



T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

RÜZGAR HIZI TAHMİNİ İÇİN YAPAY SİNİR AĞI VE
ADAPTİF SANSÜRLEME TEKNİĞİ TABANLI
YENİ YAKLAŞIMLARIN GELİŞTİRİLMESİ

YÜKSEK LİSANS TEZİ

NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ALİ OGÜN SARP

ŞUBAT 2021

T.C.
NİĞDE ÖMER HALİSDEMİR ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ELEKTRİK-ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI

RÜZGAR HIZI TAHMİNİ İÇİN YAPAY SİNİR AĞI VE
ADAPTİF SANSÜRLEME TEKNİĞİ TABANLI
YENİ YAKLAŞIMLARIN GELİŞTİRİLMESİ

ALİ OGÜN SARP

Yüksek Lisans Tezi

Danışman

Doç. Dr. ENGİN CEMAL MENGÜÇ

ŞUBAT 2021

ALİ OGÜN SARP tarafından **Doç. Dr. ENGİN CEMAL MENGÜÇ** danışmanlığında hazırlanan “**Rüzgar Hızı Tahmini İçin Yapay Sinir Ağı ve Adaptif Sansürleme Tekniği Tabanlı Yeni Yaklaşımların Geliştirilmesi**” adlı bu çalışma jürimiz tarafından Niğde Ömer Halisdemir Üniversitesi Fen Bilimleri Enstitüsü **Elektrik-Elektronik Mühendisliği** Ana Bilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Başkan : Doç. Dr. Engin Cemal MENGÜÇ, Niğde Ömer Halisdemir Üniversitesi

Üye : Dr. Öğr. Üyesi Hasan ZORLU, Erciyes Üniversitesi

Üye : Dr. Öğr. Üyesi Murat PEKER, Niğde Ömer Halisdemir Üniversitesi

ONAY:

Bu tez, Fen Bilimleri Enstitüsü Yönetim Kurulunca belirlenmiş olan yukarıdaki jüri üyeleri tarafından .../.../20.... tarihinde uygun görülmüş ve Enstitü Yönetim Kurulu’nun .../.../20.... tarih ve sayılı kararıyla kabul edilmiştir.

...../...../20...

Prof. Dr. Murat BARUT
MÜDÜR

TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin bilimsel ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada bana ait olmayan her türlü ifade ve bilginin kaynağına eksiksiz atıf yapıldığını bildiririm.

Ali Ogün SARP

ÖZET

RÜZGAR HIZI TAHMİNİ İÇİN YAPAY SİNİR AĞI VE ADAPTİF SANSÜRLEME TEKNİĞİ TABANLI YENİ YAKLAŞIMLARIN GELİŞTİRİLMESİ

SARP, Ali Ogün

Niğde Ömer Halisdemir Üniversitesi

Fen Bilimleri Enstitüsü

Elektrik-Elektronik Mühendisliği Ana Bilim Dalı

Danışman : Doç. Dr. Engin Cemal MENGÜÇ

Şubat 2021, 40 Sayfa

Bu tez çalışmasında, çok katmanlı algılayıcı (ÇKA) ve tekrarlayan sinir ağına (TSA) tabanlı yeni kısa vadeli rüzgar hızı tahminciler, veri adaptif sansürleme (VAS) stratejisi ile birleştirilerek önerilmiştir. Burada, çok-adım-ileri tahmin modu dikkate alınarak, ÇKA ve TSA yapıları için tüm eğitim kümelerinden en bilgilendirici giriş/çıkış rüzgar verilerinden oluşan yeni bir eğitim veri kümesini yinelemeli olarak elde edebilen VAS stratejisine dayalı en küçük ortalama kare (EKOK) algoritması (VAS-EKOK) tasarlanmıştır. VAS-EKOK daha az bilgilendirici eğitim verilerini yüksek doğrulukla sansürlememizi sağlamış ve böylece ÇKA ve TSA'nın eğitim maliyetlerini, test süreçlerindeki tahmin başarımlarını etkilemeden azaltmıştır. Gerçek hayattaki büyük ölçekli kısa vadeli rüzgar hızı verileri üzerinde gerçekleştirilen benzetim sonuçları, önerilen bu tahmincilerin belirtilen çekici özelliklerini doğrulamıştır.

Anahtar Sözcükler: Rüzgar hızı, veri-adaptif sansürleme stratejisi, en küçük kare algoritması, çok katmanlı algılayıcı, tekrarlayan sinir ağıları

SUMMARY

DEVELOPMENT OF NEW APPROACHES BASED ON ARTIFICIAL NEURAL NETWORK AND ADAPTIVE CENSORING TECHNIQUE FOR WIND SPEED PREDICTION

SARP, Ali Oğün

Nigde Omer Halisdemir University

Graduate School of Natural and Applied Sciences

Department of Electrical and Electronics Engineering

Supervisor : Associate Professor Dr. Engin Cemal MENGÜÇ

February 2021, 40 Pages

In this thesis, novel short-term wind speed predictors based on multilayer perceptron (MLP) and recurrent neural network (RNN) are proposed by combining them with the data-adaptive censoring (DAC) strategy. Taking into account the multi-step ahead prediction mode, we design a DAC strategy based-least mean square (LMS) algorithm (DAC-LMS), which iteratively obtains a new training data set consisting of the most informative input-output wind data from all training set for MLP and RNN structures. This enables us to censor less informative training data with high accuracy and thereby the training costs of the MLP and RNN are reduced without affecting prediction performances in their testing processes. The conducted simulation results on real-life large-scale short-term wind speed data verify the mentioned attractive features of the proposed predictors.

KeyWords: Wind speed, data-adaptive censoring strategy, least mean square algorithm, multi-layer perceptron, recurrent neural networks

ÖN SÖZ

Bu tez çalışmasında, MLP ve tekrarlayan sinir ağına RNN tabanlı yeni kısa vadeli rüzgar hızı tahminciler, DAC stratejisi ile birleştirilerek önerilmiştir. Burada, çok-adım-ileri tahmin modu dikkate alınarak, MLP ve RNN yapıları için tüm eğitim kümelerinden en bilgilendirici giriş/çıkış rüzgar verilerinden oluşan yeni bir eğitim veri kümesini yinelemeli olarak elde edebilen DAC-LMS tasarlanmıştır. DAC-LMS algoritması, daha az bilgilendirici eğitim verilerini yüksek doğrulukla sansürlememizi sağlamış ve böylece MLP ve RNN'nin eğitim süresini, test süreçlerindeki tahmin başarımlarını neredeyse etkilemeden dikkate değer bir şekilde azaltmıştır. Önerilen tahmin edicilerin başarımları büyük ölçekli geçek rüzgar hızı üzerinde ölçülmüş ve eğitim süresi ve başarımla ilgili bahsedilen özellikleri doğrulanmıştır. Ayrıca bu özellikleri doğrularken, DAC-LMS algoritması, kullanıcı tarafından seçilen sansürleme oranına oldukça yakın bir sansürleme oranı elde ederek yüksek başarımda çalışmıştır.

Öncelikle tez çalışmasının yürütülmesi esnasında, bilgi, deneyim ve tecrübelerini bir an olsun benden esirgemeyen, her zaman motive eden, daima yardımcı olan ve birlikte çalışmaktan büyük onur ve şeref duyduğum danışmanım Sayın Doç. Dr. Engin Cemal MENGÜÇ'e teşekkürlerimi sunarım. Ayrıca bu zorlu tez sürecinde benden desteğini bir an için bile esirgemeyen değerli arkadaşım Elif ÇİDAM'a, tüm eğitim hayatım boyunca benden maddi ve manevi desteklerini esirgemeyen her zaman yanımda olan sevgili aileme teşekkürlerimi bir borç bilirim.

İÇİNDEKİLER

ÖZET	iv
SUMMURY	v
ÖN SÖZ	vi
İÇİNDEKİLER	vii
ÇİZELGELER DİZİNİ	viii
ŞEKİLLER DİZİNİ	ix
SİMGELER VE KISALTMALAR	x
BÖLÜM I GİRİŞ	1
BÖLÜM II MATERYAL VE METOT	6
2.1 Problem Tanımı	6
2.2 Veriye Uyarlamalı Sansür Stratejisi	6
2.3 Geleneksel En Küçük Kareler Algoritması	8
BÖLÜM III MLP Ve RNN Yapılarına Dayalı Önerilen Kısa Vadeli Rüzgar Hızı Tahminlerinin Tasarımı	9
BÖLÜM IV BENZETİM SONUÇLARI VE TARTIŞMA	14
4.1 Veri Kümesi ve Çalışma Ortamı	14
4.2 Başarım Ölçütü	15
4.3 Parametre Seçimleri	16
4.4 Önerilen MLP ve RNN'nin Tahmin Başarımları	16
BÖLÜM V SONUÇLAR	31
KAYNAKLAR	32
ÖZ GEÇMİŞ	39
TEZ ÇALIŞMASINDAN ÜRETİLEN ESERLER	40

ÇİZELGELER DİZİNİ

Çizelge 4.1. Washington veri kümesi için bir-adım-ileri MLP ve RNN tahmin edicilerinin ortalama eğitim süreleri.....	22
Çizelge 4.2. Storm Lake veri kümesi için bir-adım-ileri MLP ve RNN tahmin edicilerinin ortalama eğitim süreleri.....	23
Çizelge 4.3. Washington veri kümesi için eğitilmiş bir-adım-ileri MLP tahmin edicisinin R_p Ve CC değerleri açısından test başarımı	24
Çizelge 4.4. Storm Lake veri kümesi için eğitilmiş bir-adım-ileri MLP tahmin edicisinin R_p Ve CC değerleri açısından test başarımı	25
Çizelge 4.5. Washington veri kümesi için eğitilmiş bir-adım-ileri RNN tahmin edicisinin R_p Ve CC değerleri açısından test başarımı	26
Çizelge 4.6. Storm Lake veri kümesi için eğitilmiş bir-adım-ileri RNN tahmin edicisinin R_p Ve CC değerleri açısından test başarımı	27
Çizelge 4.7. Washington veri kümesi için önerilen bir-adım-ileri tahmin edicilerin klasik versiyonlarıyla karşılaştırıldığında eğitim süresi ve test tahmin başarımı üzerine yüzde etkisi	28
Çizelge 4.8. Storm Lake veri kümesi için önerilen bir-adım-ileri tahmin edicilerin klasik versiyonlarıyla karşılaştırıldığında eğitim süresi ve test tahmin başarımı üzerine yüzde etkisi	29
Çizelge 4.9. Önerilen DAC-LMS algoritmasının kestirilmiş sansürleme oranı \hat{P}_{cr}	30

ŞEKİLLER DİZİNİ

Şekil 3.1. Önerilen Kısa Vadeli Rüzgar Hızı Tahmin Edicileri; MLP (a) ve Yerel Geri Beslemeli RNN (b)	10
Şekil 4.1. Büyük Ölçekli Washington ve Strom Lake Bölgelerine ait Gerçek Rüzgar Hızı Sinyalleri	15
Şekil 4.2. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%30$ olarak seçilmiştir.)	19
Şekil 4.3. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%50$ olarak seçilmiştir.)	19
Şekil 4.4. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%70$ olarak seçilmiştir.)	20
Şekil 4.5. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%30$ olarak seçilmiştir.)	20
Şekil 4.6. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%50$ olarak seçilmiştir.)	21
Şekil 4.7. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%70$ olarak seçilmiştir.)	21

SİMGE VE KISALTMALAR

Simgeler	Açıklama
k	Zaman İndeksi
d_k	k 'inci Öğretme (hedef) sinyali
\mathbf{h}_0	k 'inci Ağırlık Vektörü
\mathbf{x}_k	k 'inci Giriş Regresör Vektörü
n_k	Sıfır Ortalamalı Gauss Beyaz Ölçüm Gürültüsü
N	Sıra Sayısı
y_k	k 'inci Çıkışı Vektörü
e_k	k 'inci Hata Sinyali
z_k	Genel Sansürleme Kuralı
τ	Sansürleme Eşik Değeri
P_{cr}	Sansür Oranı
\mathbf{R}_{xx}	Giriş Vektörünün Oto-Korelasyon Matrisi
$Q^{-1}(\cdot)$	Birleşik Kümülatif Dağılımın Tersisi
$[\cdot]^T$	Vektörel Transpozu
p	d_k 'nın Uzunluğu
K	Bilgilendirici Veri Sayısı
d_i^{inf}	MLP ve RNN Tahmin Edicilerinin En Bilgilendirici Hedef Verisi
\mathbf{x}_i^{inf}	MLP ve RNN Tahmin Edicilerinin En Bilgilendirici Giriş Verisi
$V(x_k)$	Aday Lyapunov Fonksiyonu
σ	Standart Sapma
μ	Adım büyüklüğü
\geq	Büyük eşittir
\in	Elemanıdır
N	Filtre Derecesi

\leq	Küçük Eşittir
J_k	k 'inci Maliyet Fonksiyonu
∇	Gradyent
∂	Kısmi türev
β	Unutma Faktörü
$\lambda_{\max}(\cdot)$	\mathbf{R}_{xx} 'in En Büyük Öz Değeri
\neq	Eşit Değildir
\approx	Yaklaşık Olarak Eşit

Kısaltmalar

Açıklama

NWP	Sayısal Hava Tahmini (Numerical Weather Prediction)
LMS	En Küçük Ortalama Kare (Least Mean Square)
LSTM	Uzun/Kısa Vadeli Bellek (Long/Short Term Memory)
CNN	Evrşimsel Sinir Ağları (Convolutional Neural Networks)
RNN	Tekrarlayan Sinir Ağları (Recurrent Neural Networks)
ARMA	Oto-Regresif Hareketli Ortalama (Auto-Regressive Moving Average)
ARIMA	Oto-Regresif Entegre Edilmiş Hareketli Ortalama (Auto-Regressive Integrated Moving Average)
ARIMAX	Dışsal Değişkenli Oto-Regresif Entegre Edilmiş Hareketli Ortalama (Exogenous Variable Auto-Regressive Integrated Moving Average)
YSA	Yapay Sinir Ağı (Artificial Neural Network)
FIR	Sonlu Darbe Cevaplı (Finite Impulse Response)
MLP	Çok Katmanlı Algılayıcılar (Multi Layer Perceptron)
DAC	Veri Adaptif Sansürleme (Data Adaptive Censoring)

BÖLÜM I

GİRİŞ

Günümüzde belirgin şekilde görülen enerjiye ulaşım sıkıntısından dolayı yenilenebilir enerji kaynaklarına olan önem her geçen gün artmaktadır. Yenilenebilir doğal enerji kaynaklarından birisi olan rüzgar enerjisi de hala önemini korumaktadır. Rüzgar enerjisi; büyük rezervler, yenilenebilirlik ve kirlilik içermemesi gibi avantajlarından dolayı, ideal bir enerji üretim şekli olarak kabul edilmektedir (Mishra vd., 2018; Tian vd., 2018a, b). Bu doğal enerji kaynağında en önemli etken enerjinin çıkış gücüdür. Bu güç de rüzgar çiftliklerine gelen rüzgarın şiddeti ve sürekliliği ile doğru orantılıdır (Pradhan ve Bhende, 2019). Rüzgarın şiddetinin ve sürekliliğinin bu derece önemli olduğu durumda rüzgar hızının rastgeleliği ve hızlı değişimlere sahip olması büyük bir dezavantajdır (Araghi vd., 2019). Bu durumun önüne geçmek için rüzgar hızının doğru ve hızlı bir şekilde tahmin edilmesi büyük önem arz etmektedir. Doğru tahminler sonucunda da iletim planlarının zamanında ayarlanmasını sağlamaktadır. Bu durum ise rüzgar çiftliklerine olan güvenilirliği arttırmaktadır (Murthy ve Rahi, 2017; Vargas vd., 2019).

Rüzgar hızı tahmini, farklı zaman periyotlarında; uzun vadeli, orta vadeli ve kısa vadeli olmak üzere 3 farklı şekilde gerçekleştirilmektedir (Wang vd., 2016). Kısa vadeli tahmin; tüketicilerin yanı sıra üretim, iletim ve dağıtım yapan firmaların da bulunduğu piyasada yaygın olarak kullanılmakta olup, 10 saniye ile 8 saat aralığında yapılan tahmin durumlarında kullanılmaktadır. Orta vadeli tahmin, 8 saat ile bir hafta aralığında olan tahmin durumları için geçerlidir. Bakım planlaması ve rüzgar çiftlikleri gibi bir haftadan daha uzun süreli tahminlere ihtiyaç duyulan yerlerde ise uzun vadeli tahminler yapılmaktadır. Rüzgar hızının zamana bağlı rastgeleliliği ve belirsizliği, kısa vadeli tahminlerin hem teorik hem de pratik olarak rüzgar enerjisi üretiminde önemli yere sahip olmasını sağlamaktadır (Tian, 2020). Enerji üretiminde en temel etken yerel rüzgar hızı olduğundan dolayı, rüzgar hızının doğru ve hızlı bir şekilde tahmin edilmesi, üretimde güvenilirliği ve sürekliliği arttıracak temel faktördür (Hu vd., 2018).

Rüzgar hızını etkileyen birçok parametre vardır. Nem, sıcaklık, atmosfer basıncı gibi durumlar rüzgar hızını etkileyen başlıca parametrelerdir (Niau, 1995; Song vd., 2020).

Elbette bu çevresel etkenler dikkate alındığında, tasarlanan tahmin modelleri daha doğru ve güvenilir sonuçlar üretebilmektedir. Fakat bu değişkenleri ölçmek için harici sensörlere ihtiyaç duyulmaktadır ve bu sensörlerin kurulumu, testi ve iletimi tahmin işlemine ciddi bir mali külfet getirmektedir. Ayrıca, bu değişkenler tahmin modelinin harici girdisi olarak kullanılacağından modelin karmaşıklığını ve eğitim süresini arttırmaktadır. Bu yüzden, literatürde yapılan birçok çalışmada, sadece geçmiş rüzgar verilerini aktif bir şekilde kullanan modellerin ön plana çıktığı görülmektedir (Tian, 2020).

Literatürde, Kalman filtresi, fiziksel tahmin yöntemi, derin öğrenme modeli, kalıcılık yöntemi, bulanık mantık, zaman serisi yöntemi, yapay sinir ağı ve hibrit modeller gibi birçok teknik rüzgar hızı tahmininde kullanılmış ve bu yöntemlerin avantaj ve dezavantajlarından aşağıda bahsedilmiştir (Tian, 2020).

- Kalman filtresi, kısa vadeli rüzgar hızı tahminlerinde yaygın kullanılan bir yöntemdir. Bu yöntem, dinamik sistem tabanlı olduğundan önceki tahmin verisini, dinamik ağırlık düzeltme özelliklerine sahip olan en son ölçülen değere göre önceki tahmini değeri düzeltebilme prensibine göre çalışır. (Galanis vd., 2017; Cai vd., 2019; Zuluaga vd., 2015). Fakat rüzgar hızının doğru tespitinde, gürültüyü ortadan kaldırmak çok büyük öneme sahiptir ve yok etmek de oldukça zordur. Hız ve gürültünün sürekli değişkenlik göstermesi, kalman filtresinin tahminini güçleştirmektedir.
- Fiziksel tahmin yöntemleri temel olarak sayısal hava tahmini yöntemi (Numerical Weather Prediction, NWP) (Yang vd., 2018; Wang vd., 2019a) ve uzaysal korelasyon yöntemi (Ye vd., 2017) olmak üzere ikiye ayrılır. 1 ile 3 gün süresince rüzgar hızı verisi elde edebilen NWP tabanlı tahmin yöntemi nispeten kararlı gözükse de hesap yükü oldukça fazladır ve bu yüzden kısa vadeli rüzgar hızı tahminlerinde kullanım için uygun değildir. Öte yandan, uzaysal korelasyon yöntemi, yakın bir saat dilimi içinde rüzgar çiftlikleri etrafında bulunan istasyonların rüzgar hızı verilerine bağlı bir modeldir. Bu yöntem ile yapılan tahminler doğrudan istasyonun konumu ve rüzgar yönünden etkilenmektedir.

- Günümüzde bir makine öğrenmesinin alt dalı olan derin öğrenme modelinin birçok çeşidi rüzgar hızı tahmininde kullanılmaktadır. Bunlar uzun/kısa vadeli bellek (Long/Short Term Memory, LSTM) ağları (Zhang vd., 2019a), evrimsel sinir ağları (Convolutional Neural Networks, CNN) (Zhou vd., 2018; Mi vd., 2019), tekrarlayan sinir ağları (Recurrent Neural Network, RNN) (Li vd., 2019) gibi birçok modele sahiptir. Bu modeller, eğitim için çok fazla veriye ihtiyaç duymaktadırlar ve hesap yükleri göz ardı edilemeyecek kadar fazladır.
- Kalıcılık (persistence) yöntemi, tahmin edilen rüzgar hızı verilerinin en son bulunan verilerin kayan ortalama (moving average) değerlerine eşit olduğu varsayımını kullanan bir yöntemdir (Santamaria-Bonfil vd., 2016). Bu yöntemle gerçekleştirilen tahminler yüksek hatalı ve kararsız davranışlar sergileyebilmektedir. Bunun temel sebebi en yakın örnekleme zamanının rüzgar hızı değerinin, bir sonraki örnek zamanda yapılan tahmin değeriyle aynı olacak şekilde kullanılmasıdır.
- İnsan ve makinenin en fazla birbirine yaklaştığı durum olarak bilinen bulanık mantık (Fuzzy Logic) yöntemi; yapay zeka, sosyoloji, tıp ve fen bilimleri gibi alanların ortak çalışma noktasında yer almaktadır (An vd., 2014; Khorramdel vd., 2018). Bu yöntem, rüzgar hızı tahmini için doğrusal bir model kullanır. Fakat doğrusal olmayan dinamiklere sahip olan rüzgar hızı kestiriminde yetersiz kalmaktadır. Ayrıca bulanık mantık tabanlı sistemlerin öğrenme başarımı diğer sistemlere kıyasla daha düşüktür (Wang ve Zhang, 2018).
- Zaman serisi yöntemi, model oluşturmak için bir dizi geçmiş veri kullanan ve rüzgar hızının değişim yasasını tanımlayabilen matematiksel bir model belirlemek için model tanıma, parametre tahmini ve model testi yolunu kullanan bir yöntemdir. Ayrıca, zaman serileri, oto-regresif hareketli ortalama (Auto Regressive Moving Average, ARMA) (Erdem ve Shi, 2011), oto-regresif entegre edilmiş hareketli ortalama (ARIMA) (Cadenas vd., 2016), dışsal değişkenli oto-regresif entegre hareketli ortalama (ARIMAX) (Yan vd., 2017) modellerini içerir. Fakat bu yöntem, düşük-dereceli modellemede düşük tahmin başarımı ve yüksek-dereceli modellemede ise parametre tahmininin zor olması gibi bazı sorunlar barındırır.
- Yapay sinir ağı, insan beyninin yapısını ve işlevini taklit etmek için tasarlanmış güçlü bir alet olarak karşımıza çıkmaktadır. Belli bir topolojik yapı ile büyük ölçekte birbirine bağlanmış çok sayıda basit işlem elemanlarından oluşur. Oldukça

kısa vadeli tahminlerde kullanılan bu yöntem, paralel işleme, dağılmış depolama ve hataya dayanıklılık, kendi kendine öğrenme, organize etme ve adaptasyon etme gibi özelliklere sahiptir (Hüseyin ve Tansu, 2019). Oldukça kısa vadeli rüzgar hızı tahmini için radyal temel fonksiyon sinir ağı (Chang vd., 2017), bulanık sinir ağı (Ma vd., 2017), Elman sinir ağı (Yu vd., 2018,2017), aşırı öğrenme makinesi (ELM) (Sun vd., 2018; Luo vd., 2018; Tian vd., 2019), eko durum ağı (Chitsazan vd., 2019), dalgacık sinir ağı (Santhosh vd., 2018; Wang vd., 2017), doğrusal olmayan sinir ağı (Maruliya Begam ve Deepa, 2019; Liu vd., 2018) olmak üzere bir çok ağ yapısı kullanılmıştır. YSA'nın en büyük sıkıntısı, ağın eğitim süresini ciddi oranda artıran çok fazla veriye ihtiyaç duymasındır. YSA'ların bu problemi bu tez çalışmasının yapılmasını motive etmiştir.

Son yıllarda, veri-adaptif sansür (Data-Adaptive Censoring, DAC) stratejisi (Berberidis vd., 2016), işlem ve depolama maliyeti gerektiren büyük miktarda verilerle başa çıkmak için mükemmel ve verimli bir araç haline gelmiştir. DAC stratejisinin temel amacı, belli bir kural doğrultusunda daha az bilgilendirici verilerden kurtulmak için aralıklı sansürlemeyi kullanmaktır. Kısacası DAC stratejisi, çevrimiçi bir şekilde sadece bilgilendirici verileri adaptif olarak seçme eğilimi göstermektedir. Bu nedenle, DAC stratejisi yapısı gereği çoğu büyük veri uygulamalarında (Berberidis vd., 2016; Wang vd., 2018; Sheikholeslami vd., 2018; Zhu vd., 2018; Wang vd., 2019; Yang vd., 2019) önemli bir yere sahiptir.

Bu tez çalışmasında, DAC stratejisi kullanılarak, MLP ve RNN'ye tabanlı yeni kısa vadeli rüzgar hızı tahmin edicileri önerilmiştir. Bu amaç için DAC stratejisine tabanlı en küçük ortalama kare (Least-Mean Squares, LMS) algoritması (DAC-LMS), çok-adım-ileri tahmin modu göz önüne alınarak tasarlanmıştır. Burada, DAC-LMS algoritması, MLP ve RNN yapılarının eğitimi için tüm eğitim kümesinden en bilgilendirici giriş/çıkış verilerinden oluşan yeni bir eğitim veri kümesini yinelemeli olarak elde eder. Böylelikle bu algoritma, MLP ve RNN'nin eğitim süresini önemli ölçüde azaltan ve test sürecindeki tahmin başarımlarını neredeyse etkilemeyen daha anlamlı bir eğitim kümesi oluşturmamıza olanak sağlamıştır. Gerçek hayattaki büyük

ölçekli kısa vadeli rüzgar hızı verileri üzerinde benzetim sonuçları, önerilen tahmin edicilerin bahsedilen bu özelliklerini doğrulamıştır.

Tezin geri kalanı şu şekilde devam etmektedir: Bölüm II’de sırasıyla problem tanımı, veri-adaptif uyarlamalı sansür stratejisi ve geleneksel en küçük kareler (LMS) algoritması verilmektedir. Bölüm III’te MLP ve RNN yapıları tabanlı olarak önerilen kısa vadeli rüzgar hızı tahmin edicilerinin tasarımı verilmektedir. Bölüm IV’te, benzetim sonuçları ve tartışmalara kapsamlı şekilde yer verilmiştir. Son olarak, Bölüm V’te ise yapılan çalışmanın sonucu verilmektedir.



BÖLÜM II

MATERYAL VE METOT

2.1 Problem Tanımı

Herhangi bir zaman indeksi olan k için skaler hedef sinyali (örneğin, rüzgar hızı sinyali) şu şekilde modellenebilir:

$$d_k = \mathbf{h}_o^T \mathbf{x}_k + n_k \quad (2.1)$$

burada \mathbf{h}_o , $\mathbf{x}_k = [x_{0,k} x_{1,k} \dots x_{N,k}]^T$ ve n_k sırasıyla ideal ağırlık vektörü, giriş vektörü ve sıfır ortalamalı Gauss beyaz ölçüm gürültüsüdür. Ayrıca N , giriş vektörünün (\mathbf{x}_k) derecesini temsil etmektedir. Bu tip problemlerde temel amaç, herhangi bir kaynaktan ölçülen d_k hedef sinyalinden en optimum ağırlık vektörü \mathbf{h}_o 'ı tahmin etmektir.

2.2 Veriye Uyarlamalı Sansür Stratejisi

Burada, önerilen rüzgar hızı tahmin edicilerinin çalışma prensiplerini daha iyi anlamak için kısa olarak DAC stratejisinden bahsedilmektedir (Berberidis vd., 2016). DAC stratejisinin altında yatan temel fikir, minimum kaynak gereksinimleri ile optimum ağırlık katsayısı \mathbf{h}_o 'ı çevrimiçi bir şekilde bulmaktır. Bu amaçla, sırasıyla çıkış ve hata sinyallerine sahip bir adaptif sonlu dürtü yanıtı (Finite Impulse Response, FIR) filtre yapısını aşağıda tanımlandığı gibi kullanabiliriz:

$$y_k = \mathbf{h}_k^T \mathbf{x}_k \quad (2.2)$$

$$e_k = d_k - y_k = d_k - \mathbf{h}_k^T \mathbf{x}_k \quad (2.3)$$

burada, $\mathbf{h}_k = [h_{0,k} h_{1,k} \dots h_{N,k}]^T$ ve $\mathbf{x}_k = [x_{0,k} x_{1,k} \dots x_{N,k}]^T$, sırasıyla uyarlamalı FIR filtresinin ağırlık ve giriş vektörleridir. Bunun yanı sıra N , FIR filtresinin derecesini temsil etmektedir.

Hedef sinyali d_k , dikkate alındığı takdirde, genel sansürleme kuralı (Berberidis vd., 2016);

$$z_k := \begin{cases} *, & x_k \in C_k \\ d_k, & \text{aksi takdirde} \end{cases} \quad (2.4)$$

olarak tanımlanır. Burada * ifadesi, k 'nci veri sansürlendiğinde bilinmeyen bir değerdir ve bu nedenle kullanılmaz.

Asıl amacımızın olası iletim ve depolama maliyetlerini azaltarak optimal ağırlık vektörü \mathbf{h}_o 'ı bulmak olduğunu hatırlayarak, herhangi bir $\{z_i, x_i\}_{i=1}^{k-1}$ için, eğer $d_k \in C_k$ ise iki sansürleme değişkeni $c_k = 1$ olur. Aksi durumda ise $c_k = 0$ 'a eşit olmaktadır. Bu sayede her bir veri, DAC kuralı yardımıyla çevrimiçi bir şekilde sansürlenmiş veri (daha az bilgilendirici) ya da sansürsüz veri (en bilgilendirici) olarak sınıflandırılabilir (Berberidis vd., 2016):

$$(z_k, c_k) := \begin{cases} (d_k, 0), & \text{eğer } \frac{e_k}{\sigma_k} \geq \tau_k \\ (*, 1), & \text{aksi takdirde} \end{cases} \quad (2.5)$$

burada τ_k ve σ_k sırasıyla, k zamanında sansürlemenin eşik değerini ve ölçüm gürültüsünün standart sapmasını temsil etmektedir.

Eşik parametresi τ_k , sansür oranını doğrudan etkilediğinden dolayı DAC stratejisinde önemli bir rol oynamaktadır. Bu nedenle, bu parametrenin istenen sansür oranını $P_{cr} = (K - p)/K \in (0,1)$ 'yı sağlamak için doğru bir şekilde seçilmesi gerekir, burada K ve p bilgilendirici veri sayısını ve hedef sinyali d_k 'nın uzunluğunu belirtmektedir. Benzer şekilde, sansürlemenin eşik değeri τ_k aşağıda yer alan denklem ile yenilemeli olarak belirlenebilir (Berberidis vd., 2016):

$$\tau_k = \left[\frac{p+(n-1)(1-P_{er})}{(n-1)(1-P_{er})} \right]^{1/2} Q^{-1} \left(\frac{1-P_{er}}{2} \right) \quad (2.6)$$

burada $Q^{-1}(\cdot)$ birleşik tamamlayıcı kümülatif dağılımı tersini temsil eder (Berberidis vd., 2016). Denklem (2.6)'da sansür eşiği τ_k her tekrarlamada güncellenebilir olduğundan dolayı ciddi olarak hesap yüküne sahiptir. Bu durumun üstesinden gelinebilmesi için, ortalama bir sansür oranı sağlayan her yineleme için sabit bir eşik değeri τ 'nun aşağıdaki gibi seçilmesi gerekir (Berberidis vd., 2016):

$$\tau \approx Q^{-1}\left(\frac{1-P_{er}}{2}\right) \quad (2.7)$$

Bu çalışmada, önerilen rüzgar hızı tahmincisinin eğitim sürecinde hem ortalama bir sansür oranı hem de daha az hesaplama karmaşıklığı sağlamak için, DAC stratejisinde sansürlemenin eşik değerini (τ) belirlemek için Denklem (2.7) kullanılmıştır. DAC stratejisi hakkında daha fazla ayrıntılı bilgi için yer alan çalışmaya bakınız (Berberidis vd., 2016).

2.3 Geleneksel En Küçük Kare Algoritması

Geleneksel LMS algoritması, hem çevrimiçi parametre tahmin yeteneğine hem de hesaplama karmaşıklığı açısından basit bir yapıya sahip olması nedeniyle iyi bilinen bir adaptif filtreleme algoritmasıdır (Haykin, 1996). Denklem (2.1)'deki optimal ağırlık vektörü \mathbf{h}_0 'ın tahmini için, LMS algoritmasının ağırlık güncelleme kuralı, anlık maliyet fonksiyonu $J_k = e_k^2/2$ 'nin minimize edilmesinden türetilir ve aşağıdaki gibi tanımlanır:

$$\mathbf{h}_{k+1} = \mathbf{h}_k + \mu \mathbf{x}_k e_k \quad (2.8)$$

burada μ , algoritmanın yakınsama dinamiklerini kontrol eden adım boyutu parametresidir ve $0 < \mu < \frac{2}{\lambda_{max}(\mathbf{R}_{xx})}$ aralığında seçilir (Haykin, 1996). $\lambda_{max}(\cdot)$, otokorelasyon matris \mathbf{R}_{xx} 'in maksimum öz değerini temsil eder (Haykin, 1996). LMS algoritmasının türetilmesine ve yakınsaklık analizine ait detaylı bilgiler için (Haykin, 1996)'de yer alan çalışmaya bakınız.

BÖLÜM III

MLP VE RNN YAPILARINA DAYALI ÖNERİLEN KISA VADELİ RÜZGAR HIZI TAHMİNLERİNİN TASARIMI

Bu bölümde, DAC stratejisi ile bir araya getirilmiş MLP ve RNN yapıları tabanlı kısa vadeli rüzgar hızı tahmin edicilerinin tasarımı sunulacaktır. Bu çalışmada önerilen yapılar, rüzgar sinyallerinin çok-adım-ileri tahminini yapabilmesi adına iki aşamadan oluşmaktadır. İlk aşamanın temel amacı, (Şekil 3.1’de sunulan önerilen tahmin edicilerin blok diyagramlarından görüldüğü gibi) DAC stratejisini kullanarak en bilgilendirici giriş/çıkış verisinden oluşan eğitim veri kümesini elde etmektir. Şekil 3.1’de, her ne kadar bu aşama akan rüzgar sinyalinin çok-adım-ileri tahmin edilmesi görevini üstleniyor gibi görünse de bu yapının asıl görevi, DAC-LMS algoritması üzerinden MLP ve RNN yapılarını eğitim sürecinde kullanarak en bilgilendirici giriş/çıkış verilerini yinelemeli olarak elde etmektir.

Bu amaçla, Berberidis ve arkadaşlarının (Berberidis vd., 2016) yaptığı çalışmaya benzer şekilde, Denklem (2.8)’de geleneksel LMS algoritmasının (Haykin, 1996) içine DAC stratejisini yerleştirmek için öncelikle kesilmiş anlık maliyet fonksiyonu aşağıdaki gibi tanımlanır:

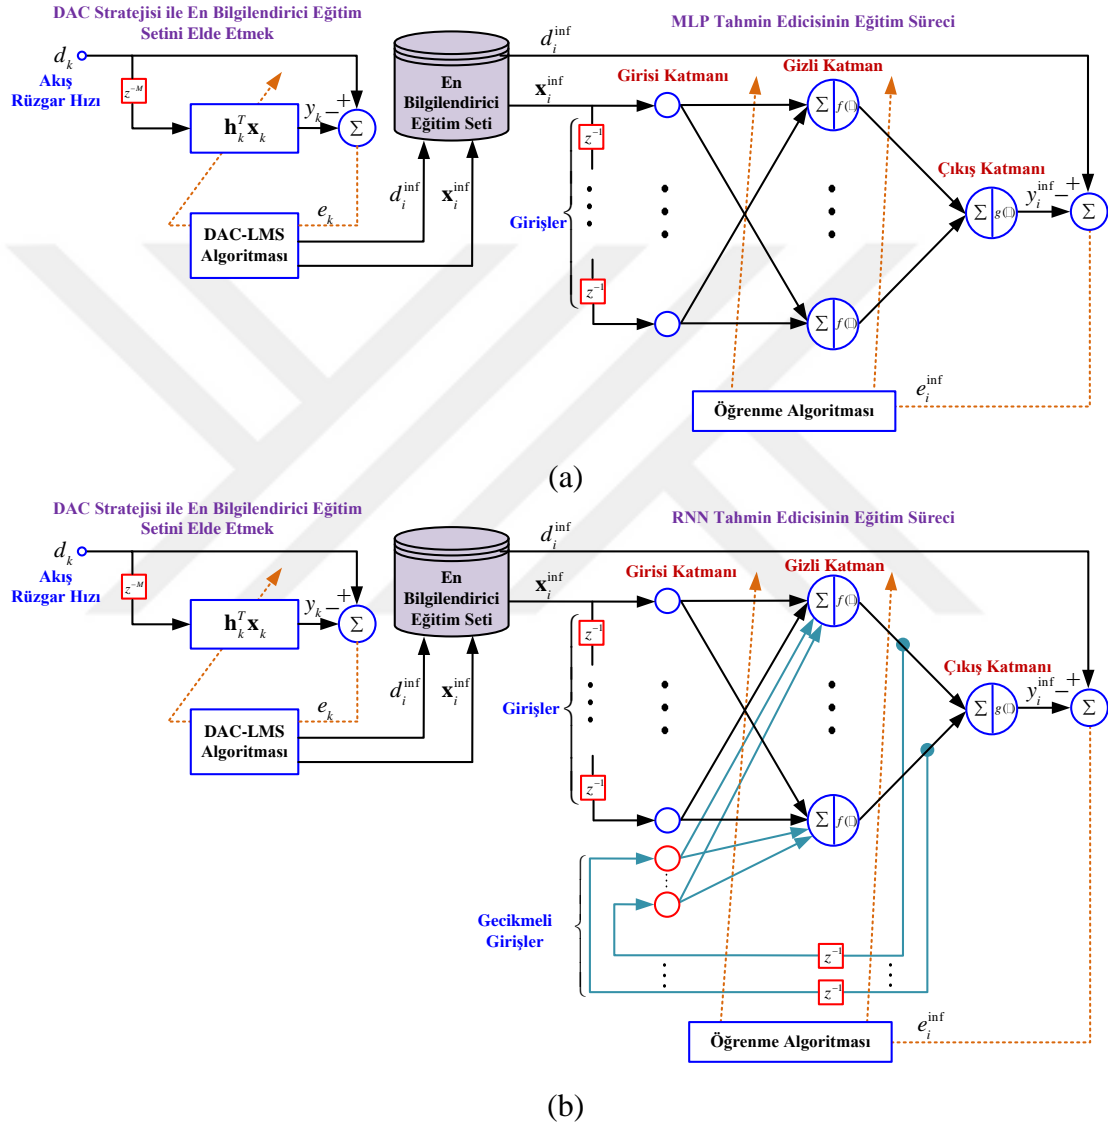
$$J_k^{(\tau)} := \max \left\{ 0, \left(\frac{e_k^2 - \tau^2 \sigma_k^2}{2} \right) \right\} := \begin{cases} \frac{1}{2} (e_k^2 - \tau^2 \sigma_k^2), & |e_k| \geq \tau \sigma_k \\ 0, & |e_k| < \tau \sigma_k. \end{cases} \quad (3.1)$$

Alt diferansiyel hesabının standart kurallarını kullanarak, Denklem (3.1)’de \mathbf{h}_k ağırlık vektörüne göre minimize edilirse, öncelikli olarak DAC-LMS algoritmasının ağırlık vektörü kuralı aşağıdaki gibi elde edilir (Berberidis vd., 2016):

$$\mathbf{h}_{k+1} := \begin{cases} \mathbf{h}_k + \mu \mathbf{x}_k e_k, & |e_k| \geq \tau \sigma_k \\ \mathbf{h}_k, & \text{aksi takdirde.} \end{cases} \quad (3.2)$$

Açıklama 1: Eğer gelen veri sansürlenmiş ise Denklem (2.8)’deki geleneksel LMS algoritmasının aksine, Denklem (3.2)’de ki DAC-LMS algoritmasındaki ağırlık vektörü

h_k 'yı güncellemez, yani dikkate alınan veri bilgilendirici değildir. DAC stratejisinin bu son derece harika özelliği, LMS algoritmasının tüm verilerle değil, yalnızca bilgilendirici verilerle çevrimiçi bir şekilde çalışmasını sağlar. Böylelikle, depolama ve olası iletim maliyetlerini önemli ölçüde azaltmamıza bununla birlikte çevrimiçi olarak tüm veriler yerine en bilgilendirici verilerle çalışmamıza olanak sağlar.



Şekil 3.1 Önerilen kısa vadeli rüzgar hızı tahmin edicileri; MLP (a) ve Yerel geri beslemeli RNN (b)

Daha sonra, tüm eğitim örnekleri arasında en bilgilendirici olanları elde etmek için, Denklem (3.2)'daki DAC-LMS algoritmasının ağırlık vektörü kuralı aşağıdaki gibi değiştirilir:

$$\begin{aligned}
& \text{Eğer,} \quad |e_k| \geq \tau\sigma_k \quad \left\{ \begin{array}{l} \mathbf{h}_{k+1} := \mathbf{h}_k + \mu\mathbf{x}_k e_k \\ d_i^{inf} := d_k, \quad i = 1, 2, \dots, K \\ \mathbf{x}_i^{inf} := \mathbf{x}_k, \quad i = 1, 2, \dots, K \end{array} \right. \\
& \text{Aksi takdirde} \quad \{ \mathbf{h}_{k+1} := \mathbf{h}_k \}
\end{aligned} \tag{3.3}$$

burada, sırasıyla d_i^{inf} ve \mathbf{x}_i^{inf} ifadeleri, MLP ve RNN tahmin edicilerinin i 'inci zaman indeksinde en bilgilendirici hedef (çıkış) ve giriş verilerini temsil ederken, K bu bilgilendirici verilerin sayısını temsil eder.

Açıklama 2: Denklem (3.3)'te sabit eşik değeri τ , Denklem (2.7) kullanılarak hesaplanırken, gerçek dünya rüzgar hızı tahminleri için σ_k ifadesi aşağıdaki denklem kullanılarak tahmin edilir:

$$\hat{\sigma}_k^2 = \beta\hat{\sigma}_{k-1}^2 + (1 - \beta)e_k^2 \tag{3.4}$$

burada $\beta \in (0,1)$, unutm faktörüdür.

Açıklama 3: DAC-LMS algoritması, Denklem (3.3)'teki güncelleme kuralları sayesinde daha az bilgilendirici giriş ve hedef (çıkış) verisini sansürler. MLP ve RNN'nin eğitim süresini önemli ölçüde azaltan daha anlamlı ve bilgilendirici bir eğitim kümesi oluşturmamızı sağlar.

Öneri: $|e_k| \geq \tau\sigma_k$ için, Denklem (3.3)'teki DAC-LMS algoritmasında, eğer adım boyutu μ aşağıdaki gibi seçilirse algoritma Lyapunov anlamında asimptotik kararlıdır:

$$0 < \mu < \frac{2}{\lambda_{max}(\mathbf{R}_{xx})} \tag{3.5}$$

burada $\mathbf{R}_{xx} = E\{\mathbf{x}_k\mathbf{x}_k^T\}$ olmak üzere \mathbf{x}_k , giriş vektörünün otokorelasyon matrisini, $\lambda_{max}(\cdot)$ ise \mathbf{R}_{xx} 'in en büyük öz değerini temsil eder.

İspat: Bu ispatın yapılabilmesi için, öncelikle Lyapunov'un ikinci yöntemi diye adlandırılan aşağıdaki tanımın yapılması gerekir (Khalil, 2002; Mengüç ve Acır, 2017).

Tanım: $x_k = 0$ 'ın ele alınan dinamik bir sistemin denge noktası olduğunu varsayarsak, $D \subset \mathbb{R}^n$, $V(x_k): D \rightarrow \mathbb{R}$ fonksiyonunu $x_k = 0$ 'ı içeren bir alanı temsil eder. Böylece, Lyapunov'un 3 önemli koşulu aşağıdaki gibi tanımlanır:

- (i) $V(0) = 0$ için $x_k = 0$,
- (ii) $V(x_k) > 0$ için $x_k \neq 0$,
- (iii) $\Delta V_k = V(x_{k+1}) - V(x_k) \leq 0$ için $x_k \neq 0$.

Burada eğer ilk iki koşul sağlanırsa, $V(x_k)$ fonksiyonu bir aday Lyapunov fonksiyonudur. Dikkate alınan bir sistem için eğer tüm koşullar sağlanırsa, çözüm Lyapunov anlamında kararlı olarak adlandırılır. Ayrıca, ele alınan sistem ilk iki koşulu sağlamasının yanı sıra kesin negatiflik şartı olan $\Delta V_k = V(x_{k+1}) - V(x_k) \leq 0$ 'ı da sağlıyorsa, çözüm asimptotik olarak kararlı denir.

Yukarıda yazılan Lyapunov'un ikinci metodunu dikkate alarak, Denklem (3.3) için bu çalışmada aday Lyapunov fonksiyonu olarak $V(e_k) = e_k^2$ fonksiyonu seçilmiştir. Böylece Denklem (3.3)'ün Lyapunov anlamında kararlılığını sağlanması için:

$$\Delta V_k = V(e_{k+1}) - V(e_k) = e_{k+1}^2 - e_k^2 < 0 \quad (3.6)$$

şartının yerine getirilmesi gerekir.

Bu kapsamda yeterince küçük adım boyutu μ için, hata sinyali e_{k+1} aşağıdaki gibi tanımlanır:

$$\begin{aligned} e_{k+1} &= e_k + \Delta \mathbf{h}_k^T \frac{\partial e_k}{\partial \mathbf{h}_k} \\ &= e_k - (\mu \mathbf{x}_k e_k)^T \mathbf{x}_k \\ &= e_k - \mu e_k \mathbf{x}_k^T \mathbf{x}_k \\ &= e_k (1 - \mu \mathbf{x}_k^T \mathbf{x}_k). \end{aligned} \quad (3.7)$$

Denklem (3.7)'yi, Denklem (3.6)'da yerine koyduğumuz takdirde, ΔV_k :

$$\Delta V_k = e_k^2 [(1 - \mu \mathbf{x}_k^T \mathbf{x}_k)^2 - 1] \quad (3.8)$$

olarak elde edilir.

Denklem (3.8)'de $\Delta V_k < 0$ şartının sağlanması için adım boyutu μ 'nün

$$0 < \mu < \frac{2}{\mathbf{x}_k^T \mathbf{x}_k} \quad (3.9)$$

aralığında seçilmesi gerekir.

Denklem (3.9)'dan görüldüğü üzere, adım boyutu μ 'nün üst sınırı k anına bağlı olarak değişmektedir. Bu yüzden sabit bir üst sınır bulunabilmesi için Denklem (3.9), bağımsızlık varsayımları (Haykin, 1996) altında incelendiğinde, μ 'nün alt ve üst sınırları aşağıdaki gibi elde edilir:

$$0 < \mu < \frac{2}{E\{\mathbf{x}_k^T \mathbf{x}_k\}} = \frac{2}{\lambda_{max}(\mathbf{R}_{xx})}. \quad (3.10)$$

BÖLÜM IV

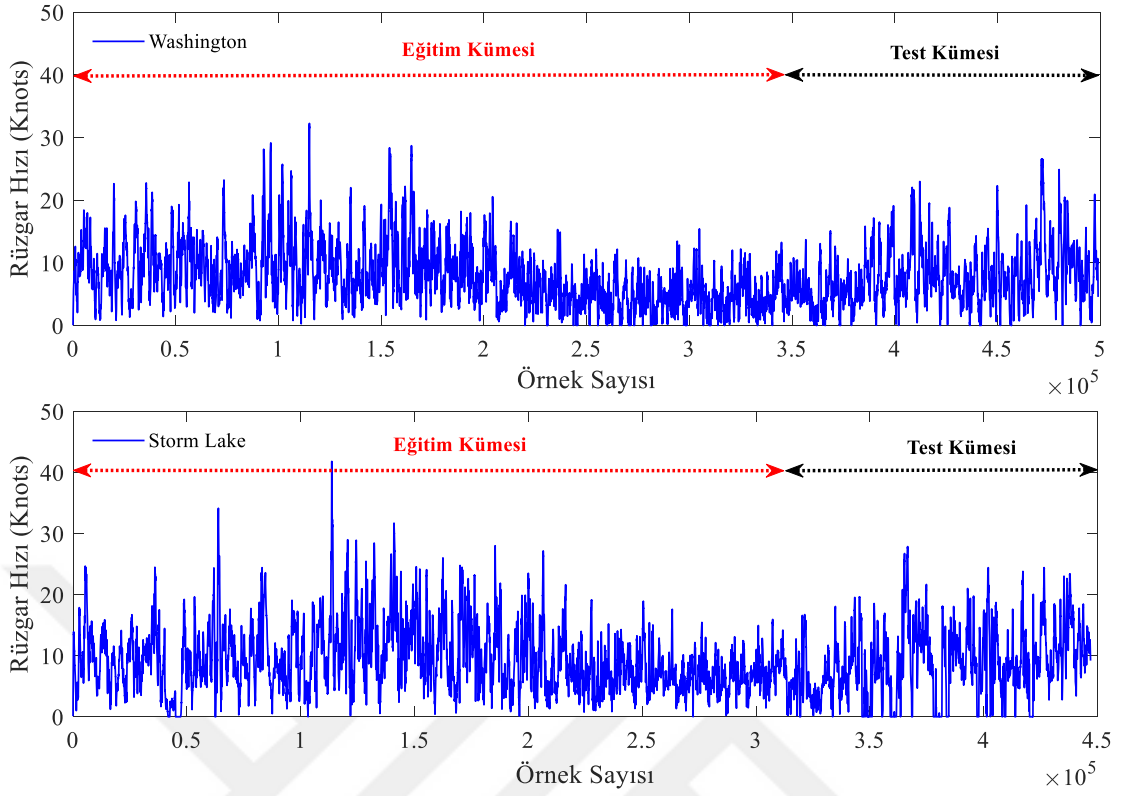
BENZETİM SONUÇLARI VE TARTIŞMA

Burada, önerilen MLP ve RNN tahmin edicilerinin kısa vadeli rüzgar hızı tahmin başarımları, tahmin kazancı ve çalışma süreleri açısından gerçek hayattaki büyük ölçekli rüzgar hızı verileri üzerinde değerlendirilmiş olup, başarımları kendilerinin klasik olanları ile karşılaştırılmıştır. Önerilen tahmin ediciler, DAC stratejisi sayesinde eğitim sürecinde en bilgilendirici rüzgar verilerini kullanırken, klasik olan yapılar ise tüm verileri kullanmaktadır.

4.1 Veri Kümesi ve Çalışma Ortamı

Bu çalışmada, (Wind Database)'de yer alan gerçek hayattaki iki büyük ölçekli rüzgar hızı veri kümesi kullanılmıştır. İlk veri kümesi, ABD'nin Washington bölgesinden 1 Ocak 2004, 00:00 ile 31 Aralık 2004, 23:59 arasında ölçülen bir dakikalık veriler olup, toplam 498.994 rüzgar hızı örneğine sahiptir. İkinci veri ise 1 Ocak 2001, 00:00 ile 30 Aralık 2001, 00:58 arasında ABD'nin Storm Lake bölgesinden ölçülen bir dakikalık toplam 446.917 rüzgar hızı örneğinden oluşmaktadır. Veri kümeleri, yüksek frekanslı gürültü bileşenlerinin etkilerini ortadan kaldırmak için, 100'üncü dereceden hareketli ortalama filtreden geçirilmiştir. Şekil 4.1'de, bu rüzgar hızı sinyalleri gösterilmiştir. Tahmin görevindeki sıralı veriye dayalı akış hesaba katılarak, her veri kümesinin %30'i eğitim kümesi ve kalan %30'u ise test kümesi olarak kullanılmıştır (Şekil 4.1'de görüldüğü gibi).

Ayrıca benzetimler, Intel (R) Core (TM) i7 – 8750H 2.2 GHz CPU ve 8 GB RAM içeren bir kişisel bilgisayar ile MATLAB R2018a yazılım ortamında gerçekleştirilmiştir.



Şekil 4.1. Büyük ölçekli Washington ve Storm Lake bölgelerine ait gerçek rüzgar hızı sinyalleri

4.2 Başarım Ölçütü

Önerilen tahmin edicilerin tahmin başarımlarını ölçmek için, tahmin kazancı (Prediction Gain, R_p), korelasyon katsayısı (Correlation Coefficient, CC) ve çalışma süreleri olmak üzere 3 temel ölçüm kullanılmıştır. Tahmin kazancı ve korelasyon katsayısı sırasıyla Denklem 4.1 ve Denklem 4.2’de gösterildiği gibi hesaplanmıştır.

$$R_p = 10 \log_{10} \left(\frac{\sigma_d^2}{\sigma_e^2} \right) \text{ (dB)} \quad (4.1)$$

burada, σ_d^2 gerçek rüzgar sinyalinin varyansını temsil ederken, σ_e^2 ise gerçek rüzgar sinyali \mathbf{d} ve tahmin edilen rüzgar sinyali \mathbf{y} arasındaki farkla $\mathbf{e} = \mathbf{d} - \mathbf{y}$ tanımlanan hata sinyalinin varyansını temsil etmektedir.

$$CC = \frac{\text{cov}(\mathbf{d}, \mathbf{y})}{\sigma_d \sigma_y} \quad (4.2)$$

burada, $cov(\cdot)$ kovaryans fonksiyonunu, σ_d ve σ_y sırasıyla \mathbf{d} ve \mathbf{y} 'nin standart sapmalarını temsil etmektedirler.

4.3 Parametre Seçimleri

Önerilen tahmin edicilerde, DAC-LMS algoritması için sansür oranları (P_{cr}); %30, %50 ve %70 olmak üzere 3 farklı değere ayarlanmıştır. Örneğin, P_{cr} oranı %30 seçildiğinde eğitim verileri %30 oranında sansürlenir ve geriye kalan veriler önerilen tahmin edicileri eğitmek için en bilgilendirici veriler olmaktadır. Simülasyon sonuçları birbirinden bağımsız 10 denemenin ortalaması alınarak elde edilmiştir. DAC-LMS algoritmasının adım boyutu, Denklem 3.5'te verilen Lyapunov anlamında gerekli kararlılık koşulunu karşılamak için $\mu = 0.001$ olarak seçilmiştir. M-adım-ileri tahmin modu özelliğine sahip olan bu algoritmadaki FIR filtresinin sırası, MLP ve RNN'nin giriş boyutlarına eşit olacak şekilde $N = 10$ olarak seçilmiştir. Ayrıca, DAC-LMS'nin diğer parametreleri olan $\beta = 0.995$ ve $\hat{\sigma}_0^2 = 0$ olarak ayarlanmıştır.

4.4 Önerilen MLP ve RNN'nin Tahmin Başarımları

Önerilen MLP ve RNN yapılarının eğitim süreci üzerindeki DAC stratejisinin etkinliğini ölçmek için, farklı hesaplama karmaşıklıklarına sahip aşağıdaki yedi geri yayılım (Back Propagation) tabanlı öğrenme algoritması kullanılmıştır:

- (i) Gradyan iniş (gradient descent, GD),
- (ii) Momentum ve adaptif öğrenme oranı ile gradyan iniş (gradient descent with momentum and adaptive learning rate, GD-MALR),
- (iii) Levenberg-Marquardt (LM),
- (iv) Broyden Fletcher-Goldfarb-Shanno Quasi-Newton (BFGS-QN),
- (v) Esnek (Resilient, RE),
- (vi) Ölçeklendirilmiş eşlenik gradyan (Scaled conjugate gradient, SCG),
- (vii) Bir-adım sekant (One-step secant, OSS).

Şekil 3.1 (a) ve (b)'den görüldüğü gibi, MLP ve yerel geri beslemeye sahip olan RNN yapıları, girdi, gizli ve çıktı olarak adlandırılan üç katmandan oluşmaktadır. Bu yapıların ağ topolojileri, 10 – 10 – 1 olarak ayarlanmıştır. Hem MLP hem de RNN yapılarına ait gizli katmanlarda yer alan nöronlar ($f(\cdot)$) için tanjant sigmoid fonksiyonu kullanılırken, bu yapıların çıkış katmanındaki nöron da ($g(\cdot)$) lineer fonksiyon kullanılmıştır. Kullanılan öğrenme algoritmalarının öğrenme oranları, 10^{-4} olarak ayarlanmış olup, MLP ve RNN 500 devir (epoch) boyunca eğitilmiştir.

Çizelge 4.1 ve 4.2'de, Washington ve Storm Lake rüzgar hızı verileri için bir-adım-ileri MLP ve RNN tahmin edicilerinin ortalama eğitim süreleri özetlenmiştir.

Çizelge 4.3 – 4.6'da ise eğitilmiş bir-adım-ileri MLP ve RNN tahmin edicilerinin test tahmin başarımları sırasıyla R_p (dB) ve CC değerleri açısından her iki veri kümesi için karşılaştırmalı olarak sunulmuştur.

Çizelge 4.1 – 4.6'da, klasik MLP ve RNN tahmin edicileri tüm eğitim kümesi kullanılarak yedi farklı öğrenme algoritması ile eğitilirken, önerilen MLP ve RNN tahmin edicileri DAC-LMS algoritmasının modifiye edilmiş hali kullanılarak %30, %50 ve %70 gibi 3 farklı sansür oranlarında elde edilen en bilgilendirici eğitim kümesi kullanılarak benzer öğrenme algoritmalarıyla eğitilmiştir.

Ayrıca Çizelge 4.7 ve 4.8'de önerilen bir-adım-ileri MLP ve RNN tahmin edicilerinin yüzde etkisi, eğitim süresi ve test tahmin başarımları klasik versiyonlarıyla karşılaştırılarak özetlenmiştir. Son olarak, Çizelge 4.9'da, DAC stratejisinin eğitim veri kümesinde iyi çalışıp çalışmadığını test etmek için modifiye edilmiş DAC-LMS algoritmasının tahmini sansür oranı P_{cr} değerleri sunulmuştur.

Çizelge 4.1 – 4.9'daki sonuçlar dikkate alındığında aşağıdaki yorumlara ulaşılmaktadır:


- Beklendiği gibi, tüm öğrenme algoritmaları için, DAC-LMS tarafından elde edilen daha bilgilendirici bir eğitim setinin kullanılması, önerilen bir-adım-ileri MLP ve RNN tahmin edicilerinin eğitim sürelerini, tüm eğitim seti kullanılan

klasik versiyonlarıyla kıyasla sansür oranına bağlı olarak önemli ölçüde kısaltılmıştır.


- DAC-LMS algoritmasının, sansürleme mekanizmasından dolayı eğitim kümesindeki veri sayısını azaltmasına rağmen, bu durum R_p ve CC değerleri açısından önerilen bir-adım-ileri MLP ve RNN tahmin edicilerinin tahmin başarımlarını önemli ölçüde etkilememiştir.
- Çizelge 4.1 – 4.8 incelendiğinde, bilgilendirici eğitim kümesinin kullanılması bazı durumlarda tahmin başarımlarını artırmıştır.
- Tüm durumlarda, tahmini sansürleme oranı P_{cr} , farklı sansürleme oranları açısından DAC-LMS'nin doğru ve sağlam bir şekilde çalıştığını destekleyen gerçek (tasarımcı tarafından seçilen) oran P_{cr} 'ye çok yakındır (Çizelge 4.9'dan görüldüğü üzere).

Ayrıca, Şekil 4.2, 4.3 ve 4.4'de, örnek görsel sonuçlar olarak; BFGS-QN öğrenme algoritması tarafından eğitilmiş, önerilen MLP ve RNN tahmin edicilerinin bir-adım-ileri tahmin başarımlarını gösterilmiştir. Şekil 4.2, 4.3 ve 4.4'den görüldüğü üzere, önerilen tahmin ediciler, eğitim kümesinin sırasıyla sadece %70, %50 ve %30'unu kullanılarak eğitilmiş olmalarına rağmen, gerçek rüzgar sinyalleri doğru bir şekilde tahmin edilmiştir. Test sürecindeki bu başarımın temel nedeni, önerilen MLP ve RNN'nin tüm eğitim kümesi yerine en bilgilendirici eğitim kümesi ile eğitilmiş olmasıdır.

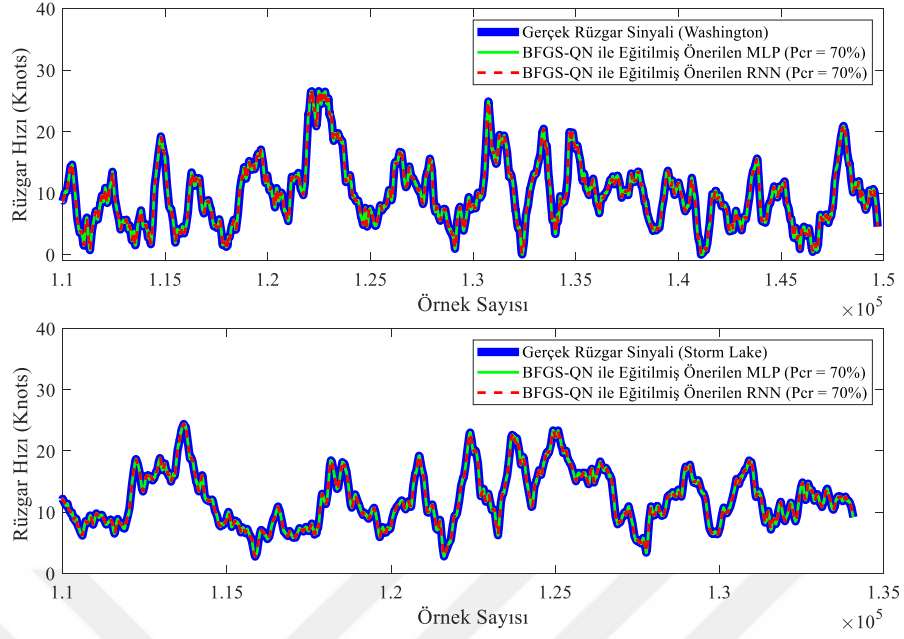
Şekil 4.5, 4.6 ve 4.7'de, farklı tahmin ufukları (Prediction Horizon) $M = 2, 4$ ve 6 için çok-adım-ileri tahmin başarımları değerlendirilmiştir. Tahmin ufkunun artırılması tüm yapıların R_p başarımlarının düşmesine neden olmuştur. Aslında bu beklenen bir durumdur. Öte yandan, tüm ufuklar için önerilen tahmin ediciler, klasik versiyonlar kadar iyi test başarımları elde etmiştir.



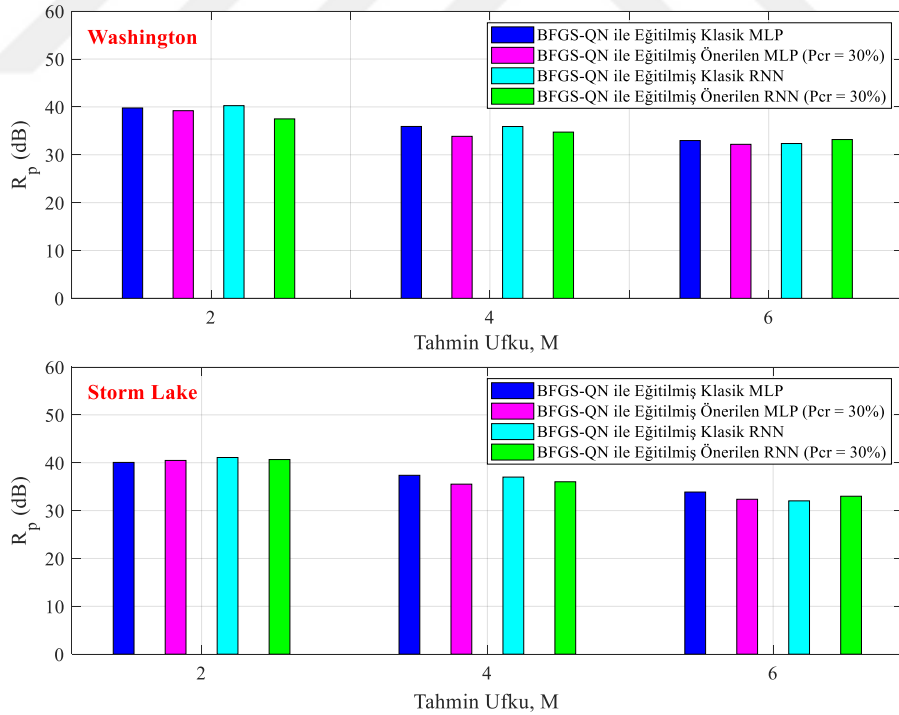
Şekil 4.2. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%30$ olarak seçilmiştir.)



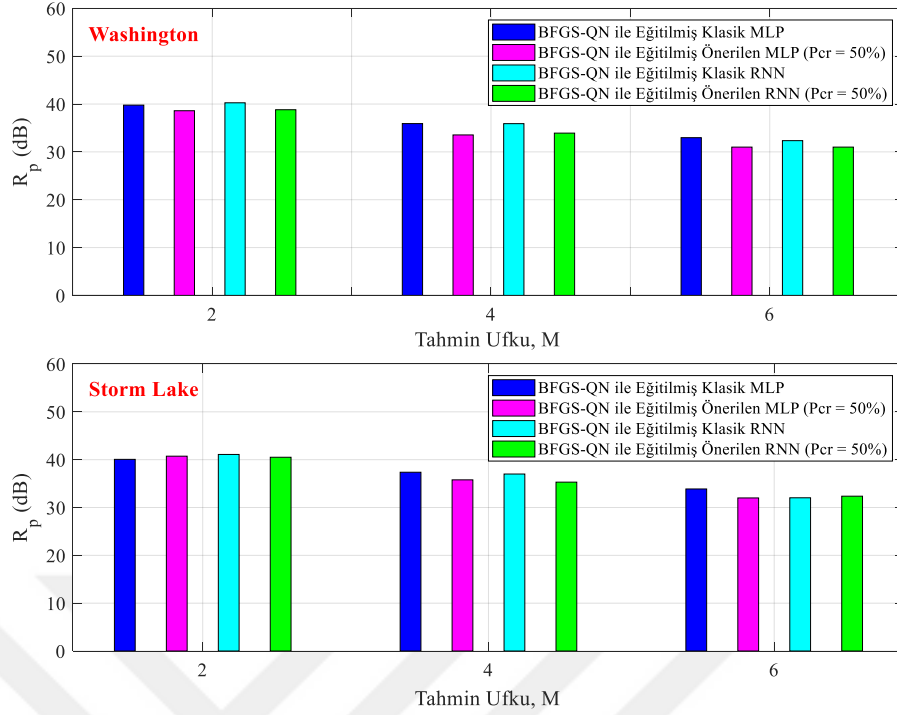
Şekil 4.3. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%50$ olarak seçilmiştir.)



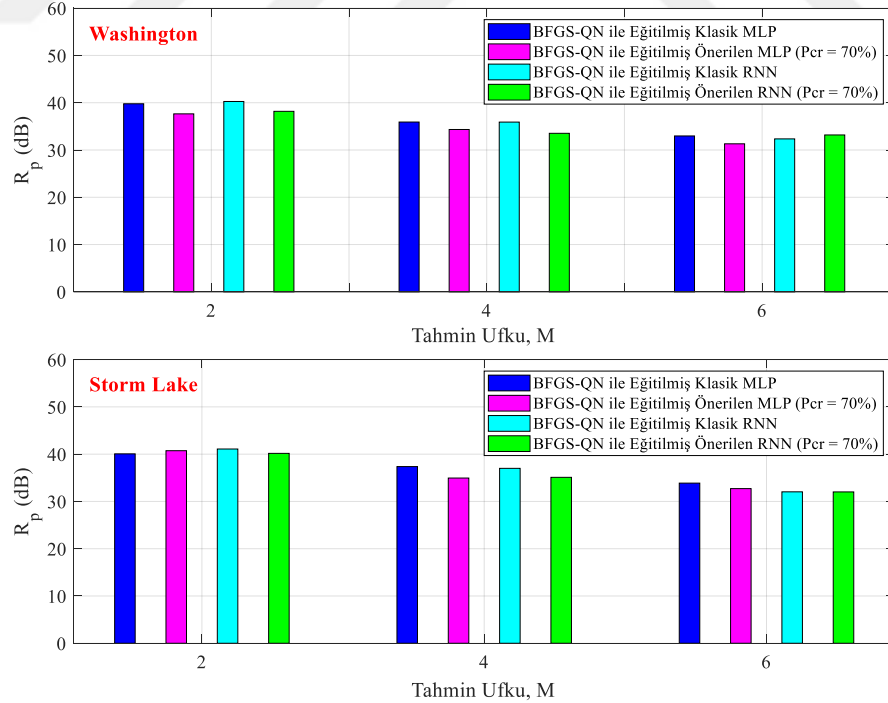
Şekil 4.4. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının bir-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%70$ olarak seçilmiştir.)



Şekil 4.5. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%30$ olarak seçilmiştir.)



Şekil 4.6. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%50$ olarak seçilmiştir.)



Şekil 4.7. Washington ve Storm Lake eğitim kümeleri için BFGS-QNN ile eğitilmiş önerilen MLP ve RNN yapılarının çok-adım-ileri tahminleri (sansürleme oranı $P_{cr} = \%70$ olarak seçilmiştir.)

Çizelge 4.1. Washington veri kümesi için bir-adım-ileri MLP ve RNN tahmin edicilerinin ortalama eğitim süreleri

Veri Kümeleri	Öğrenme Algoritması	Ortalama Eğitim Süresi (saat:dakika:saniye)				Ortalama Eğitim Süresin(saat:dakika:saniye)			
		Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi			Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Washington	GD	00:28	00:20	00:14	00:09	01:00	00:41	00:31	00:19
	GD-MALR	00:29	00:20	00:14	00:09	00:59	00:41	00:30	00:18
	LM	03:47	02:34	01:54	01:11	02:57:57	02:01:57	01:26:45	52:38
	BFGS-QN	01:37	01:13	00:51	00:32	03:41	02:33	01:57	01:17
	RE	00:28	00:20	00:14	00:09	01:01	00:41	00:32	00:19
	SCG	00:54	00:37	00:27	00:17	01:52	01:24	01:01	00:36
	OSS	02:07	01:29	01:06	00:41	04:14	02:55	02:09	01:17

Çizelge 4.2. Storm Lake veri kümesi için bir-adım-ileri MLP ve RNN tahmin edicilerinin ortalama eğitim süreleri

Veri Kümeleri	Öğrenme Algoritması	Ortalama Eğitim Süresi (saat:dakika:saniye)				Ortalama Eğitim Süresin(saat:dakika:saniye)			
		Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi			Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Storm Lake	GD	00:24	00:17	00:12	00:07	00:51	00:36	00:27	00:16
	GD-MALR	00:23	00:16	00:12	00:08	00:51	00:36	00:26	00:16
	LM	03:12	02:16	01:37	01:00	02:17:26	01:36:10	01:09:45	41:54
	BFGS-QN	01:26	01:03	00:49	00:29	03:23	02:16	01:41	01:06
	RE	00:24	00:17	00:12	00:07	00:52	00:37	00:27	00:16
	SCG	00:48	00:34	00:23	00:14	01:38	01:10	00:51	00:31
	OSS	01:53	01:20	00:59	00:36	03:46	02:41	01:57	01:13

Çizelge 4.3. Washington veri kümesi için eğitilmiş bir-adım-ileri MLP tahmin edicisinin R_p Ve CC değerleri açısından test başarımı

Veri Kümeleri	Öğrenme Algoritması	R_p (dB)				CC			
		Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi			Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Washington	GD	19.215	21.696	21.946	23.242	0.9935	0.9961	0.9962	0.9973
	GD-MALR	30.569	29.652	27.910	30.513	0.9995	0.9994	0.9990	0.9994
	LM	43.541	43.103	43.333	42.501	0.9999	0.9999	0.9999	0.9999
	BFGS-QN	44.008	43.625	43.755	43.790	0.9999	0.9999	0.9999	0.9999
	RE	35.653	34.828	34.264	35.420	0.9998	0.9998	0.9997	0.9998
	SCG	40.746	40.204	40.715	40.230	0.9999	0.9999	0.9999	0.9999
	OSS	39.410	40.816	41.070	40.019	0.9999	0.9999	0.9999	0.9999

Çizelge 4.4. Storm Lake veri kümesi için eğitilmiş bir-adım-ileri MLP tahmin edicisinin R_p Ve CC değerleri açısından test başarımı

Veri Kümeleri	Öğrenme Algoritması	R_p (dB)				CC			
		Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi			Klasik MLP Tahmin Edici	Önerilen MLP Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Storm Lake	GD	22.209	21.680	22.734	24.713	0.9966	0.9962	0.9970	0.9982
	GD-MALR	26.551	28.374	26.941	28.454	0.9986	0.9988	0.9986	0.9999
	LM	45.560	44.687	44.633	44.868	0.9999	0.9999	0.9999	0.9999
	BFGS-QN	45.938	45.260	46.043	45.556	0.9999	0.9999	0.9999	0.9999
	RE	35.242	34.604	33.305	34.724	0.9999	0.9998	0.9997	0.9998
	SCG	41.482	42.507	41.025	40.703	0.9999	0.9999	0.9999	0.9999
	OSS	41.651	42.193	41.419	40.681	0.9999	0.9999	0.9999	0.9999

Çizelge 4.5. Washington veri kümesi için eğitilmiş bir-adım-ileri RNN tahmin edicisinin R_p Ve CC değerleri açısından test başarımı

Veri Kümeleri	Öğrenme Algoritması	R_p (dB)				CC			
		Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi			Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Washington	GD	24.841	24.502	25.637	25.865	0.9962	0.9950	0.9974	0.9975
	GD-MALR	29.409	31.114	30.982	30.746	0.9993	0.9995	0.9995	0.9995
	LM	44.375	44.179	43.845	43.874	0.9999	0.9999	0.9999	0.9999
	BFGS-QN	44.975	44.820	44.549	44.294	0.9999	0.9999	0.9999	0.9999
	RE	34.613	34.574	34.232	36.433	0.9996	0.9998	0.9997	0.9998
	SCG	43.356	43.272	43.128	42.894	0.9999	0.9999	0.9999	0.9999
	OSS	42.910	44.233	43.395	42.959	0.9999	0.9999	0.9999	0.9999

Çizelge 4.6. Storm Lake veri kümesi için eğitilmiş bir-adım-ileri RNN tahmin edicisinin R_p Ve CC değerleri açısından test başarımı

Veri Kümeleri	Öğrenme Algoritması	R_p (dB)				CC			
		Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi			Klasik RNN Tahmin Edici	Önerilen RNN Tahmin Edicisi		
			$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Storm Lake	GD	28.081	27.296	27.933	27.206	0.9991	0.9990	0.9991	0.9991
	GD-MALR	31.074	28.959	30.603	30.093	0.9995	0.9993	0.9995	0.9995
	LM	45.992	45.874	45.992	44.870	0.9999	0.9999	0.9999	0.9999
	BFGS-QN	44.042	45.564	45.490	45.521	0.9999	0.9999	0.9999	0.9999
	RE	31.728	33.001	31.951	32.751	0.9995	0.9997	0.9997	0.9997
	SCG	44.004	44.538	45.316	45.098	0.9999	0.9999	0.9999	0.9999
	OSS	44.563	44.334	43.836	43.882	0.9999	0.9999	0.9999	0.9999

Çizelge 4.7. Washington veri kümesi için önerilen bir-adım-ileri tahmin edicilerin klasik versiyonlarıyla karşılaştırıldığında eğitim süresi ve test tahmin başarımı üzerine yüzde etkisi

Veri Kümeleri	Öğrenme Algoritması	Önerilen MLP Tahmin Edicisi						Önerilen RNN Tahmin Edicisi					
		Eğitim Süresi (Sn.)			R_p (dB)			Eğitim Süresi (Sn.)			R_p (dB)		
		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Washington	GD	↓28.57%	↓50.00%	↓67.86%	↓1.36%	↑3.20%	↑4.12%	↓31.67%	↓48.33%	↓68.33%	↑12.91%	↑14.21%	↑20.96%
	GD-MALR	↓31.03%	↓51.72%	↓68.97%	↑5.78%	↑5.35%	↑4.55%	↓30.51%	↓49.15%	↓69.49%	↓2.99%	↓8.70%	↓0.18%
	LM	↓32.16%	↓49.78%	↓68.72%	↓0.44%	↓1.19%	↓1.12%	↓31.47%	↓51.25%	↓70.53%	↓1.01%	↓0.48%	↓2.39%
	BFGS-QN	↓24.74%	↓47.42%	↓67.01%	↓0.34%	↓0.95%	↓1.51%	↓30.77%	↓47.06%	↓65.16%	↓0.87%	↓0.57%	↓0.50%
	RE	↓28.57%	↓50.00%	↓67.86%	↓0.11%	↓1.10%	↑5.26%	↓32.79%	↓47.54%	↓68.85%	↓2.31%	↓3.90%	↓0.65%
	SCG	↓31.48%	↓50.00%	↓68.52%	↓0.19%	↓0.53%	↓1.07%	↓25.00%	↓45.54%	↓67.86%	↓1.33%	↓0.08%	↓1.27%
	OSS	↓29.92%	↓48.03%	↓67.72%	↑3.08%	↑1.13%	↑0.11%	↓31.10%	↓49.21%	↓69.69%	↑3.57%	↑4.21%	↑1.50%

Çizelge 4.8. Storm Lake veri kümesi için önerilen bir-adım-ileri tahmin edicilerin klasik versiyonlarıyla karşılaştırıldığında eğitim süresi ve test tahmin başarımı üzerine yüzde etkisi

Veri Kümeleri	Öğrenme Algoritması	Önerilen MLP Tahmin Edicisi						Önerilen RNN Tahmin Edicisi					
		Eğitim Süresi (Sn.)			R_p (dB)			Eğitim Süresi (Sn.)			R_p (dB)		
		$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$	$P_{cr} = 30\%$	$P_{cr} = 50\%$	$P_{cr} = 70\%$
Storm Lake	GD	↓29.17%	↓50.00%	↓70.83%	↓2.78%	↓0.53%	↓3.11%	↓29.41%	↓47.06%	↓68.63%	↓2.38%	↑ 2.36%	↑ 11.27%
	GD-MALR	↓30.43%	↓47.83%	↓65.22%	↓6.80%	↓1.52%	↓3.16%	↓29.41%	↓49.02%	↓68.63%	↑ 6.87%	↑ 1.47%	↑ 7.17%
	LM	↓29.17%	↓49.48%	↓68.75%	↓0.26%	0.00%	↓2.44%	↓30.03%	↓49.23%	↓69.51%	↓1.92%	↓2.03%	↓1.52%
	BFGS-QN	↓26.74%	↓43.02%	↓66.28%	↑ 3.46%	↑ 3.29%	↑ 3.36%	↓33.01%	↓50.25%	↓67.49%	↓1.48%	↑ 0.22%	↓0.83%
	RE	↓29.17%	↓50.00%	↓70.83%	↑ 4.01%	↑ 0.70%	↑ 3.22%	↓28.85%	↓48.08%	↓69.23%	↓1.81%	↓5.50%	↓1.47%
	SCG	↓29.17%	↓52.08%	↓70.83%	↑ 1.21%	↑ 2.98%	↑ 2.49%	↓28.57%	↓47.96%	↓68.37%	↑ 2.47%	↓1.10%	↓1.88%
	OSS	↓29.20%	↓47.79%	↓68.14%	↓0.51%	↓1.63%	↓1.52%	↓28.76%	↓48.23%	↓67.70%	↑ 1.30%	↓0.56%	↓2.33%

Çizelge 4.9. Önerilen DAC-LMS algoritmasının kestirilmiş sansürleme oranı \hat{P}_{cr}

Actual P_{cr}	Estimated \hat{P}_{cr}	
	Washington	Storm Lake
70%	69.994%	69.752%
50%	50.536%	49.754%
30%	31.426%	30.722%

BÖLÜM V

SONUÇLAR

Bu tez çalışmasında, yapısı gereği büyük veri uygulamalarında tercih edilen DAC stratejisiyle birleştirilmiş LMS yapısı için MLP ve RNN tabanlı, yeni kısa vadeli rüzgar hızı tahmin edicileri önerilmiştir. DAC-LMS algoritması, MLP ve RNN yapılarının eğitiminde en bilgilendirici giriş/çıkış rüzgar hızı verilerinden oluşan yeni bir eğitim veri kümesi elde etmek amacıyla, rüzgar hızı sinyalleri için çok-adım-ileri tahmin modu dikkate alınarak tasarlanmıştır. Yüksek doğrulukla daha az bilgilendirici eğitim verilerini sansürlememizi sağlayan DAC-LMS algoritması, test sürecindeki MLP ve RNN'nin eğitim sürelerini, test tahmin başarımlarını neredeyse etkilemeden önemli ölçüde düşürmüştür. MLP ve RNN yapılarının eğitiminde en bilgilendirici giriş/çıkış rüzgar hızı verilerinin kullanımı ve karşılaştırılabilir test başarımları, yinelemeli olarak elde edilen bu eğitim veri kümesinin maliyetinin de düştüğünü doğrulamaktadır. Gerçek hayattaki büyük ölçekli kısa vadeli rüzgar hızı verileri üzerinde benzetim sonuçları, önerilen tahmin edicilerin iyileştirilmesi beklenen özellikleri doğrulanmıştır ve simülasyonlarla gösterilmiştir.

KAYNAKLAR

An, S., Shi, H., Hu, Q.H., Li, X.Q. and Dang, J.W., “Fuzzy rough regression with application to wind speed prediction” *Inform. Sci.* 282, 388–400, 2014.

Araghi, A.R., Riahy, G.H., Carlson, O. and Gros, G., “Enhancing the net energy of wind turbine using wind prediction and economic NMPC with high-accuracy nonlinear WT models” *Renew. Energy*, 2019. <http://dx.doi.org/10.1016/j.renene.2019.11.070>.

Berberidis D., Kekatos V., and Giannakis G. B., “Online censoring for large-scale regressions with application to streaming big data,” *IEEE Transactions on Signal Processing*, vol. 64, no. 15, pp. 3854–3867, 2016.

Cadenas, E., Rivera, W., Campos-Amezcuca, R. and Heard, C., “Wind speed prediction using a univariate ARIMA model and a multivariate NARX model” *Energies* 9 (2), 1–15, 2016.

Cai, H.S., Jia, X.D., Feng, J.S., Yang, Q.B., Hsu, Y.M. and Chen, Y.D., “A combined filtering strategy for short term and long term wind speed prediction with improved accuracy” *Renew. Energy* 136, 1082–1090, 2019.

Chang, C.W., Lu, H.J., Chang, Y.R. and Lee, Y.D., “An improved neural network-based approach for short-term wind speed and power forecast” *Renew. Energy* 105, 301–311, 2017.

Chitsazan, M.A., Fadali, M.S. and Trzynadlowski, A.M., “Wind speed and wind direction forecasting using echo state network with nonlinear functions” *Renew. Energy* 131, 879–889, 2019.

Erdem, E. and Shi, J., “ARMA based approaches for forecasting the tuple of wind speed and direction” *Appl. Energy* 88 (4), 1405–1414, 2011.

Galanis, G., Papageorgiou, E. and Liakatas, A., “A hybrid Bayesian Kalman filter and applications to numerical wind speed modeling” *J. Wind Eng. Ind. Aerodyn.* 167, 1–22, 2017.

Haykin S., Adaptive Filter Theory 3rd ed., *Prentice-Hall, Inc.* Upper Saddle River, NJ, USA, 1996.

Hu, Y.G., Li, H., Shi, P.P., Chai, Z.S., Wang, K., Xie, X.J. and Chen, Z., “A prediction method for the real-time remaining useful life of wind turbine bearings based on the Wiener process” *Renew. Energy* 45, 2–460, 2018.

Huseyin, A. and Tansu, F., “Wind speed forecasting by subspace and nuclear norm optimization based algorithms” *Sustain. Energy Technol. Assess.* 35, 139–147, 2019

Islam, M.J., Khan, A.M., Parves, M.R., Hossain, M.N. and Halim, M.A., “Prediction of deleterious non-synonymous SNPs of human STK11 gene by combining algorithms, molecular docking, and molecular dynamics simulation” *Sci. Rep.* 9, 16426, 2019.

Khalil H. K., *Nonlinear Systems.* **Prentice Hall**, 2002.

Khorrandel, B., Chuang, C.Y., Safari, N. and Price, G.C.D., “A fuzzy adaptive probabilistic wind power prediction framework using diffusion kernel density estimators” *IEEE Trans. Power Syst.* 33 (6), 7109–7121, 2018.

Li, F., Ren, G.R. and Lee, J., “Multi-step wind speed prediction based on turbulence intensity and hybrid deep neural networks” *Energy Convers. Manage.* 186, 306–322, 2019.

Liu, Y.W., Zhang, S.H., Chen, X.J. and Wang, J.Z., “Artificial combined model based on hybrid nonlinear neural network models and statistics linear models research and application for wind speed forecasting” *Sustainability* 10 (12), 4601, 2018.

Luo, X., Sun, J.K., Wang, L., Wang, W.P., Zhao, W.B., Wu, J.S., Wang, J.H. and Zhang, S.J., “Short-term wind speed forecasting via stacked extreme learning machine with generalized correntropy” *IEEE Trans. Ind. Inf.* 14 (11), 4963–4971, 2018.

Ma, X.J., Jin, Y. and Dong, Q.L., “A generalized dynamic fuzzy neural network based on singular spectrum analysis optimized by brain storm optimization for short-term wind speed forecasting” *Appl. Soft Comput.* 54, 296–312, 2017.

Maruliya Begam, K. and Deepa, S.N., “Optimized nonlinear neural network architectural models for multistep wind speed forecasting” *Comput. Electr. Eng.* 78, 32–49, 2019.

Menguc E.C., and Acir N., “An augmented complex-valued Lyapunov stability theory based adaptive filter algorithm,” *Signal Processing*, vol. 137, pp. 10–21, Aug. 2017.

Mi, X.W., Liu, H. and Li, Y.F., “Wind speed prediction model using singular spectrum analysis, empirical mode decomposition and convolutional support vector machine” *Energy Convers. Manage.* 180, 196–205, 2019.

Mishra, A., Tripathi, P.M. and Chatterjee, K., “A review of harmonic elimination techniques in grid connected doubly fed induction generator based wind energy system” *Renew. Sustain. Energy Rev.* 89, 1–15, 2018.

Murthy, K.S.R. and Rahi, O.P., “A comprehensive review of wind resource assessment” *Renew. Sustain. Energy Rev.* 72, 1320–1342, 2017.

Niau, E.C., “Expressions for wind speed, relative humidity, rainfall, absolute humidity, vapour pressure and dew point as functions of temperature” *Renew. Energy* 6 (1), 23–28, 1995.

Pradhan, C. and Bhende, C.N., “Online load frequency control in wind integrated power systems using modified Jaya optimization” *Eng. Appl. Artif. Intell.* 77, 212–228, 2019.

Santamaria-Bonfil, G., Reyes-Ballesteros, A. and Gershenson, C., “Wind speed forecasting for wind farms: a method based on support vector regression” *Renew. Energy* 85, 790–809, 2016.

Santhosh, M., Venkaiah, C. and Kumar, D.M.V., “Ensemble empirical mode decomposition based adaptive wavelet neural network method for wind speed prediction” *Energy Convers. Manage.* 168, 482–493, 2018.

Sheikholeslami F., Berberidis D., and Giannakis G. B., “Large-scale kernel-based feature extraction via low-rank subspace tracking on a budget,” *IEEE Transactions on Signal Processing*, vol. 66, no. 8, pp. 1967–1981, Nisan 2018.

Song, Z., Deng, Q.L. and Ren, Z.G., “Correlation and principal component regression analysis for studying air quality and meteorological elements in Wuhan, China” *Environ. Prog. Sustain. Energy* 39 (1), e13278, 2020.

Sun, N., Zho, J.Z., Chen, L., Jia, B.L., Tayyab, M. and Peng, T., “An adaptive dynamic short-term wind speed forecasting model using secondary decomposition and an improved regularized extreme learning machine” *Energy* 165, 939–957, 2018.

Tian, Z., “Short-term wind speed prediction based on LMD and improved FA optimized combined kernel function LSSVM” *Engineering Applications of Artificial Intelligence* 91, 103573, 2020.

Tian, Z.D., Li, S.J., Wang, Y.H. and Wang, X.D., “Wind power prediction method based on hybrid kernel function support vector machine” *Wind Eng.* 42 (3), 252–264, 2018a.

Tian, Z.D., Ren, Y. and Wang, G., “Short-term wind speed prediction based on improved PSO algorithm optimized EM-ELM” *Energy Sources A Recovery Util. Environ. Eff.* 41 (1), 26–46, 2019.

Tian, Z.D., Wang, G., Ren, Y. and Li, S.J., “An adaptive online sequential extreme learning machine for short-term wind speed prediction based on improved artificial bee colony algorithm” *Neural Netw. World* 28 (3), 191–212, 2018b.

Vargas, S.A., Esteves, G.R.T., Macaira, P.M., Bastos, B.Q., Cyrino, O., Fernando, L. and Souza, R.C., “Wind power generation: A review and a research agenda” *J. Cleaner Prod.* 218, 850–870, 2019.

Wang W., Zhao H., Dogançay K., Yu Y., Lu L., and Zheng Z., “Robust adaptive filtering algorithm based on maximum correntropy criteria for censored regression,” *Signal Processing*, vol. 160, pp. 88–98, Haziran 2019.

Wang Z., Yu Z., Ling Q., Berberidis D., and Giannakis G. B., “Decentralized RLS with data-adaptive censoring for regressions over largescale networks,” *IEEE Transactions on Signal Processing*, vol. 66, no. 6, pp. 1634–1648, Mart 2018.

Wang, D.Y., Luo, H.Y., Grunder, O. and Lin, Y.B., “Multi-step ahead wind speed forecasting using an improved wavelet neural network combining variational mode decomposition and phase space reconstruction” *Renew. Energy* 113, 1345–1358, 2017.

Wang, H., Han, S., Liu, Y.Q., Yan, J. and Li, L., “Sequence transfer correction algorithm for numerical weather prediction wind speed and its application in a wind power forecasting system” *Appl. Energy* 1–10, 2019a.

Wang, J.Z., Song, Y.L., Liu, F. and Hou, R., “Analysis and application of forecasting models in wind power integration: A review of multi-step-ahead wind speed forecasting models” *Renew. Sustain. Energy Rev.* 60, 960–981, 2016.

Wang, Y.L., Zhou, X., Liang, L.K., Zhang, M.J., Zhang, Q. and Niu, Z.Q., “Short-term wind speed forecast based on least squares support vector machine” *J. Inf. Process. Syst.* 14 (6), 1385–1397, 2018.

Wind Database. [Online], Iowa State University, Available: [Iowa Environmental Mesonet \(iastate.edu\)](http://mesonet.iastate.edu), 2019.

Yan, L., Wang, H., Zhang, X., Li, M.Y. and He, J., “Impact of meteorological factors on the incidence of bacillary dysentery in Beijing, China: A time series analysis (1970–2012)” *Plos One* 12 (8), e0182937, 2017.

Yang L., Zhu H., Wang H., Kang K., and Qian H., “Data censoring with network lifetime constraint in wireless sensor networks,” *Digital Signal Processing*, vol. 92, pp. 73–81, Eylül 2019.

Yang, J., Astitha, M., Monache, L.D. and Alessandrini, D., “An analog technique to improve storm wind speed prediction using a dual NWP model approach” *Mon. Weather Rev.* 146 (12), 4057–4077, 2018.

Ye, L., Zhao, Y.N., Zeng, C. and Zhang, C.H., “Short-term wind power prediction based on spatial model” *Renew. Energy* 101, 1067–1074, 2017.

Yu, C.J., Li, Y.L., Xiang, H.Y. and Zhang, M., “Data mining-assisted short-term wind speed forecasting by wavelet packet decomposition and Elman neural network” *J. Wind Eng. Ind. Aerodyn.* 175, 136–143, 2018.

Yu, C.J., Li, Y.L. and Zhang, M.J., “An improved wavelet transform using singular spectrum analysis for wind speed forecasting based on Elman neural network” *Energy Convers. Manage.* 148, 595–904, 2017.

Yu, J.B. and Lv, J.X., “Weak fault feature extraction of rolling bearings using local mean decomposition-based multilayer hybrid denoising” *IEEE Trans. Instrum. Meas.* 66 (12), 3148–3159, 2017.

Zhang, Z.D., Ye, L., Liu, Y.Q., Ji, C., Yu, X., Yin, X.L. and Li, J., “Wind speed prediction method using shared weight long short-term memory network and Gaussian process regression” *Appl. Energy* 247, 270–284, 2019a.

Zhou, J.Z., Liu, H., Xu, Y.H. and Jiang, W., “A hybrid framework for short term multi-step wind speed forecasting based on variational model decomposition and convolutional neural network” *Energies* 11 (9), 2292, 2018.

Zhu H., Qian H., Luo X., and Yang Y., “Adaptive Queuing Censoring for Big Data Processing,” *IEEE Signal Processing Letters*, vol. 25, no. 5, pp. 610–614, May 2018.

Zuluaga, C.D., Álvarez, M.A. and Giraldo, E., “Short-term wind speed prediction based on robust Kalman filtering: An experimental comparison” *Appl. Energy* 156, 321–330, 2015.

ÖZ GEÇMİŞ

Ali Ogün SARP, Hatay Kırıkhan ilçesinde doğdu. İlkokul ve Ortaokul öğretimimi, sırasıyla Emel Akçay(İskenderun) ve 5 Temmuz(Kırıkhan) İlköğretim Okulu'nda Hatay'da tamamladı. Daha sonrasında 8.sınıf dahil olmak üzere Lise öğretimimi İstanbul Davutpaşa Lisesi'nde tamamladı. 2012 yılında Niğde Ömer Halisdemir Üniversitesi'nde bir sene hazırlık ve bir senede Farabi(Öğrenci değişim programı) ile Gazi Üniversitesi'ndeki almış olduğum eğitimle birlikte 2018 yılında Elektrik-Elektronik Mühendisliği bölümünden mezun oldu. Yine aynı yıl Niğde Ömer Halisdemir Üniversitesi Elektrik-Elektronik Mühendisliği Ana Bilim Dalı'nda yüksek lisans öğrenimine başladı.

TEZ ÇALIŞMASINDAN ÜRETİLEN ESERLER

Bu tez çalışmasından, 1 (bir) adet uluslararası makale (incelemede) ile 1 (bir) adet uluslararası bildiri üretilmiştir. Bu üretilen çalışmalar aşağıda sunulmuştur.

Sarp A.O. and Menguc E.C. “A Novel Hybrid Approach Based on the Artificial Neural Network and Adaptive Censoring Technique for Wind Speed Prediction” *International Turkic World Congress on Science and Engineering* .

Sarp A.O., Menguc E.C. and Peker M. “Data-Adaptive Censoring for Short-Term Wind Speed Predictors Based on MLP and RNN” *Systems Journal*, Vol. 20 (İncelemede).

