

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

MİKRO ŞEBEKELER İÇİN DERİN ÖĞRENME KULLANILARAK PASİF
ADA ÇALIŞMA TESPİT YÖNTEMİ GELİŞTİRİLMESİ

Asiye KAYMAZ ÖZCANLI

DOKTORA TEZİ
Elektrik Mühendisliği Anabilim Dalı
Elektrik Tesisleri Programı

Danışman
Dr. Öğretim Üyesi MUSTAFA BAYSAL

Aralık, 2021

T.C.
YILDIZ TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

**MİKRO ŞEBEKELER İÇİN DERİN ÖĞRENME KULLANILARAK PASİF
ADA ÇALIŞMA TESPİT YÖNTEMİ GELİŞTİRİLMESİ**

Asiye KAYMAZ ÖZCANLI tarafından hazırlanan tez çalışması 30.12.2021 tarihinde aşağıdaki jüri tarafından Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü Elektrik Mühendisliği Anabilim Dalı, Elektrik Tesisleri Programı **DOKTORA TEZİ** olarak kabul edilmiştir.

Dr. Öğretim Üyesi Mustafa BAYSAL
Yıldız Teknik Üniversitesi
Danışman

Jüri Üyeleri

Dr. Öğretim Üyesi Mustafa BAYSAL, Danışman
Yıldız Teknik Üniversitesi

Prof. Dr. Uğur Savaş SELAMOĞULLARI, Üye
Yıldız Teknik Üniversitesi

Dr. Öğretim Üyesi Abdulfetah Abdela SHOBOLE , Üye
İstanbul Sabahattin Zaim Üniversitesi

Dr. Öğretim Üyesi Bedri KEKEZOĞLU
Yıldız Teknik Üniversitesi

Dr. Öğretim Üyesi Mohammed VADİ, Üye
İstanbul Sabahattin Zaim Üniversitesi

Danışmanım Öğrt. Üyesi Dr. Mustafa BAYSAL sorumluluğunda tarafımda hazırlanan Mikro Şebekeler için Derin Öğrenme Kullanılarak Pasif Ada Çalışma Tespit Yöntemi Geliştirilmesi başlıklı çalışmada veri toplama ve veri kullanımında gerekli yasal izinleri aldığımı, diğer kaynaklardan aldığım bilgileri ana metin ve referanslarda eksiksiz gösterdiğimi, araştırma verilerine ve sonuçlarına ilişkin çarpıtma ve/veya sahtecilik yapmadığımı, çalışmam süresince bilimsel araştırma ve etik ilkelerine uygun davrandığımı beyan ederim. Beyanımın aksinin ispatı halinde her türlü yasal sonucu kabul ederim.

Asiye KAYMAZ ÖZCANLI

İmza

Bu alıřma, “2211-C Öncelikli Alanlar Burs Programı” kapsamında Türkiye Bilimsel ve Teknolojik Arařtırma Kurumu (TÜBİTAK) tarafından desteklenmiřtir,

Aileme

ve

çocuklarıma

TEŞEKKÜR

Doktora eğitimimde akademik danışmanlığımı yürüten, tez dönemim süresince bilgi ve fikirlerini esirgemedi paylaşan değerli hocam Dr. Öğretim Üyesi Mustafa Baysal'a katkılarından ötürü teşekkürlerimi sunarım. Tez izleme süresince yapıcı eleştirileri, yönlendirmeleri ile yol gösteren değerli tez izleme komitesi üyeleri Prof. Dr. Uğur Savaş Selamoğulları ve Dr. Öğretim Üyesi Abdulfetah Abdela SHOBOL hocalarıma içtenlikle teşekkür ederim. İlkokuldan bugüne kadar eğitime katkıda bulunmuş tüm hocalarıma emeklerinden ötürü teşekkür ederim.

Beni bugünlere getiren canım anneme ve babama, her zaman yol gösteren ablama, sevgili abilerime ayrıca teşekkür ederim. Doktoram sırasında desteğini esirgemeyen değerli eşime, oğullarım Ömer Selim ve Salih Emre'ye en derin sevgilerim ve şükranlarımı sunarım, iyi ki varsınız.

Bu tez çalışması sırasında "2211-C Öncelikli Alanlar Bursu" ile tezime destek veren Türkiye Bilimsel ve Teknolojik Araştırma Kurumu'na (TÜBİTAK) ve diğer tüm çalışma arkadaşlarıma teşekkürlerimi sunarım.

Asiye KAYMAZ ÖZCANLI

İÇİNDEKİLER

SİMGE LİSTESİ	viii
KISALTMA LİSTESİ	ix
ŞEKİL LİSTESİ	x
TABLO LİSTESİ	xii
ÖZET	xiii
ABSTRACT	xv
1 GİRİŞ	1
1.1 Literatür Özeti.....	1
1.2 Tezin Amacı	6
1.3 Hipotez	7
2 MİKRO ŞEBEKELERDE ADA ÇALIŞMA	9
2.1 Mikro Şebekeler	9
2.2 Mikro Şebekelerde Ada Çalışma	11
2.3 Mikro Şebekelerde Ada Çalışma Tespit Yöntemleri	16
2.3.1 İletişime Bağlı Yöntemler (Merkezi Kontrol)	15
2.3.2 Yerel Yöntemler	15
3 DERİN ÖĞRENME	19
3.1 Giriş	19
3.2 Makine Öğrenmesi	21
3.3 Yapay Sinir Ağları	22
3.4 Derin Öğrenme	23
3.4.1 Evrişimsel Sinir Ağları (CNN)	25
3.4.2 Uzun Kısa Bellek Ağları (LSTM)	27
3.4.3 Tek Boyutlu CNN and LSTM Ağlarının Kombine Edilmesi	28
3.5 Güç Sistemlerinde Derin Öğrenme Uygulamaları	29
4 MİKRO ŞEBEKE TOPOLOJİSİ	33
4.1 AEP/CERTS Mikro Şebeke Modeli.....	33
4.2 Mikro Şebekeye Senkron ve İnverter Kaynaklı Dağıtık Üretimlerin Eklenmesi Durumu.....	35
5 ADA ÇALIŞMA TESPİT YÖNTEMLERİNİN METODOLOJİSİ	36
5.1 Giriş	36
5.2 Giriş Parametrelerinin Belirlenmesi.....	37

5.3 Önerilen Yöntemler İçin Elde Edilen Veri Setleri	40
5.4 Önerilen AÇT Metotları için İzlenen Adımlar	43
5.4.1 Ada Çalışma Tespiti İçin Önerilen LSTM Metodu.....	45
5.4.2 Ada Çalışma Tespiti için Önerilen 1D CNN Metodu	45
5.4.3 Ada Çalışma Tespiti İçin Önerilen 1D CNN-LSTM Metodu.....	42
5.5 Ada Çalışma Tespitinde Önerilen Metotlar için Kullanılan Performans Metrikleri	48
6 SİMÜLASYON SONUÇLARI	50
6.1 AÇT Metotlarında Kullanılan Parametrelerin Belirlenmesi	50
6.1.1 Eğitim ve Test Oranının Belirlenmesi.....	50
6.1.2 Veri İzleme Süresinin Belirlenmesi	51
6.1.3 Toplam Veri Sayısının Doğruluğa Etkisi.....	53
6.2 LSTM Yöntemine Dayalı Ada Çalışma Tespitinin Sonuçları	54
6.3 1D-CNN ve CNN-LSTM'e Dayalı Ada Çalışma Tespit Yöntemlerinin Sonuçları.....	56
6.4 Algılama Dışı Bölge (NDZ) Analizi	58
6.5 Mikro Şebekenin Genişletilmesi	60
6.6 Ada Çalışma Performansının Literatürdeki Benzer Çalışmalar ile Karşılaştırılması.....	61
7 SONUÇLAR VE ÖNERİLER	64
KAYNAKÇA	67
TEZDEN ÜRETİLMİŞ YAYINLAR	73

SİMGE LİSTESİ

I	Ada çalışma
NI	Ada olmayan çalışma
W	Ağırlık matrisi
ΔP	Aktif güç değişimi
$x_o^l, f(.)$	Aktivasyon fonksiyonu
b	Bias vektörü
$\odot$	Çarpım elemanı
o_t	Çıkış kapısı katmanı
$x_{o,fl}^l$	Evrişimsel katmanın çıkışı
C_{t-1}	Geçmiş hücre durumu
V_3	Gerilimim 3. tekil harmoniği
i_t	Giriş kapısı katmanı
h_t	Gizli katmanın çıkışı
C	Hafıza hücresi
C_t	Hücre durumu
L	Kayıp fonksiyonu değeri
d	Öğrenme parametresi
ΔQ	Reaktif güç değişimi
σ	Sigmoid fonksiyonu
x_t	t. zaman giriş vektörü
THD_i	Toplam akım harmoniği
THD_v	Toplam gerilim harmoniği
f_t	Unut kapısı katmanı

KISALTMA LİSTESİ

AÇT	Ada Çalışma Tespiti
CNN	Evrişimsel Sinir Ağı (Convolutional Neural Network)
DSA	Derin Sinir Ağları
DT	Karar Ağacı
DÜ	Dağıtık Üretim
DVM	Destek Vektör Makineleri
ELM	Aşırı Öğrenme Makinesi (Extreme Learning Machine)
FCL	Tam Bağlantılı Katman
FN	Yanlış Negatif (False Negative)
FN	Yanlış Pozitif (False Positive)
GPU	Merkezi İşlem Birimi (Central Processing Unit)
IEEE	The Institute of Electrical and Electronics Engineers
KNN	K en yakın komşu
LSTM	Uzun-Kısa Süreli Bellek Ağları (Long Short Term Memory)
MLP	Çok katmanlı yapay sinir ağları (Multi-Layer Perceptron)
OBN	Ortak Bağlantı Noktası
ÖSA	Özyinelemeli Sinir Ağları (Recurrent Neural Networks-RNN)
PCA	Temeş Bileşen Analizi
Relu	Düzleştirilmiş Doğrusal Birim Katmanı
SAE	Yığılmış Otokodlayıcılar (Stacked Autoencoder)
SGD	Stokastik Gradyan İniş (Stochastic Gradient Descent)
TN	Doğru Negatif (True Negative)
TP	Doğru Pozitif (True Positive)
YSA	Yapay Sinir Ağları (Artificial Neural Networks-ANN)

ŞEKİL LİSTESİ

Şekil 2.1 Mikro şebeke konsepti.....	10
Şekil 2.2 Dünya pazarında bölgelere göre planlanan yıllık mikro şebeke güç kapasitesi ve pazar harcamaları	11
Şekil 2.3 Yerel ada çalışma tespit yöntemlerinin geçmişten günümüze hiyerarşisi	14
Şekil 2.4 Mikro şebekede ada çalışma durumu	14
Şekil 2.5 Ada çalışma tespit yöntemleri	16
Şekil 3.1 Yapay zeka ve alt bölümleri	20
Şekil 3.2 Derin Öğrenme başlığı altında yayınlanan makale sayısının yıllara göre değişimi	20
Şekil 3.3 Yapay sinir ağı modeli.....	22
Şekil 3.4 Derin öğrenmenin temelleri	25
Şekil 3.5 Tek boyutlu konvolüsyonel ağların yapısı.....	26
Şekil 3.6 LSTM mimarisi ve iç yapısı.....	28
Şekil 3.7 Tek boyutlu evrimsel ağların yapısı	29
Şekil 3.8 Derin öğrenme algoritmalarının farklı yaklaşımlarla kombinasyonu	30
Şekil 4.1 AEP/CERTS Mikro şebeke tek hat diyagramı	33
Şekil 4.2 Modifiye edilmiş AEP/CERTS mikro şebeke tek hat diyagramı.....	34
Şekil 4.3 AEP/CERTS Mikro şebekede ilave kaynakların eklenmesi durumu ...	35
Şekil 5.1 Önerilen LSTM ada çalışma tespit yönteminin işlem aşamaları	37
Şekil 5.2 AEP/CERTS sistemi için gerilim harmonikleri	38
Şekil 5.3 AEP/CERTS sistemi için akım harmonikleri	38
Şekil 5.4 a)Tek LSTM ile oluşturulan ağ modeli, b)İki LSTM ile oluşturulan ağ modeli, c)iki LSTM ve seyreltme katmanı	44
Şekil 5.5 Ada çalışma tespiti için önerilen 1D CNN mimarisi	45
Şekil 5.6 Ada çalışma tespiti için önerilen 1D CNN-LSTM mimarisi	46
Şekil 5.7 Üç farklı sinir ağının ada çalışma tespitindeki akış diyagramı	47
Şekil 6.1 Farklı eğitim ve test oranlarına göre LSTM algoritmasının gösterdiği doğruluk değerleri	51
Şekil 6.2 Farklı giriş parametreleri ve farklı eğitim test oranlarının LSTM yöntemi ile karşılaştırılması	51
Şekil 6.3 Verilerin kayıt edilmesi ve ada çalışma tespit aşaması.....	52

Şekil 6.4 Örnekleme sürelerinin performansa etkisi.....	53
Şekil 6.5 Ada ve Ada olmayan çalışma durumları için üç ve on farklı girişli örneklerin LSTM ve geleneksel makine öğrenmesi yöntemleri ile karşılaştırılması.....	55
Şekil 6.6 Ada çalışma tespit için farklı giriş kombinasyonlarının doğruluğua etkisi	55
Şekil 6.7 Önerilen sinir ağlarının doğruluk ve kayıp eğrileri	57
Şekil 6.8 Üç farklı AÇT modelinin doğruluk açısından karşılaştırılması	57
Şekil 6.9 AÇT ile algılanamayan bölge (NDZ).....	57
Şekil 6.10 CNN-LSTM modelinin 200 farklı çalışma bölgesi için gösterdiği performans	57
Şekil 6.11 Üç farklı AÇT modelinin doğruluk açısından karşılaştırılması	61

TABLO LİSTESİ

Tablo 2.1	Yerel AÇT'ler için önerilen farklı seviyelerdeki sistem bileşenleri	13
Tablo 2.2	Ada tespit standartları.....	16
Tablo 3.1	Güç sistemlerinde derin öğrenmenin kullanımı.....	31
Tablo 4.1	Ada çalışma tespitinde kullanılan mikro şebekenin elektriksel parametreleri	34
Tablo 5.1	Giriş Değişkenlerinin farklı kombinasyonları ile LSTM yönteminin gösterdiği doğruluk değerleri	39
Tablo 5.2	Giriş parametrelerine göre AÇT yönteminde elde edilen performansların karşılaştırılması.....	40
Tablo 5.3	Ada çalışma tespitinde kullanılan veri seti senaryoları	42
Tablo 5.4	Seçilen çoklu-LSTM modeli için ağı eğitilmesinde kullanılan parametreler	44
Tablo 5.5	Kullanılan üç farklı modelin sinir ağı parametreleri	47
Tablo 5.6	Ada çalışma tespiti için kullanılan konfüzyon matrisi.....	48
Tablo 6.1	Farklı izleme sürelerine göre LSTM modelinin performansı	52
Tablo 6.2	LSTM ve karar ağacı için farklı örnek sayıları ile yapılan eğitimlerde performans sonuçları	54
Tablo 6.3	CNN, LSTM and CNN-LSTM modellerinin konfüzyon matrisleri	56
Tablo 6.4	Elde edilen en iyi sonuçların farklı performans matrisleri ile modellerin karşılaştırılması.....	58
Tablo 6.5	Elde edilen en kötü sonuçların farklı performans matrisleri ile modellerin karşılaştırılması.....	58
Tablo 6.6	Üç farklı AÇT modelinin 200 çalışma bölgesindeki performanslarının karşılaştırılması.....	60
Tablo 6.7	Farklı çalışma modlarına göre üretilen olay sayıları.....	61
Tablo 6.8	Önerilen yöntemlerin literatürdeki benzer çalışmalar ile karşılaştırılması.....	62

Mikro Şebekeler için Derin Öğrenme Kullanılarak Pasif Ada Çalışma Tespit Yöntemi Geliştirilmesi

Asiye KAYMAZ ÖZCANLI

Elektrik Mühendisliği Anabilim Dalı

Doktora Tezi

Tez Danışmanı: Dr. Öğretim Üyesi Mustafa BAYSAL

Mikro şebekeler fotovoltaik, rüzgar ve hidroelektrik enerji gibi başta yenilenebilir enerji kaynakları olmak üzere dağıtık üretim birimlerinin dağıtım şebekesine entegrasyonunu sağlayarak şebekeye bağlı veya ada modunda çalışabilen geleceğin enerji sisteminin önemli bir parçasını oluşturmaktadır. Mikro şebekenin işletilmesinde karşılaşılan zorluklardan biri ana şebekede meydana gelen arıza sonucu oluşan istenmeyen ada çalışma durumunun sonucu olarak gerilim ve frekansta kabul edilmeyen seviyelerin meydana gelmesi, kişilerin can ve mal güvenliği ile bağlı olduğu yüklerin zarar görmesidir. Bu durumu önlemek için ada çalışma tespiti yapılmakta ve dağıtık üretimler şebekeden izole edilmektedir. Literatürdeki çalışmaların büyük çoğunluğu dağıtık üretim seviyesinde olup, mevcut konvansiyonel ada tespit yöntemleri ihtiyacı karşılamamaktadır. Bu tez çalışmasında derin öğrenmeye bağlı algoritmalarından uzun kısa süreli bellek ağları (LSTM) ve tek boyutlu evrimsel ağlar (1D CNN) ada çalışmanın tespitinde kullanılmıştır. Veri setindeki özelliklerin daha etkin bir şekilde ortaya çıkarılması amacıyla iki ağın güçlü özelliklerinden yararlanılarak 1D CNN-LSTM yöntemleri birleştirilmiştir. Önerilen yöntemlerde mikro

şebekenin ortak bağlantı noktasında ölçümü yapılan gerilim, akım ve harmonik verileri kullanılmıştır. Önerilen yöntemin testi MATLAB/Simulink platformunda kurulan mikro şebeke sistemi üzerinde yaklaşık 4000'e yakın ada olayları (küçük ve büyük çapta aktif ve reaktif güç değişimi) ve ada olmayan şebeke olayları (arızalar ve kapasitör, doğrusal olmayan yükler, motor yükü, dağıtık üretimler gibi çeşitli anahtarlama) dikkate alınarak gerçekleştirilmiştir. Literatürdeki çalışmalardan farklı olarak şebekenin harmonikli olması durumu ilk kez bu çalışmada dikkate alınmıştır. Önerilen ada çalışma tespit yöntemlerinin performansı doğruluk, kayıp, duyarlık, kesinlik, F1 skor gibi farklı performans metrikleri kullanılarak farklı açılardan karşılaştırılmış ve değerlendirilmiştir. Önerilen yöntemler daha önce görülmeyen düşük algılama dışı bölge (NDZ)'ye sahip durumlarla ve mikro şebekeye ilave dağıtık üretimlerin eklenmesi durumunda oluşturulan senaryolarla test edilmiştir. Elde edilen sonuçlara göre uygulaması basit, yüksek doğrulukta, düşük NDZ'ye sahip, yüksek hızda ada çalışmayı tespit edebilen yöntemler ortaya konmuştur.

Anahtar Kelimeler: Ada çalışma tespit yöntemi, derin öğrenme, CNN, LSTM, mikroşebeke

Development of Passive Islanding Detection Method Based on Deep Learning for Microgrids

Asiye KAYMAZ ÖZCANLI

Department of Electrical Engineering

Doctor of Philosophy Thesis

Supervisor: Assist. Prof. Dr. Mustafa BAYSAL

Microgrid is an important part of the future energy system, which can operate in either grid connected or islanding mode, enabling the increasing integration of distributed generation units such as photovoltaic energy, wind energy and hydroelectric energy into the distribution grid. One of the major problems in the operation of the microgrid is unintentional islanding which can threat to the safety of the utility personnel, distributed generations and loads. In order to prevent this situation, islanding condition should be detected and microgrid should be isolated from the main grid. The most of the literature studies are proposed for inverter or multi-inverter based distributed generation and the existing conventional islanding detection methods (IDMs) are not suitable for microgrids. In this thesis, long-short-term memory network (LSTM) and one-dimensional convolutional network (1D-CNN) based on deep learning are proposed for islanding detection by utilizing voltage and current measured at the point of common coupling (PCC) of microgrid. 1D-CNN and LSTM are combined to extract data features more effectively by utilizing the strengths of both networks. About 4000 cases under the microgrid model are simulated on

MATLAB/Simulink platform to evaluate the performance of the proposed architectures. For the first time, the distorted main grid is taken into account with various islanding and nonislanding operating conditions such as capacitor switching, nonlinear load switching, motor switching, faults. To further investigate the validity of deep learning algorithms, a comprehensive analysis is carried out with performance metrics such as accuracy, loss, sensitivity, dependability and F1-measure. Furthermore, the robustness of the proposed methods is demonstrated with unseen samples under low none detection zone (NDZ) and the expansion of microgrid topology. According to the results, the proposed methods are presented effective islanding detection methods in the terms of high accuracy, low detection time, simple implementation, approximately zero NDZ.

Keywords: CNN, deep learning, islanding detection, LSTM, microgrid

1.1 Literatür Özeti

Günümüzde rüzgar, termal ve güneş gibi dağıtık üretim (DÜ) birimlerinin kurulması, depolama sistemlerinin entegrasyonu ve elektrikli araçlar için şarj istasyonlarının devreye alınması gibi yenilikler dağıtım seviyesinde önemli bir değişikliğe neden olmuştur [1]. Bu değişim güç sisteminde enerji etkinliğinin artması, hat kayıplarının azalması ve güç kalitesinin iyileşmesi gibi önemli avantajları beraberinde getirmiştir. Bununla birlikte ortaya çıkan bu yeni enerji sistemi oldukça karmaşık bir yapıya sahiptir ve mevcut kontrol, koruma sistemleri ihtiyacı karşılamakta yetersiz kalmaktadır. Sonuç olarak elektriğin güçlü, güvenilir, esnek kullanımı, minimum maliyet ile maksimum enerji sağlanabilmesi için yeni yaklaşımlara ihtiyaç duyulmuştur [2],[3]. Akıllı şebekeler bu noktada yeni nesil bilgisayar, bilgi, güç elektroniği, iletişim gibi teknolojileri kullanarak güç sisteminin kontrol, koruma ve işletilmesini sağlayan yakın geleceğin modern güç sistemleri olarak öngörülmektedir. Mikro şebekeler ise küçük çapta dağıtık üretim kaynaklarının şebekeye entegrasyonunu sağlaması, aynı zamanda yerel yükleri doğrudan besleyebilmesi sayesinde akıllı şebekelerin dağıtım seviyesinde önemli bir yapı taşı oluşturmaktadır. Mikro şebekeler dağıtım şebekesi ile paralel olarak çalışabilirken aynı zamanda ikincil bir güç sistemi gibi şebekeden izole edilerek ada modunda çalışabilir ve yerel yükleri beslemeye devam edebilir. Böylece, mikro şebekeler ortak bağlantı noktasının (OBN) her iki tarafında herhangi bir güç kalitesi olayı olması durumunda kendisini korumaya alarak güvenilirliği artırır [4].

Mikro şebekelerin çözülmesi gereken en önemli sorunlarından biri istenmeyen ada çalışma durumudur. Ana şebekede herhangi bir sebeple meydana gelen bir bozulma durumunda dağıtık üretim tarafına enerji akışı kesilebilir fakat mikroşebeke tarafındaki üretimin devam etmesi sebebiyle sistem enerjili kalmaya devam eder. Böyle bir durumda mikro şebekeye bağlı bulunan üretim ve tüketim

kaynaklarının zarar görmesi, çalışan personelin can güvenliği gibi olumsuz durumlar durumu söz konusudur. Şebekede meydana gelen herhangi bir gerilim ve frekans değerinin kabul edilen sınırları aşması durumunda mikro şebekenin en kısa sürede kendini izole ederek fiziksel olarak şebekeden ayrılması ve yerel yükleri beslemeye devam etmesi gerekir. Buradan hareketle mikro şebekenin standartlarda belirtilen süreler içerisinde ada çalışmayı meydana geldiği andan itibaren tespit edebilecek yöntemlere ihtiyaç duyulmuştur. Bu noktada literatürde ada çalışma tespit (AÇT) yöntemleri olarak adlandırılan uygulamalar, dağıtık üretimlerin bulunduğu şebeke sistemleri içerisinde kapsamlı bir yer tutmaktadır [5]. Geçmiş yıllarda geliştirilen metotların büyük çoğunluğu sadece bir inverter kaynağın olduğu dağıtık üretim için uygulanmıştır. Bunun yanı sıra yenilenebilir enerji kaynaklarındaki uygulamaların artışı ile birden fazla inverter kaynaklı dağıtık üretimin olduğu sistemler için de AÇT yöntemleri ortaya konmuştur. Son yıllarda ise küçük çapta inverter ve senkron kaynaklı dağıtık üretimler içeren mikro şebekeler için yeni AÇT yöntemlerine ihtiyaç duyulmuştur [6]. Geçmişte önerilen AÇT yöntemlerinin birçoğunda dağıtık üretimin çıkışındaki elektriksel parametreler ile tespit yapılmıştır. Öte yandan son zamanlarda çok sayıda dağıtık üretim kaynağının olduğu şebeke yapılarında ortak bağlantı noktasındaki elektriksel parametreler kullanılmaya başlanmıştır.

Ada çalışma tespit metotlarını iletişime bağlı yöntemler ve yerel yöntemler olmak üzere iki ana kategoride incelemek mümkündür. İletişime bağlı yöntemler adından da anlaşıldığı gibi uzaktan izlenebilir, kurulum maliyetleri yüksektir ve ada çalışmayı tespit etmede oldukça başarılı sonuçlar veren uygulamalardır. Yerel yöntemler ise dağıtık üretimlerin bağlantı noktalarındaki elektriksel parametreler değerlendirilerek tespit yapan, uygulanması iletişime bağlı yöntemlere nazaran daha basit olan AÇT yöntemlerini içermektedir. Yerel yöntemler de temel olarak aktif ve pasif olmak üzere iki gruba ayrılmaktadır. Aktif yöntemler, şebekeye dışarıdan bozucu etkiler verilerek değişimin gözlenmesine dayalı metotları içermektedir ve bu yöntemlerin en büyük dezavantajı güç kalitesini olumsuz yönde etkilemesidir. Pasif ada tespit metotları şebekenin ortak bağlantı noktasında veya dağıtık üretimlerin çıkışlarında gerilim, akım, frekans, aktif ve reaktif güç gibi elektriksel parametrelerin

ölçülerek ada çalışmanın tespit edilmesine dayanmaktadır. Bu tez çalışmasında düşük maliyet, hızlı tespit süresi, yerel ölçümlerin kullanılması ve güç kalitesini etkilememesi gibi avantajlarından dolayı pasif bir AÇT yöntemi önerilmiştir. Bununla birlikte pasif AÇT yöntemlerinin en önemli problemi geniş aralıkta NDZ'ye sahip olmasıdır. NDZ kavramı en genel anlamıyla ada çalışma durumunun tespit edilemediği bölgeyi ifade etmektedir [6]. Ortak bağlantı noktasında yüksek aktif ve reaktif güç değişim durumları için geleneksel pasif yöntemler etkili çözümler sunsa da bu değişimin sifıra yakın olduğu durumlarda yukarıda belirtilen parametrelerdeki değişimin çok düşük olmasından dolayı ada çalışmanın tespit edilemediği bölge genişlemektedir. Son yıllarda literatürde bu problemi ortadan kaldırmak, hızlı ve yüksek doğrulukta bir AÇT yöntemi ortaya koyabilmek için çeşitli yöntemlere başvurulmuştur.

Literatürde NDZ ve tespit süresini en aza indirmeyi ve doğruluğu artırmayı amaçlayan çeşitli AÇT metotları önerilmiştir. Bu pasif yöntemlerden bazıları ada çalışmayı tespit edebilmek için sistem parametrelerini kullanarak önceden tanımlanmış bir eşik değeri kullanır [7], [8], [9]. Önerilen bir çalışmada her dağıtık üretimin çıkışındaki gerilim ve frekans değişimleri kullanılarak bir eşik değeri belirlenmiş ve performansı yüksek bir model elde edilmiştir. Ancak önerilen yöntem sadece senkron kaynaklı dağıtık üretimler için uygulanmıştır [7]. Eşik değeri belirlenen bir diğer çalışmada birden fazla inverter kaynaklı dağıtık üretimin bulunduğu şebekede, dağıtık üretimin çıkışındaki gerilim ve frekanstaki değişim göz önüne alınarak gerilim değişiminin ortalama değeri olarak adlandırılan yeni bir parametre ile ada tespit algoritması oluşturulmuştur [8]. Önerilen yöntemde sıfır NDZ ve hızlı tespit sağlanmıştır fakat dağıtık üretimin ya da yüklerin devreden çıkarılması söz konusudur ve bu önemli bir dezavantajdır. Benzer bir çalışmada senkron ve inverter kaynaklı dağıtık üretimlerin bulunduğu sistemde dinamik yük davranışları da dikkate alınarak eşik değeri belirlenmesine dayalı bir yöntem önerilmiştir [9]. Önerilen yöntem oldukça düşük NDZ değerine sahip olup $\pm 1\%$ aktif ve reaktif güç dengesizliği durumunda tespit yapabilmektedir. Merino ve arkadaşları geleneksel AÇT yöntemlerinden farklı olarak dağıtık üretim kaynağının çıkışındaki parametreler yerine ortak bağlantı noktasındaki parametreleri kullanarak ada çalışmayı tespit

etmişlerdir [10]. Yapılan çalışmada bu noktadaki harmonikler incelenmiş olup şebeke ile paralel çalışmadan ada çalışmaya geçerken 5. harmonikte önemli değişimler olduğu görülmüştür. Buradan hareketle 5. harmonik belirlenen eşik değerinden büyükse ada çalışma tespiti yapılmıştır ve statik anahtara açma sinyali verilerek ada çalışmaya geçilmiştir. Önerilen yayın laboratuvar ortamında da test edilmiş olup, the Institute of Electrical and Electronics Engineers (IEEE) 1547 standardının gereklerini sağlamıştır. Bu çalışma inverter kaynaklı tek dağıtık sistem için uygulanmış olup, birden fazla kaynak durumu incelenmemiştir. Yukarıda bahsedilen yöntemlerin genel dezavantajı ise ayarlanacak eşik değeri belirlemenin zor olmasıdır. Bazı AÇT yöntemlerinde Fourier, Dalgacık ve S dönüşümü gibi sinyal işleme teknikleri başarıyla uygulanmıştır [11],[12]. Sinyal işlemeye dayalı tekniklerin uygulandığı bazı çalışmalarda gürültüsüz ortamlarda çok yüksek doğruluk elde edilirken, gürültülü ortamlarda bu doğruluğun düştüğü gözlemlenmiştir. Son yıllarda ise bahsedilen yöntemlerin dezavantajlarının üstesinden gelmek için, karar ağacı (DT), aşırı öğrenme makinesi (ELM) , destek vektör makinesi (DVM), yapay sinir ağları (YSA), derin öğrenme gibi makine öğrenmesi algoritmaları ada çalışmayı tespit etmek için önerilmiştir.

Rastgele orman algoritmasının önerildiği bir AÇT yönteminde veri seti 21 farklı giriş parametresi ile oluşturulmuştur ve yüksek doğruluk elde edilmiştir [13]. Bununla birlikte önerilen yöntem sadece 200 veri eğitilip test edilmiştir. Bu ise modelin genelleştirilebilmesini engellemektedir. Literatürdeki diğer bir çalışmada karar ağacı tekniği kullanılmış ve yöntem birden fazla dağıtık üretimin bağlı olduğu sistemde farklı çalışma koşulları dikkate alınarak geliştirilmiştir [14]. Bu yöntemde ortak bağlantı noktasından alınan gerilim, akım, frekans, güç ve THD gibi 10 farklı ölçüm parametresi dikkate alınmış olup, farklı şebeke topolojilerinde veri eldesi ile eğitim sağlanmıştır. Test sonuçlarına bakıldığında düşük NDZ elde edilebilse de, ada durumunun tespit edilmesinde %16 gibi bir hata oranı gözlemlenmiştir. Ayrıca çok fazla ölçüm indeksi kullanıldığından önerilen yöntemin uygulanabilirliği var olan röleler ve dağıtım sistemi ile hızlı cevapların alınabilmesi açısından dezavantajlı görünmektedir. Yapay sinir ağlarında kullanılan çok katmanlı algılayıcılar dalgacık dönüşümü ile

birleştirilerek inverter kaynaklı dağıtık üretim için ada çalışmanın tespitinde kullanılmıştır [15]. Ada çalışmayı tespit etmek için sıklıkla kullanılan bir diğer makine öğrenmesi ise destek vektör makinesidir ve bazı çalışmalarda inverter kaynaklı DÜ'lerin olduğu sisteme uygulanmıştır [16], [17], [18]. Bu çalışmalardan birinde önerilen yöntem geniş güç değişimlerinde başarısız olması sebebiyle aşırı/düşük gerilim ve frekans röleleri ile donatılmıştır [16]. Diğer çalışmada ise ada çalışmayı tespit etmek için ilk kez zaman serisi sinyalleri görüntüye dönüştürülerek DVM ile eğitilmiştir [18]. Sinyal işleme tekniklerinden Ayırık Fourier Dönüşümünü (DFT) ve makine öğrenmesi yöntemlerinden karar ağacını kullanan bir diğer AÇT yönteminde, dağıtık üretimlerin çıkışından elde edilen on iki elektriksel parametre kullanılarak ada çalışma sınıflandırılmıştır. Bu yöntemler birden farklı karakteristiğe sahip dağıtık üretimin olduğu sistemler için uygun olmayabilir. Literatürdeki çalışmalardan bazıları ise bir diğer makine öğrenmesi yöntemi olan aşırı öğrenme makinesini, ada çalışmayı diğer şebeke olaylarından ayırt etmek için kullanmıştır [19], [20], [21]. Önerilen yöntemlerin birinde ELM ile yüzde yüze yakın doğruluk elde edilse de, ELM'nin performansı gürültülü ortamlarda düşmektedir ve çalışma yalnızca 500 farklı olay ile test edilmiştir [20]. Düşük sayıda kullanılan veri setleri öğrenmenin ezberlenmesine sebep olabilmekte ve farklı tipte örneklerin test edilmesinde başarısız sonuçlar vermektedir.

Son yıllarda derin öğrenmeye bağlı algoritmalar da ada çalışma tespitinde kullanılmıştır [22], [23], [24]. Derin otomatik kodlayıcılar (SAE) 'ın kullanıldığı yöntemde yüksek doğruluk elde edilmesine rağmen, önerilen yöntemde arızalar, kapasitör anahtarlama, doğrusal olmayan yüklerin anahtarlama gibi sıklıkla karşılaşılan ada olmayan çalışma durumları dikkate alınmamıştır [22]. Çok katmanlı ileri yönlü yapay sinir ağının kullanıldığı yöntem, dokuz baralı güç sisteminde her baradan elde edilen 12 farklı giriş parametresi ile eğitilmiştir [23]. Diğer bir derin öğrenme algoritması olan uzun kısa dönemli hafıza (LSTM) ağları ile dağıtık üretimlerin çıkışında ölçülen akım ve gerilim sinyallerine ait ikinci harmoniğin simetrik bileşenleri ayırık dalgacık dönüşümü ile ortaya çıkarılarak ada çalışma tespiti yapılmıştır [24]. Kullanılan giriş parametreleri dağıtık üretimlerin çıkışından ve mikro şebekenin ortak bağlantı noktasından

akıllı ölçüm cihazları ile elde edildiğinden bu yöntem uygulama açısından maliyetli olabilir. Ayrıca önerilen yöntemlerden bazıları sınırlı türde şebeke olaylarını dikkate almış olup, kapsamlı şekilde arızalar, kapasitör anahtarlama, motor yükü, doğrusal olmayan yük, dağıtık üretimin devreden çıkması veya devreye girmesi gibi yaygın görülen olayları incelememişlerdir.

Yapılan literatür çalışmaları incelendiğinde etkili bir ada tespit yönteminin aşağıdaki özelliklere sahip olması gerekmektedir.

- Farklı karakteristiğe sahip dağıtık üretim sistemleri için uygulanabilmelidir.
- Ada ve ada olmayan şebeke olaylarını kapsamlı şekilde test edilmelidir.
- Minimum ölçüm parametresi kullanmalıdır.
- Geniş boyutlu bir veri seti ile doğrulanmış olmalıdır.
- Sınırlı sayıda ölçüm cihazı kullanılarak maliyet düşürülmelidir.

Yukarıdaki çalışmalar ışığında yapılan tez çalışmasında derin sinir ağları öncelikle farklı tip dağıtık üretimlerin bağlı olduğu mikro şebeke üzerinde uygulanmıştır, daha sonra karma bir model üzerinde kapsamlı veri eldesiyle daha genel bir algoritma elde edilmiştir. Yukarıdaki çalışmaların çoğunda dağıtık üretimin çıkışındaki parametreleri referans alarak bir yöntem önerilmiştir. Bu tez çalışmasında ise amaç ortak bağlantı noktasında ulaşılması kolay ölçüm parametrelerini kullanarak hızlı, efektif, düşük NDZ'ye sahip, doğruluğu yüksek ve uygulanması kolay bir ada çalışma tespit yöntemi önermektir.

1.2 Tezin Amacı

Bu tez çalışmasında amaç birden fazla dağıtık sistemin bağlı olduğu mikro şebekeler için hayati öneme sahip ada çalışma durumunun tespitinde kullanılmak üzere uygulaması basit, tespit hızı yüksek, düşük NDZ'ye sahip etkili bir AÇT yöntemi geliştirmektir. Geliştirilen yöntemde kompleks problemlerin çözümünde son yıllarda birçok farklı alanda başarılı sonuçlar alınmış olan derin öğrenme yaklaşımı kullanılmıştır. Bu teknik karmaşık veri gruplarının yüksek özelliklerini çok katmanlı sinir ağları sayesinde ortaya çıkararak öğrenme

yapabilmektedir. Önerilen bu yaklaşımda ortak bağlantı noktasındaki akım ve gerilime bağlı harmonik değerleri dikkate alınarak uygulaması kolay bir yöntem hedeflenmiştir. Tezde birden fazla farklı dağıtık üretimin bağlı olduğu mikro şebeke modelleri için uygulanabilir bir AÇT yöntemi olması öncelikli hedefler arasındadır. Bu tez çalışmasıyla dağıtık üretimlerin şebekeye bağlanmasında en önemli problemlerden biri olan ada çalışmayı diğer şebeke olaylarından efektif şekilde ayırt edebilen bir AÇT yaklaşımı önerilerek, yeni nesil güç sistemlerine önemli düzeyde katkı sunması hedeflenmektedir.


1.3 Hipotez

Bu tez çalışmasında inverter ve senkron kaynaklı mikro şebekeler için yeni bir ada çalışma tespit modeli ortaya konulmuştur. Önerilen modeller farklı derin öğrenme algoritmalarını kullanarak ada çalışmanın meydana gelip gelmediğini tahmin etmektedir. Derin öğrenme algoritmalarının girişinde ada çalışmayı tespit etmede kullanılacak parametreler mikro şebekenin ortak bağlantı noktasında gerilim ve akım ölçümleri yapılarak elde edilmiştir. Yerel olarak ölçülen sadece üç elektriksel parametre (THD_v , THD_i , V_3) ile ada çalışma tahmin edilebilmektedir. Önerilen model MATLAB/Simulink platformu kullanılarak modifiye edilmiş CERTS (the Consortium for Electric Reliability Technology Solution) ile AEP (American Electric Power) işbirliğinin oluşturduğu mikro şebeke modeli üzerinde test edilmiştir. Derin öğrenme algoritmaları ise Python/Tensorflow kütüphaneleri kullanılarak eğitilmiş ve test edilmiştir. Önerilen yöntemin doğruluğunu analiz etmek için yaklaşık dört bin ada ve ada olmayan olayın simülasyonu gerçekleştirilmiştir. Şebeke arızaları yanı sıra kapasitör, doğrusal olmayan yükler, motor yükü, ikinci dağıtık üretimin anahtarlama gibi ada olmayan şebeke olayları dikkate alınmıştır. Ada olayları ise OBN'deki çeşitli aktif ve reaktif güç değişim değerleri dikkate alınarak üretilmiştir. Literatürdeki diğer çalışmalardan farklı olarak bu tez çalışmasında ilk kez ana şebekenin harmoniksiz olması durumuna ilave olarak %5'in altında gerilim harmoniklerine sahip olduğu durumlar da dikkate alınarak gerçeğe daha yakın olaylar üretilmiştir. Tez çalışmasında tek boyutlu sıralı giriş evrimsel ağ ve uzun kısa süreli bellek (LSTM) algoritmaları kombine edilerek daha yüksek

doğrulukta bir AÇT modeli elde edilmiştir. Önerilen yöntemin performansı diğer çalışmalardan farklı olarak dağıtık üretim kaynaklarının sayısının artması durumu için de test edilmiştir. Aynı zamanda daha önce eğitim ve test aşamasında kullanılmayan OBN'deki aktif ve reaktif güç değişiminin çok düşük olduğu durumlar için ada çalışmayı tespit etmedeki performansı test edilmiştir. Önerilen yöntem kullanılan bu araçlar sayesinde çok düşük NDZ durumlarında bile yüksek doğrulukta tahmin yapabilir, farklı dağıtık üretim kaynaklarının olduğu mikro şebekeler için uygulanabilir.


2.1 Mikro Şebekeler

Elektrik enerji sistemine dağıtık üretimlere bağlı enerji kaynaklarının da katılması mevcut sistemi yapısal olarak değiştirmektedir. Büyük üretim santrallerinin yanında küçük çaplı üretim yapan dağıtık üretim santrallerinin kullanımı giderek yaygınlaşmakta ve belirli bir bölgenin ihtiyacı bu kaynaklardan sağlanmaktadır. Dağıtık sistemlerin bireysel olarak kullanılması işletme, koruma ve kontrol açısından birçok zorluğu da beraberinde getirmektedir. Bunun yerine farklı dağıtık üretimlerin bir arada bulunduğu yükleri ve depolama sistemlerini içinde barındıran, gerektiğinde otonom olarak şebeke ile paralel veya şebekeden bağımsız çalışabilen mikro şebeke kavramı ortaya çıkmıştır. Mikro şebekeler, sınırlı ve kontrol edilemeyen rüzgar ve güneş gibi dağıtık üretimleri, üretimi kontrol edilebilen yakıt hücreleri, doğal gaz kombine çevrim santralleri ve bunun yanı sıra yedek güç üniteleri, enerji depolama sistemleri, elektrikli araç şarj istasyonları, kontrollü ve kontrolsüz yükleri içinde barındırabilir. Ayrıca mikro şebekeler kojenarasyon santralleri ve dizel jeneratörler gibi dağıtılmış üretimleri bünyesinde bulundurabilir. Böylece ısı enerjisinden yararlanılarak üretilen enerji sistemleri ile verimliliği arttırabilir. Şekil 2.1’de örnek bir mikro şebeke konsepti gösterilmiştir. Acil durum yüklerine yedek güç sağlayan jeneratörlere benzer şekilde, mikro şebekeler de DÜ’lerin yük talebine daha yakın kurularak tüketici yüklerini beslemek için kullanılır. Bu sayede hat kayıplarını azaltmada ve sistemin verimliliğini arttırmada önemli etkiye sahiptirler. Mikro şebekelerin diğer uygulamaları voltaj regülasyonu, harmoniklerin giderilmesi ve talep yanıtı gibi yardımcı hizmetleri içermektedir. Mikro şebekeler kullanım amaçlarına bağlı olarak güç elektroniği dönüştürücüleri sayesinde alternatif veya doğru gerilimle besleme hatlarına bağlanabilirler. Bu yönden mikro şebekeler AC ve DC olarak iki gruba ayrılmaktadır [25].



Şekil 2.1 Mikro şebeke konsepti

Geleceğin enerji sistemleri olarak görülen mikro şebekeler Avrupa, Amerika, Kanada, Japonya gibi gelişmiş ülkelerde hem laboratuvar ortamında hem de pilot uygulama bölgelerinde etkili çözümler için test edilmektedir [26],[27]. Şekil 2.2’de bir araştırma şirketinin yaptığı tahminlere göre 2019-2028 yılları arasında dünya pazarında bulunan bölgeler için yıllık planlanan mikro şebeke kapasiteleri ve uygulama harcamaları gösterilmiştir. Araştırmaya göre 2019 yılında 3,5 GW olan mikro şebeke kapasitesinin 2028’e kadar yıllık yaklaşık %21,4’lük bir büyümeyle 20 GW seviyelerine çıkması ön görülmektedir [28]. Mikro şebekeler enerji sisteminde güvenilir, esnek bir yapı ortaya koysa da ekonomik, ticari ve teknik zorlukların çözülmesi gerekmektedir. Mikro şebekenin güvenli ve verimli şekilde işletilmesi için özellikle uzaktan ve yerel kontrol sistemleri, enerji yönetim sistemleri, güç kalitesi, arıza tespiti, ayrılma ve ada çalışma gibi koruma güvenlik sistemleri, iletişim alt yapıları konularında önemli çalışmalar yapılmaktadır.



Şekil 2.2 Dünya pazarında bölgelere göre planlanan yıllık mikro şebeke güç kapasitesi ve pazar harcamaları [28]


Mikro şebekenin en büyük avantajlarından biri şebeke ile paralel çalışırken, planlı ya da plansız bir şekilde şebekeden ayrılıp bağlı bulunduğu yükleri beslemeye devam edebilmesidir. Şebekeden bağımsız işletme durumu ‘ada çalışma’, şebekeyle paralel işletme durumu ise ‘şebeke bağlantılı’ olarak adlandırılır. Şebekeye bağlı çalışırken öncelikli amaç ekonomik açıdan en iyi işletmeyi sağlamak iken, ada çalışmada ise öncelikli amaç mikro şebekenin beslediği kritik yükleri kesintiye uğratmadan güvenli şekilde beslemek ve şebekenin zararlı etkilerinden dağıtık üretim sistemlerini korumaktır [29]. Mikro şebekenin işletilmesinde karşılaşılan zorluklardan biri de istenmeyen ada çalışma durumudur. Şebekenin gerilim ve frekansında herhangi bir sebeple kabul edilmeyen seviyelerin meydana gelmesi, hat üzerinde çalışan personelin hayati tehlikesine ve yüklerin zarar görmesine neden olabilir. Bu durumu önlemek için ada çalışma tespiti yapılmalı ve dağıtık üretimin şebekeden izole edilmesi gerekmektedir.

2.2 Mikro Şebekelerde Ada Çalışma

Ada çalışma en basit tanımıyla elektrik güç sisteminin yalnızca bir parçasının elektrik şebekesinden fiziksel olarak ayrılarak yakınındaki yükleri beslemeye devam etmesi durumudur. Ada çalışma durumu şebeke ile bağlantılı çalışmaya

göre daha zayıf olduğundan ada çalışmaya geçişin ve tekrar şebekeye bağlanmanın belirli şartları bulunmaktadır. Ada çalışma durumundan tekrar şebekeye bağlantının gerçekleşebilmesi için gerekli şartlardan biri gerilim, frekans ve faz açısındaki değerler iki tarafta senkronize olmasıdır. IEEE 1547 numaralı standartta bu koşullar detaylı olarak verilmiştir. [30]. Ada çalışma durumu bakım ve yük atma gibi planlı durumlarda ‘istemli’ veya arıza ve cihaz hatası gibi tahmin edilemeyen durumlarda ‘istemsiz’ olarak meydana gelebilir. Bu çalışmanın devamında ada çalışma olarak belirtilen durumların hepsi istemsiz olarak meydana gelen ada çalışma durumlarını ifade etmektedir. İstemsiz ada çalışma gerilim, frekans ve diğer güç sistemi parametrelerinde kabul edilmeyen limitlere neden olmaktadır. Bu sebeple istemsiz ada durumu standartlarda belirtilen süre içerisinde tespit edilmeli ve ardından ilgili röleye sinyal verilerek ada sisteminin kontrol mekanizmasının devreye girmesi sağlanmalıdır. Böylece dağıtım sistemindeki yükler güvenilir şekilde beslenmeye devam edebilir.

Literatürde geçmişten günümüze ada çalışmayı tespit edebilmek için çok sayıda yöntem ortaya konulmuştur. Ada çalışma tespit yöntemlerindeki hiyerarşiyi Şekil 2.3’teki kategoriye göre ifade etmek gerekir. Bu üç farklı kategoriye göre oluşturulan yerel AÇT metotları Tablo 2.1’deki farklı sistem bileşenlerini içermektedir ve bu da her bir kategori için önerilen çözümleri farklı kılmaktadır [6]. Geçmişte sunulan ada çalışma tespit yöntemleri inverter kaynaklı tek bir dağıtık üretimin bulunduğu eski sistemler için önerilmiştir. Yenilenebilir enerjideki şebeke entegrasyonunun artması ve birden çok inverter kaynaklı DÜ’lerin birlikte kullanımı ve bununla birlikte sistem üzerindeki belirsizliklerin artması yeni ada çalışma tespit yöntemlerine ihtiyacı arttırmıştır. Geleceğin enerji sistemleri olarak görülen mikro şebekelerin artmasıyla da önerilecek ada çalışma tespit yöntemleri bu alt kategorileri kapsayacak esnekliğe cevap vermelidir.




Şekil 2.3 Yerel ada çalışma tespit yöntemlerinin geçmişten günümüze hiyerarşisi [6]

Tablo 2.1 Yerel AÇT’ler için önerilen farklı seviyelerdeki sistem bileşenleri

Ekipmanlar	Kategoriler		
	İnverter	Çoklu İnverter	Mikroşebe
İnverter veya mikro kaynak	✓	✓	✓
Çoklu inverter veya çoklu mikrokaynak	x	✓	✓
Senkron makineler	x	x	✓
OBN'de yerel yükler	x	sıklıkla yoktur	✓
OBN'de statik anahtar	x	x	✓

Eski ve yeni sistem ada çalışma tespit metotlarını incelemek gerekirse, “istenmeyen ada” ve “ada çalışma tespit” olarak iki kavrama ayırmak gerekir. Tek inverter kaynaklı güneşe bağlı dağıtık üretimler için herhangi bir istenmeyen ada çalışma durumunda önceden belirlenen bir zaman diliminde dağıtık kaynağının kapatılması gerekirdi. Günümüz mikro şebeke sistemlerinde ise ada çalışma durumunda dağıtık kaynakların yerel yükleri herhangi bir gerilim-frekans bozunumu meydana gelmeden beslemeye devam etmesi gerekir. Çoklu inverter yapıları için önerilen yöntemlerde ada çalışma tespit yöntemleri çoğunlukla her bir inverter kaynağın çıkışına göre tespit eden bir yönetime dayanmaktadır. Bu sistem de gerçek mikro şebekeler için efektif bir çözüm sunmamaktadır [6]. Şekil 2.4’te de farklı kaynaklardan oluşturularak geliştirilen ada tespit yöntemleri ile kontrol edilen, statik anahtarlı mikro şebeke örneği gösterilmiştir.



Şekil 2.4 Mikro şebekede ada çalışma durumu

Ada çalışmanın mümkün olduğu kadar hızlı şekilde tespit edilmesi aşağıdaki sebeplerden dolayı hayati önem taşımaktadır.

- Dağıtık üretimlerin hala devrede olması nedeniyle hat üzerindeki enerji herhangi bir hat bakım işçisinin güvenliği açısından tehlike oluşturabilir.
- Ada çalışma durumunda şebekedeki gerilim ve frekans kontrolünün kaybedilmesi sonucunda tüketici makineleri ve ekipmanlarına ciddi bir zarar meydana gelebilir.
- Gerilim ve frekans seviyelerinin korunamaması durumunda dağıtık üretim kaynaklarında bozulmalara sebep olabilir.

IEEE 1547 standardına göre herhangi bir ada çalışma durumu OBN'deki küçük gerilim değişimleri için 2 saniyeden kısa sürede tespit edilmelidir. Bu durum 0.5 per-unit (pu)'ten düşük veya 1.2 pu'dan büyük gerilim değişimi durumunda ise 0.16 saniyenin altında tespit edilmelidir.

Geliştirilen yöntem ada çalışmayı diğer şebeke bozukluklarından ayırt edebilmeli ve dağıtık üretimin şebeke ile bağlantısını, güç kalitesini, ekipman zararını, frekans ve voltaj kararsızlığını gözeterek fiziksel olarak kesebilmelidir. Bu çerçevede ada çalışma tespit yöntemleri mikro şebeke başlığı altında geliştirilmektedir. Literatüre bakıldığında mikro şebeke başlığı altında bu konuda geliştirilen ortak bir kullanım, bir standart bulunmamaktadır. Bu konuda ortaya konulan sınırlı sayıda standart olup en önemlisi IEEE-1547 numaralı standardıdır ve özellikle mikro şebeke için eksiklikler barındırmaktadır [30]. Bu ise önerilen yöntemlerin test edilmesini ve uygulanabilirliğini zorlaştırmaktadır.

Ada çalışma tespit yönteminde kullanılan başlıca performans kriterleri aşağıda belirtilmiştir [31][6]. Ayrıca ortaya konulan standartlarda müsaade edilen frekans ve gerilim aralığı ile maksimum ada tespit süresi Tablo 2.2’de verilmiştir [32].


- Ada çalışmanın tespit edilemediği alan (NDZ): Literatürde NDZ olarak ifade edilen bu kriter, ada çalışmanın meydana geldiği halde tespit edilemeyen alanı gösterir. Ada çalışma tespiti mikro şebekede üretilen aktif ve reaktif gücün yükler tarafından tamamen tüketildiği en kötü durumda bile yapılabilmelidir. İyi bir ada çalışma tespiti için NDZ’nin mümkün olduğunca düşük olması istenir.
- Tespit Süresi: Bu süre mikro şebekenin ana şebekeden ayrılmasının başlangıcı ile ada çalışmanın tespit edildiği süreyi ifade eder. Önerilen yöntemin efektif olabilmesi için bu sürenin de oldukça düşük olması gerekir. IEEE 1547-2003, IEC 62116 gibi standartlarda bu sürenin 2 saniyenin altında olması gerektiği belirtilmiştir [33]. Bu süre ne kadar kısa olursa plansız ada durumlarında sistemde tekrar senkronizasyonun sağlanması o kadar kolay olur.
- Hata Oranı: Hatalı tespit, mikro şebekenin ana şebeke ile bağlantısının devam etmesine rağmen ada çalışma tespit edilmesi durumunu ifade eder. Bu durum ise yükün kapatılıp açılması veya diğer şebeke arızaları durumunda belirlenen parametrelerin normal sınırları aşması gibi sebeplerden ötürü gerçekleşir.
- Güç kalitesi: Bazı yöntemlerde sisteme dışarıdan verilen bozucu sinyaller güç çıkışını bozmakta ve kalitesini kötüleştirmektedir. Bu durumda önerilen ada çalışma tespit sisteminin güç kalitesini en az düzeyde etkilemesi gerekmektedir.

Tablo 2.2 Ada tespit standartları

Parametreler	IEEE Std. 1547-2003	IEEE Std. 929-2000	IEC 62116
Kalite Faktörü	1	2,5	1
Ada Tespit Süresi (t)	$t < 2 \text{ s}$	$t < 2 \text{ s}$	$t < 2 \text{ s}$
Frekans aralığı	$59.3 \leq f \leq 60.5 \text{ Hz}$	$59.3 \leq f \leq 60.5 \text{ Hz}$	$f_0 - 1.5 \text{ Hz} \leq f \text{ ve } f_0 + 1.5 \text{ Hz} \leq f$
Gerilim aralığı	$0.88 \leq V \leq 1.10$	$0.88 \leq V \leq 1.10$	$0.85 \leq V \leq 1.15$

2.3 Mikro Şebekelerde Ada Çalışma Tespit Yöntemleri

Ada çalışma tespit yöntemlerinin temel amacı şebeke ve dağıtık üretim tarafındaki bazı elektriksel parametrelerin izlenerek ada çalışmanın meydana gelip gelmediğini belirlemektir. Ada çalışma tespit yöntemleri literatürde temel olarak iletişime bağlı yöntemler ve yerel yöntemler olarak iki kategoriye ayrılmaktadır. Yerel yöntemler ise aktif ve pasif yöntemler olarak sınıflandırılmaktadır ve Şekil 2.5'te bazı ada çalışma tespit metotları verilmiştir. Bu yöntemler ile ilgili temel farklılıklar aşağıdaki bölümlerde detaylandırılmıştır.

**Şekil 2.5** Ada çalışma tespit yöntemleri

2.3.1 İletişime Bağlı Yöntemler (Merkezi Kontrol)

Bu yöntemde şebeke operatör tarafından ada bilgisi ve röle kontrolü merkezi denetleme kontrol ve veri toplama (SCADA) gibi iletişim sistemleri ile izlenerek yapılır. Bu metotlar en esnek yöntemlerdir ve sıfır NDZ' ye sahiptir. Bu yöntemin en önemli dezavantajı şebekeye uygulamasında yüksek maliyete sahip olmasıdır. Bu yöntem birden fazla inverter bağlı yüksek güçlü dağıtık üretimler için çok elverişli olsa da mikro şebeke gibi küçük sistemler için ekonomik değildir.

2.3.2 Yerel Yöntemler

Bu teknikler sistem parametrelerini, ortak bağlantı noktasındaki veya dağıtık üretim kaynaklarının çıkışındaki yerel ölçümlerden elde ederek kullanır.

2.3.2.1 Aktif Yöntemler

Aktif yöntemde, sisteme dışarıdan ilave bir bozucu sinyal verilir ve meydana gelen değişimler izlenerek ada çalışma tespit edilir. Bu tespit sistemi daha etkili sonuçlar verse de hem maliyet açısından hem de uygulama yönünden çeşitli zorluklara sahiptir. Ayrıca sisteme dışarıdan enjekte edilen sinyaller güç kalitesinin bozulmasına sebep olabilir. Birden fazla dağıtık üretiminin olduğu durumlarda ise ilave edilen sinyallerin karşılıklı etkileşimi nedeniyle yanlış açmalara sebep olabilmekte ve sistem kararlılığında bozucu etkiye neden olabilmektedir. Aktif metotlar bazı pasif metotlara göre yüksek güvenilirliğe sahip olmasına rağmen tespit süreleri daha yavaştır [31].

2.3.2.2 Pasif Yöntemler


Pasif yöntem ana şebeke ile mikro şebeke arasında bulunan ortak bağlantı noktasında ölçülen elektriksel parametreleri (akım, gerilim, güç, frekans, harmonik bozunum...) kullanarak ada çalışma olup olmadığını tespit eder. Belirlenen bir eşik değeri ile bu ölçülen değerler karşılaştırılıp normal olmayan bir durumda röleye açma sinyali gönderilir. Bu yöntemin dikkat çeken özellikleri uygulama kolaylığı ve güç kalitesini etkilememesidir. Diğer yandan ise yöntemin geniş bir NDZ'ye sahip olması, eşik değerinin tespit zorluğu ve sistemdeki düşük aktif reaktif dengesizliğinde ada çalışma tespitinin başarısız olması gibi

eksiklikleri bulunmaktadır. Pasif ada çalışma tespit metotlarının tasarımıda ortaya çıkan bazı zorluklar bulunmaktadır. Ada çalışmayı tespit edebilecek parametrelerin belirlenmesi bu yöntemin başarısını etkileyecek önemli adımlardan biridir. Diğer bir parametre ise eşik değere bağlı yöntemlerde doğru eşik değer limitlerinin belirlenmesidir ki bu eşik değeri hem düşük güç değişimleri için uygun olmalı hem de ada olmayan olayları ayırt edebilmek için doğru seçilebilmelidir. Şebekedeki bazı geçici hal karakteristikleri ada olayları ile benzer karakteristiğe sahip olabilmektedir, bu da röleye yanlış açma sinyali vermeye neden olmaktadır. Pasif ada tespit yöntemlerini kendi içerisinde geleneksel metotlar, sinyal işlemeye bağlı metotlar ve akıllı metotlar olarak sınıflandırabiliriz. Geleneksel yöntemlerde akım, gerilim, frekans, THD gibi parametreler izlenip uygun bir algoritma belirlenerek, herhangi bir yöntemden yararlanılmadan ada çalışma tespit edilir. Sinyal işlemeye dayalı metotlarda Fourier, Dalgacık ve S dönüşümü gibi sinyal işleme teknikleri kullanılarak ada çalışma tespit edilir. Akıllı metotlar ise genellikle yapay zeka yöntemlerinden faydalanılarak elektriksel parametrelerin farklı algoritmalar ile eğitilmesiyle oluşturulur. Hali hazırda elektrik güç sistemlerinde ortaya çıkan problemlerin çözümü için güç sistemlerinin işletilmesi, planlanması, kontrolü gibi konularda yapay zekaya başvurulmaktadır [34],[35],[36],[37]. Son yıllarda veri setinden güç sistem özelliklerini analiz ederek ada çalışmayı öğrenme yoluyla tespit eden akıllı yöntemler kullanılmaya başlanmış olup, bazı güç sistemleri olaylarının karakteristiklerini ortaya çıkarmada en iyi yöntemler olarak tanımlanmaktadır [38]. Bu çalışmada da akıllı yöntemlerden derin öğrenmeye bağlı algoritmalar kullanılarak pasif ada çalışma metotları önerilmiştir. Bu bağlamda kullanılan yöntemlerin teorik detayları bir sonraki bölümde incelenmiştir.


3.1 Giriş

Yapay zeka en genel anlamıyla insan zihninin yeteneklerinin ve problem çözme kabiliyetlerinin taklit edilerek bilgisayarlar ve makineler üzerinde uygulanmasıdır. Bu uygulama metotları altı farklı grup içinde sınıflandırılabilir. Bu sınıflar öğrenme metotları, istatistiksel metotlar, araştırma metotları, optimizasyon teorisi, oyun teorisi ve karar verme algoritmalarıdır ve alt dalları ile birlikte Şekil 3.1’de gösterilmektedir. Bu metotlar içinde makine öğrenmesi son yıllarda yaygın şekilde kullanılmaktadır. Makine öğrenmesi, insan müdahalesi olmadan büyük çapta gerçek veya sentetik verileri kullanarak öğrenme yeteneğinin otomatik olarak kazandırıldığı farklı algoritmalarından oluşmaktadır. Sinir ağlarına bağlı makine öğrenmesi algoritmaları yapay sinir ağları, tekrarlayan sinir ağlar, derin sinir ağları gibi çeşitli alt kısımlara ayrılmaktadır ve güç sistemlerine bağlı uygulamalarda giderek artan şekilde bu yöntemlere başvurulmaktadır. Özellikle derin öğrenme (derin sinir ağları) farklı disiplinleri içeren konuşma tanıma, resim sınıflandırma, doğal dil işleme, arıza tahminleri gibi alanlarda büyük başarılar sağlamıştır.

Son yıllarda özellikle karmaşık ve doğrusal olmayan problemlerin çözümünde gelişmiş eğitim algoritmaları ile derin öğrenme metodu kullanılarak birçok alanda yüksek başarılar elde edilmiştir. Derin öğrenme algoritmaları geleneksel sinir ağlarından farklı olarak karmaşık verilerdeki özellikleri birden fazla katman kullanarak ortaya çıkarır [39]. Şekil 3.2’de derin öğrenmenin son yıllardaki bütün alanlarda ve özellikle elektrik güç sistemlerindeki popülaritesini gösteren grafik yer almaktadır [40]. 2012 ile 2019 yılları arasında derin öğrenme ile ilgili yayınlanan makalelerin sayısı yıllık olarak gösterilmiştir.



Şekil 3.1 Yapay zeka ve alt bölümleri



Şekil 3.2 Derin Öğrenme başlığı altında yayınlanan makale sayısının yıllara göre değişimi

3.2 Makine Öğrenmesi


Makine öğrenmesi yapay zekanın bir alt dalı olup, bilgisayarlar aracılığı ile geçmiş veriler üzerinde anlamlı çıkarımlar yaparak tahminler yapabilen algoritmaların bütünüdür [41]. Görüntü tanıma, konuşma, doğal dil işleme, sinyal işleme gibi çok farklı alanlarda başvurulmuş makine öğrenmesi algoritmaları farklı yaklaşımlar içermektedir. Literatürde destek vektör makineleri, karar ağacı, rastgele orman, k-en yakın komşu (kNN), aşırı öğrenme makinesi, yapay sinir ağları gibi algoritmalar sıklıkla kullanılmıştır. Elektrik güç sistemlerinde de özellikle son yıllarda enerji, yük ve arıza tahminlerinde son yıllarda bu yöntemlere başvurulmuştur. Makine öğrenmesi yöntemleri, etiketli verilerin kullanıldığı denetimli öğrenme, özelliklerin otomatik olarak çıkarıldığı denetimsiz öğrenme ve ödül ceza sistemine dayalı pekiştirmeli öğrenme olarak üç ana gruba ayrılır [42]. Geleneksel makine öğrenmesi yöntemlerinin ham verideki öz nitelikleri ortaya çıkarmadaki yeteneği derin öğrenme ile kıyaslandığında sınırlıdır ve eğitim sürecinde bir uzmana ihtiyaç duymaktadır [43]. Geleneksel makine öğrenmesi yöntemleri ile derin öğrenme arasındaki temel farklar aşağıda verilmiştir.

- Makine öğrenmesinde kullanıcılar tarafından sağlanan küçük verilerle işlem yapılırken, derin öğrenme tekniğinde iyi sonuçların alınabilmesi için çok sayıda etiketlenmemiş veriye ihtiyaç duyulmaktadır.
- Derin öğrenme tekniğinde eğitimi gerçekleştirmek için yüksek performanslı bir donanıma ihtiyaç vardır.
- Derin öğrenmede verilerin eğitilmesiyle yeni özellikler kendiliğinden ortaya çıkarken, makine öğrenmesinde kullanıcılar tarafından özelliklerin doğru şekilde tanımlanması gerekir.
- Makine öğrenmesinin tersine derin öğrenme tekniğinde eğitim için daha fazla zamana ihtiyaç duyulur.
- Klasik makine öğrenmesinden çok daha fazla matematiksel işlemi içinde barındıran derin sinir ağları bu özellikleri sayesinde yüksek boyutlu verilerde daha yüksek doğrulukta sonuçlar vermektedir.

- Derin öğrenme, sistemin kendi başına daha akıllı olmasını sağlayan denetimsiz öğrenme tekniklerini destekler. Makine öğrenmesinde ise denetimli öğrenme sistemi daha çok kullanılır.
- Makine öğrenmesinde problemler küçük parçalara bölünerek alınan sonuçlar tek bir sonuçta birleştirilir. Derin öğrenmede ise adım adım problemlerin çözümü üzerine gidilir.

3.3 Yapay Sinir Ağları

Yapay sinir ağlarının temeli veri seti içindeki kompleks yapıları ve doğrusal olmayan ilişkileri öğrenebilmek için insan beynindeki nöronlar arasındaki ilişkinin taklidine dayanmaktadır. YSA veriden öğrenebilme, hafızaya alma, genelleme yapabilme ve sınırsız sayıda değişkenle çalışabilme gibi önemli özellikleri sayesinde çok geniş alanda kullanılabilmekte ve başarılı sonuçlar vermektedir. Aynı zamanda YSA algoritmaları paralel hesaplama yeteneği sayesinde gerçek zamanlı işlemler için uygun çözümler sunabilmektedir. Bunun yanı sıra YSA'lardan etkin çözümler alabilmek için büyük veri setlerine ihtiyaç duyulmaktadır. Az sayıda veri seti ile öğrenme işlemi sağlıklı olarak yapılamayabilir veya ezberleme (overfitting) durumu ile karşılaşılabilir. Bu durumda eğitim aşamasında yüksek doğruluklar elde edilebilmesine rağmen test aşamasında kötü performans göstermektedir. YSA'nın temel yapısı nöronlar, ağırlıklar ve biastan oluşmaktadır. Çok farklı yapıları olmasına rağmen en yaygın kullanılan YSA yapısı çok katmanlı algılayıcı (MLP) 'dır. Bu mimari Şekil 3.3'te verilmiş ve denklem 3.1, 3.2 ve 3.3'te teoriksel olarak ifade edilmiştir.



Şekil 3.3 Basit yapay sinir ağı modeli

$$y = f(x) = s(W * x + b) \quad (3.1)$$

$$z = g(x) \rightarrow r = s(W' * y + b') \quad (3.2)$$

$$J_{SAE}(\Theta) = \sum_t L(x^{(t)}, g_{\theta}(f_{\theta}(x^{(t)}))) \quad (3.3)$$

Giriş verisi ara katmanlardan geçerek çıkış katmanına ulaşır. Burada $X_1, X_2, X_3, \dots, X_5$ giriş katmanının nöronlarını, H_1, H_2, H_3 ara katmanlardaki nöronları, ve $Z_1, Z_2, Z_3, \dots, Z_5$ ise çıkış katmanındaki nöronları temsil etmektedir. Giriş katmanındaki nöronlar belirli ağırlık katsayıları (W) ile çarpılıp bias (sapma) vektörü ile toplanıp bir aktivasyon fonksiyonundan geçerek çıkışa ulaşır. Ara katmanda ilk katmandan gelen çıkış bu defa burada giriş katmanı gibi davranır ve tekrar aynı işlemlerden geçerek nihai çıkış katmanına ulaşır. İleri yönlü sinir ağlarında bu işlem denklem 3.3'te belirtildiği gibi giriş ve çıkış arasındaki hata oranı minimuma düşürülene dek ağırlıklar ve biaslar güncellenir. Bu minimum hata ve güncelleme süreci, belirli bir öğrenme algoritması kullanılarak yapılır. Girişten çıkışa kadar yapılan işlemin sayısı tur olarak ifade edilir. En uygun tur sayısında ağırlık eğitimi işlemi sonlandırılır. Eğitme işleminin amacı hatayı mümkün olduğu kadar sıfıra yaklaştırarak istenen en uygun çözüme ulaşmaktır.


3.4 Derin Öğrenme

Derin öğrenme (DL), yapay sinir ağları temeline dayanan algoritmaların birden fazla ara katman kullanarak oluşturulan öğrenme şeklinin genel adı olarak tanımlanabilir. Derin öğrenme yöntemi, yapay sinir ağlarına bağlı bir makine öğrenmesi olup, lineer olmayan ve aralarında karmaşık ilişkiler bulunan problemlerde özellikle çok sayıda verinin olduğu işlemlerde farklı eğitim algoritmaları ile uygulanmaktadır. DL, doğrusal olmayan sorunları (tanıma, algılama, sınıflandırma, vb.) çözmek ve kompleks karakteristiğe sahip verilerin özelliklerini ortaya çıkarmak için kullanılır. McCulloch ve Pitts tarafından derin öğrenme fikri aslında 1943'e kadar uzanmaktadır [44]. Derin sinir ağlarının gelişimi; yeterli verinin olmaması hesaplama ve eğitim metodlarının yetersiz olması, yerel minimum ve maksimum noktaları belirlemedeki kısıtlar, optimizasyon sorunları gibi teknolojik kısıtlamalar nedeniyle uzun zaman almıştır [48],[49]. Kompleks matematiksel işlemler içermesi nedeniyle geçmişte

eğitim işlemleri günlerce hatta haftalarca sürmekteydi. Bilgisayar teknolojilerinde GPU (grafiksel işlemci ünitesi) kullanımı bu süreleri dakikalar mertebesine indirmiştir. Özellikle Geoff Hinton, Yann LeCun ve Yoshua Bengio tarafından 2006-2007 yıllarında ortaya çıkarılan yeni öğrenme algoritmaları derin öğrenmenin gelişiminde çığır açmıştır [45],[46].

Bu ilerlemelerin bir sonucu olarak derin öğrenme yöntemleri, görüntü tanıma [47], genetik [48], otonom araçlar [49], robotik [50] gibi alanlarda geniş bir uygulama alanı elde etmiştir. Google, Facebook, Microsoft, IBM gibi önde gelen teknoloji şirketleri; Big Sur, Tensorflow, Watson platformları gibi araştırma ve geliştirme projelerine büyük yatırımlar yapmışlardır. Derin öğrenmenin temel yönleri, kullanılan yöntemler, sorun kategorileri, genel kullanım durumu, performans endeksleri, uygulama endüstrisi ve model parametreleri olarak özetlenebilir ve Şekil 3.4'te daha detaylı olarak gösterilmiştir. Şekil 3.4'te görüldüğü gibi derin öğrenme bilgisayarlı görme, sosyal medya, finans, genetik, otomotiv ve EPS gibi çeşitli alanlara uygulanmıştır. Ayrıca derin öğrenme, bir veri kümesini sınıflandırmak, algılamak veya tahmin etmek için herhangi bir video, görüntü, konuşma sinyali veya zaman serisini kullanabilmektedir. Tensorflow, Caffe, Theano, Keras vb. gibi çok sayıda kütüphane sayesinde derin öğrenme algoritmaları rahatlıkla uygulanabilmektedir. En önemli zorluklardan biri veri setini eğitmek için model parametrelerini belirlemektir. Bunlar aktivasyon fonksiyonu, katman sayısı, dönem, ağırlık vb. parametrelerdir. Bu parametrelerin tanımları ilgili referansta ayrıntılı olarak verilmiştir [56].

Derin öğrenme mimarileri, kullanılan eğitim algoritmalarına göre farklı gruplara ayrılabilir. Yaygın olarak kullanılan derin öğrenme mimarilerine evrimsel sinir ağı, yığılmış oto kodlayıcılar (SAE), sınırlı Boltzmann makinesi (RBM), tekrarlayan sinir ağı (RNN) örnek olarak verilebilir. Bu çalışmada kullanılan algoritmalar aşağıdaki bölümde detaylı olarak verilmiştir.




Şekil 3.4 Derin Öğrenmenin Temelleri

3.4.1 Evrişimsel Sinir Ağları (CNN)

Yaygın olarak kullanılan derin öğrenme algoritmalarından biri olan CNN, tek veya daha fazla evrişimsel katmanı ve bunun ardından bir veya daha fazla ile ileri beslemeli katmanla donatılmış derin sinir ağıdır. Klasik CNN, evrişimsel katman, havuzlama katmanı, tam bağlantılı (FC) katman yapılarının ard arda sıralanması ile oluşturulmaktadır. Bu denklemler sırasıyla denklem 3.4, 3.5 ve 3.6'da verilmiştir. Girdileri standart hale getirmek ve aşırı öğrenmeyi önlemek için genellikle bırakma (dropout) ve toplu normalleştirme (batch normalization) kullanılır. Şekil 3.5'te bir giriş katmanı, bir evrişim (konvolüsyon) katmanı, filtreler katmanı, havuzlama katmanı, tam bağlantılı katman ve sınıflandırma katmanını içeren temel bir CNN mimarisini gösterilmektedir. Giriş katmanında kullanılacak olan veri ham olarak ilgili ağa verilir. Verinin büyüklüğü ağın doğruluğunu doğrudan etkilemektedir. Veri kapasitesi büyüdükçe de yüksek belleğe ve eğitim süresine ihtiyaç duyulmaktadır. Konvolüsyon katmanı ve filtreler bu sinir ağının temelini oluşturmaktadır. Giriş verisi üzerinde dönüşüm işlemi filtreler ile sağlanmaktadır. CNN'lerde bir aktivasyon fonksiyonu olarak doğrultulmuş lineer birim ünitesi (ReLU) uygulanmaktadır. Bu katman ile giriş verisindeki negatif değerler sıfıra çekilir.

Konvolüsyon katmanındaki doğrusal olan yapıyı doğrusal olmayan bir yapıya dönüştürerek aktifleştirir. Havuzlama katmanı aktivasyon fonksiyonundan sonra kullanılır ve bir sonraki konvolüsyon katmanı için giriş boyutunun genişliğini ve yüksekliğini azaltma görevini ifa eder. Bu sayede verilerin ezberlenmesinin önüne geçilir ve hesaplama maliyeti düşer. Tam bağlantılı katman ise bu katmanlardan sonra gelir ve kendisinden önce gelen evrişimsel katmanın tüm alanlarına bağlıdır. Seyreltme katmanı ise bazı durumlarda ağın ezberlemesinin önüne geçmek için bu mimarilerde kullanılabilir. Son olarak çıkış katmanında ise sınıflandırma yapılır ve genellikle softmax fonksiyonu başarısından dolayı tercih edilir. Ağın sınıflandırma tipine göre belirli miktarda çıktı üretir. Ada çalışma tespitinde sınıflandırma sayısı şekilden de görüleceği üzere ada ve ada olmayan durumlar olmak üzere ikidir.



Şekil 3.5 Tek boyutlu konvolüsyonel ağların yapısı

$$x_{o,fl}^l = f(\sum_{i,m} x_i^{l-1} * k_{i,o,fl}^l + b^l) \quad (3.4)$$

$$x_o^l = f[\max(\sum_{i,m} x_i^{l-1}) + b^l] \quad (3.5)$$

$$x_o^l = f(x_i^{l-1} * d_{i,o}^l + b^l) \quad (3.6)$$

Burada; x tek boyutlu giriş matrisini ($n \times 1$), $f(\cdot)$ aktivasyon fonksiyonunu, $k_{i,o,fl}^l$ kernel filtresini ($k \times 1$), $x_{o,fl}^l$ konvolüsyon ağın çıkış katmanını, b bias vektörünü, d ise öğrenme parametrelerini göstermektedir.

CNN yapıları son yıllarda geleneksel makine öğrenmesi yöntemlerine kıyasla görüntü tanıma, konuşma tanıma, doğal dil işleme, farklı alanlardaki

sınıflandırma problemlerinde yüksek doğruluk elde ederek araştırmacıların ve endüstrinin sıklıkla başvurduğu derin öğrenme algoritmalarındandır [51]. Bu tez çalışmasında da literatürdeki bu örneklerle dayanarak güç sistemlerinde ada çalışmanın tespit edilmesinde başvurulan en önemli algoritmalarından olmuştur.

3.4.2 Uzun Kısa Bellek Ağları (LSTM)

Tekrarlayan ağlar (recurrent) yapay sinir ağları türlerinden biri olup, yönlü çevrimlerden oluşan bir kaç birimin birbirleri ile bağlantısı sonucu oluşmaktadır. Zaman serileri gibi problemlerde veriler de doğası gereği sıralı ve bağlı olup bir sonraki değer önceki değere bağlıdır. Kendi içinde sahip oldukları döngülerle hem yeni gelen bilgiyi işler, hem de önceden gelen bilgileri kendi içinde tutabilirler. Ağın yapısı giriş seviyesindeki sinir ağı planının önceki veriyi kullanarak sonraki veriyi tahmin etme potansiyeline sahiptir [52],[53]. Tekrarlayan ağlarda en yaygın kullanılan yapı LSTM (uzun kısa süreli bellek ağları) olmuştur. Bellek hücreleri ve kapılardan oluşan LSTM, gradyan düşümü problemlerine çözüm olarak ve karmaşık zaman serilerinin üstesinden gelmek için üretilmiştir [54].

LSTM, tekrarlayan sinir ağlarının bir türü olup, uzun vadeli geçici bağımlılıkları yakalar ve kaybolan gradyan problemlerinin üstesinden gelir. RNN'lerin gizli katmanları, bellek hücreleri ve kapıları içeren LSTM birimleri ile değiştirilir. Bellek hücreleri (C) kapıların kontrolüyle ile bilgiyi depolar. Bellek hücresinin içine ve dışına bilgi akışını kontrol etmek için kullanılan giriş kapısı (input gate), çıkış kapısı (output gate) ve unut kapısı (forget gate) vardır. LSTM, metin sınıflandırma, zaman serisi modelleme gibi sıralı modelleme görevlerinde etkin bir şekilde kullanılır. LSTM mimarisi Şekil 3.2'de gösterilmektedir. Bir LSTM bloğu için matematiksel ifadeler denklem 3.7 ile 3.12 arasında verilmiştir.

$$i_t = \sigma(x_t U^i + h_{t-1} W^i + b_i) \quad (3.7)$$

$$f_t = \sigma(x_t U^f + h_{t-1} W^f + b_f) \quad (3.8)$$


$$o_t = \sigma(x_t U^o + h_{t-1} W^o + b_o) \quad (3.9)$$

$$C_t = \sigma(f_t \odot C_{t-1} + i_t \odot \check{C}_t U^i + b_c) \quad (3.10)$$

$$\check{C} = \tanh(x_t U^g + h_{t-1} W^g) \quad (3.11)$$

$$h_t = \tanh(C_t) \odot o_t \quad (3.12)$$


Yukarıda verilen denklemler yapay sinir ağlarının temeliyle aynı olup giriş vektörünün ağırlık matrisi ile çarpılıp bias vektörüyle toplanarak bir aktivasyon fonksiyonundan geçirilmesine dayanır. Diğer farklılar ise Şekil 3.6'ta detaylı olarak verilmiştir.



Şekil 3.6 LSTM mimarisi ve iç yapısı

3.4.3 Tek Boyutlu CNN and LSTM Ağlarının Kombine Edilmesi

CNN-LSTM'nin kombine edilmesiyle hem yerel bilgileri hem de uzun seri dizilerini içeren üst düzey özelliklerin öğrenmesi sağlanır. CNN katmanları, ham verileri işler ve küresel zamansal bilgi çıkarımı sağlarken, LSTM katmanları ise sınıflandırma için kullanılabilecek bu tür yerel bilgileri çıkarmayı sağlar. Şekil 3.7'te 1D CNN-LSTM ağının bir örneği; iki evrişim katmanından, bir havuzlama katmanından, bir LSTM katmanından, tam bağlantılı katmandan ve çıktı katmanından oluşmaktadır.



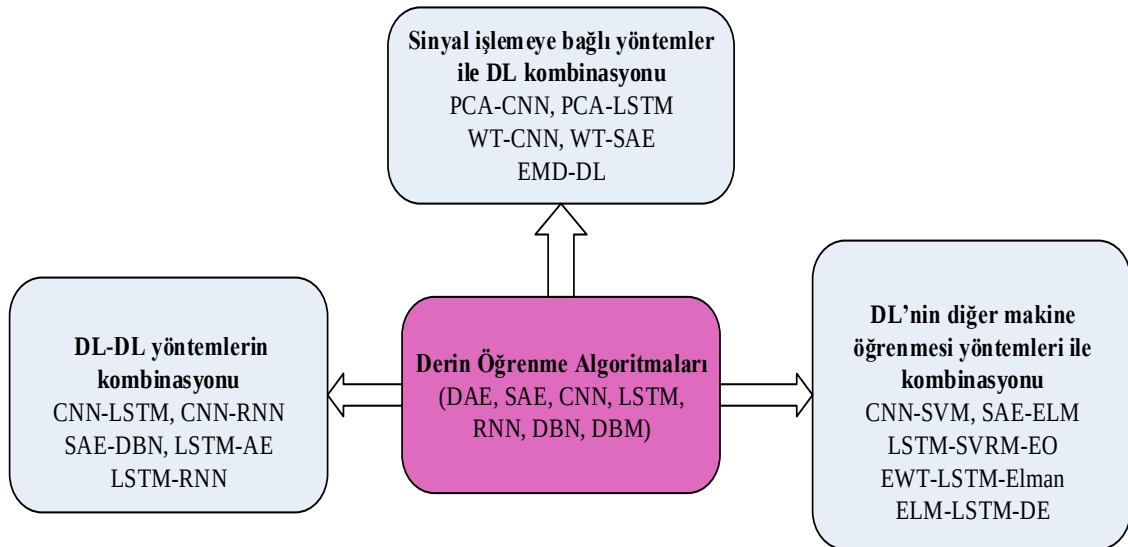
Şekil 3.7 Tek boyutlu evrişimsel ağların yapısı

3.5 Güç Sistemlerinde Derin Öğrenme Uygulamaları

Akıllı şebeke kavramı günümüzde kullanılan enerji talebi, üretim ve depolama alanlarını entegre edebilen güç sistemlerinin geliştirilmesiyle ortaya çıkmıştır. Bu şebekeler, Enerji tüketimini en aza indirmek ve kullanımını optimize etmek için olağanüstü düzeyde enerji üretme ve dağıtma esnekliği gerektirir. Ayrıca akıllı güç sistemleri alanındaki dağıtık üretimlerin geniş çapta kullanılması, artan güç talebi, elektrik şebekelerinin verimliliği ve kalitesindeki önemli ihtiyaçlar gibi son gelişmeler güç sistemlerinin yeniden planlanması, işletilmesi ve kontrolünü zorunlu hale getirmiştir. Güç sisteminin kompleks ve doğrusal olmayan bir yapıya dönüşmesi mevcut yöntemleri elverişsiz kılmaktadır. Bu bağlamda son yıllarda güç sistemlerinde makine öğrenimi, yapay sinir ağları ve derin öğrenme teknikleri gibi çok sayıda yapay zeka uygulaması mevcut sorunları giderebilmek için güç sistemlerinde önerilmektedir.

Bu bölümde son yıllarda derin öğrenme yönteminin kullanıldığı elektrik güç sistemi uygulamalarına yer verilmiştir. Bu uygulamalar yük, rüzgar ve güneş enerjisi tahmini, güç kalitesi bozulmalarının tespiti ve sınıflandırılması, güç sistemi ve ekipmanlarında arıza tespiti ve diğer uygulama alanları olmak üzere dört kategoride incelenmiştir ve Tablo 3.1'de özet olarak verilmiştir.

Yöntemleri birleştirme fikri, tek tek yöntemlerin dezavantajlarının üstesinden gelmek için farklı algoritmaların birlikte kullanılması olarak tanımlanabilir. Böylece güç sistemlerinde DL uygulamalarını içeren birleşik yaklaşımlar Şekil 4'te gösterildiği gibi üç grupta sınıflandırılabilir. Birinci birleştirilmiş yaklaşımlar, LSTM-AE, SAE-DBN ve CNN-LSTM gibi iki DL algoritması oluşturularak elde edilir. İkinci birleştirilmiş yaklaşımlar, veri filtreleme, veri ayrıştırma gibi veri ön işleme ile gerçekleştirilir. Örneğin dalgacık dönüşümü (WT), WT-SAE, EWT-LSTM-Elman sinir ağı, WT-DNN gibi DL yöntemleri ile veri ayrıştırması için birleştirilir. Son olarak, bazı yaklaşımlar, SAE-DVM, SAE-ELM ve derin pekiştirmeli öğrenme (DRL) gibi makine öğrenme algoritmaları ile birleştirilmiştir. Bu birleştirilmiş yöntemler de aşağıdaki bölümlerde ayrıntılı olarak belirtilmiştir. Ayrıca güç sisteminde kullanılan derin öğrenme algoritmaları ve bu algoritmaların farklı yöntemlerle kombinasyonu Şekil 3.2'de gruplandırılmıştır.



Şekil 3.8 Derin öğrenme algoritmalarının farklı yaklaşımlarla kombinasyonu

Tablo 3.1 Güç sistemlerinde derin öğrenmenin kullanımı


Problem Kategorileri	Yöntemler	Elektrik Güç Sistemindeki Uygulamalar	Eğitimde Kullanılan Veriler
*Yük Tahmini	LSTM-RNN, DBN, RBM Deep CNN	*Yük Tüketim Tahmini	*güç tüketimi, yük karakteristiği, evsel davranışlar
*Rüzgar Gücü Tahmini	LSTM-RNN,	*Rüzgar hızı, rüzgar gücü	*rüzgar hızı, rüzgar yönü, rüzgar gücü, sıcaklık, atmosfer basıncı, nem...
*Güneş GücüTahmini	CNN and K-Means Clustering, FF-DNN, D-RNN	*Güneş gücü, güneş ışıınım tahmini	*güneş radyasyonu, ışıınım, güneş hava verileri
Güç Kalitesi Problemlerinde Tespit ve Sınıflandırma	SAE, SAE-SVM, WT-SAE, CNN, Wide-CNN, CDBN, FF-DNN, SSAE	*Güç kalitesi bozuklukları sınıflandırma *Ada Çalışma	*gerilim ve akım sinyalleri *efektif gerilim akım ölçümleri, aktif güç , reaktif güç, frekans, harmonik ölçümleri...
Güç Sistemi ve Ekipmanlarında Arıza Tespiti ve Sınıflandırma	SAE, WT-DNN, LSTM-SVM, DNN, DBN-DNN, CSAE	* Güç sistemlerinde arızaların sınıflandırılması ve tespiti (tek faz, iki faz, faz-faz...) *Transformatör, dişli kutusu, yakıt hücresi arıza tespiti	*dişli arıza verileri, rotor akım sinyalleri, dişli kutusu yağı, basınç verisi, transformatör yağ verisi, akım ve gerilim sinyalleri...
Güç Sistemlerindeki Diğer Uygulamalar	Derin pekiştirmeli öğrenme, BM, WT-DNN, Wide-Deep CNN	*Akıllı şebekelerde yanlış veri ilavesi tespiti *Güç sistem güvenliği (siber atak tespiti) *Akıllı şebekelerde elektrik kaçak tespiti *Yenilenebilir enerji sistemleri optimizasyonu	*geçmiş enerji verileri güç üretim, tüketim verileri elektiriksel cihaz verileri yangın, doğal felaket, çevre kirliliği verileri, enerji kesinti verileri...

Son yıllarda Tablo 3.1’den de görüldüğü üzere güç sisteminin pek çok alanında derin öğrenme yöntemleri yoğun olarak kullanılmıştır. Literatürdeki makaleler incelendiğinde uygulama alanları arasında en çok kullanılan alan ise geçmiş

verilerinde geniş çapta elde edilebilir olması avantajı ile yenilenebilir enerji sistemlerindeki tahmin uygulamalarıdır. Bunun yanı sıra mevcut veri kullanımının kısıtlı olduğu arıza teşhisi, güç kalitesi bozukluklarının tespiti gibi uygulamalar için yapay veriler simülasyon programları üzerinden veri seti elde edilerek gerçek zamanlı uygulamalar ile derin öğrenme yöntemleri kullanılmaktadır. Teknolojinin ilerlemesi ile birlikte akıllı şebekelerdeki veri kayıt sisteminin gelişmesi ve akıllı cihazların kullanımının artması ile gerçeğe dayalı geniş çapta veri elde edilmesi bu tür yapay zeka uygulamalarının güç sistemlerinde yaygın olarak kullanılmasında büyük kolaylık sağlayacaktır.


4.1 AEP/CERTS Mikro Şebeke Modeli

Tez çalışmasının bu aşamasında daha önce çeşitli analizleri yapılan inverter, senkron ve inverter-senkron kaynaklı mikro şebeke modeli referans alınan gerçek bir mikro şebeke modeline adapte edilmiştir. Referans olarak seçilen model CERTS (The Consortium for Electric Reliability Technology Solution) ile AEP (American Electric Power) işbirliğinin oluşturduğu laboratuvar mikro şebeke test sistemidir [55]. Sistemin orijinalinde iki adet inverter kaynaklı dağıtık üretim ile senkron makine içeren doğal gaz kaynaklı dağıtık üretim ve ayrıca bir enerji depolama sistemi bulunmaktadır ve Şekil 4.1’de gösterilmiştir. Bu mikro şebekeyi baz alarak oluşturduğumuz modelde A1 ve B1 dağıtık üretimleri ile bunlara bağlı yükler kullanılmıştır ve Şekil 4.2’de verilmiştir. Sistemin parametreleri [56], [57], [58], [59] numaralı referanslardan derlenerek oluşturulmuştur. Test sistemi 480 volt ve 60 Hz frekans ile çalışmaktadır. Kullanılan inverter bazlı doğalgaz kaynağı A1: 100 kW [60], B1 senkron generatörlü doğal gaz kaynağı ise 93 kW değerindedir [61]. Kullanılan yükler eşit ve değişken olup her biri 0-90 kW ile 0-45 kVar arasındadır [62].



Şekil 4.1 AEP/CERTS mikro şebeke tek hat diyagramı

Mikro şebeke modelinde statik anahtar, simülasyon süresi içerisinde belirli sürede aktif edilmek üzere ayarlanmıştır. Bu süre içinde şebeke ve dağıtık üretim değerleri senkronizasyonu sağladığı anda şebekeye bağlantı gerçekleşmektedir. Bu durum içinde şebekenin gerilimi ile dağıtık üretim kaynağının gerilimi arasındaki faz farkının 0 olması gerekmektedir.




Şekil 4.2 Modifiye edilmiş AEP/CERTS mikro şebeke tek hat diyagramı

Tablo 4.2 Ada çalışma tespitinde kullanılan mikro şebekenin elektriksel parametreleri

Sistemin Model Parametreleri	
Parametre	Tanım
Ana Şebeke	13.2 kV, 1500 kVA
Senkron Gen.	480 V, 93kW
İnverter	480 V, 100kW
Yük 3-5-6	0-90 kW, 0-45 kVAR
Trafo 1	250 kVA, 13.2 kV/480 V
Trafo 2 & Trafo 3	100 kVA, 480 V/480 V
İletim Hattı	Z1 : $R=0.0225 \Omega$, $X=0.0055 \Omega$ Z2 : $R=0.00535 \Omega$, $X=0.00068 \Omega$ Z4: $R=0.0259 \Omega$, $X=0.00345 \Omega$ Z3=Z5=Z6 : $R=0.0194 \Omega$, $X=0.0026 \Omega$

4.2 Mikro Şebekeye Senkron ve İnverter Kaynaklı Dağıtık Üretimlerin Eklenmesi Durumu

Bu çalışmada önerilen ada yöntemlerinin performanslarını değerlendirmek amacıyla mevcut yöntemin kullanıldığı iki farklı dağıtık üretime sahip AEP/CERTS mikro şebeke modeli ilave kaynaklar kullanılarak Şekil 4.3'teki gibi genişletilmiştir. Genişletilen model önerilen ada çalışma tespit metotlarının performansını değerlendirmek üzere kurulmuştur. Bölüm 6.4'te bu sonuçlar detaylı olarak verilmiştir.




Şekil 4.3 AEP/CERTS mikro şebekede ilave kaynakların eklenmesi durumu

Bu genişletilmiş model için Şekil 4.3'te görüldüğü üzere arıza durumu, motor devreye girmesi, doğrusal olmayan yük ve kapasitör anahtarlama gibi ada olmayan çalışma durumları da yeni senaryolar olarak önerilen metotlarda test edilmek üzere gerçekleştirilmiştir.

5.1 Giriş

Akıllı yöntemlerin kullanıldığı metotlarda öğrenme işleminin temel adımları; öğrenmenin gerçekleştirileceği verilerin yani giriş parametrelerinin belirlenmesi, bu girişlere ait kapsamlı bir veri setinin oluşturulması ve daha sonra kullanılacak metot ile öğrenme işlemi için eğitim ve test aşamaları olarak sıralanabilir. Bu tez çalışmasında da ilk olarak ada çalışmaya etki eden elektriksel büyüklüklerin ortaya çıkarılması hedeflenmiştir. Bu amaçla kullanılan mikro şebeke topolojisi üzerinde çeşitli simülasyonlar yapılmış ve ada öncesi ve ada sonrası durumlar için on farklı elektriksel parametrenin değişimi gözlemlenmiştir. Çalışmanın ikinci aşamasında bu parametreler dikkate alınarak ada ve ada olmayan senaryolar ortaya çıkarılmış ve önerilecek algoritmada giriş verileri olarak kullanılmak üzere kayıt edilmiştir. Bu kapsamda ilk aşamada tek kaynaklı dağıtık üretim durumları için ölçümler alınmış olup daha sonra iki farklı dağıtık üretim kaynağının olduğu nihai mikro şebeke modeli için ölçüm işlemleri tamamlanmıştır. Yaklaşık 3000 farklı senaryo ile veri setleri elde edilmiştir. Üçüncü aşama olarak bu veriler derin öğrenme algoritmalarında LSTM yöntemi ile eğitim ve test işlemlerine tabi tutulmuştur. Aynı zamanda kullanılan veri seti için en uygun izleme süresi, eğitim/test oranı, tur sayısı, öğrenme algoritması gibi ağın doğruluğunu etkileyen hiper parametreler deneysel yollarla belirlenmiştir. Bu aşamadan sonra LSTM yöntemi klasik yapay sinir ağı ve konvensiyonel makine öğrenmesi algoritmaları ile karşılaştırılarak performans değerlendirmeleri yapılmıştır. Bu sonuçlarda LSTM yöntemi en yüksek doğruluk sağlayan öğrenme algoritması olmuştur. Tezin dördüncü aşamasında ise derin öğrenme algoritmalarından 1D-CNN yöntemi ve CNN-LSTM algoritmaları birleştirilerek oluşturulan mimari ada çalışma tespitinde farklı öneriler olarak test edilmiştir. Bu üç algoritma kendi aralarında performans testlerine tabi

tutulmuş olup avantaj ve dezavantajları ortaya çıkarılmıştır. Tezin beşinci aşamasında ise literatürdeki çalışmalardan farklı olarak düşük güç değişimine sahip durumlar için daha önce görülmeyen veriler test edilmiştir. Aynı zamanda iki farklı kaynağa sahip mikro şebeke modeli genişletilmiş ve yeni senkron ve inverter arayüzlü kaynaklar da eklenerek 600 farklı yeni senaryo için örnekler kayıt edilmiştir. Bu örnekler de eğitim ve test verisine eklenmeden oluşturulan algoritma ile test edilmiştir. Böylece önerilen modellerin genelleştirilebilirliği yapılan testlerle ortaya konmuştur. Son aşamada ise önerilen yöntemler literatürdeki mevcut çalışmalarla karşılaştırılarak tablo halinde sunulmuştur. Bu aşamaların sadece LSTM modeli için gerçekleştirilen adımları görsel olarak Şekil 5.1’de özetlenmiştir.




Şekil 5.1 Önerilen LSTM ada çalışma tespit yönteminin işlem aşamaları


5.2 Giriş Parametrelerinin Belirlenmesi

Tezin ilk aşamasında önerilen yöntem için kullanılacak parametrelerin belirlenmesinde harmonik değerlerin şebekeye bağlantılı çalışma durumunda ve şebekeden bağımsız yani ada çalışma durumunda etkisini incelemek üzere farklı

simülasyon çalışmaları yapılmıştır. Bu çalışmalar sonucunda modifiye edilmiş AEP/CERTS mikro şebeke modelinde harmonik değerlerin değişiminin ada çalışma üzerinde önemli değişikliklere sebep olduğu görülmüş ve Şekil 5.2 ve 5.3'te bu değişiklikler verilmiştir. Şekilden de anlaşılacağı üzere şebeke bağlantılı durumdan ada çalışmaya geçerken gerilim harmoniklerinin arttığı, akım harmoniklerinin ise azaldığı gözlemlenmiştir.



Şekil 5.2 AEP/CERTS sistemi için gerilim harmonikleri



Şekil 5.3 AEP/CERTS sistemi için akım harmonikleri

Geniş ve kapsamlı bir veri seti sayesinde farklı kombinasyonlar yaparak hangi parametrelerin ada çalışmanın tespit edilmesinde daha etkili olduğunu görebilmek mümkün olmuştur. OBN'de kayıt edilen 10 farklı parametrenin makine öğrenmesi algoritmalarında nasıl sonuçlar vereceğini ortaya konmuştur. Yapılan simülasyon çalışmalarında giriş parametreleri farklı eğitim/test oranları ile birlikte kullanılmıştır. Bu kombinasyonlar Tablo 5.1'de verilmiştir. Burada ortaya çıkan en önemli sonuç bütün parametrelerin bir arada kullanılması her zaman en iyi sonucu vermediğidir. Bunun yerine ada çalışmayı tespit eden az sayıda ama yüksek doğruluğa sahip parametrelerin kullanılması hem işlem

süresini kısaltmakta hem de hesaplama maliyetini düşürmektedir. Tez çalışmasının başında yapılan simülasyon sonuçlarını doğrulayan nitelikte ada çalışma tespitinde gerilim ve akım harmoniklerinin önemi bu sonuçlarda da görülmektedir.

Öncelikle sadece LSTM yöntemi kullanılarak giriş parametre sayısı 1'den başlayarak tüm parametrelerin kullanıldığı hale gelene kadar öğrenme çalışmaları yapılmıştır. Bu çalışmalardan belli başlı olanlar aşağıdaki Tablo 5.1'de verilmiştir. Elde edilen sonuçlarda ada çalışmanın tespitinde yüksek etki gösteren başlıca parametreler gerilimin ve akımın toplam harmonik distorsiyonu ile gerilimin 3. ve 5. tekil harmonikleri olmuştur. Diğer yandan gerilimin tek faz ve üç faz efektif değeri, statik anahtarın aktif gücü kendi başına ve diğerleri ile birlikte kullanıldığında doğruluğun düşmesine sebep olmuştur. Mevcut parametrelerden frekans değişimi ise çalışmaya olumsuz bir katkı sağlamasa da doğruluk üzerinde yükseltici bir parametre olamamıştır.

İlk aşama çalışmadan sonra tüm değişkenlerin bir arada kullanıldığı durum ile sadece üç önemli değişkenin kullanıldığı durum diğer klasik yöntemlerle karşılaştırılmıştır. Detaylı olarak sonuçlar Tablo 5.1 ve 5.2'de verilmiştir.

Tablo 5.1 Giriş Değişkenlerinin farklı kombinasyonları ile LSTM yönteminin gösterdiği doğruluk değerleri

Eğitim/Tes t Oranı	THD _v	THD _i	V _{rms}	THD _v + THD _i	THD _v + 3.harm	THD _i + 3.harm	THD _v +V _{rms}	THD _v + THD _i +3.har m	THD _i +3.v e 5.harm	Bütün değişkenle r
80/20	95,9	95	57,3 2	98,75	98,93	98,93	74,1 1	98,21	98,04	98,21
75/20	93,9	95,4	56,8 6	99	98,86	99,29	75,2	99,29	98,43	98,43
70/30	92,7	96	60,1 2	98,7	99,3	98,93	74,3	99,4	99,17	98,45
65/35	93,3	96	63,9 8	98,3	98,47	99,39	73,9	98,37	99,18	98,16

(İşaretlenen veri en yüksek doğruluk değerini göstermektedir)

Derin öğrenme algoritmalarından LSTM ile yapılan sonuçların yanı sıra giriş parametrelerinin etkisi diğer klasik makine yöntemleri üzerinde de incelenmiştir. LSTM ile en az sayıda parametre ile en yüksek doğruluk %THD_v ve %THD_i gerilimin 3. harmonikleri ile sağlanmıştır. Tablo 5.2'de verilen doğruluklar genel doğruluk değerinin dışında kullanılan yöntemin ada çalışmayı ve ada olmayan çalışmayı tespit etmedeki performansını gösteren doğruluk değerleri de ayrı ayrı

verilmiştir. Bu sonuçlardan ortaya çıkan genel sonuç ise tüm yöntemlerin ada olmayan çalışma durumlarını daha iyi tespit edip, ada olan durumları tespit etmede daha düşük başarı göstermesidir. Bu sonuçlara göre bütün parametreler kullanıldığında karar ağacı ve k-NN yöntemleri önerilen yöntem ile yakın sonuçlar verse de az sayıda değişken kullanıldığında önerilen yöntemin yaklaşık %10 daha iyi sonuç verdiği gözlemlenmiştir.

Tablo 5.3 Giriş parametrelerine göre AÇT yönteminde elde edilen performansların karşılaştırılması

Giriş Parametreleri	Doğruluk	LSTM	DT	k-NN	LR	SVM	Naive Bayes
3 (%THDv, %THDI, 3. harm)	Ada çalışma	98,1	87,7	88,4	0	3	13
	Ada Olmayan Ç.	100	92,3	82,6	98,2	98,5	95,7
	Toplam	99,25	90,5	86,1	60,4	60,8	45,6
10 (Bütün değişkenler)	Ada çalışma	97,2	97,2	96,8	81,1	84,1	57,1
	Ada Olmayan Ç.	99,4	98,8	98,8	84,5	94,9	95,5
	Toplam	98,7	98,2	98	83,1	90,6	72,2

5.3 Önerilen Yöntemler İçin Elde Edilen Veri Setleri

Makine öğrenmesi kullanılan uygulamaların en önemli kısımlarından biri algoritmanın uygulanacağı giriş değişkenlerinin belirlenmesi ve bu değişkenlerin elde edilmesidir. Kullanılan değişken sayısı azaldıkça işlem kompleksliği ve eğitim süresi kısalmaktadır. Bu da uygun değişkenlerin seçiminin önemini arttırmaktadır. Özellikle ada çalışma gibi durumların tespitinin IEEE 1547 numaralı standardında belirtildiği üzere 2 saniyeden daha kısa sürede tespit edilmesi gerekmektedir. Yapılacak olan çalışmada bu durum dikkate alınıp simülasyon testleri ile ada çalışmaya etkisinin olduğu tespit edilen gerilim ve akımın toplam harmonik distorsiyonu ve tekil harmonik değerleri üzerinde durulmuştur.

Verilerin elde edilmesi kısmında gerçek dünyadan alınan ölçümler ve simülasyon çalışmalarında oluşturulan benzetimler ile iki seçenek söz konusudur. Ölçüm cihazlarından alınan veriler üzerinde çalışmak hem çalışmanın doğruluğu arttırmakta hem de verileri elde etme aşamasını önemli derecede kısaltmaktadır. Yalnız güç sistemleri gibi konularda gerçek veri elde etmek oldukça zordur.

Geçmiş verilerin kaydedilmemesi, henüz uygulama aşamasına yeni geçilmiş mikro şebekelerin yeterli sayıda olmayan veri kayıtları gibi nedenler bu işlemi daha da zorlaştırmaktadır. Bu nedenle yapılan simülasyon çalışmaları ile gerçeğe en yakın ölçüde sistemler oluşturulmakta ve gerekli veri eldesi bu çalışmalar üzerinden sağlanmaktadır. Bu uygulamanın bir diğer avantajı da gerçek durumda meydana gelmemiş olan fakat simülasyonda gerçekleştirilmesi mümkün olan yüzlerce farklı çalışma kombinasyonu bilgisayar ortamında sağlayabilmesidir.

IEEE 1457 standardında belirtildiği şekilde OBN'deki aktif güç değişimi ve reaktif güç değişimi sıfıra ayarlanmalıdır. Bu durumda gerilim ve akım değerleri arasındaki değişim ada çalışma olayı öncesi ve sonrası neredeyse sıfıra düşecektir. Ada çalışma için önerilecek metodun da bu durumlarda dahi ada çalışmayı doğru şekilde tespit edebilmesi gereklidir. Bu çalışmada da ada çalışma olayları için üretim ve tüketim arasında düşük NDZ'ye sahip çeşitli güç değerleri dikkate alınarak veriler oluşturulmuştur.

Ada çalışmanın diğer durumlardan ayırt edilebilmesi için ada çalışmanın meydana gelmediği fakat sistemde değişimlere neden olan olayların da incelenmesi gerekmektedir. Etkili bir AÇT yöntemi ada çalışma durumunu arıza olayları, diğer yüklerin ve dağıtık üretimlerin açma kapama olayları, kapasitör, motor veya doğrusal olmayan yükler gibi farklı yüklerin anahtarlama olayları ile karıştırmamalıdır. Mevcut literatürde bu ada çalışma durumlarının meydana geldiği olasılıklar yaygın olarak yüklerin ve dağıtık üretimlerin farklı güç değerlerindeki kombinasyonları şeklinde ele alınmaktadır. Bu çalışmada üretim ve tüketim kaynaklarının farklı çalışma kapasiteleri ele alınarak ada olmayan çalışma durumları simülasyon ile gerçekleştirildi.

Bu durumlar literatürde de yaygın olarak aşağıdaki başlıklarda verildiği gibi arızalar, sistemde kapasitörün devreye girip çıkması, yüklerin devreden çıkmaları, doğrusal olmayan veya motor yüklerin devreye girmesi olarak sıralanabilir [23], [63], [64] . Bu tez çalışmasında da referanslarda dikkate alınan ölçütlere göre bir veri eldesi oluşturulmuştur.

Tablo 5.4 Ada Çalışma Tespitinde Kullanılan Veri Seti Senaryoları


Ada Çalışma Durumları		Ada Olmayan Çalışma Durumları	
Tanımlar	Sayı	Tanımlar	Sayı
Yük Değişimleri (PF:0,7-0,8-0,9-1) (%20 ile %100 arasında yüklenme durumları)	255	Arıza Durumları (üç faz toprak, iki faz toprak, tek faz toprak, faz-faz arızası)	400
Harmonikli Şebeke (%1,75-%3)	80	Kapasitör Anahtarlama (50-100-200-500 kVar)	95
İnverter kademeli üretim (0-20-40-60-80-100-110 kW)	80	Motor yükü Devreye Girmesi (100-200-400 kW)	80
Senkron kademeli üretim (0-20-40-60-80-100-110 kW)	80	Doğrusal olmayan yük anahtarlama (%1,5, %2.5, %5, %6, %10 harmonikli)	100
Sadece senkron kaynak devrede Yük Değişimleri (PF:0,7-0,8-0,9-1)	128	Arıza Durumları (üç faz toprak, iki faz toprak, tek faz toprak, faz-faz arızası) (sadece senkron devrede)	112
Sadece senkron kaynak devrede Harmonikli Şebeke (%1,5-%2)	32	Kapasitör Anahtarlama (50-100-250-500 kVar) (sadece senkron devrede)	64
Sadece inverter kaynak devrede Yük Değişimleri (PF:0,7-0,8-0,9-1)	96	Motor yükü Devreye Girmesi (50-75-160-250 kW) (sadece senkron devrede)	64
Sadece inverter kaynak devrede Harmonikli Şebeke (%1,5-%2)	32	Arıza Durumları (üç faz toprak, iki faz toprak, tek faz toprak, faz-faz arızası) (sadece inverter)	160
Harmonikli şebeke (%3)	55	Kapasitör Anahtarlama (50-100-250-500 kVar) (sadece inverter)	80
PF=0,8 , büyük güç değişimi	15	Motor yükü Devreye Girmesi (80-110-160 kW) (Sadece inverter)	48
NDZ bölgesinde durumlar (inverterin reaktif güç üretmesi (Vref (0,95-1,05)- PF=0,95, PF=1)	190	PF:0,95 harmonikli durumda (arıza-kapasitör-motor- doğrusal olmayan yük anahtarlama)	66
Dağıtık üretimler farklı güçlerde yüklenmesi (%20 ile %110 arasında çeşitli değerler)	100	Harmonikli şebeke (%3)(arıza-kapasitör-motor-doğrusal olmayan yük anahtarlama)	120
		PF=0,8 harmonikli şebeke (%3) (yüklerin veya dağıtık kaynakların devreden çıkması)	60
		PF=0,8 harmonikli şebeke (%3) (arıza-kapasitör-motor-doğrusal olmayan yük anahtarlama)	90
		PF=0,9 (yüklerin veya dağıtık kaynakların devreden girip çıkması)	90
		NDZ bölgesinde ada olmayan durumlar	28
	1143		1657
Toplam		2800	

5.4 Önerilen AÇT Metotları için İzlenen Adımlar

Giriş bölümünde detaylı şekilde anlatıldığı gibi tez çalışmasının ilk aşamasında elde edilen veri seti ile derin öğrenme algoritmalarından LSTM yöntemi ada çalışmanın tespit edilmesi için kullanılmıştır. Bu ilk aşama için kullanılan giriş sayısı, kayıt edilen verinin izleme süresi, toplam veri sayısı gibi parametreler bu bölümde analiz edilmiştir. İlk aşamada ayrıca LSTM yöntemi, klasik makine öğrenmesi yöntemlerinden karar ağacı, destek vektör makinesi (SVM), lojistik regresyon, naive bayes sınıflandırıcı ve k-NN (en yakın komşu) ve klasik yapay sinir ağı (YSA) ile karşılaştırılmıştır. Buradan elde edilen en uygun parametreler tezin ikinci aşamasında önerilen 1D CNN ve CNN-LSTM yöntemlerinde direkt kullanılmış ve derin öğrenme algoritmaları kendi aralarında karşılaştırılarak değerlendirme yapılmıştır.

5.4.1 Ada Çalışma Tespiti İçin Önerilen LSTM Metodu

Bölüm 3.4.2’de LSTM algoritmasının teorik detayları ve matematiksel denklemleri verilmiştir. Bu bölümde ada çalışma tespiti için kullanılacak LSTM algoritması için en yüksek doğruluk sağlayan en uygun modelin oluşturulması amaçlanmıştır. Bu bağlamda mevcut veri seti Şekil 5.4’te görüldüğü gibi LSTM hücresinin farklı tasarımları ile eğitilmiştir. İlk örnekte sadece bir tek LSTM ünitesi ile kullanılmış ve % 97,1 doğruluk ve 0,1 kayıp faktörü elde edilmiştir. İkinci örnekte ise iki adet LSTM ünitesi birbirine bağlanarak yeni bir model oluşturulmuş ve bu modelde %98,4 doğruluk ve 0.07 kayıp faktörü elde edilmiştir. Üçüncü model biraz daha geliştirilerek iki LSTM ünitesine bir de seyreltme (dropout) katmanı eklenmiş ve yaklaşık %99 doğruluk ve 0.05 kayıp faktörüne ulaşılmıştır. Bu şekilde ağ üzerindeki hiper parametrelerde değişiklik yapılarak ve optimizasyon yöntemleri kullanılarak en iyi performans gösteren model tipi olan nihai model seçilmiştir. Kullanılan en uygun hiper parametreler ayrıca Tablo 5.4’te verilmiştir.



Şekil 5.4 a) Tek LSTM ile oluşturulan ağ modeli, b) İki LSTM ile oluşturulan ağ modeli, c) iki LSTM ve seyreltme katmanı


Tezin bu aşaması veri setinde 10 farklı giriş parametresinin yer aldığı ve toplamda 140 ms izleme süresini içeren kayıtlar ile gerçekleştirilmiştir. En uygun LSTM modeli seçildikten sonra bu model kullanılarak en uygun giriş parametrelerinin belirlenmesi, eğitim test oranlarının değiştirilmesi ve daha hızlı bir ada çalışma tespiti yapabilmek için izleme süresi gibi parametreler değiştirilerek modelin doğruluğuna etkileri araştırılmıştır. Bu sonuçlar 6. Bölümde detaylı olarak verilmiştir. Bu bölümde sadece önerilen derin sinir ağı modellerinin mimarilerine yer verilmiştir. Şekil 5.1’de de önerilen ada tespit metodu için akış diyagramı, verilerin kayıt edilmesi aşamasından, ada çalışmanın sınıflandırıldığı son aşamaya kadar detaylı olarak verilmiştir.

Tablo 5.5 Seçilen çoklu-LSTM modeli için ağın eğitilmesinde kullanılan parametreler

Model Parametreleri	En iyi durumlar	Alternatifler
Eğitim/Test	70/30	80/20-75/25-70/30-50/50
Nöron sayısı	128	16-34-64-128
Maksimum tur sayısı	200	5-10-20-40-60-100-500
Mini-Batch Boyutu	27	8-16-27-32-64-2800
Optimizasyon aracı	Adam	SGD-Adam
Öğrenme oranı	0.001	0.0001-0.5
Veri karıştırma	her tur	tek sefer-asla-her tur
Gradyan eşik değeri	2	0.5-1-2

5.4.2 Ada Çalışma Tespiti için Önerilen 1D CNN Metodu

Literatürdeki çalışmada tek katmanlı LSTM ile gerilim sinyalinin negatif, pozitif ve sıfır bileşenleri giriş olarak kullanılmış ve sinyal işleme tekniklerinden yararlanılarak bir ada çalışma tespit yöntemi önerilmiştir [65]. Bu tez çalışmasında çoklu-LSTM modeli ile bir ada çalışma tespiti farklı giriş parametreleri ile sinyal işleme tekniklerine ihtiyaç olmadan gerçekleştirilmiştir. Önerilen ikinci ve üçüncü derin algoritmaları ise literatürde ilk defa 1D CNN ve 1D CNN-LSTM modellerinden yararlanılarak gerçekleştirilmiştir. Tek boyutlu CNN modeli için farklı mimariler üzerinde çok sayıda eğitim ve test gerçekleştirilmiştir. Elde edilen en yüksek doğruluk ve en düşük kayıp faktörü baz alınarak yapılan sonuçlara göre Şekil 5.5'teki model oluşturulmuştur.




Şekil 5.5 Ada çalışma tespiti için önerilen 1D CNN mimarisi

Bu modele göre iki adet evrimsel katman, havuzlama ve seyreltme katmanları ile sınıflandırmayı yapabilmek için tam bağlantılı katmanlardan yararlanılmıştır.

5.4.3 Ada Çalışma Tespiti için Önerilen 1D CNN-LSTM Metodu

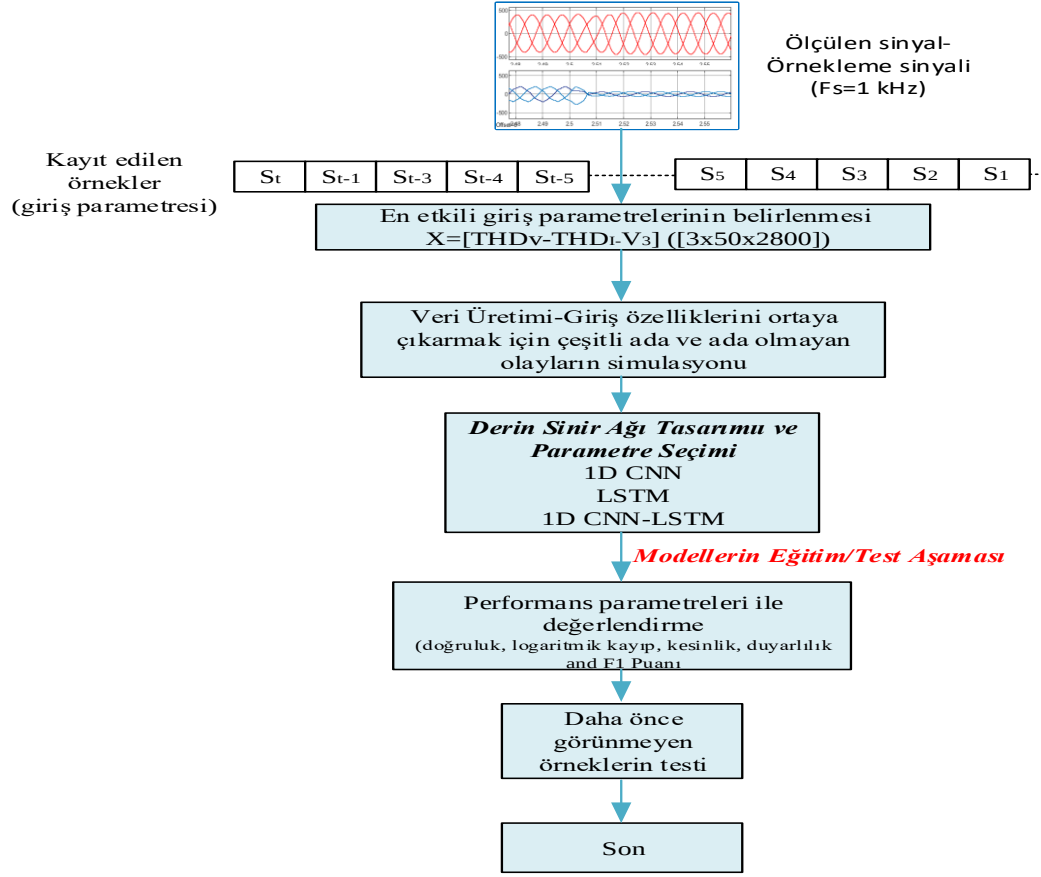
Bu bölümde, 1D CNN ve LSTM algoritmalarını birleştiren bir hibrit derin sinir ağı (DNN) ada çalışma tespiti için önerilmiştir. 1D CNN ve LSTM modeli önceki bölümlerde ayrı ayrı oluşturulmuş ve daha iyi performans elde etmek için birleştirilmiştir. Önerilen modelde, tek boyutlu CNN ile ilk aşamada girdi örneklerinin önemli bilgileri ortaya çıkarılmaktadır. LSTM sinir ağı ise, ikinci aşamada ada ve ada olmayan durumları eğitmek ve sınıflandırmak için tasarlanmıştır. Doğruluk ve kayıp faktörü dikkate alınarak seçilen model parametreleri, evrimsel katmanların sayısı, kernel boyutu, maksimum havuzlama

ve tam bağlantılı katmandaki nöron sayılarından oluşmaktadır. Model parametreleri maksimum performansı elde etmek için farklı seçenekler ile eğitilerek optimize edilmiştir. Böylece elde edilen nihai 1D CNN-LSTM mimarisi, iki tek boyutlu konvolüsyon (evrişim) katmanı, seyreltme katmanı, düzleştirme katmanı, LSTM katmanı, tam bağlantılı katman ve sınıflama katmanları ile tasarlanmıştır. CNN algoritmasında aktivasyon fonksiyonu olarak RELU kullanılmıştır. Aşağıdaki LSTM katmanı, 0,5'lik bir seyreltme ile 64 birimden oluşmuştur. Aşağıdaki tam bağlantılı (FC) katman ise sigmoid aktivasyon fonksiyonu kullanılarak 32 nöron ile oluşturulmuştur. Tasarlanan 1D CNN-LSTM'in mimarisi Şekil 5.6'da gösterilmiştir.



Şekil 5.6 Ada çalışma tespiti için önerilen 1D CNN-LSTM mimarisi

Şekil 5.7'de ada çalışma tespiti için 2800 verisetinde giriş olarak ortak bağlantı noktasındaki akım ve gerilim toplam harmonik distorsiyonları ile 3. Tekil gerilim harmonik bozunumu kullanılmıştır. Bu girişler ile elde edilen veri seti üç farklı model üzerinde eğitim ve test olarak %70/30 oranında ayrılmış ve modeller çalıştırılmıştır.



Şekil 5.7 Üç farklı sinir ağının ada çalışma tespitindeki akış diyagramı
Aşağıda verilen Tablo 5.6’da ada çalışma tespiti için kullanılan katmanlar ve katmanlardaki nöron sayıları ile aktivasyon fonksiyonları verilmiştir.

Tablo 5.6 Kullanılan üç farklı modelin sinir ağı parametreleri

1D CNN	LSTM	1D CNN-LSTM
Conv1D (64) (RELU)	LSTM (64)	Conv1D (64) (RELU)
Max-Pooling	LSTM (64)	Dropout
Dropout	Dropout	Conv1D (64) (RELU)
Conv1D(64) (RELU)	Flatten	Dropout
Max-Pooling	Dense(32) (Sigmoid)	Max-Pooling
Dropout	Dense(1) (Sigmoid)	LSTM (64)
Flatten		Dropout
Dense(32) (RELU)		Dense (32) (Sigmoid)
Dense(1) (Sigmoid)		Dense (1) (Sigmoid)
		Flatten
Toplam parametre sayısı		
19201	60737	45000

5.5 Ada Çalışma Tespitinde Önerilen Metotlar için Kullanılan Performans Metrikleri

Ada çalışma tespitinde önerilen yöntemlerin performanslarını değerlendirebilmek amacıyla farklı türde ölçütler kullanılmaktadır. Bu tez çalışmasında literatürde özellikle makine öğrenmesinde sınıflandırmaya dayalı çalışmalarda yaygın olarak kullanılan performans metrikleri kullanılmıştır. Sonuçların diğer çalışmalar ile karşılaştırılabilmesi açısından birden fazla performans parametresine yer verilmiştir. Model doğruluğu, kayıp faktörü, duyarlılık, kesinlik, F1 skoru, yanlış alarm oranı (FAR) bu çalışmanın sonuçlarında kullanılan performans metrikleri olarak sınıflandırılabilir. Bu metrikler Tablo 5.7’de verilen hata matrisinden yararlanılarak hesaplanabilir. Ayrıca ilgili denklemler Eşitlik 5.1 ve 5.7 arasında verilmiştir.

Model doğruluğu modelin başarısını ölçmek için kullanılan kriterlerden biri olup doğru tahmin edilen veri sayısının toplam tahmin edilen veri sayısına bölünmesi ile hesaplanır ve genellikle yüzde olarak ifade edilir. Sınıflandırma problemlerinde kullanılan bir performans ölçütüdür. Bu kriter tek başına kullanıldığında yanıltıcı olabilmektedir. Özellikle dengesiz veri setlerinde yani sadece bir sınıfın yüksek oranda veri setini oluşturduğu durumlarda yanlış değerlendirmeler yapılabilir. Örneğin 1000 adet veri setinin içinde 900 adet ada çalışma durumu 100 adet de ada olmayan çalışma durumu var ise doğru tahminlerin sayısının 940 olması ile %94 doğruluk sağlanması modelin iyi çalıştığı anlamına gelmez. Bu durumlarda doğruluk ile başka kriterlere de bakılması gerekir.

Tablo 5.7 Ada Çalışma Tespiti için Kullanılan Konfüzyon matrisi

	Tahmin	
	edilen ada çalışma (1)	Tahmin edilen ada olmayan (0)
Gerçek ada çalışma (1)	GP	FP
Gerçek ada olmayan çalışma (0)	FN	TN

(Doğru tahminler Gerçek Pozitif (GP) ve Gerçek Negatif (GN); yanlış tahminler Yanlış Pozitif (YP) ve Yanlış Negatif (YN))

- Hata (konfüzyon) Matrisi: Veri setindeki bulunan sınıfların mevcut sayısı ile bunların doğru ve yanlış olarak sınıflandırdığı sayıları tablo halinde veren bir başarı ölçerdir
- Kesinlik: Pozitif olarak tahmin ettiğimiz değerlerin gerçekten kaç adedinin pozitif olduğunu göstermektedir.
- Duyarlılık (Hassasiyet): Pozitif olarak tahmin etmemiz gereken işlemlerin ne kadarını pozitif olarak tahmin ettiğimizi göstermektedir. Modelin doğruları bilme konusundaki etkinliği de denilebilir.
- F1 Skor: Kesinlik ve duyarlılık değerlerinin harmonik olarak ortalamasını vermektedir.
- Kayıp faktörü: İkili sınıflandırmalarda bu kriter tahminin gerçek değerden ne kadar değişiklik gösterdiğine bağlı olarak belirsizliği hesaba katar. Mükemmel bir modelde log kaybı 0'dır.

$$Sınıflandırma doğruluğu (\%) = 100x \frac{GP+GN}{GP+YP+YN+GN} \quad (5.1)$$

$$Duyarlılık(\%) = 100x \frac{GP}{GP+YN} \quad (5.2)$$

$$Kesinlik (Dependibility)(\%) = 100x \frac{TP}{GP+YP} \quad (5.3)$$

$$F1 \text{ puanı } (\%) = 100x2x \frac{(DuyarlılıkxKesinlik)}{(Duyarlılık+Kesinlik)} \quad (5.4)$$


$$Kayıp fonksiyonu (L) = -\frac{1}{N} * \sum_{i=1}^M T_i \log(X_i) \quad (5.5)$$

6.1 AÇT Metotlarında Kullanılan Parametrelerin Belirlenmesi


Bu bölümde derin öğrenmeye dayalı algoritmalarda modelin eğitim ve test aşamasından önce kullanıcı tarafından belirlenen ve modelin doğruluğunu önemli ölçüde etkileyen parametrelerin etkisi araştırılmış ve en uygun parametreler buna göre seçilmiştir.

6.1.1 Eğitim ve Test Oranının Belirlenmesi

Literatürdeki çalışmalarda kullanılan eğitim ve test oranları verinin içyapısına ve boyutuna göre farklılık göstermiştir. Genel itibari ile en sık kullanılan eğitim test oranı %70 ve % 30 olarak alınmaktadır. Diğer yandan çok yüksek boyutlu verilerde yüz binlerce hatta belki milyonlarca veri ile yapılan öğrenme işlemlerinde bu oranın alınmasının gerekli olmadığı yapılan çalışmalarda aktarılmıştır. Eğer veri miktarı çok büyükse eğitim test oranının % 90 ve % 10 olarak alınabileceği vurgulanmaktadır [66]. Örnek vermek gerekirse 100.000 örnekli bir veride 10.000 test verisi modelin performansını ölçmek için yeterli cevabı verir. Ancak 1000 örnekli bir veri çalışmasında ise sadece 100 örneğin test edilmesi örneklerin çeşitliliği açısından yanıltıcı olabilir. Bu nedenle bu çalışmada farklı eğitim ve test oranlarının doğruluk üzerindeki etkisi araştırılmıştır. Elde edilen sonuçlara göre Şekil 6.1’de kullanılan dört farklı oran arasında ciddi bir fark görülmemiştir. Bu da verinin tutarlı bir şekilde dağılım gösterdiği sonucunu vermektedir. Aynı zamanda daha iyi bir değerlendirme yapabilmek için Şekil 6.2’deki grafikte hem eğitim ve test oranları hem de kullanılan parametrelere göre elde edilen sonuçlar kıyaslanmıştır.



Şekil 6.1 Farklı eğitim ve test oranlarına göre LSTM algoritmasının gösterdiği doğruluk değerleri




Şekil 6.2 Farklı giriş parametreleri ve farklı eğitim test oranlarının LSTM yöntemi ile karşılaştırılması

6.1.2 Veri İzleme Süresinin Belirlenmesi

Bu çalışmada ada ve ada olmayan olay senaryoları, mikro şebeke modeli üzerinde simülasyon başlatıldıktan sonra 2500. milisaniye anında gerçekleştirilmiştir. Elektriksel parametrelerin kayıt edilmesi ise 140 ms boyunca olay meydana gelmeden önce 2,48. saniyeden itibaren 2,61. saniyeye kadar 1 kHz'lik örnekleme frekansı ile yapılmıştır. Bu süre yaklaşık 6 çevrim olarak hesaplanmıştır. Ayrıca veri sinyalinden örneklerin alınması ve modelin eğitilmesine kadarki işlemler Şekil 6.3'te daha anlaşılır şekilde gösterilmiştir. Son yıllarda literatürde yapılan güncel araştırmalarda ada çalışmayı 50 ms'nin altında tespit edebilen çalışmalar görülmüştür [9]. Buradan hareketle bu çalışmada daha kısa sürede örnekleme alınarak öğrenme çalışmaları yapılarak sonuçların nasıl değiştiği ortaya konulmuştur. Elde edilen sonuçlara göre 140 ms yerine 50 ms gibi bir izleme ile de yaklaşık aynı doğruluğa ulaşabildiği

görülmüştür. Bu öğrenmede anahtar değişiminden hemen sonraki değerlerin ada çalışma tespitini yapmada yeterli olduğu ortaya konmuştur. Tablo 6.1’de 140 ms ve 50 ms olarak kayıt edilen eğitim setinin performansları görülmektedir.




Şekil 6.3 Verilerin kayıt edilmesi ve ada çalışma tespit aşaması

Tablo 6.1 Farklı izleme sürelerine göre LSTM modelinin performansı

Farklı izleme süreleri	10ms	20ms	30ms	40ms	50ms	60ms	100ms	140ms
Doğruluk	61,71	83,86	97,57	99,29	99	98,86	99,29	99,43
Kayıp faktörü	0,63	0,4	0,1	0,1	0,05	0,05	0,05	0,01

Kayıt edilen verilerin boyutu düşürülüp daha az sayıda sıralı veri LSTM ile eğitildiğinde Şekil 6.4’teki grafikte gösterilen doğruluk sonuçları elde edilmiştir. Bu sonuçlara göre daha kısa sürede örnekler takip edilerek ada çalışmanın tespit edilmesi mümkün görülmektedir.



Şekil 6.4 Örneklem sürelerinin performansa etkisi

Şekil 6.4'teki performanslar değerlendirildiğinde olay başlamadan 10 ms önce örnekler ile olay başladıktan sonra 40 ms sonrasına kadar örnekler kayıt edilerek eğitim ve test işlemleri gerçekleştirilmiştir. Buradan hareketle ada çalışma tespit süresini hesaplamak istersek ada çalışmadan önceki süre hariç tutulduğunda izleme süresi 40 ms olarak alınabilir. Bilgisayar işlemcisinin önerilen veriyi test etme süresi 10 ms olarak kabul edilmiştir. Bu durumda ada çalışma tespit süresi gözlem süresi ve derin öğrenme metodunun test süresi toplamına eşittir. Bu tez çalışması için de ortalama olarak ada çalışma tespit süresi 50 ms olarak hesaplanmıştır.

6.1.3 Toplam Veri Sayısının Doğruluğa Etkisi

Tez izleme aşamalarında sırasıyla toplam veri sayıları 400-750-1500-2000-2800 olarak genişletilmişti. Genelleştirilebilir bir model elde edebilmek için veri boyutunun arttırılması ile birlikte mikro şebekede meydana gelecek olaylar simule edilirken çok sayıda farklı durumu içine almak gerekir. Yapılan simülasyon çalışmaları detaylı olarak incelenecek olursa, örneğin bir kapasitör anahtarlanması modellenirken aynı kapasitörün devreye girip çıkması olayında farklı sayıda yüklenme durumu dikkate alınarak verilerin boyutu arttırılmıştır. Dikkate alınan bu durumlar ada çalışmanın tespiti için yeterli olabilir, aynı zamanda gereğinden fazla örnek de eğitime eklenmiş olabilir. Bu durumu daha iyi tanımlamak için rastgele olarak karıştırılan 2800 farklı olay içeren veri seti parçalara ayrılarak tekrar eğitime sokulmuştur. Bu durumda elde edilen sonuçlar Tablo 6.2'de verilmiştir. Burada LSTM modeli üç giriş parametresi (%THDv,

%THDı .ve 3. Gerilim Harmoniği) kullanılarak eğitilmiştir. Karar ağacı yöntemi ise bütün parametreleri kullanılarak eğitilmiştir. Karar ağacı algoritmasında az sayıda veri ile düşük doğrulukta sonuçlar verdiği önceki bölümlerde ispatlanmıştı.


Tablo 6.2 LSTM ve karar ağacı için farklı örnek sayıları ile yapılan eğitimlerde performans sonuçları

Veri Sayısı	500	750	1000	1500	1750	2000	2250	2500	2800
LSTM (%70/%30)	94	97,8	98	97,8	98,5	98,67	98,07	97,73	98,81
Karar Ağacı K=10	92,4	94,7	94,5	96	95,8	96,7	96,4	96,4	97
Eğitim Süresi (LSTM) (s)	48	55	67	94	110	122	135	150	185


Elde edilen sonuçlardan anlaşılaacağı üzere 1750 ve üzeri veri sayısının olduğu durumlarda doğruluk değerinin çok az miktarda değiştiği gözlemlenmiştir. Bu sonuç ise uygun koşullarda hazırlanan eğitim verisinin daha az veri sayısı ile de yüksek doğruluk sağlanabileceğini ortaya çıkarmıştır.

6.2 LSTM Yöntemine Dayalı Ada Çalışma Tespitinin Sonuçları

Bu tez çalışmasının ilk aşamasında derin öğrenme algoritmalarından LSTM yöntemi ile bir ada çalışma tespit yöntemi ortaya konulmuş ve bu yöntem geleneksel makine öğrenmesi yöntemlerinden karar ağacı, k en yakın komşu, destek vektör makinesi ve tek katmanlı yapay sinir ağı algoritmaları ile karşılaştırılmıştır. Bu karşılaştırma farklı sayıda giriş parametreleri kullanılarak yapılmıştır. En yüksek giriş parametre sayısı, veri setinde de belirtildiği üzere 10 farklı elektriksel parametreye göre belirlenmiş olup, bu parametreler sırayla azaltılarak doğruluk üzerindeki etkileri araştırılmıştır. Şekil 6.5’de bu algoritmaların üç farklı giriş parametresi ve on farklı giriş parametresi kullanılması durumundaki sonuçları ada çalışma ve ada olmayan çalışmadaki doğruluk performanslarına göre verilmiştir. Şekil 6.6’da ise bütün parametrelerin etkisi LSTM’e en yakın performansı veren karar ağacı ve tek katmanlı yapay sinir ağı ile karşılaştırılmıştır. Bu karşılaştırma yanlış tespit oranı (DI) ve doğruluk üzerinden yapılmıştır.



Şekil 6.5 Ada ve Ada olmayan çalışma durumları için üç ve on farklı girişli örneklerin LSTM ve geleneksel makine öğrenmesi yöntemleri ile karşılaştırılması



Şekil 6.6 Ada çalışma tespit için farklı giriş kombinasyonlarının doğruluğa etkisi

Şekildeki grafikler incelendiğinde en yüksek doğruluğun LSTM metodu ile elde edildiği görülmüştür. LSTM'den sonraki en iyi performansı gösteren geleneksel makine öğrenmesi algoritması ise karar ağacı olmuştur. Burada amaç en düşük giriş parametre sayısı kullanılarak model üzerindeki işlem maliyetini ve tespit süresini kısaltmaktır. Araştırma bulgularına göre en düşük sayıdaki girişler, THD_v, THD₁, V₃ elektrik parametreleri ile sağlanmış olup, bu sayede en yüksek doğruluk değeri elde edilmiştir.

6.3 1D-CNN ve CNN-LSTM'e Dayalı Ada Çalışma Tespit


Yöntemlerinin Sonuçları

Tezin birinci kısmında LSTM yöntemi geleneksel makine öğrenmesi teknikleri ile karşılaştırılarak en iyi performansı göstermiştir. Tezin ikinci kısmında ise farklı derin öğrenme algoritmalarının ada çalışma tespiti üzerindeki etkileri incelenmiştir. Bu kapsamda ilk defa tek boyutlu CNN ve CNN-LSTM algoritmaları ada çalışma tespiti için bu tez çalışmasında önerilmiştir. Yapılan eğitim ve test çalışmalarında 2800 adet veri setini içeren örneklerle elde edilen karşılaştırmalı sonuçlar Tablo 6.3'te konfüzyon matrisi olarak Şekil 6.7'de ise grafiksel olarak verilmiştir. Burada verilen sonuçlar test sonuçları olup 2800 verinin %30'u rastgele olarak test için ayrılmıştır. Bu sonuçlara göre 840 farklı ada ve ada olmayan çalışma senaryoları için elde edilen hata matrisi sonuçları tabloda verilmiştir. Her algoritma için toplam ada ve ada olmayan çalışma durumu aynı olsa da veriler rastgele ayrıştırıldığı için ada ve ada olmayan çalışmalar ayrı ayrı incelendiğinde birbirine yakın fakat farklı değerler almaktadır.

Tablo 6.3 CNN, LSTM and CNN-LSTM modellerinin konfüzyon matrisleri


	CNN		LSTM		CNN-LSTM	
Gerçek	Tahmin Sınıfı		Tahmin Sınıfı		Tahmin Sınıfı	
Sınıf	I	NI	I	NI	I	NI
I	359/334	0/3	332/335	1/7	348/332	0/8
NI	1/9	480/494	0/4	502/494	1/0	491/500

(I: Ada çalışma, NI: Ada olmayan çalışma, her sütündeki birinci ve ikinci değerler en iyi ve en kötü performansı sırasıyla gösterir)



Şekil 6.7 Önerilen sinir ağlarının doğruluk ve kayıp eğrileri

Şekilde 6.7’de gösterilen sonuçlar hata matrisinden farklı olarak Python/Spider platformunda elde edilen sonuçlara göre doğruluk ve kayıp performans metrikleri kullanılarak grafiksel olarak çizdirilmiştir. Bu şekillere göre eğitim ve test sonuçları mavi ve turuncu çizgilerle ayrı ayrı gösterilmiştir. Sonuçlar modellerin 200 tur çalıştırılmasıyla elde edilmiştir. Bu sayede ilk başlarda kararsız gibi görünen sonuçlar tur sayısı arttıkça kararlı hale gelmiştir. Önerilen yöntemler ayrıca aşağıdaki farklı performans metrikleri ile de karşılaştırılmıştır. Bu sonuçlara göre en kötü performansı LSTM modeli göstermiş olup CNN ve CNN-LSTM modeli birbirine çok yakın ve yüksek doğrulukta sonuçlar vermiştir. Bu doğruluklarda ortalama değerler, modellerin 10 kez çalıştırılıp sonuçların ortalamasının alınması ile elde edilmiştir. Böylece yanıltıcı sonuçların önüne geçilmiştir.



Şekil 6.8 Üç farklı AÇT modelinin doğruluk açısından karşılaştırılması

Tablo 6.4 Elde edilen en iyi sonuçların farklı performans matrisleri ile modellerin karşılaştırılması

Yöntemler	Doğruluk	Duyarlılık	Kesinlik	F1-Skor	Kayıp
CNN	100	100	100	100	0.0018
LSTM	99.88	100	99.7	99.8	0.0088
CNN-LSTM	100	100	100	100	0.0018

Tablo 6.5 Elde edilen en kötü sonuçların farklı performans matrisleri ile modellerin karşılaştırılması


Yöntemler	Doğruluk	Duyarlılık	Kesinlik	F1-Puanı	Kayıp
CNN	99.4	98.9	99.7	99.3	0.0376
LSTM	98.5	99.7	96.8	98.2	0.05
CNN-LSTM	99.4	98.8	99.7	99.3	0.0247

Tablo 6.4 ve 6.5'te modellerin on kez çalıştırılmasıyla elde edilen en iyi ve en kötü sonuçlar doğruluk, duyarlılık, kesinlik, F1-puanı ve kayıp faktörü açısından değerlendirilmiştir.

6.4 Algılama Dışı Bölge Analizi

Algılama dışı bölge (NDZ) kavramı en genel tanımıyla ada tespit yöntemlerinin ada çalışmayı tespit edemediği alanı ifade eder ve önerilen ada çalışma tespit yönteminin performansının değerlendirilmesinde kullanılan kriterlerden biridir. İyi bir ada çalışma tespiti için NDZ'nin mümkün olduğunca düşük olması istenir. Ayrıntılı olarak inceleyecek olursak şebeke tarafındaki anahtarın açılması durumunda şebekenin ortak bağlantı noktasında aktif güç değişimi ve reaktif güç değişimi meydana gelecektir. ΔP ve ΔQ olarak tanımlanan bu değişim büyük bir aralıkta ise düşük/yüksek frekans koruma ve düşük/yüksek gerilim koruma röleleri belirli bir eşik değere ayarlanarak ada çalışma kolaylıkla tespit edilebilmektedir. OBN'deki frekans ve gerilimdeki değişimi ada çalışmanın gereken sürede tespit edilebilmesi için yeterince büyük olmalıdır. Şekil 6.9'da gösterilen bölge aktif ya da reaktif güç değişiminin çok küçük değerlerde olduğu, bu durumda kullanılan rölelerin ada çalışmayı tespit edemedikleri alanı ifade etmektedir. Burada gerilim ve frekansın belirtilen alt ve üst sınırlarına göre aktif ve reaktif güç aralığı oluşmaktadır. Bu bölge mikro şebekede bulunan dağıtık

üretimlerin karakteristiklerine göre değişiklik göstermektedir. Senkron karakteristikli mikro şebekelerde frekans NDZ'nin aktif güç değişim sınırlarına göre yapılırken, inverter karakteristikli mikro şebekelerde ise bu ayarlar reaktif güç değişim sınırlarına göre yapılır. Gerilim ayarında ise tam tersi durum söz konusudur [67]. Geleneksel pasif AÇT yöntemlerinin en önemli dezavantajlarından biri NDZ alanının büyük olmasıdır. Bu amaçla kullanılan akıllı yöntemlerle NDZ'nin sifıra düşürülmesi hedeflenmektedir.




Şekil 6.9 AÇT ile algılanamayan bölge (NDZ)

Literatürdeki çalışmaların büyük çoğunluğunda tespit edilemeyen bölge ile ilgili detaylı bir analiz ya da veri bulunmamaktadır [68][8][69]. Yukarıda ifade edilen genel alanın içindeki değerleri içinde bulunduran küçük güç değişimleri için modeller test edilip bu sonuca göre NDZ için genel bir yorum yapılmaktadır. Diğer yandan önerilen birkaç çalışmada ise detaylı olarak bu analiz yapılmıştır ve yüzde olarak ne kadar iyileştirme sağlandığı somut örneklerle verilmiştir [70]-[9]-[71].

Bu çalışmada önerilen üç farklı sinir ağının düşük NDZ'li durumlar için gösterdiği performansı değerlendirmede 200 farklı olay, Şekil 6.10'da verilen bölgelerde oluşturulmuştur. Şekil 6.10'da görüldüğü gibi ada tahmini için oluşturulan örneklerin büyük kısmı %0.008 gibi çok düşük aktif ve reaktif güç değişimi olan bölgelerde gerçekleştirilmiştir. Bu yerlerdeki ada çalışma tespiti de

rahatlıkla yapılabilmiştir. CNN-LSTM modelinin hatalı tespit ettiği bölgeler kırmızı işareti ile gösterilmiştir. 200 farklı durum için Tablo 6.6’da ise üç farklı modelin doğru ve yanlış tahmin sayıları verilmiştir.



Şekil 6.10 CNN-LSTM modelinin 200 farklı çalışma bölgesi için gösterdiği performans

Tablo 6.6 Üç farklı AÇT modelinin 200 çalışma bölgesindeki performanslarının karşılaştırılması

Yöntemler	En kötü sonuçlar*	En iyi sonuçlar*	En kötü doğruluk (%)	En iyi doğruluk (%)
LSTM	5	1	97,5	99,5
CNN	4	1	98	99,5
CNN-LSTM	2	1	99	99,5

*200 olay içerisinde yanlış tespit edilen olay sayısı

Bu sonuçlara göre en iyi durumda dahi 200 olaydan 1’i yanlış tahmin edilmiştir. En kötü durumda ise en iyi performansı CNN-LSTM modeli elde etmiştir.


6.5 Mikro şebekenin Genişletilmesi

Önerilen üç farklı model Şekil 4.3’te verilen genişletilmiş çalışma sistemi üzerinden elde edilen 600 farklı yeni olay için test edilmiş ve sonuçlar karşılaştırılmıştır. Çalışma modlarına göre Tablo 6.7’de 4 farklı bölüme ayrılıp ayrı ayrı performansları değerlendirilmiştir. Mod 0 olarak belirlediğimiz çalışma, referans aldığımız 2800 verinin elde edildiği temel mikro şebeke modelidir.

Tablo 6.7 Farklı çalışma modlarına göre üretilen olay sayıları

Durum	S1	S2	Ada Çalışma Olay Sayısı	Ada Olmayan Olay Sayısı	Toplam Test Sayısı
Mod 0*	Açık	Açık	1140	1640	2800
Mod 1	Açık	Kapalı	90	110	200
Mod 2	Kapalı	Açık	90	110	200
Mod 3	Kapalı	Kapalı	90	110	200
Mod 4	Tüm durumların birleştirilmesi		270	330	600

(*Durum 0 referans sistem)

**Şekil 6.11** Farklı çalışma modlarına göre performans karşılaştırılması

Şekil 6.11'de görüldüğü üzere CNN-LSTM modeli en kompleks olan üçüncü durumda en iyi performansı göstermiştir. Önerilen modellerde Mod 1 ve Mod 2 çalışma durumlarında ise birbirine yakın doğruluk değeri elde edilmiştir. Bu sonuçlardan da anlaşıldığı üzere mevcut sistem üzerinden derin öğrenmeye bağlı oluşturulan ada çalışma tespit yöntemi sistemin ilave kaynaklarla genişletilmesi durumunda bile yüksek doğrulukta çalışmaya devam etmektedir. Bu da önerilen yöntemlerin bir diğer önemli avantajı olarak kabul edilmektedir.

6.6 Ada Çalışma Performansının Literatürdeki Benzer Çalışmalar ile Karşılaştırılması

Ada tespit çalışmasıyla ilgili sonuçlar literatürdeki benzer çalışmalarla karşılaştırılmış olup önerilen çalışmalar ada tespit çalışmasında kullanılan ölçüm noktası, giriş parametre sayısı, toplam veri seti sayısı, ada ve ada olmayan

durumlardaki olay türü sayısı, dağıtık üretimin konfigürasyonu, ada çalışma tespit süresi, NDZ analizi ve karşılaştırılan metotlar yönünden incelenmiştir. Tablo 6.8’de bu sonuçlar özetlenmiştir.

Tablo 6.8 Önerilen yöntemlerin literatürdeki benzer çalışmalar ile karşılaştırılması

Ref.	Yöntem	Ölçüm noktası	Giriş sayısı ₁	Veri seti sayısı ₁	Olay türü sayısı _{1*}	DÜ yapısı	Tespit Süresi	NDZ analizi	Karşılaştırılan metotlar
[72]	ANFIS	PCC	7	x	2	İDÜ	~40 ms	$I_{ndz}=\%49$	ANN, ANFIS
[73]	SVM	PCC	7	x	3	İDÜ s	~40 ms	$I_{ndz}=\%9.5$	ANN, ANFIS
[74]	Feedback mechanism	PCC	1	x	2	İDÜ	~700 ms	x	x
[20]	ELM with S-Transform	DG terminals	2	1500	2	SG and İDÜ	78.5 ms	x	ANN, SVM
[75]	Adaboost	PCC	5	270	3	SGs	~219 ms	$+0.5\% \leq \Delta P \leq +8\%$	SVM, Bayes
[76]	Adaboost	PCC	10	456	2	İDÜs	x	x	UOV/UOF ,Adaboost
[77]	ANN with DFT	PCC	6	x	3		x	x	x
[15]	Multi-ANN with WT	PCC	3	x	3	IDÜ	~50 ms	%6 düşürülmüş	x
[23]	Multi-ANN and APBM	each bus	12	1320	4	SGs	x	$\Delta P, \Delta Q = \pm 3\%$	x
[22]	SAE	PCC	4	1000	1	İDÜ	180 ms	x	DT, SVM
[24]	LSTM STFT	DG terminals	6	x	3	SG and İDÜ	2-10 ms	x	DT, SVM, ANN
[68]	GWO-ANN	DG terminals	3	2016	3	SG and İDÜ	~100 ms	x	SVM, ELM
[78]	ANN	PCC	5	420	5	İDÜ	40 ms	%11.3 düşürülmüş	SVM, ANFIS
[64]	Adaptif sinyal tahmini	PCC	1	2000	4	SG and İDÜ	220 ms	$\Delta Q = \pm 1.2\%$ $\Delta P = \pm 0.65\%$	Prony, ESPIRIT
Önerilen yöntemler	Multi-LSTM								
	1D CNN	PCC	3	3000	6	SG and İDÜ	~50 ms	Yaklaşık sıfır NDZ	SVM, DT, ANN, k-NN
	CNN-LSTM								

(SG: Senkron Generatör, İDÜ: inverter arayüzlü dağıtık üretim, PHEV: hibrit elektrik araç ,APBM: Andrews plot-metodu, RPNN: ridgelet probabilistic sinir ağı, GWO: grey wolf optimizasyonu *ada olmayan durumlar : arıza, gerilim bozukluğu, kapasitör, motor, doğrusal olmayan yük anahtarlama, dağıtık üretim veya yük anahtarlama.)

Tablo 6.8'e bakıldığında, bu tez çalışmasında ada çalışma tespiti için önerilen derin öğrenme algoritmalarının diğer akıllı yöntemlere kıyasla büyük bir veri kümesine ve minimum NDZ'ye sahip olduğu açıkça görülmektedir. Önerilen modeller sinyal işleme gibi herhangi bir ön işleme ihtiyaç duymamaktadır. Önerilen yöntemde, voltaj bozulması dışında tüm olası ada ve ada olmayan çalışma durumları kapsamlı şekilde dikkate alınmıştır. Önerilen yöntemler, en düşük algılama hızına ve özellik sayısına sahip olmasa da karşılaştırılan bazı yöntemlerden üstündür. Önerilen yöntem ayrıca tek veya birden fazla dağıtık üretimlerin olduğu mikro şebekeler için de uygulanabilmektedir.

Önerilen yöntemlerin performansı, elde edilen sonuçların daha doğru analiz edilmesi açısından ortalama test sonuçlarına göre değerlendirilmiştir. Diğer yandan önerilen yöntemler NDZ, görünmeyen örneklerin tahmini ve geleneksel makine öğrenmesi algoritmalarının karşılaştırılması gibi durumlar için analiz edilmiştir. Önerilen yöntem ile $\pm\%0.5$ 'ten küçük güç uyumsuzluğu koşulları için %97.93 doğruluk değeri ile neredeyse sıfır NDZ'ye sahiptir. Önerilen yöntemler yukarıdaki çalışmalardan farklı olarak mevcut mikroşebeke modeli genişletilerek test edilmiştir. Ayrıca mevcut veri seti k-NN, DT, ANN ve SVM yöntemleri ile ada çalışma için test edilmiş ve LSTM yöntemi ile karşılaştırılmıştır.

Bu tez çalışmasında senkron ve inverter arayüzlü mikro şebekeler için ada çalışmayı tespit etmek amacıyla LSTM, 1D CNN ve 1D CNN-LSTM'e dayalı derin öğrenme yaklaşımları önerilmiştir. Önerilen yöntemde, ada çalışma tespiti için mikro şebekenin ortak bağlantı noktasındaki toplam gerilim harmoniği, toplam akım harmoniği ve 3. tekil gerilim harmoniği elektriksel verileri giriş olarak kullanılmıştır. Önerilen yaklaşımlar, mikro şebekenin geniş güç değişimi altında ada ve ada olmayan olayları içeren yaklaşık dört bin senaryo için eğitilmiş ve test edilmiştir. Ada çalışma senaryoları dağıtık üretimlerin ve yüklerin geniş güç aralıkları için değerlendirilmiştir. Ada olmayan çalışma senaryoları ise farklı noktalardaki arıza durumları, çeşitli kapasitör, motor, doğrusal olmayan yüklerin anahtarlama ve dağıtık üretim ile mevcut yüklerin anahtarlama durumları dikkate alınarak oluşturulmuştur. Literatürdeki çalışmaların hepsi ana şebekeyi saf sinüs gerilim olarak kabul etmişlerdir. Bu senaryolar ilk kez, hem saf sinüs şebeke hem de harmonikli şebeke gerilimi dikkate alınarak oluşturulmuştur. Tez çalışmasının ilk kısmında LSTM'e dayalı pasif ada çalışma tespit yöntemi DT, SVM, k-NN ve çok katmanlı ANN gibi geleneksel makine öğrenmesi teknikleri ile karşılaştırılmıştır. Elde edilen test sonuçlarına göre minimum girdi özelliklerine sahip önerilen LSTM modeli, daha yüksek doğruluk ve daha düşük kayıp ile karşılaştırılan yöntemlerden daha iyi performans göstermiştir. Tezin ikinci kısmında ise derin öğrenmeye dayalı 1D CNN ve CNN-LSTM algoritmaları ada çalışmayı tespit etmek için önerilmiş ve bu üç derin öğrenme yaklaşımı kendi aralarında performans olarak karşılaştırılmıştır. Bu sonuçlara göre ise CNN-LSTM yaklaşımı ile diğer yöntemlerden daha yüksek doğruluk elde edilmiştir. Ada ve ada olmayan olayları ortalama %99,7 sınıflandırma doğruluğu ve %0.05 kayıp değeri ile tespit edebilmiştir. Önerilen yöntemler diğer çalışmalardan farklı olarak eğitim ve test veri setinde yer almayan örneklerle doğrulanmıştır. Ayrıca kullanılan mikro şebeke sistemine ilave dağıtık üretim kaynakları eklenmesi durumu da dikkate alınmıştır. Bu durum için üretilen altı yüz yeni senaryo için

de tahmin çalışmaları yapılmış ve %98'in üzerinde doğruluk performansı elde edilmiştir. Önerilen yöntemler, $\pm 0,5$ 'ten küçük aktif reaktif güç uyumsuzluğu ile neredeyse sıfır NDZ'ye sahip koşullar için %97,93 doğruluk elde etmiştir. Önerilen yöntemler, EPS'nin güç kalitesini ve kararlılığını olumsuz yönde etkilememektedir. Önerilen algoritmalar, ada çalışmayı yaklaşık 50 ms içinde algılayabilmektedir. En nihayetinde yüksek tespit hızı, yaklaşık sıfır NDZ, yüksek doğruluğa sahip olan ada çalışma tespit yöntemleri farklı tip dağıtık üretim kaynaklarını içeren mikro şebekeler için uygundur.

Yapılan araştırma çalışmaları incelendiğinde elde edilen sonuçlar aşağıdaki şekilde özetlenebilir.

- Bu tez çalışmasında ada çalışma tespiti için ilk kez derin öğrenmeye dayalı 1D CNN ve CNN-LSTM yaklaşımları önerilmiştir.
- Önerilen yaklaşımlar hem tekli hem de birden fazla senkron ve inverter ara yüzlü dağıtık üretimleri içeren mikro şebekeler için uygulanabilmektedir.
- Önerilen yaklaşımlar mikro şebekenin ortak bağlantı noktasındaki THD_v, THD_i, V₃ yerel ölçümlerini kullanarak sadece üç parametre ile minimum işlem maliyeti sağlamaktadır.
- Ada tespit çalışması için oluşturulan veri setinde diğer akıllı yöntemlerden farklı olarak ana şebekenin harmonikli olması durumu ilk kez bu çalışmada dikkate alınmıştır.
- Önerilen yöntemler herhangi bir eşik ayarına ihtiyaç duymamaktadır.
- Önerilen yöntemlerin esnekliği mikro şebeke sisteminin genişletilmesi (ilave senkron ve inverter arayüzlü kaynakların eklenmesi) durumları dikkate alınarak doğrulanmıştır. Bu kapsamda oluşturulan altı yüz adet ada ve ada olmayan çalışma durumlarını içeren yeni senaryolar %98'in üzerinde doğrulukla tahmin edilmiştir.
- Önerilen yöntemler iki yüz adet düşük aktif ve reaktif güç uyumsuzluğuna sahip durumlar ile test edilmiş ve yöntemlerin yaklaşık sıfır NDZ'ye sahip olduğu gösterilmiştir.

- Önerilen yöntemler, 50 milisaniyeden daha kısa sürede ada durumunu tespit edebilmektedir.
- Tez çalışmasından elde edilen bulgular doğrultusunda gelecekte önerilen ada çalışma tespit yönteminin gerçek zamanlı gömülü sistemlerle test edilmesi ve bulguların karşılaştırılması planlanmaktadır.
- Ada çalışma tespitinde derin öğrenme algoritmaları ile alınan sonuçlar değerlendirildiğinde bu yaklaşımların güç sistemlerindeki arıza ve güç kalitesi problemlerinin tespitinde de kullanılabileceği öngörülmektedir.

- [1] R. C. Dugan and T. E. Mcdermott, "Distributed Generation," *IEEE Ind. Appl. Mag.*, pp. 19–25, 2002.
- [2] S. Golshannavaz, S. Afsharnia, and P. Siano, "A comprehensive stochastic energy management system in reconfigurable microgrids," *Int. J. Energy Res.*, 2016.
- [3] K. Yigit and B. Acarkan, "A new ship energy management algorithm to the smart electricity grid system," *Int. J. Energy Res.*, pp. 1–16, 2018.
- [4] R. H. Lasseter, "Microgrids and distributed generation," *Intell. Autom. Soft Comput.*, vol. 16, no. 2, pp. 225–234, 2007.
- [5] S. K. G. Manikonda and D. N. Gaonkar, "Comprehensive review of IDMs in DG systems," *IET Smart Grid*, vol. 2, no. 1, pp. 11–24, 2019.
- [6] J. M. Lee, "Islanding Detection Methods for Microgrids," p. 125, 2011.
- [7] A. G. Abd-elkader and S. M. Saleh, "Zero non-detection zone assessment for anti-islanding protection in rotating machines based distributed generation system," *Int. J. Energy Res.*, no. February, pp. 1–20, 2020.
- [8] A. G. Abd-Elkader, S. M. Saleh, and M. B. Magdi Eiteba, "A passive islanding detection strategy for multi-distributed generations," *Electr. Power Energy Syst.*, vol. 99, no. February, pp. 146–155, 2018.
- [9] X. Xie, C. Huang, and D. Li, "A new passive islanding detection approach considering the dynamic behavior of load in microgrid," *Electr. Power Energy Syst.*, vol. 117, no. October 2019, p. 105619, 2020.
- [10] J. Merino, P. Mendoza-Araya, G. Venkataramanan, and M. Baysal, "Islanding Detection in Microgrids Using Harmonic Signatures," *IEEE Trans. Power Deliv.*, vol. 30, no. 5, pp. 2102–2109, 2015.
- [11] P. K. Ray *et al.*, "Detection of Islanding and Fault Disturbances in Microgrid using Wavelet Packet Transform," *IETE J. Res.*, vol. 2063, no. May, 2018.
- [12] M. Ahmadipour, H. Hizam, and M. Lutfi, "A novel islanding detection technique using modified Slantlet transform in multi-distributed generation," *Electr. Power Energy Syst.*, vol. 112, no. April, pp. 460–475, 2019.
- [13] O. N. Faqhruldin, E. F. El-Saadany, and H. H. Zeineldin, "A universal islanding detection technique for distributed generation using pattern recognition," *IEEE Trans. Smart Grid*, vol. 5, no. 4, pp. 1985–1992, 2014.
- [14] K. El-Arroudi, G. Joos, I. Kamwa, and D. T. McGillis, "Intelligent-based approach to islanding detection in distributed generation," *IEEE Trans. Power Deliv.*, vol. 22, no. 2, pp. 828–835, 2007.
- [15] E. Shahryari, M. Nooshyar, and B. Sobhani, "Combination of neural

- network and wavelet transform for islanding detection of distributed generation in a small-scale network distributed generation in a small-scale network,” *Int. J. Ambient Energy*, vol. 40, no. 3, pp. 263–273, 2017.
- [16] B. Matic-cuka and M. Kezunovic, “Islanding Detection for Inverter-Based Distributed Generation Using Support Vector Machine Method,” *IEEE Trans. Smart Grid*, vol. 5, no. 6, pp. 2676–2686, 2014.
 - [17] M. R. Alam, K. M. Muttaqi, and A. Bouzardoum, “A multifeature-based approach for islanding detection of DG in the subcritical region of vector surge relays,” *IEEE Trans. Power Deliv.*, vol. 29, no. 5, pp. 2349–2358, 2014.
 - [18] S. K. G. Manikonda and D. N. Gaonkar, “Islanding detection method based on image classification technique using histogram of oriented gradient features,” *IET Gener. Transm. Distrib.*, vol. 14, no. 14, pp. 2790–2799, 2020.
 - [19] T. S. Menezes, R. A. S. Fernandes, and D. V. Coury, “Intelligent islanding detection with grid topology adaptation and minimum non-detection zone,” *Electr. Power Syst. Res.*, vol. 187, no. February, p. 106470, 2020.
 - [20] M. Mishra and P. K. Rout, “Fast discrete s-transform and extreme learning machine based approach to islanding detection in grid-connected distributed generation,” *Energy Syst.*, 2018.
 - [21] A. Khamis, Y. Xu, Z. Y. Dong, and R. Zhang, “Faster Detection of Microgrid Islanding Events Using an Adaptive Ensemble Classifier,” *IEEE Trans. Smart Grid*, vol. 9, no. 3, pp. 1889–1899, 2018.
 - [22] X. Kong, X. Xu, Z. Yan, S. Chen, H. Yang, and D. Han, “Deep learning hybrid method for islanding detection in distributed generation,” *Appl. Energy*, vol. 210, no. April 2017, pp. 776–785, 2018.
 - [23] D. Kumar and P. S. Bhowmik, “Artificial neural network and phasor data-based islanding detection in smart grid,” *IET Gener. Transm. Distrib.*, vol. 12, no. 21, pp. 5843–5850, 2018.
 - [24] A. A. Abdelsalam, A. A. Salem, E. S. Oda, and A. A. Eldesouky, “Islanding Detection of Microgrid Incorporating Inverter Based DGs Using Long Short-Term Memory Network,” *IEEE Access*, vol. 8, pp. 106471–106486, 2020.
 - [25] B. J. Brearley and R. R. Prabu, “A review on issues and approaches for microgrid protection,” *Renew. Sustain. Energy Rev.*, vol. 67, pp. 988–997, 2017.
 - [26] N. Hatziaargyriou, H. Asano, R. Iravani, and C. Marnay, “Microgrids,” *IEEE power energy Mag.*, no. august, 2007.
 - [27] Z. Xu, P. Yang, C. Zheng, Y. Zhang, J. Peng, and Z. Zeng, “Analysis on the organization and Development of multi-microgrids,” *Renew. Sustain. Energy Rev.*, vol. 81, no. March 2016, pp. 2204–2216, 2018.
 - [28] Navigant Research, “Microgrid Overview.”

- [29] A. Llaria, O. Curea, J. Jiménez, and H. Camblong, "Survey on microgrids: Unplanned islanding and related inverter control techniques," *Renew. Energy*, vol. 36, no. 8, pp. 2052–2061, 2011.
- [30] T. Basso, "IEEE 1547 and 2030 Standards for Distributed Energy Resources Interconnection and Interoperability with the Electricity Grid," *Nrel*, no. December, p. 22, 2014.
- [31] C. Li, C. Cao, Y. Cao, Y. Kuang, L. Zeng, and B. Fang, "A review of islanding detection methods for microgrid," *Renew. Sustain. Energy Rev.*, vol. 35, pp. 211–220, 2014.
- [32] J. A. Laghari, H. Mokhlis, M. Karimi, A. H. A. Bakar, and H. Mohamad, "Computational Intelligence based techniques for islanding detection of distributed generation in distribution network: A review," *Energy Convers. Manag.*, vol. 88, pp. 139–152, 2014.
- [33] "IEEE Std 1547TM-2003 (R2008) - for Interconnecting Distributed Resources with Electric Power Systems," 2003.
- [34] M. Q. Raza and A. Khosravi, "A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings," *Renew. Sustain. Energy Rev.*, vol. 50, pp. 1352–1372, 2015.
- [35] Y. Bicer, I. Dincer, and M. Aydin, "Maximizing performance of fuel cell using artificial neural network approach for smart grid applications," *Energy*, vol. 116, pp. 1205–1217, 2016.
- [36] V. A. Evangelopoulos and P. S. Georgilakis, "Optimal operation of smart distribution networks: A review of models, methods and future research," *Electr. Power Syst. Res.*, vol. 140, pp. 95–106, 2016.
- [37] F. Yaprakdal and M. Baysal, "Optimal Operational Scheduling of Reconfigurable Microgrids in Presence of Renewable Energy Sources," *Energies*, no. May, 2019.
- [38] B. K. Panigrahi, A. Bhuyan, J. Shukla, P. K. Ray, and S. Pati, "A comprehensive review on intelligent islanding detection techniques for renewable energy integrated power system," *Int. J. Energy Res.*, 2021.
- [39] Y. Bengio, "Learning Deep Architectures for AI," *Found. Trends Mach. Learn.*, vol. 2, no. 1, 2009.
- [40] A. K. Ozcanli, F. Yaprakdal, and M. Baysal, "Deep learning methods and applications for electrical power systems: A comprehensive review," *Int. J. Energy Res.*, no. February, pp. 1–22, 2020.
- [41] Y. Lecun, Y. Bengio, and G. Hinton, "Deep learning," *Nature*, vol. 521, no. 7553, pp. 436–444, 2015.
- [42] G. Helbing and M. Ritter, "Deep Learning for fault detection in wind turbines," vol. 98, no. September, pp. 7–9, 2018.
- [43] Y. Bengio and Y. Lecun, "Scaling Learning Algorithms towards AI To appear in " Large-Scale Kernel Machines ", " *MIT Press*, no. 1, pp. 1–41, 2007.

- [44] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *Bull. Math. Biophys.*, vol. 5, no. 4, pp. 115–133, 1943.
- [45] G. Hinton, S. Asindero, and Y. Whye Teh, "A fast learning algorithm for deep belief nets," *Neural Comput.*, vol. 18, no. 7, pp. 1527–54, 2006.
- [46] Y. Lecun, L. Bottou, Y. Bengio, and P. Haffner, "Reducing the Dimensionality of Data with Neural Networks," *Science (80-.)*, vol. 313, no. 5786, pp. 504–507, 2006.
- [47] A. Krizhevsky, I. Sutskever, and G. E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," *Adv. Neural Inf. Process. Syst.*, pp. 1–9, 2012.
- [48] T. Yue and H. Wang, "Deep Learning for Genomics: A Concise Overview," in *Handbook of Deep Learning Applications*, 2018.
- [49] NVIDIA, "Deep learning for self-driving cars." [Online]. Available: <https://www.nvidia.com/en-us/deep-learning-ai/industries/automotive/>. [Accessed: 10-May-2018].
- [50] M. S. Gashler, "Deep Learning in Robotics : A Review of Recent Research," *arXiv:1707.07217*, pp. 1–41.
- [51] S. Kiranyaz, O. Avci, O. Abdeljaber, T. Ince, M. Gabbouj, and D. J. Inman, "1D convolutional neural networks and applications - A survey," *arXiv*, pp. 1–20, 2019.
- [52] R. J. Williams and D. Zipser, "A learning algorithm for continually running fully recurrent neural networks," *Neural Comput.*, vol. 1, pp. 270–280, 1989.
- [53] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," in *arXiv:1412.3555*, 2014.
- [54] S. Hochreiter and J. Schmidhuber, "Long Short Term Memory," *Neural Comput.*, vol. 9, no. 8, pp. 1735–1780, 1997.
- [55] M. Barnes, T. Green, R. Lasseter, and N. Hatziargyriou, "Real-World MicroGrids- An Overview," in *IEEE International Conference on System of Systems Engineering*, 2007.
- [56] S. Krishnamurthy and R. Lasseter, "Control of Wound Field Synchronous Machine Gensets for Operation in a CERTS," 2009.
- [57] W. Du, R. H. Lasseter, L. Fellow, A. S. Khalsa, and S. Member, "Survivability of Autonomous Microgrid during Overload Events," vol. 3053, no. c, 2018.
- [58] J. Stevens, H. Vollkommer, and D. Klapp, "CERTS Microgrid System Tests," pp. 1–4, 2007.
- [59] J. Eto and R. Lasseter, "Overview of the CERTS Microgrid Laboratory Test Bed," 2009.
- [60] "InVerde." [Online]. Available: <https://www.tecogen.com/chp->

cogeneration/inverde.

- [61] M. J. Erickson and D. Klapp, "Modeling and Control of a Natural Gas Generator Set in the CERTS Microgrid," *2013 IEEE Energy Convers. Congr. Expo.*, pp. 1640–1646, 2013.
- [62] R. H. Lasseter *et al.*, "CERTS Microgrid Laboratory Test Bed," *IEEE Trans. Power Deliv.*, vol. 26, no. 1, pp. 325–332, 2011.
- [63] V. L. Merlin, R. C. Santos, A. P. Grilo, J. C. M. Vieira, D. V. Coury, and M. Oleskovicz, "A new artificial neural network based method for islanding detection of distributed generators," *International Journal of Electrical Power & Energy Systems*, vol. 75, pp. 139–151, 2016.
- [64] M. Bakhshi, R. Noroozian, and G. B. Gharehpetian, "Islanding detection scheme based on adaptive identifier signal estimation method," *ISA Trans.*, vol. 71, pp. 328–340, 2017.
- [65] A. A. Abdelsalam, A. A. Salem, E. S. Oda, and A. A. Eldesouky, "Islanding Detection of Microgrid Incorporating Inverter Based DGs Using Long Short-Term Memory Network," *IEEE Access*, vol. 8, pp. 106471–106486, 2020.
- [66] A. Ng, *Machine Learning Yearning- Draft*. 2018.
- [67] J. C. M. Vieira, W. Freitas, W. Xu, and A. Morelato, "An Investigation on the Nondetection Zones of Synchronous Distributed Generation Anti-Islanding Protection," vol. 23, no. 2, pp. 593–600, 2008.
- [68] S. Admasie, S. Basit, A. Bukhari, T. Gush, R. Haider, and C. H. Kim, "Intelligent Islanding Detection of Multi-distributed Generation Using Artificial Neural Network Based on Intrinsic Mode Function Feature," vol. XX, no. Xx, pp. 1–10.
- [69] A. Taheri Kolli and N. Ghaffarzadeh, "A novel phaselet-based approach for islanding detection in inverter-based distributed generation systems," *Electr. Power Syst. Res.*, vol. 182, no. September 2019, 2020.
- [70] Q. Cui, K. El-Arroudi, and G. Joos, "Islanding detection of hybrid distributed generation under reduced non-detection zone," *IEEE Trans. Smart Grid*, vol. 9, no. 5, pp. 5027–5037, 2018.
- [71] N. B. Hartmann, R. C. Dos Santos, A. P. Grilo, and J. C. M. Vieira, "Hardware Implementation and Real-Time Evaluation of an ANN-Based Algorithm for Anti-Islanding Protection of Distributed Generators," *IEEE Trans. Ind. Electron.*, vol. 65, no. 6, pp. 5051–5059, 2018.
- [72] D. Mlakic, H. R. Baghaee, and S. Nikolovski, "A Novel ANFIS-based Islanding Detection for Inverter Interfaced Microgrids," *IEEE Trans. Smart Grid*, vol. PP, no. c, p. 1, 2018.
- [73] H. R. Baghaee, D. Mlakic, S. Nikolovski, and T. Dragicevic, "Anti-Islanding Protection of PV-Based Microgrids Consisting of PHEVs Using SVMs," *IEEE Trans. Smart Grid*, vol. 11, no. 1, pp. 483–500, 2020.
- [74] V. R. Reddy and E. S. Sreeraj, "A Feedback-Based Passive Islanding

- Detection Technique for One-Cycle-Controlled Single-Phase Inverter Used in Photovoltaic Systems,” *IEEE Trans. Ind. Electron.*, vol. 67, no. 8, pp. 6541–6549, 2020.
- [75] S. A. Chavoshi, R. Noroozian, and A. Emiri, “Islanding detection of synchronous distributed generation resources using AdaBoost algorithm,” *Int. Trans. Electr. energy Syst.*, pp. 1–6, 2015.
 - [76] J. Ke, Z. Zhengxuan, Y. Zhe, F. Yu, B. Tianshu, and Z. Jiankang, “Intelligent islanding detection method for photovoltaic power system based on Adaboost algorithm,” *IET Gener. Transm. Distrib.*, vol. 14, no. 18, pp. 3630–3640, 2020.
 - [77] A. G. Abd-Elkader, D. F. Allam, and E. Tageldin, “Islanding detection method for DFIG wind turbines using artificial neural networks,” *International Journal of Electrical Power & Energy Systems*, vol. 62, pp. 335–343, 2014.
 - [78] F. Hashemi, M. Mohammadi, and A. Kargarian, “Islanding detection method for microgrid based on extracted features from differential transient rate of change of frequency,” *IET Gener. Transm. Distrib.*, vol. 11, no. 4, pp. 891–904, 2017.

Konferans Bildirileri

1. A. Kaymaz Özcanlı and M. Baysal, “Senkron Generatör İçeren Mikro şebekelerde Farklı Çalışma Koşullarındaki Harmonik Analizi,” in *Elektrik Elektronik Mühendisliği Kongresi 2019 (EEMKON)*.
2. A. Kaymaz Özcanlı and M. Baysal, “The effect of islanding on harmonic distortion in the inverter-based microgrid,” in *World Energy Strategies Congress and Exhibition 2019 (WESCE’19)*, 2019, pp. 242–247.

Makaleler

1. A. K. Özcanlı, F. Yaprakdal, and M. Baysal, “Deep learning methods and applications for electrical power systems: A comprehensive review,” *Int. J. Energy Res.*, no. February, pp. 1–22, 2020.
2. A. K. Özcanlı and M. Baysal, “A novel Multi-LSTM based deep learning method for islanding detection in the microgrid,” *Electr. Power Syst. Res.*, vol. 202, 2021.
3. A. K. Özcanlı and M. Baysal, “Islanding Detection in Microgrid Using Deep Learning Based on 1D CNN and CNN-LSTM Networks,” *Sustainable Energy, Grids and Networks* ., (underreview).