

## Konutların Günlük Elektrik Güç Tüketimi Tahmini İçin Uygun Model Seçimi

Aykut ÇAYIR, Işıl YENİDOĞAN, Hasan DAĞ  
T.C. Kadir Has Üniversitesi Yönetim Bilişim Sistemleri  
{aykut.cayir, isil.yenidogan, hasan.dag}@khas.edu.tr

(Geliş/Received: 23.03.2018; Kabul/Accepted: 03.09.2018)

### Özet

Zamana bağlı değişim gösteren olayların modellenmesi zorlu bir veri analizi problemidir. Bu olaylardan biri olan elektrik güç tüketiminde ise veriden mevsimsel etki ve tatil günleri gibi örüntülerin öğrenilerek bir tüketim tahmin modelinin geliştirilebilmesi için klasik makine öğrenmesi ve derin öğrenme yöntemlerinden yararlanılmaktadır. Bu çalışmada, İngiltere'nin Londra şehrindeki belirli bir bölgede 30 farklı eve ait yaklaşık 3 yıllık elektrik güç tüketimi veri kümesi kullanılarak uygun bir kısa vadeli tüketim tahmin modelinin makine öğrenmesi algoritmaları ile bulunması amaçlanmıştır.

**Anahtar kelimeler:** Zaman serisi, makine öğrenmesi, derin öğrenme, konut bazlı elektrik enerjisi tüketim tahmini.

## Finding a Model for Forecasting the Daily Household Electrical Power Consumption

### Abstract

Developing a forecast model for phenomenon changing in time is a hard data analysis problem. Both machine learning and deep learning techniques are used to develop models that can learn seasonality effect and holiday patterns on electrical power consumption data, which form a time-series data set. In this paper, we try to develop a forecast model based on learning algorithms for short-term household electrical power consumption using data belonging to 30 different houses in a region in London.

**Keywords:** Time series, machine learning, deep learning, household electrical energy consumption forecasting.

### 1. Giriş

Günümüzde sensör ağları ve nesnelerin interneti konularındaki gelişmeler veri üretim hızını olağan üstü arttırdığı için bu verileri saklamaya yönelik teknolojiler de ciddi ölçüde gelişmiştir. Bununla beraber, üretilen bu verilerden anlamlı bilgileri çıkartmak için bilinen istatistiksel makine öğrenmesi ve makine öğrenmesinin bir alt grubu olan ve beyin yapısını temel alarak tasarlanan yapay sinir ağları (YSA) modeli olan derin öğrenme konularında da ciddi gelişmeler olmaktadır. Özellikle derin öğrenme tekniklerinin yapısal olmayan veri kümelerindeki başarısı dikkatleri bu alana çekmeyi başarmıştır [1].

İstatistiksel makine öğrenmesi uzun yıllar veri madenciliğinde öğrenmeye dayalı yöntem olarak kullanılmış ve buna bağlı çok çeşitli yöntemler geliştirilmiştir. Son dönemde bu yöntemler arasında, birçok problemde tekniğin

bilinen durumunda en iyi sonuçlara ulaşan iki temel metodu göze çarpmaktadır: Bu metotlar, çekirdek hileli doğrusal yöntem [2] ve topluluk öğrenme modeli [3] olarak bilinirler.

Öte yandan, akıllı şebekelerde artık sıklıkla kullanılan akıllı sayaçlardan da dakikalık veriler almak mümkün hale gelmiştir. Anlık verilerin sayaçlarda depolanıp saat başlarında veya saatte birkaç kez merkezi bir veri depolama sistemine gönderilmesi yaygın bir uygulama haline gelmiştir. Bu verilerden hareketle sistemdeki kısa veya uzun vadeli gelecekteki elektrik enerjisi talebinin tahmini yapılabilir. Bu çalışmada, Londra'da belirli bir bölgede bulunan 30 farklı evden yaklaşık 3 yıl boyunca alınan elektrik güç tüketimi zaman serisi veri kümesi için uygun bir tahmin modelinin geliştirilmesi hedeflenmiştir. Model, istatistiksel öğrenme algoritmaları olan çekirdek hileli doğrusal model ve topluluk öğrenme yöntemleri ile

birlikte zaman serileri için uygun olduğu literatürde [1, 6] belirtilmiş olan derin öğrenme yöntemi sonuçlarının karşılaştırarak oluşturulmasına dayalı olacaktır.

Bu çalışmanın 2. bölümünde zaman serileri üzerine yapılan ve son tekniklerin bilinen durumlarında en iyi sonuçları veren çalışmalar ele alınmaktadır. Veri kümesinin tanımlayıcı istatistikleri, özellikleri ve veri ön işleme kullanılan yöntemler Bölüm 3'te anlatılmaktadır. Bölüm 4'te kullanılan yöntemlere ilişkin detaylar ve model seçim kriterleri sunulurken, Bölüm 5 ile çalışmanın sonuçları ve geleceğe yönelik yapılabilecek çalışmalar verilmektedir.

## 2. İlişkili Çalışma

Bu bölümde zamana bağlı değişim gösteren olayların analizleri ve elektrik enerjisi tüketim tahmin modellerine ilişkin literatür taramalarına yer verilmiştir.

Yu ve ark. [7] öncelikle enerji kullanımına ilişkin istatistiksel bir dağılım oluşturabilmek için bir istatistik analiz modeli sunmaktadır. Aynı çalışmada bir sonraki aşama olarak, enerji kullanımına ilişkin tahmin modelini oluşturmak amacı ile destek vektör makinelerinden (DVM) ve yapay sinir ağından (YSA) yararlanmışlardır. Enerji tüketiminin Gauss dağılımına yakınsadığı ve DVM tabanlı modellerin çok katmanlı YSA'larından daha isabetli tahminler yaptığı sonuçlarına ulaşmışlardır.

Kumar ve ark. [8] borsa verileri üzerinde en iyi tahminleri yapabilecek algoritmaların detaylı karşılaştırmalarını sunmuşlardır. Ayrıca bu makalede, DVM ile rassal orman (RO) algoritması literatürde bilinen diğer algoritmalar ile karşılaştırılmış ve borsa verisi üzerinde en iyi tahminlerin DVM tarafından yapıldığı gösterilmiştir.

Cheng ve ark. [9] RO algoritması kullanarak elektrik güç sistemlerindeki kısa süreli yük tahmininde bulunmuşlardır. Özniteliklerin sayısının yöntemin genelleştirme yetisini düşürmesinden dolayı klasik RO algoritmasının kullandığı farklı öznitelik alt kümeleri yerine tüm özniteliklerin hesaba katılıp ortalama yöntemi ile birleştirildiği bir RO yöntemi önermektedirler. Bu yöntemin mevcut müşterek öznitelik seçimine dayalı

yöntemlerden daha iyi sonuçlar verdiğini göstermişlerdir.

Fugon ve ark. [10] çalışmalarında rüzgâr gücü tahmini yapmak için destek vektör makineleri, rassal orman ve yapay sinir ağları modellerini eğitmişlerdir. Rassal orman modelinin kısa vadeli rüzgâr gücü tahmini için en iyi sonuçları verdiğini göstermişlerdir.

Gers ve ark. [11] Mackay-Glass kaotik zaman serisi için Uzun Kısa Vadeli Bellek (UKVB) modeli kullanarak belli bir zaman penceresinde tahmin yapabilen bir model sunmuşlardır. Malhotra ve ark. [12] ise UKVB ile zaman serilerinde anormallik tespiti yapmışlar ve sonuçların diğer bilinen anormallik tespiti yöntemlerinden daha başarılı olduğunu göstermişlerdir.

Filonov ve ark. [13] çok değişkenli hata tespit modelini UKVB mimarisi kullanarak geliştirmişlerdir. Aynı zamanda bu çalışmada siber saldırı simülasyonu ile UKVB tabanlı sistemlerinin başarısını göstermişlerdir.

Gamboa [14] derin öğrenme yöntemleri ile zaman serileri üzerinde çalışacaklara rehberlik etmesi amacıyla zaman serilerinde tahmin ve anormallik tespiti üzerinde kullanılabilir derin öğrenme algoritmalarını incelemiştir.

Zhang ve ark. [15] çok değişkenli heterojen zaman serisi veri kümesinde olay sınıflandırma problemi için UKVB mimarisinden yararlanmıştır.

Türkiye'deki elektrik tüketimini geleceğe yönelik tahmin etmek için önerilen çalışmalardan biri olan Oğcu ve ark. [16] yapmış olduğu çok katmanlı YSA ve destek vektör bağlanım (regrasyon) modellerinin karşılaştırıldığı çalışmadır. Bu çalışmada, Türkiye'nin aylık elektrik tüketim verisi üzerinde destek vektör bağlanım tahmin modelinin YSA modeline göre oldukça iyi sonuç verdiği gösterilmiştir. Kavaklıoğlu [17] çok değişkenli destek vektör bağlanım modeli kullanarak Türkiye'deki elektrik tüketimini sosyo-ekonomik göstergelerin fonksiyonu olarak modellemeyi başarmış ve 1975 ile 2006 yılları arasındaki verileri kullanarak 2026 yılına kadar olan uzun vadeli tüketim miktarlarını tahmin etmeye çalışmıştır. Tso ve ark. [18] elektrik enerji tüketiminin tahmini için aşamalı bağlanım, karar ağacı ve çok katmanlı YSA olmak üzere üç ayrı modeli incelemiştir. Bu

çalışmada basit bir karar ağacı modeli ile diğer iki modelden çok daha başarılı tahmin sonuçları elde edilebildiğini göstermişlerdir.

Beccali ve ark. [19] İtalya'da Palermo bölgesinde, 1 Haziran 2002 ile 10 Eylül 2003 arasında toplanan elektrik tüketim verisine ek olarak sıcaklık, nem, global solar radyasyon, atmosferik basınç ve rüzgâr hızı verileriyle birlikte çalışmışlardır. Yaptıkları çalışmada elektrik enerjisinin konuta dayalı elektrik tüketiminin yakın dönem için (bir saat sonrası) hava sıcaklığı ve klima kullanımı etkisini de göz önüne alarak tahmin etmeyi amaçlamışlardır. Bu amaca ulaşmak için öz devinimli Elman Yapay Sinir Ağları metodu kullanmışlar ve modelin eğitimi için elektrik enerjisi tüketiminden başka değişkenler de tanımlamışlardır.

Beccali ve arkadaşları çalışmalarında zaman serisi problemlerinde kullanılan yapay sinir ağları metodunun stabilitesi ve tatmin edici performansı nedeniyle uygunluğunu teyit etmiş ve kısa dönem elektrik enerjisi talep tahminleme için geçmiş zaman verileri yanı sıra konfor indeksi, iklimleme cihazları kullanımı gibi parametrelerin de göz önüne alınması gerekliliğine dikkat çekmişlerdir.

Bütün bu çalışmalardan görüldüğü üzere veri kümelerinin zamana bağlı oluşları gibi yapısal bir benzerlik ve elektrik enerjisi tüketim tahmini gibi ortak bir uygulama alanı (Bknz. Suganthi, L., ve Samuel, A. A. [20] ile Swan, L. G. ve. Ugursal, V. I. [21]) olsa bile model geliştirme için ortak bir yöntem veya bir kural üretmek mümkün olmamıştır. Bazı tekniklerin benzer veri setlerine uygulanmış olmalarına rağmen çok farklı başarımlar elde ettiği gözlemlenmiştir. Bu sebepten çalışmada kullanılan veri seti için bir model önerebilmek amacıyla farklı tekniklerin karşılaştırılması sonucunda uygun bir modelin seçilmesi yaklaşımı benimsenmiştir.


### 3. Veri Kümesi

Bu çalışmada kullanılan veriler İngiltere'nin Londra şehrinde akıllı sayaç enerji tüketimi (Smart Meter Energy Consumption) veri kümesine aittir [5]. Veriler Kasım 2011 ile Şubat 2014 zaman aralığında ve her yarım saatte bir olacak şekilde 30 farklı evin KW saat

türünden elektrik güç tüketimi kayıtları olarak toplanmıştır. Tüm veri kümesi toplamda 1 milyon adet gözlem içermektedir.

Veriler kullanılmadan önce ön işlemden geçirilmiştir. Aykırı değer kontrolü yapılmış ve veri setinde aykırı değer olmadığı için ön işlem aşaması iki kısımdan oluşmuştur: eksik verilerin giderilmesi ve veri dönüşümü. İlk aşamada tüm veri kümesinde toplam 29 eksik veri içeren kayıt olduğu tespit edilmiş ve eksik olan bu gözlemler veri kümesinden çıkartılmıştır. Ön işlemin son aşaması olan veri dönüşümü iki şekilde uygulanmıştır. Birinci adımda zaman bilgisi Unix zaman kayıtlarına çevrilip tüm gözlemler bu bilgi ile indekslenmiştir. Veri dönüşümünün son adımında ise yarım saatte bir olarak toplanmış olan gözlemler tarih-endeks bilgisi kullanılarak KW saat türünden günlük elektrik güç tüketim miktarlarına dönüştürülmüştür.

Şekil 1 veri ön işleme aşamasından sonraki gerçek günlük güç tüketimleri KW saat türünden göstermektedir.



Şekil 1: Veri Ön İşleme Sonrası Günlük Güç Tüketimi Verisi.

### 4. Yöntemler


Bu çalışmada istatistiksel makine öğrenmesinde durumları bilinen tekniklerden bir çekirdek hileli doğrusal model olan destek vektör bağlanım modeli, bir topluluk öğrenme algoritması olan rassal orman bağlanım modeli ve makine öğrenmesinin bir alt grubu olan derin öğrenmede yapay sinir ağlarından esinlenilerek zaman serisi ve sekans verileri için tasarlanmış olan uzun-kısa vadeli bellek (UKVB) olarak isimlendirilen YSA modeli eğitilmiştir. Bu modellerin eğitilmesinde kullanılan araçlar şunlardır:

- Python 2.7 Programlama dili
- Sklearn 0.18 İstatistiksel makine öğrenmesi kütüphanesi
- Tensorflow 1.0.2 Derin öğrenme kütüphanesi
- Keras 2.0 Yüksek seviyeli derin öğrenme kütüphanesi
- 

#### 4.1 Destek vektör bağlanım modeli

Destek vektör makineleri karar sınıfının maksimum marj ile sınıflardan ayrılmasına dayanan bir ikili sınıflandırma modeli olarak Cortes ve ark. [4] tarafından geliştirilmiştir. Doğrusal olarak ayrılabilen veri kümelerinde başarılı olmasına rağmen doğrusal olarak ayıramayan verilerde oldukça başarısızdır. Bu problemi aşabilmek amacıyla çekirdek hileleri geliştirilmiştir. Çeşitli çekirdek hileleri bulunmaktadır. Doğrusal olmayan verilerde en sık kullanılan çekirdek hilesi ise radyal bazlı fonksiyondur.

Destek vektör makineleri sınıflandırma amacıyla kullanılabilen gibi bağlanım problemleri için de kullanılmaktadır. Bu çalışmada DVM doğrusal olmayan bağlanım problemi olarak ele alınan günlük elektrik güç tüketimi (Bknz. Şekil 1) verisine tahmin modeli oluşturmak amacıyla radyal bazlı fonksiyon çekirdeği hilesi kullanılarak uygulanmıştır. Şekil 2’de turkuaz renk ile çizilen çizgi DVM bağlanım modelinin tahmini değerlerini, kırmızı çizgiler ise gerçek değerleri göstermektedir. Modelin veri üzerindeki mevsimsel etkiyi ve eğilimleri yakaladığı rahatlıkla görülmektedir.

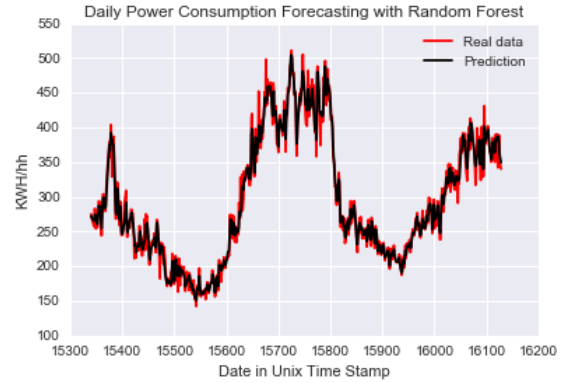


Şekil 2: Destek Vektör Bağlanım Tahmin Modelinin Gerçek Değerlerle Uyumu.

#### 4.2 Rassal orman bağlanım modeli

Rassal orman algoritması rassal alt öznelik kümelerinden oluşturulmuş birden fazla sınıflandırma ve bağlanım ağacı içeren bir topluluk öğrenme algoritmasıdır [22, 23]. RO modeli bağlanımda ve sınıflandırma problemlerinde çok sık kullanılan bir modeldir.

Rassal orman algoritması eşit sayıda rastgele gözlemler içeren ağaç sayısı kadar alt eğitim kümeleri tarafından eğitilir.



Şekil 3: Rassal Orman Bağlanım Tahmin Modelinin Gerçek Değerlerle Uyumu.

Sınıflandırma ve bağlanım problemlerinde gözlemler her bir ağacın yapraklarında bulunur. RO modeli sınıflandırma problemlerinde ormanı oluşturan karar ağaçlarının en fazla oylamış olduğu sınıfı test verisine atar. Bağlanım problemlerinde ise, her bir bağlanım ağacının nihai yaprağındaki gözlemlerin ortalaması ve en sonunda her bir bağlanım ağacından gelen sonuçların ortalaması ile test verisinin bağlanım değeri elde edilir.

Şekil 3’de 1000 bağlanım ağacı ile oluşturulmuş RO modelinin gerçek verilerle uyumu gösterilmektedir. Bu modelin mevsimsel etki ve eğilimleri çok iyi öğrendiği ve gerçek verilere yakın tahminlerde bulunduğu görülmektedir.

#### 4.3 Uzun-kısa vadeli bellek sinir ağı modeli

Uzun-kısa vadeli bellek bir çeşit özdevinimli yapay sinir ağı modelidir [1, 24, 25]. Özdevinimli yapay sinir ağlarında her bir sinir hücresi modeli bir geri besleme döngüsüne sahiptir. UKVB mimarisi çok katmanlı yapay sinir ağı mimarisinden farklı olarak zaman eksenini üzerinden de eğitilmeyi mümkün

kılmaktadır. Geri besleme çevrimi ağırlıkların yenilenmesinde bir önceki ve bir sonraki gözlemin belirli bir zamandaki değerlerini dikkate almayı sağlar.

Klasik çok katmanlı YSA modelinden farklı olarak, UKVB modeli eğitilmesinde bir çeşit geri yayılım algoritması olan zaman ile geri yayılım (Backpropagation Time Through) kullanılır. UKVB eğitiminde yaşanan gradyanların sönmesi ve patlaması problemini ortadan kaldırmak için bu yöntem geliştirilmiştir [26].

Şekil 4'te 500 adet saklı sinir hücresi ile oluşturulmuş UKVB modelinin gerçek veriler ile uyumu görülmektedir. Bu model eğitilirken çapraz doğrulama yöntemi ile en uygun zaman adımı (time step) değeri 1 olarak seçilmiştir. Bu modelin mevsimsel etkiyi, diğer zaman örüntülerini ve eğilimlerini öğrendiği görülmektedir. Ancak yer yer tahminlerinin DVM ve RO bağlanım modellerinin ve gerçek değerlerin gerisinde olduğu açıkça görülmektedir.

#### 4.4 Değerlendirme ölçütleri


Bu çalışmada geliştirilen modeller üç farklı ölçüte göre değerlendirilmiştir. Sırasıyla bu ölçütler R-Kare, düzeltilmiş R-Kare ve ortalama mutlak hata ölçütleridir. R-Kare gerçek bir fonksiyon ile o fonksiyona ait kestirimin ne kadar uyduğunu ölçen bir metriktir.

$$R^2 = \frac{\sum_i \hat{y}_i^2}{\sum_i y_i^2} \quad (1)$$

Denklem (1) R-Kare ölçütünün tanımını vermektedir. Bu denklemde  $\hat{y}$  tahmin değerlerini ve  $y$  ise gerçek değerleri göstermektedir. Bu oran 1'e ne kadar yakınsa gerçekleştirilen eğri uydurma işlemi de o kadar başarılıdır.

$$\text{Düzeltilmiş } R^2 = 1 - \frac{(1-R^2)(N-1)}{N-p-1} \quad (2)$$

Denklem (2)'de ise düzeltilmiş R-Kare ölçütünün tanımı verilmektedir. Bu denklemde  $R^2$  denklem (1)'de hesaplanan R-Kare değerini,  $N$  gözlem sayısını ve  $p$  ise bağlanımda kullanılan öznelilik sayısını göstermektedir. Bu değer 1'e ne kadar yakınsa bağlanım o kadar başarılıdır.



Şekil 4: Uzun-Kısa Vadeli Bellek YSA Tahmin Modelinin Gerçek Değerlerle Uyumu.

$$\text{Ortalama Mutlak Hata} = \frac{1}{n} \sum_i |y_i - \hat{y}_i| \quad (3)$$

Ortalama mutlak hata kayıp ya da maliyet fonksiyonu olarak denklem (3)'teki gibi tanımlanır. Bağlanımda bu maliyet değerinin minimize edilerek olabildiğince en küçük değer olması beklenir.

Tablo 1: Modellerin Değerlendirme Ölçütleri.

Model	$R^2$	Düzeltilmiş $R^2$	OMH
DVM	0.943774	0.943684	15.324859
RO	0.984872	0.984848	7.449141
UKVB	0.906085	0.905933	21.847188

RO algoritmasının günlük elektrik güç tüketimi tahmininde her üç metrikt de diğer iki algoritmadan çok daha iyi olduğu Tablo 1'de görülmektedir.

#### 4.5 Model seçimi

Modellerin en iyi sonuçları verdiği parametrelerin uygun değerlerinin bulunması ve tüm model eğitimlerinin bu parametreler ile gerçekleştirilmesi model seçim aşamasıdır. Bu aşamada  $k$  parçalı çapraz doğrulama işlemi tercih edilmiştir.

Model parametreleri 4-Parçalı çapraz doğrulama kullanılarak seçilmiştir. Tüm veri kümesinin rassal %80'ni eğitime geriye kalan rassal %20'lik kısmı ise deneye ayrılmıştır. En düşük mutlak hata kayıp skorunu veren model seçilmiş deneyler bu modeller ile gerçekleştirilmiştir.

## 5. Sonuç

Makine öğrenmesinde ve veri madenciliğinde tüm veri kümeleri için genel geçer iyi sonuçlar veren bir model olmayacağı "No Free Lunch Theorem" [27] olarak çok iyi bilinmesine rağmen literatürde UKVB modelinin zaman serisi tahmin modellemesinde oldukça başarılı oldukları öne sürülmektedir [1, 11, 13, 14, 15].

Bu çalışmada veri madenciliğinde durumu bilinen tekniklerden çekirdek hileli, topluluk ve derin öğrenme yöntemlerinden literatürde zaman serilerinde tahmin modelleri için en iyi sonuçları veren destek vektör bağlanım, rassal orman bağlanım ve uzun-kısa vadeli bellek YSA modelleri R-Kare, düzeltilmiş R-Kare ve ortalama mutlak hata ölçütlerine göre karşılaştırılmıştır. Elde edilen sonuçlar günlük elektrik gücü tüketimi problemi için en uygun modelin bir topluluk öğrenme algoritması olan RO yöntemi olduğunu göstermektedir. DVM ve UKVB yöntemleri ise umut verici sonuçlar göstermesine rağmen RO bağlanım modelinin oldukça altında kalmıştır. Böylece UKVB modelinin zaman serisi tahminlerinde genel geçer bir yaklaşım olmadığı açıkça gösterilmiştir.

## 6. Kaynaklar

1. LeCun, Yann, Yoshua Bengio, and Geoffrey Hinton. "Deep learning", *Nature* **521**.7553 (2015): 436-444.
2. Suykens, Johan AK, and Joos Vandewalle. "Least squares support vector machine classifiers", *Neural processing letters*, **9**.3 (1999): 293-300.
3. Dietterich, Thomas G. "Ensemble learning", *The handbook of brain theory and neural networks*, **2** (2002): 110-125.
4. Cortes, Corinna, and Vladimir Vapnik. "Support-vector networks", *Machine Learning*, **20**.3 (1995): 273-297.
5. CACI ACORN Group (2010) [Online]. Available: <https://data.london.gov.uk/dataset/smartmeter-energy-use-data-in-london-households>
6. Greff, Klaus, et al. "LSTM: A search space odyssey", *IEEE transactions on neural networks and learning systems*, (2017).
7. Yu, Wei, et al. "Towards statistical modelling and machine learning based energy usage forecasting in smart grid", *ACM SIGAPP Applied Computing Review*, **15**.1 (2015): 6-16.
8. Kumar, Manish, and M. Thenmozhi. "Forecasting stock index movement: A comparison of support vector machines and random forest", (2006).
9. Cheng, Ying-Ying, Patrick PK Chan, and Zhi-Wei Qiu. "Random forest based ensemble system for short term load forecasting", *Machine Learning and Cybernetics (ICMLC), 2012 International Conference on*. Vol. **1**. IEEE, 2012.
10. Fugon, Lionel, Jérémie Juban, and Georges Kariniotakis. "Data mining for wind power forecasting", *European Wind Energy Conference & Exhibition EWEC 2008*, EWEC, 2008.
11. Gers, Felix A., Douglas Eck, and Jürgen Schmidhuber. "Applying LSTM to time series predictable through time-window approaches", *Neural Nets WIRN Vietri-01*, Springer London, 2002. 193-200.
12. Malhotra, Pankaj, et al. "Long short term memory networks for anomaly detection in time series", *Proceedings*, Presses universitaires de Louvain, 2015.
13. Filonov, Pavel, Andrey Lavrentyev, and Artem Vorontsov. "Multivariate Industrial Time Series with Cyber-Attack Simulation: Fault Detection Using an LSTM-based Predictive Data Model", *arXiv preprint arXiv:1612.06676*, (2016).
14. Gamboa, John Cristian Borges. "Deep Learning for Time-Series Analysis.", *arXiv preprint arXiv:1701.01887*, (2017).
15. Zhang, Shengdong, et al. "Deep Symbolic Representation Learning for Heterogeneous Time-series Classification", *arXiv preprint arXiv:1612.01254*, (2016).
16. Oğcu, Gamze, Omer F. Demirel, and Selim Zaim. "Forecasting electricity consumption with neural networks and support vector regression." *Procedia-Social and Behavioral Sciences* **58** (2012): 1576-1585.
17. Kavaklioglu, Kadir. "Modeling and prediction of Turkey's electricity consumption using Support Vector Regression." *Applied Energy* **88**.1 (2011): 368-375.
18. Tso, Geoffrey KF, and Kelvin KW Yau. "Predicting electricity energy consumption: A comparison of regression analysis, decision tree and neural networks." *Energy* **32**.9 (2007): 1761-1768.
19. Beccali, M., et al. "Short-term prediction of household electricity consumption: Assessing weather sensitivity in a Mediterranean area." *Renewable and Sustainable Energy Reviews* **12**.8 (2008): 2040-2065.
20. Suganthi, L., and Anand A. Samuel. "Energy models for demand forecasting—A review." *Renewable and sustainable energy reviews* **16**.2 (2012): 1223-1240.

21. Swan, Lukas G., and V. Ismet Ugursal. "Modeling of end-use energy consumption in the residential sector: A review of modeling techniques." *Renewable and sustainable energy reviews* **13.8** (2009): 1819-1835.
22. Breiman, Leo. "Random forests", *Machine Learning*, 45.1 (2001): 5-32.
23. Loh, Wei-Yin. "Classification and regression trees", *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1.1 (2011): 14-23.
24. Gers, Felix A., Jürgen Schmidhuber, and Fred Cummins. "Learning to forget: continual prediction with LSTM", (1999): 850-855.
25. Graves, Alex, and Jürgen Schmidhuber. "Frame-wise phoneme classification with bidirectional LSTM and other neural network architectures", *Neural Networks*, 18.5 (2005): 602-610.
26. Hochreiter, Sepp, et al. "Gradient flow in recurrent nets: the difficulty of learning long-term dependencies." (2001).
27. Domingos, Pedro. "A few useful things to know about machine learning." *Communications of the ACM* 55.10 (2012): 78-87.

