



Uzun Kısa Süreli Hafıza ve Evrişimsel Sinir Ağları ile rüzgâr enerjisi üretim tahmini

Pelin GÖRGEL*

Istanbul Üniversitesi-Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul
paras@istanbul.edu.tr ORCID: 0000-0001-8884-1290, Tel: (212) 473 70 70 (17460)

Erkan KAVLAK

Istanbul Üniversitesi-Cerrahpaşa, Bilgisayar Mühendisliği Bölümü, İstanbul
erkan.kavлак@gmail.com

Geliş: 25.07.2019, Revizyon: 12.10.2019, Kabul Tarihi: 27.01.2020

Öz

Rüzgâr türbinleri rüzgârın hızı yardımıyla elektrik enerjisi elde etmeyi sağlamaktadır. Rüzgârın yön ve hızı, coğrafi farklılıklar ve homojen olmayan ısınmaya bağlı zamansal farklılıklar gösterir. Rüzgâr hızı yükseklik arttıkça artar, rüzgâr gücü hıza bağlı olarak yükselir. Rüzgâr türbinleri kullanılarak rüzgâr enerjisi kaynaklı elektrik üretim uygulamaları ilk yatırım maliyetlerinin yüksek olmasıyla beraber gün geçtikçe artmaktadır. Bu çalışmada amaç geliştirilen makine öğrenmesine dayalı bir sistem yardımıyla elektrik enerjisi üretim tahmini yapılarak kullanılan rüzgâr gücünün değişkenliği gibi dezavantajların üstesinden gelmektir. Ayrıca dengesiz maliyetleri azaltma ve üretim tahmininde yapılacak iyileştirme ile santralin kâr maksimizasyonunu sağlama hedeflenmektedir. Çalışmamızda Evrişimsel Sinir Ağları (ESA) ve Uzun Kısa Süreli Hafıza (UKSH) metodlarının hibrit olarak önerildiği ve ESA-UKSH olarak adlandırılan yöntem kullanılmıştır. Kullanılan veri seti İzmir Urla bölgesine ait rüzgâr türbininden alınan gerçek verilerdir. Bu veri seti bir yıla ait günlük ve hatta onar dakikalık çözünürlükte rüzgâr hızı verilerinden oluşmaktadır. Yapılan eğitim ve testlerde bir yıl gibi uzun zaman dilimine ait veriler kullanıldığı gibi üç günlük kısa zaman dilimine ait veriler de kullanılmıştır. Ayrıca hibrit yöntemin dışında karşılaştırma amaçlı olarak ESA, UKSH ve Geçitli Tekrarlayan Ünite (GTÜ) yöntemleri tek tek uygulanıp sonuçlar grafik halinde gösterilmiştir. Geliştirilen hibrit ESA-UKSH öğrenme yapısı ile yapılan üretim tahmininde ortalama kare hata (Mean Square Error - MSE) 1,17 'ye kadar düşürülmüştür.

Anahtar Kelimeler: Rüzgâr enerjisi üretim tahmini; Makine öğrenmesi; Evrişimsel Sinir Ağları; Uzun Kısa Süreli Hafıza

* Yazışmaların yapılacağı yazar

Giriş

Rüzgâr türbinleri ticari olarak işletilerek rüzgârın 5-6 metre/saniye (18-21,6 km/saat) hıza ulaştığında devreye giren düzenekler olup rüzgâr enerji santralleri (RES) olarak kullanılırlar. Bu düzenekler rüzgârın kinetik enerjisini sırasıyla hareket ve elektrik enerjisine dönüştüren makinelerdir. Bu türbinler 25-30 metre/saniye (90 – 108 km/saat) ve üzeri rüzgâr hızında kendilerini korumaya alarak üretimi durdururlar. Ülkemizde enerjide dışa bağımlılığının ve fosil yakıt kaynaklı çevresel etkilerin azaltılması amacıyla sağlanan yatırım teşvikleri ve destekler sayesinde RES gibi yenilenebilir enerji kaynaklarına yapılan yatırımlar giderek artmaktadır. Bununla birlikte bu santrallerin üretim tahmini ile ilgili bilişim teknoloji çözümleri geliştirilmektedir (Wu ve Hong, 2007). Türkiye’de mevcut rüzgâr enerjisi potansiyeli 48.000 MW’tır (“İstatistik Raporu Ocak 2019”, 2019). Bu potansiyele sahip alan ise toplam yüz ölçümünün %1,3’üne denk gelmektedir. Ülkemizde 2018 yılında rüzgâr enerjisinden 19.752.159 MWh elektrik üretilmiştir. 2018 yılında işletmede olan rüzgâr enerji santrallerinin toplam kurulu gücü ise 7.005 MW’tır. Türkiye’de yer seviyesinden 50

metre yükseklikte ve rüzgâr hızı 7,5 m/s ve üzeri olan alanlarda her kilometrekareye 5 MW gücünde rüzgâr santrali kurulabilmektedir (“İstatistik Raporu Ocak 2019”, 2019). Türkiye’de aktif rüzgâr enerjisi santrallerinde kullanılan rüzgâr türbinleri çeşitli ülkelerde geliştirilmiş farklı markalara ait türbinlerdir (Tablo 1). Bu çalışmada RES’lerde türbin bazında rüzgâr hızı tahmini ve buna bağlı üretim tahmini için çeşitli makine öğrenmesi ve derin öğrenme algoritmaları üzerinde çalışılmış ve çıktılarının performansları değerlendirilmiştir. Burada amaç dengesizlik maliyetlerini azaltma ve üretim tahmininde yapılacak iyileştirme ile santralin kâr maksimizasyonunu sağlayabilmektir.

Günümüzde genel olarak elektrik santralleri için üretim tahmin hizmeti sağlayan yerli ve yabancı çeşitli çözümler bulunmaktadır. Ancak bu çözümlerin hemen hiçbiri gerçek zamanlı ve türbin bazlı bir rüzgâr hızı tahmini üzerine çalışmamaktadır. Bu çözümler tarafından sağlanan tahminlerin, tüm santralin genel karakteristiği ile en yakın meteoroloji ölçüm istasyonundan (genellikle en yakın havaalanı)

Tablo 1. 1 Ocak 2019 itibariyle Türkiye’deki rüzgâr türbini adetleri ve toplam güçleri (“İstatistik Raporu Ocak 2019”, 2019)

Marka	Menşei	Türbin Adedi	Toplam Güç (MW)	Pay %
Nordex	Danimarka	707	1845,5	26,36
Vestas	Danimarka	580	1537,5	21,96
Enercon	Almanya	774	1295,3	18,50
GE	ABD	442	1029,95	14,71
Siemens	Almanya/İspanya	358	903,76	12,91
Gamesa				
Sinovel	Çin	96	108	1,54
Suzlon	Hindistan	52	106,25	1,52
Acciona	İspanya	20	58	0,83
Senvion	Almanya	1	3	0,04
Unison	Güney Kore	2	1,25	0,02
Northel	Türkiye	7	0,82	0,01
Ayetek	Türkiye	1	0,5	0,01
Shriram	Hindistan	1	0,25	0,00
Milres	Türkiye	0	0	-
Leitwind	İtalya	0	0	-
Diğer	Bilinmeyen	18	50	0,71
Toplam		3088	7000,08	100,00

elde edilen meteorolojik tahminlerin korelasyonu oluşturulan; günlük bazda, minimum saatlik çözünürlükte ve doğruluk oranları oldukça düşük olduğu gözlemlenmiştir. Bu açıdan bakıldığında çalışmada önerilen türbin bazında senelik ve günlük gibi uzun ve kısa dönemli saatlik veya 10 dakikalık çözünürlükte rüzgâr hızı ve üretim tahmini, üretim alanında oldukça yeni bir yaklaşım olarak değerlendirilmelidir.


Geçmiş literatür çalışmalarına bakıldığında, Çelik (2003); Weibull, Rayleigh ve Lognormal gibi dağılım yöntemlerini kullanarak rüzgâr hızını modelleyerek enerji üretim tahmini yapmıştır. Yapılan çalışmada ortalama kare hata 2,79 olarak hesaplanmıştır. Landberg ve diğerleri (2002) ve Giebel ve diğerleri (2001) rüzgâr gücü ile elektrik üretim tahmini çalışmalarında Zephyr adı verilen dinamik modellere dayalı istatistiksel bir sistem kullanmışlardır. Sanchez (2006) ise çalışmada farklı tahmin modellerinin adaptif doğrusal (lineer) kombinasyonunu kullanmıştır. Bunun için Kalman filtresi ve yinelenen en küçük kareler (recursive least squares - RLS) yöntemlerinden faydalanmıştır. Akdağ ve Dinler (2009) aynı amaç doğrultusunda kendi

geliştirdikleri güç yoğunluk (power density) metodunu kullanmışlardır. Bu çalışma kapsamında 01.05.2017 – 31.05.2018 tarih aralığında bir rüzgâr türbini için elde edilen rüzgâr hızı veri seti kullanılarak tahmin yapılmıştır. Tahmin için farklı makine ve derin öğrenme algoritmaları kullanılmıştır. Ayrıca son aşamada farklı çözünürlükteki veri setleri ile önerilen ESA-UKSH hibrit algoritmasının tahmin başarımı incelenmiştir.

Materyal ve yöntem

Uzun Kısa Süreli Hafıza Metodu (UKSH)

Uzun Kısa Süreli Hafıza (Long Short-Term Memory) algoritması uzun vadeli bağımlılıkları öğrenebilen özel bir Yinelenen Sinir Ağları (Recurrent Neural Networks – RNN) türüdür (Hochreiter ve Schmidhuber, 1997). UKSH sinir ağındaki geri yayılımda farklı katmanlardan gelen hata değerini korur. Böylelikle belli sayıda adımdan sonra sabit bir hata değeri sağlayarak yinelenen ağların öğrenme adımlarının devamını sağlar. Bu işlemi giriş ve çıkış arasına yeni bir kanal açarak yapmaktadır (Şekil 1).




Şekil – 1: UKSH algoritması genel yapısı (Olah, 2015)

UKSH yapısında tek bir ağ katmanı yerine, birbirlerine bağlı 4 katman bulunmaktadır. Dışarıdan depolanabilen, hücreye yazılabilen ve okunabilen bilgiyi alan bir yapıdır. UKSH’de kullanılan kapılar yardımıyla hücrenin hangi bilgiyi depolayacağına, okuma yazma ve silme gibi işlemlerin gerçekleşme zamanına karar verilir. Bu kapılar aktivasyon fonksiyonunun

gerçekleştiği bir ağ yapısını barındırır. Nöron yapısına benzer şekilde gelen giriş verisini belirlenen bir ağırlığa göre geçirme veya durdurma özelliği gösterirler (Chung vd., 2014). Bu ağırlıklar yinelenen ağın öğrenme aşaması esnasında hesaplanmaktadır. Bu ağ yapısı yardımıyla hücre, gelen veriyi alma, iletme veya silme işlemlerini öğrenir. UKSH algoritmasının

ilk adımı hangi giriş verisinin hücreden geçirileceğine karar vermektir. Bu karar, “kayıyı unut katmanı” (forget the gate layer) olarak adlandırılan bir sigmoid katmanı tarafından yapılır. Sigmoid (σ) katmanı, her bir bileşenden ne kadarının geçmesi gerektiğini tanımlayan 0 ile 1 arasında rakamlar verir. x_t ve h_{t-1} değerlerine bakılarak C_{t-1} hücre durumu her sayı için 0 ile 1 arasında bir çıkış değeri verir (Denklem 1). 0 değeri “bunu tamamen tut (completely keep this)” anlamına gelirken, 1 değeri “bundan tamamen kurtul (completely get rid of this)” anlamına gelir (Şekil 2).

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



Şekil 2. UKSH sigmoid katmanı (Olah, 2015)

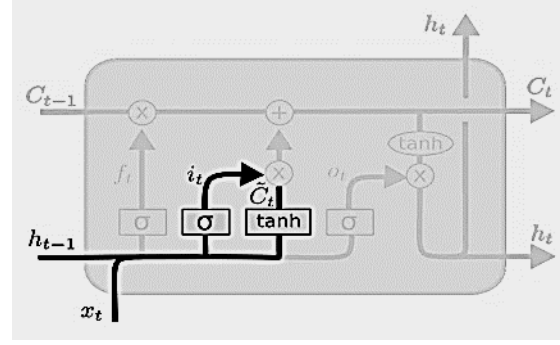
Hücre durumuna hangi yeni bilginin depolanacağına bir sonraki adımda karar verilir. Bu adım iki aşamadan oluşur. İlk aşamada, giriş katmanı olarak adlandırılan bir sigmoid katmanı hangi değerlerin güncelleneceğine karar verir. Sonraki, bir tanh katmanı hücreye eklenecek \tilde{C}_t yeni aday değerler vektörünü oluşturur (Şekil 3). Bir sonraki adımda, hücre durumunu güncellemek amacıyla için bu ikisi birleştirilir (Denklem 2,3).

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$


$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3)$$

Daha sonra Denklem 4’te gösterildiği gibi, bir önceki C_{t-1} durumu yeni C_t hücre durumuna güncellenir (Şekil 4).

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (4)$$



Şekil 3. Sigmoid katmanı ile tanh katmanı birleşimi (Olah, 2015)




Şekil 4. UKSH yeni hücre durumu (Olah, 2015)

Son aşamada; hücre durumunun hangi kısımlarının çıktı olacağına karar veren bir sigmoid katmanı çalıştırılır (Denklem 5). Hücre durumu tanh katmanı vasıtasıyla sigmoid kapı çıktısıyla çarpılır (Denklem 6). Böylece sadece karar verilen kısımlar çıktı olarak elde edilir (Şekil 5) (Chung vd., 2014).

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t * \tanh(C_t) \quad (6)$$



Şekil 5. UKSH çıkışı (Olah, 2015)

Evrişimli Sinir Ağları (ESA) (Convolutional Neural Network-CNN)

Evrişimli Sinir Ağları örüntü tanıma, sınıflandırma, veri kestirimi gibi birçok alanda etkin şekilde kullanılan bir yapay sinir ağıdır. ESA algoritması bir veri veya görüntüyü tamamını ya da kendine ait özneliklerini kullanarak çeşitli katmanlarda işler (Şekil 8).

a) Evrişimli katman (Convolutional layer)

Evrişimli Katman özellikleri saptamak için kullanılır ve ana yapı katmanı olma özelliği taşır. Verilen girişin özelliklerini algılayarak düşük ve yüksek frekans özelliklerini belirlemek için kenar belirleme gibi bazı filtreler kullanılır (Kaynar vd., 2009). Giriş verisinin sol üst köşesinden başlayarak tümünde gezdirilen filtre matrisi ile karşılıklı veri değerleri birbirleriyle çarpılır, çıkan sonuçlar toplanır ve çıktı matrisine depolanır. Ardından, bu filtre sağa 1 piksel kaydırılarak işlemler tekrarlanır. Bu çalışmada 5x5 boyutlu filtre matrisinden faydalanılmıştır.

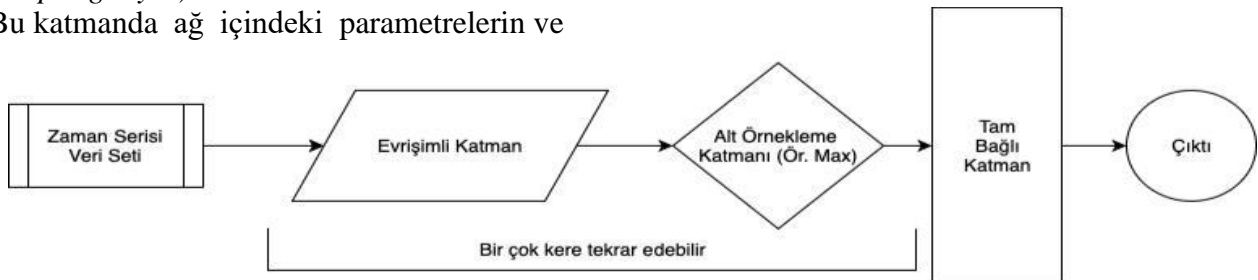
b) Doğrusal olmayan katman (Non-Linear layer)

Sisteme doğrusal olmayan fonksiyonların tanıtılmasıdır. Bu çalışmada evrişimli (convolutional) katmandan sonra doğrusal olmayan katman kullanılmıştır. UKSH yapısında kullanılan ve doğrusal olmayan sigmoid ve tanh gibi fonksiyonlar yerine sinir ağı eğitiminin hızı konusunda en iyi sonucu veren Denklem 7 kullanılmıştır (Wilamowski ve Yu, 2010).

$$f(x) = \max(0, x) \quad (7)$$


c) Alt örnekleme katmanı (Pooling / Down sampling layer)

Bu katmanda ağ içindeki parametrelerin ve



Şekil 8. Zaman serisi için uygulanabilir ESA şeması


hesaplama sayılarının azalması için uygunluk kontrol edilir. Bu sayede ağıdaki uyumsuzluk kontrol edilmiş olur (Somon vd., 2010). Filtre, belirlenen komşuluktaki en büyük sayıyı alır. Böylece, sinir ağının doğru karar vermesi için yeterli bilgiyi içeren daha küçük çıktılar kullanılmış olur (Şekil 6).



Şekil 6. Alt örnekleme katmanı ile basitleştirilmiş bir matris örneği

c) Düzleştirme katmanı (Flattening layer)

Düzleştirme katmanı, gerekli veriyi son katman olan tam bağlı katman girişi olacak şekilde matrisi tek boyutlu bir diziyeye çevirerek işlevini tamamlar (Şekil 7).



Şekil 7. Alt örnekleme katmanı ile basitleştirilmiş bir matris örneği

d) Tam bağlı katman

Sınıflama için kullanılan tam bağlı katmandaki her bir nöron başka bir katmandaki her bir nörona bağlıdır. Çok katmanlı algılayıcı sinir ağı (multi-layer perceptron neural network - MLP) ile aynı prensipte çalışır (Wilamowski ve Yu, 2010).

Geçitli Tekrarlayan Ünite (GTÜ)

GTÜ (Gated Recurrent Unit- GRU), standart tekrarlayan yapay sinir ağı ile gelen unutmama (yok olma) problemini çözmeyi amaçlamaktadır. UKSH ve GTÜ, her ikisi de benzer şekilde tasarlandığından ve bazı durumlarda eşit olarak mükemmel sonuçlar ürettiği için UKSH' nin bir varyasyonu olarak da düşünülebilir (Pinson, 2006).

Standart bir yinelenen sinir ağının meyil problemini çözmek için GTÜ, “güncelleme ve sıfırlama” kapısını kullanır (Şekil 9). Temel olarak, bunlar çıktıya hangi bilgilerin iletilmesi gerektiğine karar veren iki vektördür. Onlar hakkında özel olan şey, bilginin uzun zaman önce, zaman içinde yıkmadan veya tahminle


ilgisi olmayan bilgileri uzak tutmak için eğitilmesidir.

a) Güncelleme kapısı (Update gate)

Güncelleme kapısı, bir UKSH' nin unut kapısı (forget gate) ve giriş kapısına (input gate) benzer davranır. Hangi bilgilerin atılacağına ve hangi yeni bilgilerin ekleneceğine karar verir.

b) Sıfırlama kapısı (Reset gate)

Sıfırlama kapısı, ne kadar geçmiş bilginin unutulacağına karar vermek için kullanılan bir kapıdır. GTÜ yapısı UKSH' ye göre daha az kapı içermektedir (Şekil 9). Bu nedenle, algoritmayı eğitmek UKSH' ye göre daha hızlıdır. Bu çalışmada karşılaştırma amaçlı GTÜ algoritmaları da test edilmiştir.




Şekil 9. UKSH ve GTÜ farkları

Önerilen yöntem

Bu çalışmada Evrişimsel Sinir Ağları ve Uzun Kısa Süreli Hafıza algoritmalarının hibrit kullanılması önerilmiştir. Bu yöntemde ESA katmanlarına UKSH katmanı eklenerek ESA-UKSH hibrit modeli kurgulanmış ve elektrik

üretim tahmini için deneysel sonuçlar bulunmuştur. Modelde doğrusal olmayan katman da kullanılmıştır. Önerilen yapının katmanları ve akışı Şekil 10'da gösterilmiştir.




Şekil 10. ESA-UKSH hibrit yöntemi akış şeması

Veri Seti ve Başarımlar


Çalışma kapsamında 01.05.2017 – 31.05.2018 tarih aralığında bir rüzgâr türbini için elde edilen rüzgâr hızı veri seti kullanılarak tahmin yapılmıştır. Öncelikle İzmir Urla bölgesinde bulunan rüzgâr türbininden sağlanan ve bir yılı kapsayacak şekilde her gün saatlik çözünürlükte alınan 8640 adet veri ile çalışılmıştır. Sayıların

büyük olmasından kaynaklanan normalizasyon gereksinimi için değerler (-1,1) arasında ölçeklendirilmiştir. Şekil 11 çalışmada kullanılan veri setini göstermektedir.




Şekil 11. Günlük çözünürlükte rüzgâr türbini verisi


1 yıllık ve günlük çözünürlükte veri seti ESA algoritması ile kullanıldığında MSE 12,37 olarak hesaplanmıştır. 300 adet veri algoritmayı eğitmek için kalanı ise test için kullanılmıştır. Eğitim, test ve tahmin edilen sonuç grafiği Şekil 12’de verilmiştir. Aynı veri seti için 3 gizli katmanlı bir UKSH modeli kurulmuştur. Kullanılan modelde 100 iterasyon 5 kez tekrar ettirilmiştir. Bu adımdan sonra yapılan test işleminde MSE değeri 8,4 olarak hesaplanmıştır. Kullanılan test verisi ve tahmin edilen veri Şekil 13’teki grafikte gösterilmektedir. Önerilen ESA-UKSH modelinde ESA katmanlarına UKSH katmanı eklenerek yapılan tahmin sonunda ise MSE 2,009 olarak hesaplanmıştır (Şekil 14). Ayrıca 3 günlük, 5 günlük ve 1 aylık olarak alınan ve 10 dakika çözünürlükteki veriler de kullanılmıştır. 3 günlük ve 10 dakika çözünürlükte toplam 432 adet veri bulunmaktadır. Bu veri seti bir saatlik ortalamaya çevrildiğinde, veri seti 72 adet olurken bunların 48 adedi algoritmayı eğitmek, kalanı ise test için kullanılmıştır. UKSH algoritması kullanılarak yapılan kestirimde MSE değeri 2,06 olarak hesaplanmıştır. Sonuç grafiği Şekil 15’tedir. 5 günlük ve 10 dakika çözünürlükte ise toplam 720 adet veri bulunmaktadır. Bu veri seti bir saatlik ortalamaya çevrildiğinde, veri seti 120 adet olurken bunların 80 adedi algoritmayı eğitmek, kalanı ise test için kullanılmıştır. UKSH algoritması kullanılarak yapılan kestirimde hata değeri 2,89 olarak hesaplanmıştır (Şekil 16).



Şekil 12. ESA ile 1 yıllık, günlük çözünürlükte üretim tahmin grafiği



Şekil 13. UKSH ile 1 yıllık, günlük çözünürlükte üretim tahmin grafiği




Şekil 14. ESA – UKSH ile 1 yıllık, günlük çözünürlükte üretim tahmin grafiği


1 aylık 10 dakika çözünürlükte elde edilen veri toplam 4320 adet veri bulunmaktadır. Bu veri seti bir saatlik ortalamaya çevrildiğinde, veri seti 720 adet olurken bunların 480 adedi

algoritmayı eğitmek, kalanı ise test için kullanılmıştır. ESA algoritması kullanılarak yapılan kestirimde MSE değeri 2,2 olarak hesaplanmıştır. Sonuç grafiği Şekil 17’de verilmiştir. Önerilen çalışmada ayrıca 1 yıllık saatlik çözünürlükte geniş bir veri seti de kullanılmıştır. Bu veri seti için bahsedilen algoritmaların yanında karşılaştırma amaçlı


GTÜ, Sarimax ve Prophet yöntemleri de test edilmiştir. Şekil 18’de de görüldüğü gibi MSE değeri Sarimax, Prophet, GTÜ, ESA, UKSH VE ESA-UKSH yöntemleri için sırasıyla 11.97, 11.52, 2.24, 1.89, 1.21, 1.17 olarak hesaplanmıştır.




Şekil 15. UKSH ile 3 günlük, 10 dakika çözünürlükte üretim tahmin grafiği



Şekil 16. UKSH ile 5 günlük, 10 dakika çözünürlükte üretim tahmin grafiği



Şekil 17. ESA ile 1 aylık, 10 dakika çözünürlükte üretim tahmin grafiği



Şekil 18. Farklı yöntemler ile 1 yıllık, saatlik çözünürlükte üretim tahmin grafiği

Sonuç

Rüzgâr türbinlerine yapılan yatırımların artış miktarıyla doğru orantılı olarak toplam üretimdeki payları da artmaktadır. Bu durum özellikle ilerleyen yıllarda üretim tahmini konusunda yatırımcı ve işletmecilerin daha fazla kaynak ayırmalarını gerektirecektir. Ekipmanların yaşlanmasına bağlı olarak bakım planlaması açısından da üretim tahmini ve piyasa entegrasyonları için çeşitli bilişim sistemlerine yatırım yapmak işletmeciler için kaçınılmaz olacaktır. Bu çalışmada akademik çeşitli alanlar için uygulaması mevcut olan çeşitli makine öğrenmesi ve derin öğrenme

algoritmalarının rüzgâr enerjisinin tahmininde kullanım olanakları araştırılmıştır. Yapılan çalışmalar sonucunda bu algoritmaların her birinin çalışma karakteristikleri incelenmiş ayrıca farklı parametre değişkenleri ile denemeler yapılarak bunların sonuçlara etkileri izlenmiştir. Tüm algoritmalar için geçerli olan bir sonuç olarak, 10 dakika gibi yüksek çözünürlükteki veri seti ile çalışılmasının ve kısa vadeli gelecek tahmini yapmanın tüm algoritmaların başarımını artırdığı gözlemlenmiştir. Ancak veri çözünürlüğünün yüksekliği ve gelecek tahmini için öngörülen

vadenin uzun tutulduğu durumda sistem kaynağı ihtiyacı ve çıktı sürelerinin artışının uygulanan algoritmalar için geçerli olduğu görülmüştür. Bu çalışma kapsamında ESA, UKSH, GTÜ, Prophet, Sarimax ve önerilen ESA-UKSH algoritmaları arasında yapılan kestirim (tahmin) hatası kriteri göz önünde bulundurulduğunda ESA – UKSH hibrit yönteminin daha başarılı sonuçlar vermesi bu yöntemin yatırımcı ve işletmeciler tarafından sahada (yerinde) kullanılabilir olduğunu göstermektedir.

Yaşanan teknolojik gelişmeler bu tür çalışmaların gerçek zamanlı veri ile sahada yapılabilmesi için olanaklar sağlamaktadır. Bu çalışma ile ilgili gelecek çalışmalarda özellikle RES makine ekipmanlarının yaşlanmasına bağlı olarak artan bakım maliyetlerinin azaltılması hedeflenebilir. Bunun için tanılayıcı, önleyici, kestirimci bakım gibi analiz ve tahmin yöntemleri oldukça popüler bir konu olup bu konuda çok çeşitli sektörler için global çapta gerek akademik gerekse endüstriyel birçok çalışma yapılmakta veya yakın gelecekte yapılması hedeflenmektedir. Rüzgâr enerjisi türbinlerinde kullanılan teknoloji ve ekipmanların yüksek fiyatları göz önünde bulundurulduğunda bu konuda yapılacak çalışmaların sağlayacağı katma değer oldukça anlamlı olacaktır.

Kaynaklar

- Akdag, S. A., Dinler, A., (2009), A new method to estimate Weibull parameters for wind energy applications, *Energy Conversion and Management*, **50**, 1761–1766.
- Celik, A. N., (2003), Energy output estimation for small-scale wind power generators using Weibull-representative wind data, *Journal of Wind Engineering and Industrial Aerodynamics*, **91**, 693–707.
- Chung, J., Gulcehre, C., Cho, K., Bengio, Y., (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling, *Proceedings*, In *NIPS 2014 Workshop on Deep Learning*, December 2014.
- Giebel, G., Landberg, L., Nielsen, T. S., Madsen, H. (2001). The Zephyr project. The next generation prediction system. *Proceedings, EWEC 2001*, 777– 780.
- Hochreiter, S., Schmidhuber, J., (1997), Long Short-Term Memory, *Neural Computation*, **9**, 8, 1735-1780.
- Kaynar, O., Taştan, S., Demirkoparan, F., (2009), Yapay Sinir Ağları İle Doğalgaz Tüketim Tahmini, *10. Ekonometri ve İstatistik Sempozyumu*, 27-29 Mayıs 2009, Erzurum.
- Landberg, L., Giebel, G., Madsen, H., Nielsen, T. S., Jørgensen, J. U., Laursen, L., (2002). Wind farm production prediction-the Zephyr model. *Technical report*. Roskilde, Denmark.
- Olah, C., (2015). Understanding LSTM Networks. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>, Erişim tarihi Mart 11, 2019.
- Pinson P., (2006), Estimation of the Uncertainty in Wind Power Forecasting, *Doktora Tezi*, Mines Paris.
- Sanchez, I., (2006), Short-term prediction of wind energy production, *International Journal of Forecasting*, **22**, 43– 56.
- Soman, S., Zareipour, H., Malik, O., Mandal, P., (2010), A Review of Wind Power and Wind Speed Forecasting Methods With Different Time Horizons, *North American Power Symposium 2010*, USA.
- Türkiye Rüzgâr Enerjisi Birliği. “İstatistik Raporu Ocak 2019”. https://www.tureb.com.tr/files/bilgi_bankasi/turkiye_res_durumu/istatistik_raporu_ocak_2019.pdf. Erişim tarihi Nisan 11, 2019.
- Wilamowski B. M., Yu, H., (2010), Improved computation for Levenberg-Marquardt Training, *IEEE Transactions on Neural Networks*, **21**, 6, 930-937.
- Wu, Y., ve Hong, J., (2007). A literature review of wind forecasting technology in the world, *Proceedings, IEEE Lausanne POWERTECH*, Switzerland.

Estimation of wind power generation with Long Short-Term Memory and Convolutional Neural Networks

Wind turbines provide electricity with the help of wind speed. The direction and speed of the wind have geographical and temporal differences due to inhomogeneous heating. The wind speed increases as the altitude increases and the wind power increases depending on the speed. Wind power generation applications using wind turbines are increasing day by day along high initial investment costs. The aim of this study is to overcome the disadvantages such as the variability of the wind power by estimating the electrical energy generation with the help of a system based on machine learning. In addition, it is aimed to reduce the unbalanced costs and improve the prediction of energy generation to maximize the profit. In our study, a method called CNN-LSTM which hybrids Convolutional Neural Networks (CNN) and Long Short Term Memory (LSTM) methods is proposed. The data utilized is actual data obtained from the wind turbine resides in Izmir Urla location. This data set consists of wind speed of 1-year with daily and also ten minute resolution. In training and test steps, the data of the long period such as 1-year is used as well as the data of the short period such as 3-day. In addition to the proposed hybrid method, CNN, LSTM, Prophet, Sarimax and Gated Recurrent Unit (GRU) methods are applied respectively and the results are demonstrated graphically. The mean square error (MSE) is reduced to 1.17 for the estimation of energy generation using the developed hybrid CNN-LSTM learning structure.

The Long Short-Term Memory algorithm is a special type of Recurrent Neural Networks (RNN) that can learn long-term dependencies. LSTM retains the error value of different layers in back propagation for a neural network. Thus, it maintains the learning by providing a constant error value after number of iterations. This is done by opening a new channel between the input and output. Convolutional Neural Networks are artificial neural networks that are used effectively in many areas such as pattern recognition, classification and data estimation. The CNN algorithm processes the data or image in various layers using the data itself or its own attributes. Convolution layer which is the main structure layer is used to determine the data properties. Filters like edge detection are utilized to detect low and high frequency characteristics of an

input. In this study a nonlinear layer is used after a convolutional layer. In the proposed method, CNN-LSTM hybrid model is constructed by adding LSTM layer to CNN layers and the experimental results are calculated for electricity generation estimation. Within the scope of this study, the wind speed data set obtained from a wind turbine between the dates 01.05.2017 and 31.05.2018 is utilized for the estimation using different machine learning algorithms as well as the proposed CNN-LSTM hybrid algorithm. As the data set with one year and daily resolution is used with ESA algorithm, MSE is calculated as 12.37. For training 300 data are used and the rest are used for testing. A LSTM model with 3 hidden layers is established for the same data set. 100 iterations are repeated 5 times. As a result the MSE value is calculated as 8.4. In the proposed CNN-LSTM model, for the estimation made by adding the LSTM layer to CNN layers, the MSE is calculated as 2.009.

Furthermore, 3-day, 5-day and 1-month data sets with ten minute resolution are used. There are 432 data in 3-day and ten minute resolution. When this data set is converted to one-hour average, the data number decreases to 72 and 48 of them are used to train the algorithm and the rest are used for testing. In the estimation made by using LSTM algorithm, MSE value is calculated as 2.06. The data number in 5-day and ten minute resolution is 720. When this data set is converted to one-hour average, the data number decreases to 120, 80 of them are used for training and the rest are used for testing. The MSE is 2.89 for LSTM algorithm. There are totally 4320 data in 1-month data set with ten minute resolution. This set is converted to one-hour average and the data number decreases to 720. 480 of them are used to training and the rest are used for testing. The MSE value is 2.2 in energy estimation using CNN algorithm. In the proposed study, a large data set for 1-year with one hour resolution is also used. Additionally GRU, Sarimax and Prophet methods are also tested for comparison. MSE value is calculated as 11.97, 11.52, 2.24, 1.89, 1.21, 1.17 for Sarimax, Prophet, GRU, CNN, LSTM and CNN-LSTM methods respectively. According to the experimental results the proposed CNN-LSTM method can be used by the investors and operators in the field of electricity generation estimation.

Keywords: Estimation of wind power generation; Machine learning; Convolutional Neural Networks; Long Short-Term Memory