri, tatil günleri	Ağustos 2018 (1 dakika)	2018	%2.88
N et al. (2010)	Elman Sinir Ağı	Saatlik	geçmiş yük verisi, rüzgar hızı, nemlilik, minimum- maksimum sıcaklık	-	-	0.0046 (MSE)
El-Hendawi ve Wang (2020)	Dalgacık Paket Dönüşümü, Sinir Ağları	Günlük (saatlik)	Bir gün ve bir hafta önceki yük, sıcaklık, nem, saat, gün ve gün tipleri	2011-2016	2016	%1.52
Lv et al. (2020)	Bi-GRU	Günlük	geçmiş yük verisi, elektrik fiyatı, ay, hafta, saat ve takvim bilgileri	2013-2017	2017	%3.35 , %3.06
Mbae ve Nwulu (2020)	Gri Verhulst ve EWMA	Günlük (saatlik)	geçmiş yük verisi	2014-2019	2019	%2.96
Jiang et al. (2018)	LSTM	saatlik	geçmiş yük verisi	2017 (2 ay)	2017	38.74 (RMSE)
Jiang et al. (2020)	VDM, FFT ve SVR	Aylık	geçmiş yük verisi	2014 (4 ay)	2014	%0.1448 - %0.1962
He (2017)	CNN ve RNN	Günlük (saatlik)	geçmiş yük, sıcaklık, tatil günleri	2000-2012 (3 yıl)	2012	1,41%
Zhang et al.(2018)	IEMD, ARIMA, FOA ve WNN	Saatlik	sıcaklık ve yük verileri	2011-2012	2012	%0.82
Centra (2011)	Holt-Winter	saatlik	geçmiş yük verisi	2008	2008	%5.2
Bouktif et al. (2020)	LSTM, PSO ve GA	saatlik	geçmiş yük verisi	2008-2016	-	342.57 (RMSE), 311.44 (RMSE)
Estebasari ve Rajabi (2020)	CNN GASF, GADF, MTF ve RP	15-dakika	geçmiş yük verisi	2006-2010	-	%12.54

3. MATERYAL VE METOT

3.1. Gramian açısai alan (Gramian Angular Field -GAF)

Zaman serisini görüntüye dönüştürmek için kullanılan yöntemlerden biridir. GAF ile zaman serisi kartezyen koordinat sistemi yerine polar koordinat sistemi ile temsil edilir. GAF zamansal bağımlılığı korumak için önemli bir yol sağlar. Çünkü konum sol üstten sağ alta hareket ettikçe zaman da artar (Wang ve Oastes, 2015).

Koordinat sistemleri, bir noktanın farklı boyutlarda tanımlanabilmesini sağlar. İki boyutlu görüntüler de farklı koordinat sistemleri kullanılarak temsil edilebilirler. Kartezyen ve polar koordinat sistemi bu koordinat sistemlerindendir. Kartezyen koordinat sisteminde her bir nokta (x, y) ikilisinden oluşmaktadır. Polar koordinat sisteminde ise her bir nokta, noktanın orijine uzaklığı ve bir açı ile gösterilmektedir. Kartezyen sisteminden farklı olarak (r, θ) ile ifade edilir. Şekil 3.1’ de iki sistemin koordinat düzlemi üzerinde gösterimi yer almaktadır.




Şekil 3.1. Kartezyen ve Polar Koordinat Sistemi gösterimi

Bu iki sistem arasındaki farklardan biri, kartezyen sistemde bir nokta sadece bir (x,y) ikilisi ile ifade edilirken polar koordinat sisteminde sonsuz sayıda koordinat seti ile gösterilebilmesidir. Bazı problemlerde daha basit hesaplama ve analiz yöntemi tercih edilmek istendiğinde polar yani kutupsal koordinat sistemi tercih edilebilir. Kartezyen sisteme göre daha basit hesaplama ve daha az karmaşık sisteme sahiptir.

Kartezyen koordinat sistemi mutlak zaman değerine bağlı değildir ve sadece zaman aralığına bağlıdır. GAF yönteminde polar koordinat sistemi kullanılmasının en önemli avantajlarından bir diğeri de polar koordinat sisteminin hem zaman aralığına hem de mutlak zaman değerine bağlı olmasıdır. Farklı zaman aralıklarındaki zamansal

korelasyon hakkında bilgi edinmek için de polar koordinat sistemi önemli bir yere sahiptir.



Şekil 3.2. Zaman serisinden görüntü elde edilmesi akış diyagramı

Şekil 3.2 'de zaman serisinin görüntüye dönüştürülme aşamasının akış diyagramı gösterilmiştir. İlk olarak zaman serisi istenilen aralıkta ölçeklenir. Daha sonra her bir verinin açısal kosinüs ve yarıçapı hesaplanarak polar koordinat sistemine dönüştürülür. Son olarak kullanılacak metot seçilir ve seçime göre sinüs farkları veya kosinüs toplamları alınarak mxm boyutunda bir gram matrise dönüştürülür. Gram matris 2D görüntünün temsili olarak adlandırılır.

GAF görüntüsünü oluşturmak için zaman serisi $[-1,1]$ veya $[0,1]$ aralığında Denklem (3.1) veya Denklem (3.2) kullanılarak ölçeklenmelidir. Verilerin ölçeklenmesi farklı zaman aralıklarındaki kuvvetli ilişkileri ortaya çıkarmada önemli bir rol almaktadır. Denklemlerde, x_i , zaman serisindeki her bir veriyi gösterirken $\tilde{x}$ ölçeklenmiş zaman serisini ifade etmektedir.

$$\tilde{x}_{[-1,1]} = \frac{(x_i - \max(x)) + (x_i - \min(x))}{\max(x) - \min(x)} \quad (3.1)$$

$$\tilde{x}_{[0,1]} = \frac{(x_i - \min(x))}{\max(x) - \min(x)} \quad (3.2)$$

Daha sonra, ölçeklenen zaman serisi polar koordinat sistemi ile temsil edilir. Bunun için Denklem (3.3) kullanılarak ölçeklenen verilerden her bir noktanın açısai kosinüsü ve yarı çapı hesaplanır ve polar koordinat sistemine dönüştürülür.

$$\begin{cases} \phi = \arccos(\tilde{x}_i), -1 \leq \tilde{x}_i \leq 1, \tilde{x}_i \in \tilde{X} \\ r = \frac{t_i}{N}, t_i \in \mathbb{N} \end{cases} \quad (3.3)$$

Bu koordinat sistemi, iki nokta arası toplam veya fark dikkate alınarak Gramian Angular Summation Field (GASF) veya Gramian Angular Difference Field (GADF) ile matris yapısına dönüştürülür. Bu iki dönüşüm arasındaki fark kullanılan trigonometrik fonksiyonlardan kaynaklanmaktadır. GADF Denklem (3.4) ve (3.5)' de ki gibi sinüs fonksiyonuna dayanırken, GASF Denklem (3.6) ve (3.7)' de ki kosinüs fonksiyonunu baz alır.


$$GADF = \begin{bmatrix} \sin(\phi_1 - \phi_1) & \cdots & \sin(\phi_1 - \phi_n) \\ \vdots & \ddots & \vdots \\ \sin(\phi_n - \phi_1) & \cdots & \sin(\phi_n - \phi_n) \end{bmatrix} \quad (3.4)$$

$$GADF = \sqrt{I - \tilde{X}^2} \cdot \tilde{X} - \tilde{X}' \cdot \sqrt{I - \tilde{X}^2} \quad (3.5)$$

$$GASF = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_1 + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (3.6)$$

$$GASF = \tilde{X}' \cdot \tilde{X} - \sqrt{I - \tilde{X}^2} \cdot \sqrt{I - \tilde{X}^2} \quad (3.7)$$

Tüm bu işlemler sonucunda zaman serisinin GADF ve GASF ile görüntüye dönüştürülmesi Şekil 3.3' de gösterilmiştir.




Şekil 3.3. Zaman Serisi GADF/GASF dönüşümü

Bu çalışmada, GAF kullanılarak tek boyutlu zaman serisi, noktalar arasındaki kutupsal koordinat ilişkisine göre iki boyutlu görüntüye dönüştürülmüştür. Bu dönüşüm ile tüketim verileri arasındaki güçlü zamansal ilişkileri açığa çıkarmak ve tüketim verisinin zamandan bağımsız bir şekilde değerlendirmemek amaçlanmıştır.

3.2. Yinelemeli Sinir Ağları (Recurrent Neural Network - RNN)

Yinelemeli sinir ağları, gizli durumların önceki çıktıları kullanmasına olanak sağlayan bir sinir ağıdır. Normal sinir ağlarında girdiler birbirinden bağımsızdır. Yani bir önceki verinin sonraki veriler için bir önemi yoktur. Ama zaman serisi gibi sıralılık örüntüsü (sequence pattern) içeren problemlerde önceki bilgiye ihtiyaç duyulur. Bu durumda bir önceki veriye ait bilgileri hafızasında tutan RNN' ler ortaya çıkmaktadır (Altunkaya ve Yılmaz, 2020).




Şekil 3.4. RNN yapısı

Şekil 3.4’ de yinelemeli sinir ağının basit bir yapısı gösterilmektedir. A, yapay sinir ağındaki bir nöronu temsil etmektedir. x_t , ağın girdi değeri iken h_t , ağın çıktı değerini göstermektedir. RNN yapısında her bir nöronun çıktısı yine kendisine girdi olarak gelir ve bir döngü oluşturur. Bu döngü, önceki zamana ait bilgilerin tekrar kullanılmasını sağlar ve geçmiş bilgilerle mevcut bilgiler arasında bir anlamlandırma yaparak gelecek hakkında bir tahmin yapabilmeyi sağlar.

Geçmişten günümüze RNN için farklı ağ mimarileri ortaya atılmıştır. İlk önerilen mimarilerden olan Jordan ve Elman ağı mimarisi Şekil 3.5’ de gösterilmiştir.


Jordan ağı, çok katmanlı algılayıcılar ile benzerlik göstermektedir. Girdi, çıktı ve gizli katmanlara ilaveten durum elemanları (state units) adı verilen özel bir katman daha içermektedir. Durum elemanları, çıktı katmanından aldıkları değerleri bir sonraki tekrarda gizli katmanlara girdi olarak taşımaktadır. Böylelikle ağ önceki adımın son çıktısını hafızasında tutmuş olur. Ayrıca Jordan ağında her bir durum katmanındaki her bir elemanın kendisine de bağlantısı bulunmaktadır.

Elman ağları, girdi, çıktı ve gizli katman dışında içerik katmanı (context layer) içermektedir. Jordan ağlarına göre bazı önemli farklılıklara sahiptir. Bunlardan birincisi içerik katmanının girdi olarak aldıkları değerleri çıkış katmanından değil de gizli katmandan almalarıdır. Diğer fark ise bu içerik katmanlarının, Elman sinir ağındaki durum katmanındaki gibi kendilerine bağlantılarının olmamasıdır. Elman sinir ağları, gizli katman çıktısını hatırlar.



Şekil 3.5. RNN mimarisi (a) Jordan yinelemeli ağ mimarisi (b) Elman yinelemeli sinir ağı

Geleneksel yapay sinir ağlarındaki zorluklardan biri modelin farklı tekrarlar da öğrendikleri bilgileri hatırlayamamasıdır. Yinelemeli sinir ağları ile bu soruna çözüm getirilmiştir. RNN' ler önceki girdileri hafızalarında tutabilmek için girdiler arasında ilişki kurarlar ve bu ilişkileri hatırlayabilmek için de kendi içlerinde döngü benzeri bir yapı kullanırlar. Şekil 3.6 'da RNN yapısında önceki bilgilerin hafızada nasıl tutulduğu gösterilmiştir. Her yeni girdi geldiğinde, modele bu giriş bilgisi ile önceki girdinin gizli katman bilgisi de verilir. Yani her çıkan sonuç bir sonraki adıma girdi olarak verilir ve böylelikle geçmiş bilgiler kaybolmadan bir sonraki katmanlara aktarılır. Bu da yinelemeli sinir ağlarının geçmiş bilgilere ihtiyaç duyan zaman serisi gibi problemlerde normal sinir ağına göre daha başarılı sonuç vermesine olanak sağlamaktadır.




Şekil 3.6. RNN açılmış hali

RNN' lerin teoride uzun vadeli hafıza sorunları için başarılı olduğu düşünülse de yapılan uygulamalar sonucunda kısa dönem hafıza için daha başarılı olduğu görülmüştür. Yinelemeli sinir ağları, geçmiş ile mevcut zaman bilgileri arasında anlam ilişkisi kurabilmekte ve bu nedenle de zamana bağlı problemlerde daha başarılı sonuçlar verebilmektedir. Fakat hangi bilgiler hatırlanacak ne kadar süre ile hatırlanacak buna çözüm bulamamaktadır. Bu da gereksiz bilgilerin de hafıza da tutulmasına neden olmaktadır. Bazı problemlerde bu istenmeyen bir durumdur ve tüm geçmiş bilgilerin saklanması gereksizdir.

Tekrarlayan sinir ağlarının diğer sorunu da patlayan ve kaybolan gradyan problemidir. Gradyan, ağırlıkları güncellemek için kullanılan bir değerdir. RNN eğitiminde geleneksel sinir ağlarında olduğu gibi geri yayılım algoritması kullanılmaktadır. Bu geri yayılım boyunca gradyan hesaplaması yapılmaktadır. Hesaplanan gradyanlar ağırlıkları güncellemede ve kayıp fonksiyonunu minimuma düşürmede kullanılır. Katmanlar arasında uzun ilişkiler içeren ağlarda hatanın etkisi düşmektedir ve bütün katmanlar zamana bağlı adımlarla birbirine çarpımla bağlı oldukları için türevleri

zayıflamaya başlamaktadır. Yani gradyan sifira yaklařmaya bařlayabilir. Gradyanlar çok küçük olduėunda parametre gncellemeleri nemsiz hale gelir bu da gerek bir ėrenme yapılamaması demektir. Gradyanların çok byk olması ise, çok byk aėrılık gncellemeleri ile aėın dengesizliėine sebep olacaktır. Sonu olarak gradyan patlama ve kaybolma problemi aėrılıkların sifira yakınsamasına ya da çok byk deėerlere ulařmasına neden olarak modelin doėru bir řekilde eėitilememesine yol aacaktır. RNN’ in bu gradyan sorununu zmek iin farklı zmler getirilmiřtir. LSTM ve GRU’ da bu problemler iin geliřtirilmiř yinelemeli sinir aėı trlerindendir.

Yinelemeli sinir aėında gemiř bilgilerin oluřturduėu vektrn hesaplanması iin “tanh” ve “relu” gibi farklı aktivasyon fonksiyonu kullanılmaktadır. řekil 3.7’ de gsterildiėi gibi tanh fonksiyonu -1 ile 1 arasında deėerler alırken relu fonksiyonu 0 ile 1 arasında deėerler almaktadır. Tanh fonksiyonunun alabileceėi deėerler sabit olduėu iin t zamanda ilerledike gradyanın çok byk ve küçük olması diėer aktivasyon fonksiyonlarına gre daha zordur. Fakat tahn fonksiyonu Denklem (3.8) ile hesaplanmaktadır ve trevi u noktalarda sifira yakınsar. Bu da kaybolan gradyan probleminden mustarip olduėunu gstermektedir. Denklem (3.9)’ da grldėi gibi ReLU fonksiyonu negatif deėer reten nronlar iin sifır deėerini retir. Bu ReLU’ nun aynı anda tm nronları aktive etmeyeceėi anlamına gelmektedir. Bylelikle diėer aktivasyon fonksiyonlarına gre daha verimli ve hızlı alıřma konusunda stnlk saėlar.



řekil 3.7. Aktivasyon fonksiyonları. (a) Tanh fonksiyonu (b) ReLU fonksiyonu


$$\tanh(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (3.8)$$

$$f(x) = \begin{cases} 0, & x < 0 \\ x, & x \geq 0 \end{cases} \quad (3.9)$$

3.3. Uzun Kısa Süreli Bellek (Long Short Term Memory-LSTM)

Uzun Kısa Süreli Bellekler (LSTM), uzun süreli bağımlılıkları öğrenebilen bir RNN türüdür. RNN' in teoride uzun dizilerle de iyi sonuç vermesi gerektiği düşünülürken bunun pratikte doğru olmadığı yapılan çeşitli çalışmalar sonucu gözlemlenmiştir. Bu da RNN' in kısa vadeli bir hafızası olduğunu ve uzun vadeli geçmiş bilgileri hatırlamakta başarısız olduğunu göstermektedir. Yani RNN' de bağlamlar arası boşluk arttıkça eski bilgileri kullanması zor hale gelmektedir. RNN' in bu gibi sorunlarına çözüm bulmak için LSTM ve GRU gibi farklı metotlar önerilmiştir.


LSTM ilk olarak Hochreiter ve Schmidhuber (1997) tarafından ortaya atılmıştır. Daha sonra bu çalışma üzerinde birçok değişiklik yapılmış ve farklı LSTM modelleri önerilmiştir. Ancak uzun kısa süreli belleklerdeki genel amaç uzun zaman aralığında ağırlıklı hangi bilgileri depolayacağı, hangi bilgileri hafızasından atacağı ve depoladığı bilgilerden hangi bilgileri çıkaracağıdır.



Şekil 3.8. (a) RNN Mimarisinin iç yapısı. Tekrar eden kısmı tek bir tanh katmanından oluşmaktadır. (b) LSTM Mimarisinin iç yapısı. Tekrar eden kısım dört katmandan oluşmaktadır.

RNN' de temel mantık girdi verisindeki her bir bilgi geçmişten gelen bilgilerle birlikte ele alınarak tekrarlı olarak incelenir. RNN' de bu tekrar eden modül Şekil 3.8(a)'da görüldüğü gibi tek bir tanh katmanı ile basit bir yapıdan oluşmaktadır. LSTM buna ek


olarak bilgi akışını sağlayan üç kapı daha içerir. Şekil 3.8(b)' de LSTM' in iç yapısı gösterilmiştir.



Şekil 3.9. LSTM kapıları

LSTM hücreleri Şekil 3.9' da gösterildiği gibi giriş, çıkış ve unutma kapısı olmak üzere üç kapıdan oluşmaktadır. Ayrıca RNN' den farklı olarak hücre durumu (cell state) katmanını içermektedir. LSTM mimarisindeki c_t ve h_t iki farklı vektör olarak bir sonraki hücreye aktarılırlar.

Hücre durumu, katmanlar boyunca anlamlı bilgileri taşıyan bir iletişim hattıdır. Geçmiş bilgiler bu ağ boyunca hafızada tutulmakta ve kısa süreli bellek görevi görmektedir. Hücre durumunun taşıyacağı bilgiler LSTM' in yapısındaki kapılar tarafından sağlanır.




Şekil 3.10. Unutma kapısı

$$f_t = \sigma(w_f[h_{t-1}, x_t] + b_f) \quad (3.10)$$

Unutma kapısı, hangi bilgilerin taşınıp taşınmayacağına karar veren kapıdır. Şekil 3.10' de gösterildiği üzere bu katman sigmoid katmanını ve noktasal çarpım işleminden oluşmaktadır. t anındaki bilgi olan x_t ve t-1 zamanından gelen h_{t-1} verisi sigmoid

aktivasyon fonksiyonuna verilir. Sigmoid fonksiyonu, gelen veriye göre 0 ile 1 arasında bir çıktı üretmektedir. Denklem (3.10) ile fonksiyon sonucu hesaplanır ve bu sonuca göre bilginin ne kadarının geçeceğine karar verilmektedir. Fonksiyon sonucunda 0 olan bilgiler unutulurken 1 olan bilgiler hücre durumuna aktarılır.




Şekil 3.11. Giriş kapısı

$$i_t = \sigma(w_i[h_{t-1}, x_t] + b_i) \quad (3.11)$$

$$\tilde{c}_t = \tanh(w_c[h_{t-1}, x_t] + b_c) \quad (3.12)$$

$$c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (3.13)$$

Şekil 3.11’ de gösterilen bir diğer kapı, sigmoid ve tanjant katmanlarından oluşan Giriş kapısıdır. Giriş kapısı, hücre durumundaki bilgilerin güncellenip güncellenmeyeceğine karar verir. Mevcut giriş bilgisi ve bir önceki katman çıktısı Denklem (3.11)’ de ifade edildiği gibi sigmoid fonksiyonuna ve Denklem (3.12)’ de gösterildiği gibi tanh fonksiyonuna verilir. Sigmoid aktivasyon fonksiyonuna göre 0 olan bilgiler gereksiz, 1 olan bilgiler önemli olarak belirlenir. Tanh fonksiyonu ile de veriler -1 ile 1 aralığında ölçeklenir. Bu iki işlem sonucu Denklem (3.13) ‘de ki gibi çarpılarak hangi bilginin güncelleneceğine karar verilir.



Şekil 3.12. Çıkış kapısı

$$o_t = \sigma(w_o[h_{t-1}, x_t] + b_o) \quad (3.14)$$


$$h_t = o_t * \tanh(c_t) \quad (3.15)$$

Şekil 3.12’ de gösterilen Çıkış kapısı ile bir sonraki katmanın girişi olan çıkış verisi ve nihai tahmin sonuçları belirlenir. Denklem (3.14) ile mevcut giriş bilgisi x_t ve bir önceki katman çıktısı h_{t-1} sigmoid fonksiyonuna verilir. Daha sonra elde edilen bu değer ile tanh fonksiyonuna verilen c_t Denklem (3.15)’ de gösterildiği gibi çarpılır ve geçmiş değer olarak bir sonraki hücreye giriş olarak verilir.

3.4. Geçitli Tekrarlayan Birim (Gated Recurrent Unit)

Geçitli tekrarlayan birimler (Gated Recurrent Unit-GRU) ilk olarak Cho, Van Merriënboer, Gulcehre, Bahdanau, Bougares, Schwenk ve Bengio (2014) tarafından ortaya atılmıştır. Yinelemeli sinir ağının uzun süreli ilişkileri öğrenebilmesini zorlaştıran gradyan kaybolma veya patlama problemine çözüm olarak önerilmiştir.

Bu mimaride RNN ve LSTM’ den farklı olarak bir dizi okurken veya üretirken her bir gizli birimin ne kadar hatırlayacağını veya unutacağını kontrol eden bir sıfırlama kapısı ile bir güncelleme kapısı içeren yeni gizli bir birim bulunmaktadır. Ayrıca LSTM’ de bulunan giriş ve unutma kapısı bu mimaride güncelleme kapısı olarak tek bir yapıda birleştirilmiştir. Bu da GRU’ nun yapısını basitleştirmiş ve hesaplama zamanını azaltmıştır.




Şekil 3.13. GRU mimarisi

GRU mimarisinde Şekil 3.13’ de gösterildiği gibi güncelleme ve sıfırlama kapısı mevcuttur. Güncelleme kapısı, LSTM’ deki unutma ve giriş kapısına benzer ve hangi bilgilerin çıkarılacağına, hangi bilgilerin ekleneceğine karar verir. Bu da gradyan

kaybolma sorununa çözüm getirmektedir. Sıfırlama kapısı ise hangi bilgilerin unutulacağına karar verir.

$$h_t = c_t \quad (3.16)$$


GRU modelinde her bir GRU hücresine x_t girdi vektörü ve geçmiş bilgileri içeren c_{t-1} vektörü giriş parametresi olarak gelmektedir. h_t ile c_t vektörleri ise LSTM' den farklı olarak GRU da birbirlerine eşittir ve Denklem (3.16) ile ifade edilir. Yani bu vektörler hem çıktı vektörünü hem de bir sonraki hücrenin girdi vektörünü temsil eder.



Şekil 3.14. GRU sıfırlama kapısı

$$r_t = \sigma(w_r[h_{t-1}, x_t] + b_r) \quad (3.17)$$


Şekil 3.14' de gösterilen sıfırlama kapısında geçmişten gelen bilgi ile mevcut bilgi, r_t ile birleştirilmiştir. r_t Denklem (3.17)' de verilen formül ile hesaplanmaktadır. Ayrıca r_t önceki durum ve yeni çıktıların nasıl birleşeceğini belirlemekten sorumludur. Sıfırlama kapısı, modelin bir sonraki zamanda ilgisiz olabilecek geçmiş bilgileri çıkarmasını sağlar. Her bir döngüde önceki ve yeni girişlerin birleşik performansını yeniden değerlendirir ve yeni girişler için gerektiği gibi sıfırlanır. Hesaplama sonucunda sigmoid aktivasyon fonksiyonundan dolayı 0 ile 1 arasında değerler üretilir. 0'a yakın değerlerin çıkarılacağı 1' e yakın değerlerin aktarılacağı anlamına gelmektedir.



Şekil 3.15. GRU güncelleme kapısı

$$z_t = \sigma(w_z[h_{t-1}, x_t] + b_z) \quad (3.18)$$

Şekil 3.15 ile GRU' nun güncelleme kapısı gösterilmiştir. x_t mevcut girişi, h_{t-1} önceki durumda hesaplanan değeri ve w_z öğrenilebilir ağırlık matrisini ifade etmektedir. Güncelleme kapısı, önceki hafızadaki bilgilerden hangisinin tutulacağından sorumludur ve buna Denklem (3.18)' de ki formül ile karar verir.



Şekil 3.16. GRU hücresindeki son aşama

$$\tilde{h}_t = \tanh(w_h[r_t * h_{t-1}, x_t] + b_h) \quad (3.19)$$

$$k_t = (1 - z_t) * h_{t-1} \quad (3.20)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t \quad (3.21)$$

GRU' da son olarak Şekil 3.16' da gösterilen ve h_t olarak ifade edilen mevcut andaki çıktı hesaplanır. Bu aşamada ilk olarak $\tilde{h}_t$, Denklem (3.19)' da gösterildiği gibi sıfırlama kapısından gelen r_t ile bir önceki zaman çıktısı h_{t-1} , -1 ile 1 aralığında çıktı üreten tanh hiperbolik fonksiyonuna verilerek hesaplanır. Daha sonra çıktı üzerinde önemli etkisi olan güncelleme kapısı çıktısı z_t ile $\tilde{h}_t$ değerlerine çarpım uygulanır ve bu üretilen değer ve Denklem (3.20) ile hesaplanan k_t değeri, Denklem (3.21)' de ifade edildiği gibi toplanır ve nihai sonuç elde edilmiş olur.


3.5. Evrişimsel Sinir Ağları (Convolutional Neural Network - CNN)

Evrişimsel Sinir Ağları (CNN), çok katmanlı algılayıcılara (MLP) dayanan bir sinir ağı türüdür. İleri yönlü bir sinir ağı olan CNN, hayvanların görme merkezinden esinlenilerek ortaya atılmıştır (Şeker, 2017). CNN genel olarak Şekil 3.18' de gösterildiği gibi, konvolüsyon, aktivasyon, havuzlama ve tam bağlı katmandan oluşur.

CNN hem özellik çıkarma hem de sınıflandırma işlemleri için kullanılabilir. Burada dikkat edilesi gereken nokta, bu iki işlemi oluştururken yapılarının farklı olmasıdır.

CNN özellik çıkarmak için kullanılacaksa Şekil 3.17’ de gösterildiği gibi tam bağlı katman modelden çıkarılmalıdır.

Bu çalışmada CNN, sınıflandırma işlemi için değil yük görüntülerinden özellik çıkarmak için kullanılmıştır. Bu nedenle tam bağlı katman modelden çıkarılmıştır.



Şekil 3.17. CNN mimarisi

3.5.1. CNN Katmanları

3.5.1.1. Konvolüsyon Katmanı (Convolutional Layer)

Görüntünün üzerinde kernel olarak adlandırılan belirli filtrelerin dolaştırılması ile görüntünün özellik haritasının çıkarılması işlemidir. Konvolüsyon işlemi, f ana resim, h kernel olarak ifade edildiğinde Denklem (3.22)’ deki formül ile hesaplanır (Sertkaya, 2018).


$$f * h = \sum_k \sum_l f(k, l) h(i - k, j - l) \quad (3.22)$$

$$f = \begin{bmatrix} f_1 & f_2 & f_3 \\ f_4 & f_5 & f_6 \\ f_7 & f_8 & f_9 \end{bmatrix} \quad h = \begin{bmatrix} h_1 & h_2 & h_3 \\ h_4 & h_5 & h_6 \\ h_7 & h_8 & h_9 \end{bmatrix}$$

$$f * h = f_1 h_9 + f_2 h_8 + f_3 h_7 + f_4 h_6 + f_5 h_5 + f_6 h_4 + f_7 h_3 + f_8 h_2 + f_9 h_1$$

Şekil 3.18 ‘de 5x5 boyutundaki bir görüntü matrisi üzerinde 3x3 boyutundaki bir filtrenin uygulanışı gösterilmiştir. Bu işlem seçilen filtrenin görüntü üzerinde kaydırılması ile gerçekleştirilir. Her konumda filtre ile görüntünün üst üste geldiği

yerler çarpılarak toplanır ve sonuç yeni bir matrise yazılır. En son sonuçlardan oluşan bu yeni matris ile özellik haritasını oluşturulmuş olur. Seçilen filtre 2x2, 3x3 veya 5x5 gibi farklı boyutlarda bir pencere olabilir.




Şekil 3.18. Konvolüsyon işleminin görüntü üzerinde uygulanması

3.5.1.2. Havuzlama Katmanı (Pooling Layer)

Alt-Örnekleme (Subsampling) katmanı olarak da bilinen bu katmanın amacı çıktının boyutunu azaltmaktır. Bu işlem bazı bilgilerin kaybolmasına neden olsa da modelin ezberlemesini önlemek ve hesap yükünü azaltmak gibi avantajlara sahiptir. Konvolüsyon işleminde olduğu gibi havuzlama içinde belirli filtreler görüntü üzerinde kaydırılır. Bu filtreler, görüntüde pencere üzerine denk gelen noktaların minimum, maksimum veya ortalama değerlerinin alınmasıdır.


Şekil 3.19’ da görüntü üzerine minimum, maksimum ve ortalama filtrelerinin uygulanması ile havuzlama işlemi gösterilmiştir.



Şekil 3.19. Farklı filtrelerle uygulanmış havuzlama işlemi

3.5.1.3. DropOut Katmanı


Dropout katmanı ağı eğitimi aşamasında ezberlemeyi önlemek için kullanılır. Bu katmanda belli eşik değerler kullanılarak gereksiz ya da zayıf olan düğümlerin kaldırılmasını sağlar. Bu da ağı performansı artırır. Şekil 3.20’ de dropout kullanılmamış ve kullanılmış iki farklı ağı yapısı gösterilmektedir.



Şekil 3.20. (a) Normal ağ yapısı (b) Dropout kullanılmış ağ yapısı

3.5.1.4. Düzleştirme Katmanı (Flattening Layer)

Konvolüsyon ve havuzlama katmanından sonra elde edilen matris halindeki veriyi tek boyutlu veriye dönüştürmek için kullanılır. Verileri tam bağlı katmanın girişine hazır hale getirebilmeyi sağlar. Şekil 3.21’ de düzleştirme işlemi sonucu veriler gösterilmiştir.



Şekil 3.21. Düzleştirme işlemi

3.5.1.5. Tam Bağlı Katman (Fully Connected Layer)

Tam bağlı katman, verilerden özellik çıkarma, boyut azaltma ve düzleştirme işlemlerinden sonra ağıın sonunda kullanılır. Verileri düzleştirme katmanından alır ve sinir ağı yoluyla öğrenme işlemi gerçekleştirir.

3.5.2. CNN Hiper Parametre Optimizasyonu

Uygun hiper parametre seçiminin derin öğrenme mimarisinde önemli bir yeri vardır. Öğrenme oranı (learning rate), mini-batch boyutu ve epoch sayısı gibi optimizasyon parametreleri ve aktivasyon fonksiyonları, dropout değeri, katman sayısı gibi özel model parametreleri CNN sonucunu etkileyen parametrelerdendir.

Öğrenme oranı, sabit bir değer veya belirli bir düzeyde artan veya azalan şekilde ayarlanabilir. Genel olarak öğrenme oranı 0.1 ile 0.000001 arasında seçilmektedir. Bu değerin çok düşük veya çok yüksek seçilmesi modeli kötü etkileyecektir. Eğer optimum değerden çok küçük olursa ideal değere ulaşması çok uzun zaman alacaktır. Eğer çok büyük olursa da ideal değer aşılabılır ve model hiçbir zaman ideal değere ulaşamayabilir. Yerel minimum değere takılmadan ideal değere ulaşabilecek şekilde ve ideal değeri yakalayabilecek bir öğrenme oranı seçilmelidir.

Mini-batch boyutu, ağıın performansını artırmak ve belleği daha iyi kullanmak için tüm verilerin küçük gruplar halinde işlenmesi için kullanılır. Modelin aynı anda kaç veriyi işleyeceği anlamına gelir. Büyük mini-batch boyutu daha fazla belleğe ihtiyaç duyulmasına sebep olurken, küçük mini-batch boyutu, hata hesaplamasında daha çok gürültüye neden olur. Genel olarak mini-batch boyutları hepsi aynı olup %1-%5 arasında ideal olarak seçilmektedir. %1'den küçük seçilirse gürültü çok fazla olmakta, %5'ten fazla seçilirse modelin eğitim değerleri düşmektedir (Sertkaya, 2018).

Epoch sayısı, modelin baştan sona yaptığı tam bir turdur. Epoch sayısının düşük olması modelin eksik öğrenmesine sebep olabilirken fazla seçilmesi de modelin fazla öğrenmesine sebep olabilir. Buna tahmini bir değer vermek yerine, tensorflow kütüphanesindeki earlystopping özelliği kullanılarak modelin istenilen seviyeye geldiğine otomatik olarak durdurulması sağlanabilir. Yani, doğrulama verisindeki hata da eğer belirlenen epoch boyunca iyileşme sağlanmıyorsa eğitim süreci durdurulur.

Dropout katmanı, ağıın eğitimi sırasında ezberlemesini engellemek için kullanılır. Belirlenen oran sayısı kadar nöron kaldırılır ve kaldırılan nöronlar ağıın performansına etki etmez. Genelde 0.2 ve 0.5 arasında dropout değeri kullanılır.


Aktivasyon fonksiyonu, sinir ağlarının sonuna ya da arasına konulan bir düğümdür. Bu düğüm, kendinden önceki katmandan gelen doğrusal yapıyı doğrusal olmayan yapıya çevirmek için kullanılır. Bu durum ağıın elemanlarının kolay türevlenebilir olmasını sağlar. Ağıın hesaplama hızını artırmak için kolay türevlenebilir bir fonsiyon seçimi önemlidir (Gülcü ve Kuş, 2019). En yaygın kullanılan aktivasyon fonksiyonları RELU, Leaky RELU, sigmoid ve tanjant hiperbolik fonksiyonlarıdır.

Optimizasyon fonksiyonu, doğrusal olmayan problemlerin çözümünde optimum değeri bulmak için kullanılan yöntemdir. Stochastic Gradient Descent (SGD), Adam, Adamax, RMSPop, AdaGrad ve Ada delta en yaygın kullanılan algoritmalarındandır.

4. ARAŞTIRMA SONUÇLARI


4.1. Veri Ön İşlemesi

Çalışmada kullanılan tüketim ve hava durumu verileri Meram Elektrik A.Ş. (MEPAŞ) tarafından temin edilmiştir. MEPAŞ' ın faaliyet gösterdiği Konya, Karaman, Niğde, Nevşehir, Aksaray ve Kırşehir illerine ait toplam saatlik tüketim verisi kullanılmıştır. Talep edilen enerji MEPAŞ tarafından alınıp bu merkezden illere dağıtıldığından bu iller için ayrı ayrı tüketim verisi bulunmamaktadır. Tek bir toplam tüketim olduğundan dolayı bu altı il için tüketim tahmini yapılırken hava durumu verisi olarak da Konya seçilerek tek bir ile ait veriler kullanılmıştır. 2016-2021 yıllarına ait saatlik olarak verilen toplam 43104 adet veriden yararlanılmıştır. Şekil 4.1' de bu bölgenin tüketiminin zamana bağlı değişim grafiği gösterilmiştir.



Şekil 4.1. 2016 - 2021 yılları arasındaki yük verileri

Sıcaklık, bağıl nem, rüzgâr hızı, rüzgâr yönü, bulutluluk, radyasyon ve yağış gibi hava durumu verilerine ilaveten özel günler, gün tipi ve geçmiş yük verilerinin tüketim üzerindeki etkisi incelenmiştir. Şekil 4.2' de modele giriş olarak verilen parametreler gösterilmektedir.



Şekil 4.2. Modelin giriş parametreleri

Çalışmada veri ön işleme adımlarından ilki, verilerdeki hatayı en aza düşürmek için eksik ve tekrarlı verilerin giderilmesi olmuştur. Daha sonra zaman parametreleri için her bir özelliğe ait özellik vektörü eklenmiştir. Ayrıca hafta içi günlerinden Pazartesi ve Cuma, hafta sonu günlerinden Cumartesi ve Pazar ayrı ayrı değerlendirilmiş ve bunların her biri için gün tipi parametresi eklenmiştir. Haftanın ilk ve son çalışma günü olan Pazartesi ve Cuma günlerinin tüketim üzerinde değişikliklere neden olduğu gözlemlenmiş ve bu nedenle bu günler iki farklı parametre olarak ayrılmıştır.

Son olarak eğitime başlamadan önce farklı birimdeki veriler arasındaki farkı azaltmak için verilere normalizasyon işlemi uygulanmıştır. Normalizasyon işlemi, modelin verilerdeki değişimleri en doğru şekilde yorumlayabilmesi için kullanılır ve bu da model sonucundaki doğruluğu etkiler. Denklem (4.1)' deki formül kullanılarak veriler 0-1 aralığında ölçeklenmiştir.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4.1)$$


4.2. Özellik Seçimi

Elektrik tüketimi, hava durumu ve mevsimsel etkiler gibi çeşitli dış etkenlere karşı oldukça hassas bir yapıya sahiptir. Bu nedenle kullanılacak giriş parametrelerinin model başarısı üzerindeki etkisi büyüktür. Gereksiz eklenen parametreler ya da eksik olan parametreler modelin doğruluğunu etkileyecektir. Bu olumsuz etkiyi ortadan kaldırmak için model oluşturulmadan önce kullanılacak parametreler üzerinde çeşitli özellik seçim yöntemleri uygulanabilir. Böylelikle modelin en doğru sonuca ulaşması amaçlanmış olur.

Bu çalışmada, özellikler arasındaki ilişkiyi ölçmek için parametreler arasındaki korelasyon katsayıları hesaplanmıştır. Kullanılacak veriler normal dağılıma sahip olduğundan dolayı tüketim ile diğer özellikler arasındaki ilişkiyi ölçmek için Pearson Korelasyon katsayısı kullanılmıştır. Şekil 4.3' de pearson korelasyon sonucunda oluşturulan heatmap gösterilmiştir.

Harita incelendiğinde tüketim ile benzer saatlerin tüketim miktarı, sıcaklık ve bağıl nem arasında yüksek oranda ilişki olduğu gözlemlenmiştir. Yağış ve rüzgâr yönü ile olan ilişki düşük olduğu için modeli olumsuz etkilememesi için bu parametreler modelden çıkarılmıştır. Korelasyon analizi sonucunda, tüketim ile özel günler ve gün tipi arasında düşük ilişki görünse de bunun sebebinin bu günlere ait yeterli veri

olmamasından kaynaklı olduğu yapılan testler sonucunda görülmüştür. Model değerlendirmesi bölümünde özel gün, gün tipi ve benzer gün tüketim değerlerinin model başarımına ne derece etki ettiği detaylı olarak açıklanmıştır.



Şekil 4.3. Özellikler arasındaki ilişki haritası

4.3. Parametre Optimizasyonu

CNN ve derin öğrenme algoritmaları çeşitli parametrelere sahiptir ve bu parametrelerinin her birinin model üzerinde etkisi vardır. Bu parametreler için sabit değerler kullanmak yanlış olacaktır. Bu nedenle de oluşturulan modelin farklı parametreler kullanılarak eğitilmesi ve model üzerindeki etkisinin incelenmesi gerekmektedir.

Çalışmada, öğrenme oranı, mini batch, aktivasyon fonksiyonu ve optimizasyon algoritmaları için çeşitli değerler kullanılarak hiper parametre optimizasyonu yapılmıştır. Çizelge 4.1’ de test edilen parametreler için kullanılan değerler gösterilmiştir. Bu değerler ile yapılan optimizasyon sonucunda model üzerinde kötü

etkisi olan deęerler eęitim sırasında ıkarılmıř ve bařarılı olan deęerler ile devam edilmiřtir.

Ayrıca modeller 50, 100 ve 150 gibi farklı epoch sayıları ile eęitilmiřtir. Eęitim sonucunda epoch sayısını artırmanın bařarımı ok etkilemedięi grlmř ve doęrulama-kayıp (validation-loss) grafięine bakılarak epoch sayısı 30 olarak seilmiřtir.

Yapılan optimizasyon sonucunda genel olarak en bařarılı sonu veren ęrenme oranı, mini batch, aktivasyon fonksiyonu ve optimizasyon algoritması sırasıyla 0.001, 32, tanh ve Adam deęerleri olmuřtur. Farklı modeller ile yapılan karřılařtırmalar bu parametreler kullanılarak yapılmıřtır.

izelge 4.1. Modelde kullanılan hiper parametre listesi


Hiper parametreler	Deęerler
ęrenme Oranı (LR)	0.0001, 0.001, 0.01
Batch Boyutu (BS)	12, 24, 32, 48, 64, 128
Aktivasyon Fonksiyonu (AF)	tanh, sigmoid, Leaky RELU, RELU
Optimizasyon Algoritması	SGD, Adam, RMSprop
Dropout	0.2, 0.5

4.4. Verilerin Blnmesi

Modelde kullanılan veriler zamana baęlı bir deęiřim gsterdięi iin problem bir zaman serisi problemi olarak ele alınmıřtır. Bu nedenle tketim tahmini iin ok deęiřkenli zaman serisi verileri kullanılmıřtır. Modelin farklı veri boyutları ve farklı zaman dilimleri iin doęruluęunu test edebilmek iin verilere apraz doęrulama (cross validation) uygulanmıřtır. Tketim tahmininde gemiř verilere baęlı olarak gelecek tketim tahmini yapılır. Bu da verilerde zamansal baęımlılıęa ve verilerin rastgele bir řekilde seilememesine neden olur. Bu gibi nedenlerden dolayı standart k-fold apraz doęrulamayı zaman serilerinde kullanmak uygun olmayacaktır. Zaman serisi problemlerinde apraz doęrulama iin kullanılan farklı yntemler mevcuttur.

Bu alıřmada zaman serilerine apraz doęrulama uygulamak iin time series cross validation yntemi kullanılmıřtır (Hyndman ve Athanasopoulos, 2021). Bu yntem, tahminin dayandıęı kaynaęın (origin) zamanda ileriye doęru kaymasından dolayı

“Rolling Origin Cross Validation (ROCV)” olarak da bilinmektedir. ROCV’ de amaç gelecek tahmini yapılırken rastgele seçim sırasında gelecekteki gözlemlerin kullanılmasını engellemektir. Bu yöntemi çalışmada kullanabilmek için scikit-learn kütüphanesinden TimeSeriesSplit metodu kullanılmıştır¹. Şekil 4.4’ de ROCV yöntemi ile 5-katlı çapraz doğrulamanın zaman serisi verilerine uygulanmış hali gösterilmektedir. Başlangıçta belli zaman aralığında bir eğitim ve test verisi seçilir. Daha sonra her iterasyonda eğitim verisinin boyutu tüm verileri kapsayana kadar artırılarak farklı boyut ve zaman aralığında veriler elde edilmiş olur. Daha sonra bu eğitim verisinin %30’u ayrılarak doğrulama verisi olarak kullanılmıştır.



Şekil 4.4. Zaman serisi 5-katlı çapraz doğrulama

4.5. Performans Ölçütleri

Modeller eğitildikten sonra model başarısını değerlendirmek için performans ölçütlerinden MSE, RMSE ve MAPE değerleri kullanılmıştır. Bu değerlerin düşük olması modelin tahmin tutarlılığını ve başarısının yüksek olduğunu göstermektedir.

Hata Kareler Ortalaması (Mean Absolute Error-MSE) Denklem (4.2) kullanılarak hesaplanır. Tüm örnekler için kayıpların karesi alındığı için, büyük hataların MSE üzerindeki etkisi fazladır. Bu nedenle aykırı değerler hesaba katılmak istenmiyorsa ve büyük sapmalar varsa bu ölçüm uygun olmayabilir.

¹ https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.TimeSeriesSplit.html
Erişim Tarihi: 06 Mayıs 2021

Hata Kareler Ortalamasının Karekökü (Root Mean Square Error-RMSE) tahmin hatalarının standart sapmasıdır. Denklem (4.3) kullanılarak hesaplanır.

$$MSE = \frac{1}{n} \sum_{j=1}^n e_j^2 \quad (4.2)$$

$$RMSE = \sqrt{\frac{\sum_{j=1}^n e_j^2}{n}} \quad (4.3)$$

Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error-MAPE), modelin hatasını yüzde olarak ifade ettiği için yorumlaması kolay olacağından çok tercih edilen performans ölçütlerindendir ve Denklem (4.4) ile hesaplanır. Gerçek değerler arasında sıfıra yakın değerler varsa MAPE hesaplanamayacağı için tercih edilmez.

$$MAPE = \frac{100}{n} \sum_j^n \frac{|e_j|}{|A_j|} \quad (4.4)$$


Ayrıca Denklem (4.5) ile ifade edilen R-kare değeri ile modelin veriye uyumu incelenmiştir. R-kare, 0 ile 1 arasında değer alır ve bağımsız değişkenlerin bağımlı değişkenleri ne derece açıklayabildiğini gösterir. Değerin 1'e yakın olması modelin verilere uyum sağladığını ve verileri büyük oranda açıklayabileceğini göstermektedir.

$$R^2 = \frac{\text{Sum of Squared Regression}}{\text{Sum of Squared Total}} \quad (4.5)$$

Bu tez çalışmasında, büyük sapmaların ve sıfıra yakın değerlerin performans ölçütleri üzerindeki olumsuz etkisinden dolayı tek bir ölçüt yerine birden fazla ölçüt ile hata oranı hesaplanmış ve modelin doğruluğu bu performansların birlikte yorumlanması ile açıklanmıştır.

4.6. GAF-CNN-GRU Model Mimarisi

Amaçlanan model için Şekil 4.5' de gösterildiği gibi CNN ve GRU algoritmaları kullanılarak paralel hibrit bir yapı oluşturulmuştur. CNN modülü için sırasıyla 16, 32 ve 64'lük filtre boyutu ve 3x3'lük kernel boyutu kullanılarak konvolüsyon katmanı oluşturulmuştur. Modelin aşırı ezberlemesini engellemek için 0.5 oranında dropout katmanı eklenmiştir. GRU modülü için ise 24, 50 ve 30 nörondan oluşan üç farklı GRU katmanı eklenmiştir. Daha sonra bu iki modülün sonuçları birleştirilmiş ve nihai tahmin sonuçları elde edilmiştir.



Şekil 4.5. CNN-GRU mimarisi

CNN' in giriş parametresi olarak kullanılacak görüntüler için GAF metodu kullanılmış ve geçmiş 24 saatlik yük verisi 24x24'lük görüntüye çevrilerek modele verilmiştir. GRU giriş parametreleri için ise benzer gün tüketim verisi, tatil günleri, özel günler, takvim etkisi ve hava durumu verisinden oluşan 20 boyutlu bir vektör kullanılmıştır. Böylelikle, amaçlanan model için tek değişken yerine çok değişkenli bir giriş vektörü kullanılmıştır.

CNN ve GRU modüllerinde kullanılacak aktivasyon fonksiyonu ve dropout parametreleri için hiper parametre optimizasyonu yapılmış ve en başarılı sonuç veren tanh fonksiyonu ve 0.5 dropout oranı kullanılmıştır. Ayrıca hibrit model için kullanılan öğrenme adımı, batch boyutu, epoch sayısı ve optimizasyon algoritmaları için de hiper parametre optimizasyonu yapılmıştır. Bunun için daha önce bahsedilen Çizelge 4.1' deki farklı değerler kullanılmış ve en başarılı sonucu veren parametreler sırasıyla 0.001, 32, 30 ve Adam değerleri olmuştur. İleriki bölümlerde bahsedilen farklı model ve mimarilerin karşılaştırılması bu parametreler kullanılarak yapılmıştır.

4.7. Sonuçların Değerlendirilmesi

Bu bölümde kısa dönem elektrik tüketim tahmini için amaçlanan modelin farklı derin öğrenme algoritmaları ile uygulanması ve bu modellerin sonuçları ele alınmıştır. Ayrıca tahminleme de kullanılan klasik yöntemler ile derin öğrenme algoritmalarının model başarımına etkisini incelemek ve derin öğrenme algoritmalarının tahminler üzerinde daha başarılı olduğunu göstermek için bir karşılaştırma yapılmıştır.

Amaçlanan derin öğrenme algoritmaları ile geliştirilen tahmin modeli, klasik zaman serisi yöntemleri ile karşılaştırılmıştır. Yapılan deneyler sonucunda derin öğrenme metotlarının klasik yöntemlerden daha başarılı tahminler yaptığı görülmüştür. Bu iki yöntemi karşılaştırmak için derin öğrenme algoritmalarından GRU ve klasik zaman serisi yöntemlerinden ARIMAX kullanılmıştır. ARIMA tek değişkenli bir model iken ARIMAX çok değişkenli bir ARIMA türüdür. Çizelge 4.2 'de verilen karşılaştırma sonuçlarına göre ARIMAX %7.10 'luk bir hata oranı ile tahmin yaparken GRU %3.15 hata oranı ile tahminler yapabilmektedir. Bu da klasik yöntemlerin derin öğrenme yöntemlerinden çok daha başarılı olduğunu göstermektedir.

Çizelge 4.2. GRU ve ARIMAX metotlarının karşılaştırılması

Model	MAPE
ARIMAX	% 7.10
2D-CNN-GRU	% 3.15

Amaçlanan model RNN, LSTM ve GRU gibi farklı derin öğrenme algoritmaları kullanılarak karşılaştırılmıştır. Çizelge 4.1' deki hiper parameler bu modellerin eğitiminde kullanılarak ön aşamadan geçirilmiş ve başarısız olan parametreler çıkarılmıştır. Seçilen parametreler ile modeller tekrardan çalıştırılarak her model için en başarılı sonuç veren parametreler aranmıştır. Parametre seçimi için yapılan ön değerlendirmeye göre optimizasyon algoritması olarak kullanılan SGD, Adam ve RMSprop arasından en başarılı sonuç veren algoritma Adam olarak gözlemlenmiş ve diğer tüm eğitimlerde bu optimizasyon yöntemi kullanılmıştır. Çok küçük ve büyük batch boyutundan da modellerin olumsuz etkilendiği gözlemlendiği için batch boyutu 24, 32 ve 64 olarak seçilmiştir. Tüm modeller için en iyi ve en kötü sonucu sağlayan parametreler ve başarı oranları Çizelge 4.3' de gösterilmiştir.

Çizelge 4.3. RNN, LSTM ve GRU modelleri için minimum ve maksimum başarılı parametreler ve başarı oranları


MODEL	MAPE (Min)	LR / BS / AF (Min)	MAPE (Max)	LR / BS / AF (Max)
RNN	%3.48	[0.001, 32, 'tanh']	%27.99	[0.01, 32, 'sigmoid']
LSTM	%3.63	[0.01, 32, 'LeakyRelu']	%51.33	[0.01, 64, 'LeakyRelu']
GRU	%3.15	[0.001, 32, 'tanh']	%28.16	[0.01, 32, 'sigmoid']
1D-GRU	%3.34	[0.001,64, 'sigmoid']	%28.24	[0.01,32, 'tanh']

Amaçlanan modeller test verisinin aylara bölünmesi ile ayrı ayrı hesaplanmıştır ve Çizelge 4.4’ de aylık hata oranları gösterilmiştir. GRU’ nun her ay için en başarılı sonucu veren model olduğu görülmüştür. Bu sonuçlara bakarak GRU modelinin zaman serisinin mevsimsellik problemine daha iyi çözüm getirdiği söylenebilir. RNN ortalama olarak %3.41 hata oranı ile ikinci başarılı algoritma olmuştur. Bu da RNN’ in LSTM’ e göre daha gürbüz bir model olduğunu açıklamaktadır. Ayrıca LSTM’ in uzun vadeli hafıza özelliğinden dolayı geçmiş verilere takılarak mevsimsellik sorununu aşamadığı gözlemlenmiştir.


Çizelge 4.4. Aylık MAPE oranları

Test verisinin aylara göre MAPE oranı			
	RNN	LSTM	GRU
Nisan	3,66	3,54	3,11
Mayıs	5,03	4,51	4,47
Haziran	2,89	3,21	2,64
Temmuz	1,98	2,18	1,97
Ağustos	2,78	2,53	2,46
Eylül	2,72	2,47	2,26
Ekim	2,85	3,31	2,75
Kasım	5,54	6,08	5,2
Aralık	3,74	4,3	3,16
Ocak-2021	3,78	4,04	3,3
Şubat-2021	2,54	3,13	2,61
Ortalama	3,41	3,57	3,08


14.04.2020 ile 14.02.2021 arasındaki tüm test verileri kullanılarak RNN, LSTM ve GRU modelleri ile tahminler yapılmış ve sırasıyla Şekil 4.6, Şekil 4.7 ve Şekil 4.8’de gösterilmiştir. Grafiklere bakılarak özellikle bazı zaman aralıklarında RNN’ in gerçek tüketimden fazla tahminler yaptığı, LSTM’ in ise gerçek değerlere ulaşamadığı görülmektedir. Ancak GRU grafiğine bakıldığında nerdeyse her zaman aralığında gerçek değerlere çok yakın tahminler yaptığı gözlemlenmiştir. Bu da GRU modelinin zaman bağımlılığı ve mevsimsellik sorununu çözmede daha başarılı olduğunu göstermektedir.



Şekil 4.6. RNN modeli gerçek tüketim ve tahmin grafiği



Şekil 4.7. LSTM modeli gerçek tüketim ve tahmin grafiği




Şekil 4.8. GRU modeli gerçek tüketim ve tahmin grafiği

Çizelge 4.5. 01.01.2021 tarihli 24 saatlik tüketim tahmini hata oranları (MAPE)

	RNN	LSTM	GRU
00:00 - 01:00	2,92	1,31	0,22
01:00 - 02:00	3,26	1,69	4,00
02:00 - 03:00	2,51	0,89	2,75
03:00 - 04:00	0,49	1,97	3,44
04:00 - 05:00	0,85	0,55	4,17
05:00 - 06:00	2,69	0,21	10,41
06:00 - 07:00	3,30	2,54	4,40
07:00 - 08:00	9,49	2,23	1,64
08:00 - 09:00	23,46	7,22	5,87
09:00 - 10:00	16,72	15,82	9,17
10:00 - 11:00	14,95	16,44	9,14
11:00 - 12:00	8,59	8,04	3,45
12:00 - 13:00	9,19	9,10	5,27
13:00 - 14:00	5,98	8,57	0,79
14:00 - 15:00	2,20	1,75	2,92
15:00 - 16:00	10,63	10,39	5,38
16:00 - 17:00	6,91	5,35	0,81
17:00 - 18:00	0,39	2,17	3,70
18:00 - 19:00	0,31	2,01	0,04
19:00 - 20:00	7,66	7,90	6,04
20:00 - 21:00	3,62	3,38	1,77
21:00 - 22:00	1,65	2,55	0,56
22:00 - 23:00	4,94	0,48	0,24
23:00 - 24:00	3,26	2,68	3,05
ORTALAMA	6,08	4,80	3,72

Çizelge 4.5 ‘de 1 Ocak tarihi için farklı algoritmalar kullanılarak yapılan 24 saatlik tüketim tahmininin hata oranları verilmiştir. GRU ile yapılan tahmin sonuçlarının daha tutarlı olduğu görülmektedir. 24 saat boyunca en düşük tahmin hatası %0.04 MAPE, en yüksek hata oranı ise %10.41 MAPE olarak hesaplanmıştır.

Şekil 4.9’ da yine bu tarih için yapılan 24 saatlik tahmin sonuçları ve gerçekleşen tüketim verisi grafiği gösterilmiştir. Grafiğe bakıldığında da GRU’ nun gerçek tüketimin trendini daha iyi yakaladığı görülmektedir. Fakat bazı noktalarda GRU ile yapılan tahminlerin, gerçekleşen tüketim grafiğinin altında kaldığı anlaşılmaktadır. Sonuç başarılı görünse de eksik tahminler günlük yaşantımızda olumsuz etkilere sebep olacaktır. Bu nedenle gerçekleşen tüketiminden daha az tahminler yapmamak için bir kontrol koyulması önerilmektedir.



Şekil 4.9. 01.01.2021 tarihli tahmin sonuçları grafiği

Çizelge 4.6. Kullanılan Özniteliklerin 2D-CNN-GRU Model Doğruluğu Üzerindeki Etkisi

Kullanılan Öznitelikler	MAPE
Geçmiş 24 Saatlik Tüketim+ Hava Durumu	%9.2
Geçmiş 24 Saatlik Tüketim+ Hava Durumu+ Özel Günler	%11.34
Geçmiş 24 Saatlik Tüketim+ Hava Durumu+ Benzer Gün Tüketimi	%5.5
Geçmiş 24 Saatlik Tüketim+ Hava Durumu+ Benzer Gün Tüketimi+ Özel Günler	%4.78


Çalışmada giriş parametrelerinin amaçlanan model üzerindeki etkisi incelenmiştir. Çizelge 4.6’ da kullanılan özniteliklerin modelin başarısını hangi oranda etkilediği MAPE kullanılarak hesaplanmıştır. Tabloda görüldüğü gibi sadece tüketim ve hava durumu verileri kullanılarak tahmin yapılabilir. Fakat daha doğru ve güvenilir tahminler yapmak için tüketimi etkileyen diğer öznitelikler göz ardı edilmemelidir. Benzer gün tüketimi ile gelecek saatin tüketimi arasındaki korelasyon hesaplanmış ve aralarında oldukça yüksek bir ilişki olduğu görülmüştür. Buna göre bir gün önceki ve bir hafta önceki günün aynı saatindeki tüketim modele eklenmiş ve tahmin sonucunda %3.7’lik bir iyileşme olduğu görülmüştür. Ayrıca modelin bazı günlerdeki

dengelesizliğini azaltmak ve aşırı ezberlemeyi önlemek için Çizelge 4.7’ de gösterilen özel günler de modele eklenerek modelin başarısı ölçülmüştür. Özel günlerin eklenmesi ile model başarısında %0.72’lik bir artış olmuştur. Böylelikle tüketime etki eden her parametrenin incelenmesinin model sonuçlarını gerçek değere biraz daha yaklaştırabileceği görülmüştür.

Çizelge 4.7. Modele etkisi incelenen gün tipleri, özel günler ve tatiller

Özel Günler
Pazartesi
Cuma
Hafta İçi diğer günler
Cumartesi
Pazar
Yılbaşı
Resmî Tatil
Ramazan Ayı
Ramazan Bayramı
Kurban Bayramı


Bu tez çalışmasındaki en büyük farklılık iki boyutlu CNN modeli kullanılmasıdır. Şekil 4.10 ‘da bir boyutlu ve iki boyutlu CNN kullanılarak oluşturulan 1D-CNN-GRU ve 2D-CNN-GRU modellerinin 14 Şubat 2021 tarihine ait 24 saatlik tahmin grafiği gösterilmiştir.



Şekil 4.10. GRU ile 1D ve 2D CNN kullanılarak yapılan 24 saatlik tahmin sonuçları

Geçmiş tüketim verisinin 2D görüntüye çevrilerek modele verilmesi hata oranını oldukça azaltmıştır. 14.02.2021 tarihi için 24 saatlik tüketim tahmini yapılarak modeller test edilmiştir. 1D-CNN ve 2D-CNN modelleri sonucunda sırasıyla %7.7 ve %2.4 MAPE oranı ile tahminler yapılmıştır. Bu çalışma ile tüketim verisinin bir boyutlu zaman serisi yerine görüntü olarak ele alınmasının saklı özelliklerin çıkarılmasında daha başarılı olduğu ortaya koyulmuştur.

GAF metodu kullanılan fonksiyona göre farklılık göstermektedir. Verileri 2D görüntü olarak adlandırılan gram matrise dönüştürmek için GADF sinüs, GASF ise kosinüs fonksiyonlarını kullanılır. Bu iki metodun model üzerindeki etkisini incelemek için tüketim verisi hem GADF ve hem de GASF yöntemleri ile görüntüye dönüştürülmüştür. Şekil 4.11’ de belli günlere ait 24 saatlik geçmiş tüketim verisinin görüntüye dönüştürülmesi gösterilmiştir.



Şekil 4.11. Bazı zaman serilerinin GADF ve GASF ile görüntüye dönüştürülmesi

GADF ve GASF yöntemlerinin başarıya etkilerini incelemek açısından Çizelge 4.8’ de zaman serisinin bu iki yöntemle görüntüye dönüştürülmesi sonucu modele verilmesiyle elde edilen hata oranları gösterilmektedir.

Çizelge 4.8. GADF ve GASF ile görüntü dönüşümü sonrası GRU model başarı sonuçları

Çalışma Sayısı	GADF	GASF
1.	3,52	3,94
2.	3,60	5,35
3.	3,76	3,81
4.	4,20	3,60
5.	5,52	3,37
6.	4,34	3,51
7.	3,80	3,86
8.	4,80	5,47
9.	3,46	4,24
10.	3,52	4,63
ORTALAMA	4,05	4,18

Noktalar arasındaki trigonometrik fonksiyonların toplam ve farkları hesaplanarak noktalar arasındaki zaman korelasyonu görüş açısından tanımlanmıştır. Bu iki yöntem kullanılarak oluşturulan görüntüler 2D-CNN-GRU modeline giriş parametresi olarak verilmiştir. Model sonucunda bu iki yöntemin başarısı ölçülmüş ve GADF yöntemi ile GASF’ ye göre ortalama %0.13 farkla daha başarılı tahminler elde edilmiştir. Fakat bu iki model arasındaki farkın, modellerin daha fazla tekrar sayısı ile çalıştırılması sonucunda kapanması beklenmektedir. Çünkü, GASF ve GADF’ de kullanılan iki fonksiyon birbirinin tamamlayıcısıdır ve görüntüler birbirinin tersi olacak şekilde çıkmaktadır. Bu da iki yöntemin model üzerindeki başarısında eşitlik sağlayacaktır.

5. SONUÇ ve ÖNERİLER

Enerji sektöründe tüketim tahmin planlaması önemli bir yere sahiptir. Gerçek tüketim değerinden fazla tahmin yapılması gereksiz enerji tüketimine sebep olurken düşük tahminler ise elektrik kesintilerine sebep olacaktır. Bu da firmanın hem maliyetini hem de sağladığı hizmeti olumsuz yönde etkileyecektir. İnsanların günlük yaşantısını devam ettirebilmesi için enerjinin kesintisiz bir şekilde sağlanması gerekmektedir. Bu da yapılan tahminlerin kesin ve güvenilir olmasının ne kadar önemli olduğunu açıklamaktadır.

Tüketim tahmini üzerine literatürde yapılan çalışmalar genel olarak uzun vadeli net enerji tahminleridir. Bu oluşturulan modeller bölgelerin yıllık veya on yıllık gibi uzun dönem elektrik talep tahmini için kullanılmaktadır. Ancak, elektrik tüketim verisinin durağan olmayan özelliğinden dolayı bu tahminlerin doğruluğunun zaman içerisinde değişmesi kaçınılmaz olacaktır. Bu çalışmada kısa dönem saatlik yük tahmini yapılarak tüketimin gerçek zamanlı olarak takip edilmesi amaçlanmıştır. Böylelikle arz-talep dengesizliği en aza indirilecek ve bu dengesizlikten oluşabilecek maliyet sorunları ile kesinti gibi yaşam standartlarını etkileyen olumsuz durumlar minimum seviye düşürülebilecektir.

Bu tez çalışmasında, daha güvenilir sonuçlar için tüketimi etkileyen tüm özelliklerin incelenmesi amaçlanmıştır. Tüketimi etkileyen birçok faktör vardır ve bu faktörlerin bölge üzerindeki etkisi ile bölgedeki elektrik tüketim alışkanlıkları göz ardı edilmemelidir. Sonuç olarak, tahmin modeli oluştururken tüm bu parametreler dikkate alınmalı, her bölge için en uygun model oluşturularak uygun parametreler seçilmelidir. Bu çalışmada İç Anadolu Bölgesi'ndeki belirli iller için tahmin modeli oluşturulması amaçlanmıştır. Bu nedenle bu bölgeye uygun olan hava durumu, iklim koşulları ve takvim etkisi özellikleri seçilmiştir. Seçilen bu özelliklerin de tüketim üzerindeki etkisi Pearson Korelasyon analizi ile incelenmiştir. Sıcaklık, nem, rüzgâr hızı ve yönü, radyasyon, yağış ve bulutluluk gibi hava durumu özelliklerinden tüketimi en çok etkileyen parametre hiç şüphesiz sıcaklık verisi olmuştur. Çünkü tüketim verisini bir zaman serisi olarak ele aldığımızda sezonsallık içerdiğini görebiliriz. Bu nedenle sıcaklık ve tüketim verilerinin aynı zaman aralığında benzer trendi yakalaması kaçınılmaz hale gelmektedir. Ayrıca yapılan testler sonucunda tüketim üzerinde en büyük etkiye sahip bir diğer özelliğin ise benzer gün tüketimi olduğu görülmüştür.

Tüketim verisi bir önceki günün aynı saati ve bir hafta önceki aynı saatteki tüketim verisi ile yüksek oranda bağıllık göstermektedir. Çünkü özellikle aynı mevsim içindeki benzer günlerde ve benzer saatlerde tüketim alışkanlıkları aynı olmaktadır. Yapılan deneyler sonucunda sadece 24 saatlik geçmiş tüketim ve hava durumu verileri ile oluşturulan model sonucu %9.2 iken benzer gün tüketiminin modele eklenmesi ile tahmin sonuçları %3.7 oranında iyileşme göstermiştir. Tahmin sonuçlarının güvenilirliğini artırmak için son olarak model üzerinde özel günlerin etkisi incelenmiştir. Tüketim verisi çok durağan olmayan bir yapıya sahiptir ve ani bir hava durumu değişikliği, bölgede oluşan salgın hastalıklar ve politik olaylar gibi beklenmedik durumlar, bayram ve hafta sonu gibi özel günlerdeki insanların davranışları elektrik tüketiminde hareketliliğe neden olmaktadır. Bu nedenle bu çalışmada bu günlerin model başarımını olumlu yönde etkileyeceği düşünülmüştür. Yapılan testler sonucunda da özel günlerin eklenmesinin model başarısını %0.72 oranında iyileştirdiği gözlemlenmiştir.

Bu tez çalışmasında 2D CNN ve derin öğrenme algoritmaları kullanılarak hibrit bir model önerilmiştir. Tahmin doğruluğunu artırabilmek için geçmiş tüketim verisi iki boyutlu görüntüye dönüştürülerek kullanılmıştır. Çünkü tüketim verisinin gizli kalmış özelliklerinin tek boyutlu zaman serisi yerine görüntü ile daha başarılı bir şekilde çıkarılacağı öngörülmüştür. Çalışma sonucunda yapılan testlerde bunu kanıtlar niteliktedir. Tüketim verisinin 1D-CNN modeline verilmesi ile %7.7 MAPE hesaplanırken 2D-CNN sonucunda bu hata %2.7 MAPE oranına düşmüştür. Bu da amaçlanan tüketim tahmin modeli için oldukça başarılı bir sonuç olmuştur.

Çalışmada derin öğrenme algoritmalarından RNN, LSTM ve GRU kullanılmıştır. Her bir algoritma farklı avantaj ve dezavantaja sahiptir. Bu nedenle probleme uygun algoritma seçilmesi önerilmektedir. Gelecek tahmini yapılırken geçmiş bağımlılıklardan yararlanılmaktadır. RNN, kısa dönem bağımlılıklarında daha başarılı iken LSTM ve GRU uzun dönem bağımlılıklarında daha gülbüz sonuçlar vermektedir. Yapılan testler sonucunda elektrik tüketim tahmini için çok uzun zaman bağımlılıklarının model üzerindeki etkisi her t anı için çok olumlu sonuç vermemiştir. Bu nedenle amaçlanan model sonucunda, tüketim tahmininde çok uzun vadeli geçmiş verilerin kullanılmaması önerilir. LSTM' in hem uzun zaman bağımlılığı hem de karmaşık yapısı tahmin sonuçlarında olumsuz etki oluşturmuştur. RNN ve GRU basit

yapısı ile hem daha güvenilir hem de daha doğru tahminler oluşturabilmek için ideal olmuştur.

İleriki çalışmalarda, elde edilen hata oranının daha da düşürülebilmesi için farklı hibrit metotlar kullanılması amaçlanmıştır. Ayrıca, yapılan tahminlerin gerçekleşen tüketimden az olduğu noktalar için bir çalışma yapılması gerekli görülmüştür. Çünkü eksik yapılan tahminler enerjinin verimli kullanılamamasına sebep olacaktır. Bu da enerji kesintilerine yol açarak günlük yaşantımızı olumsuz etkileyecektir. Hatta sağlık, sanayi, ulaşım gibi enerjinin büyük önem taşıdığı alanlarda çok büyük sorunlara yol açabilmektedir. Bu nedenlerden dolayı belli bir limit hesaplayarak gerçekleşen tahminden çok düşük tahminlerin önüne geçilmesi için çalışmalar yapılması amaçlanmıştır.

Ayrıca, özellikle özel günler ve tatil günlerindeki modelin başarımını artırmak için sentetik veriler üretilerek veri sayısı artırılabilir. Bu günlere ait veriler az olduğu için modelin bu günler için öğrenmesi biraz düşük olabilmektedir ve bu yöntemle bu sorunun aşılabileceği düşünülmektedir. Ayrıca transfer öğrenme (transfer learning) metodu kullanılarak bu az olan veriler için başka veriler ile eğitilerek de özel günlerin tahmin sonuçları iyileştirilebilir. Son olarak bu çalışmada tüm zamanlardaki veriler birlikte eğitilmiş ve tahmin edilmiştir. Veriler gruplandırılarak da eğitim sırasındaki öğrenme başarısının artırılabilceği düşünülmektedir. Yani özel günler, tatil günleri, hafta içi ve hafta sonu tüketim verileri parçalara ayrılır ve her biri kendi içinde eğitilir. Böylelikle, günlerin birbiri üzerindeki olumsuz etkisi bu şekilde ortadan kaldırılabilir.

6. KAYNAKÇA

- Akarslan, E. ve Hocaoglu, F. O. (2018). A novel short-term load forecasting approach using Adaptive Neuro-Fuzzy Inference System. *Proceedings - 2018 6th International Istanbul Smart Grids and Cities Congress and Fair, ICSG 2018* içinde (ss. 160–163). Institute of Electrical and Electronics Engineers Inc. doi:10.1109/SGCF.2018.8408964
- Akman, T., Yılmaz, C. ve Sönmez, Y. (2018). Elektrik Yüğü Tahmin Yöntemlerinin Analizi. *Gazi Mühendislik Bilimleri Dergisi*, 4(3), 168–175. doi:10.30855/GJES.2018.04.03.003
- Altunkaya, D. ve Yılmaz, B. (2020). Multivariate Short-term Load Forecasting Using Deep Learning Algorithms. *The Eurasia Proceedings of Science, Technology, Engineering & Mathematics (EPSTEM)*, 11, 14–19.
- Başoğlu, B. ve Bulut, M. (2017). Kısa dönem elektrik talep tahminleri için yapay sinir ağları ve uzman sistemler tabanlı hibrit sistem geliştirilmesi. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32(2), 575–583. doi:10.17341/gazimmfd.322184
- Biçer, A. (2018). *ENERJİ TALEP TAHMİNİNE YÖNELİK PROGRAM GELİŞTİRME VE BİR BÖLGE İÇİN UYGULAMASI*.
- Bouktif, S., Fiaz, A., Ouni, A. ve Serhani, M. A. (2020). Multi-Sequence LSTM-RNN Deep Learning and Metaheuristics for Electric Load Forecasting. *Energies*, 13(2), 391. doi:10.3390/en13020391
- Bozkurt, O. O., Tayşi, Z. C. ve Biricik, G. (2015). Türkiye Elektrik Piyasası için Yüğü Tahmin Sistemi. *2015 23rd Signal Processing and Communications Applications Conference, SIU 2015 - Proceedings* içinde (ss. 569–572). Institute of Electrical and Electronics Engineers Inc. doi:10.1109/SIU.2015.7129888
- Centra, M. (2011). Hourly electricity load forecasting: An empirical application to the Italian railways. *World Academy of Science, Engineering and Technology*, 80, 1026–1033.
- Ceylan, G. (2004). *YAPAY SİNİR AĞLARI İLE KISA DÖNEM YÜĞ TAHMİNİ*.
- Cho, K., Van Merriënboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H. ve Bengio, Y. (2014). *Learning Phrase Representations using RNN Encoder-Decoder for Statistical Machine Translation*.
- Choi, H., Ryu, S. ve Kim, H. (2018). Short-Term Load Forecasting based on ResNet and LSTM. *2018 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids, SmartGridComm 2018* içinde . Institute of Electrical and Electronics Engineers Inc. doi:10.1109/SmartGridComm.2018.8587554
- El-Hendawi, M. ve Wang, Z. (2020). An ensemble method of full wavelet packet transform and neural network for short term electrical load forecasting. *Electric Power Systems Research*, 182(February), 106265. doi:10.1016/j.epsr.2020.106265
- Esener, İ. I., Yüksel, T. ve Kurban, M. (2012). Sıcaklık Verisi Olmadan Kısa Dönem

Yük Tahmini İçin Yapay Zeka Tabanlı Melez Yapılar. *ELECO '2012 Elektrik - Elektronik ve Bilgisayar Mühendisliği Sempozyumu* içinde .

- Estebarsari, A. ve Rajabi, R. (2020). Single Residential Load Forecasting Using Deep Learning and Image Encoding Techniques. *Electronics*, 9(1), 68. doi:10.3390/electronics9010068
- Gülcü, A. ve Kuş, Z. (2019). A Survey of Hyper-parameter Optimization Methods in Convolutional Neural Networks. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7(2), 503–522. doi:10.29109/gujsc.514483
- Haliloğlu, E. Y. ve Tutu, Y. (2018). *TÜRKİYE İÇİN KISA VADELİ ELEKTRİK ENERJİSİ TALEP TAHMİNİ*. *Journal of Yasar University* (C. 13).
- He, W. (2017). Load Forecasting via Deep Neural Networks. *Procedia Computer Science* içinde (C. 122, ss. 308–314). Elsevier B.V. doi:10.1016/j.procs.2017.11.374
- Hocaoğlu, F. O., Kaysal, K. ve Kaysal, A. (2015). Hybrid Model for Load Forecasting (ANN and Regression). *Academic Platform Journal of Engineering and Science*, 3(2), 33–39. doi:10.5505/apjes.2015.94695
- Hochreiter, S. ve Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735–1780. doi:10.1162/neco.1997.9.8.1735
- Hyndman, R. J. ve Athanasopoulos, G. (2021). *Forecasting: Principles and Practice* (3. bs.). Melbourne, Australia. <https://otexts.com/fpp3/> adresinden erişildi.
- Jiang, P., Li, R., Liu, N. ve Gao, Y. (2020). A novel composite electricity demand forecasting framework by data processing and optimized support vector machine. *Applied Energy*, 260, 114243. doi:10.1016/j.apenergy.2019.114243
- Jiang, Q., Zhu, J. X., Li, M. ve Qing, H. Y. (2018). Electricity Power Load Forecast via Long Short-Term Memory Recurrent Neural Networks. *Proceedings - 2018 4th Annual International Conference on Network and Information Systems for Computers, ICNISC 2018* içinde (ss. 265–268). Institute of Electrical and Electronics Engineers Inc. doi:10.1109/ICNISC.2018.00060
- Lv, P., Liu, S., Yu, W., Zheng, S. ve Lv, J. (2020). EGA-STLF: A Hybrid Short-Term Load Forecasting Model. *IEEE Access*, 8, 31742–31752. doi:10.1109/ACCESS.2020.2973350
- Mbae, A. M. ve Nwulu, N. I. (2020). Day-ahead load forecasting using improved grey Verhulst model. *Journal of Engineering, Design and Technology*. doi:10.1108/JEDT-12-2019-0337
- N, S., Yelamali, A. ve Byahatti, K. (2010). Electricity short term load forecasting using Elman recurrent neural network. *2010 International Conference on Advances in Recent Technologies in Communication and Computing* içinde (ss. 351–354). doi:10.1109/ARTCom.2010.44
- Özen, M. ve Gül, Ö. (2015). ELEKTRİK DAĞITIM ŞEBEKELERİNDE TALEP TAHMİNİ. *IV. ELEKTRİK TESİSAT ULUSAL KONGRE VE SERGİSİ* içinde .
- Şeker, A. (2017). *DERİN ÖĞRENME YÖNTEMLERİ VE UYGULAMALARI HAKKINDA BİR İNCELEME*. *Gazi Mühendislik Bilimleri Dergisi*.

- Sertkaya, M. E. (2018). *DERİN ÖĞRENME TEKNİKLERİNİN BİYOMEDİKAL İMGELER ÜZERİNE UYGULAMALARI*. Fırat Üniversitesi.
- Toker, A. C. ve Korkmaz, O. (2011). *TÜRKİYE KISA SÜRELİ ELEKTRİK TALEBİNİN SAATLİK OLARAK TAHMİN EDİLMESİ*.
- Tokgöz, A. ve Ünal, G. (2018). A RNN based time series approach for forecasting turkish electricity load. *26th IEEE Signal Processing and Communications Applications Conference, SIU 2018* içinde (ss. 1–4). doi:10.1109/SIU.2018.8404313
- Topalli, A. K. ve Erkmen, I. (2003). A hybrid learning for neural networks applied to short term load forecasting. *Neurocomputing*, 51, 495–500. doi:10.1016/S0925-2312(02)00870-6
- Topalli, A. K., Erkmen, I. ve Topalli, I. (2006). Intelligent short-term load forecasting in Turkey. *International Journal of Electrical Power and Energy Systems*, 28(7), 437–447. doi:10.1016/j.ijepes.2006.02.004
- Wang, Z. ve Oates, T. (2015). *Encoding Time Series as Images for Visual Inspection and Classification Using Tiled Convolutional Neural Networks*. www.aiai.org adresinden erişildi.
- Wu, L., Kong, C., Hao, X., Chen, W. ve Chen, C.-H. (2020). A Short-Term Load Forecasting Method Based on GRU-CNN Hybrid Neural Network Model. doi:10.1155/2020/1428104
- Xu, Q., Yang, X. ve Huang, X. (2020). Ensemble Residual Networks for Short-Term Load Forecasting. *IEEE Access*, 8, 64750–64759. doi:10.1109/ACCESS.2020.2984722
- Zhang, J., Wei, Y. M., Li, D., Tan, Z. ve Zhou, J. (2018). Short term electricity load forecasting using a hybrid model. *Energy*, 158, 774–781. doi:10.1016/j.energy.2018.06.012

ÖZGEÇMİŞ

Adı ve Soyadı: D***u A*****A

Doğum Tarihi ve Yeri: 2*.0*.1**3 – Aksaray

E – posta: d*****a@gmail.com

Eğitim Bilgileri:

2018-2021	: Konya Gıda ve Tarım Üniversitesi
(Yüksek Lisans)	Bilgisayar Mühendisliği (3.88 / 4.00)
2012-2017	: Selçuk Üniversitesi
(Lisans)	Bilgisayar Mühendisliği (3.01 / 4.00)

Konferans, Bildiri ve Makaleler:

D. A*****a ve B. Y*****z , "Multivariate Short-term Load Forecasting Using Deep Learning Algorithms", *The Eurasia Proceedings of Science Technology Engineering and Mathematics*, c. 11, ss. 14-19, Ara. 2020

İş Tecrübeleri:

03.2020 – (Devam Ediyor):	: Araştırma Görevlisi Konya Gıda ve Tarım Üniversitesi Bilgisayar Mühendisliği
06.2019 – 03.2020	: Yazılım Mühendisi Meram Elektrik Perakende A.Ş. - MEPAŞ