

Uzun Kısa Dönemli Bellek Derin Öğrenme Modeli ile Türkiye Elektrik Üretiminin Saat Temelinde Tahmini

Dr. Nalan Özkurt

Dr. Hacer Şekerci Öztura

Dr. Cüneyt Güzeliş

Yaşar Üniversitesi

Elektrik ve Elektronik Mühendisliği Bölümü

Enerji Görünümü

- Dünya ölçeğinde birincil enerji arzı 1970-2015 yılları arasında 2,7 kat artarken, aynı zaman diliminde enerji kaynaklı CO₂ salınımının da 2,2 kat arttığı bilinmektedir.
- Referans senaryoya göre 2015'den 2040'a uzanan orta erimli bir ufukta; -Dünya genelinde *endüstride yıllık %0,7*, *binalarda yıllık %1,1* ve *ulaşımda yıllık %1,0* olacağı yönünde değerlendirmeler yapılmıştır.
- Birincil enerji kaynakları üzerinden yapılan bu değerlendirmelerin yanında, elektrik üretiminin de 2015'den 2040'a kadar, 1,46 katına çıkacağı tahmin edilmiştir.
- Enerji ve Tabii Kaynaklar Bakanlığı'nın 2017-2026 arasını kapsayan 10 yıllık talep tahmininde; yıllık artış oranı *referans talep için %4,5*, *yüksek talep senaryosu için %5,6* ve *düşük talep senaryosu için ise %3,7* olarak verilmiştir.
- Bir yıl önce aynı ay için üretim verilerindeki değişimler *-%3,2* (karşılığı 798,1 GWh) ile *+%16,7* (karşılığı 1.984 GWh) arasında oldukça geniş bir yelpazede değişim gösterebilmektedir.


2016-2019 yılları arasındaki aylık elektrik üretimi ve değişim oranları

Aylar	2016 (GWh)	2017 (GWh)	Artış (%)	2018 (GWh)	Artış (%)	2019 (GWh)	Artış (%)
Ocak	23.443,1	25.479,3	+8,1	26.300,9	+3,2	25.845,5	-1,7
Şubat	20.929,2	22.916,2	+7,5	23.248,7	+1,5	23.342,4	+0,4
Mart	22.038,8	23.998,7	+8,6	24.815,6	+3,4	24.637,9	-0,7
Nisan	21.330,8	22.583,4	+5,5	23.424,8	+3,7	23.591,7	+0,7
Mayıs	21.923,8	23.442,2	+6,6	23.810,1	+1,6	24.792,3	+4,1
Haziran	22.975,9	22.913,3	-0,5	23.917,6	+4,4	24.040,2	+0,5
Temmuz	24.269,9	28.362,6	+16,7	29.246,9	+3,1	28.531,6	-2,4
Ağustos	26.146,4	28.130,4	+7,6	27.608,0	-1,9	–	–
Eylül	21.264,5	24.455,3	+14,1	25.075,2	+2,5	–	–
Ekim	22.127,2	24.058,6	+7,9	23.590,5	-1,9	–	–
Kasım	22.892,9	24.729,6	+6,4	23.931,5	-3,2	–	–
Aralık	25.065,3	26.207,9	+3,9	25.746,9	-1,8	–	–
Toplam	274.407,7	297.277,5	+7,7	300.716,8	+1,2	174.781,5	

Kaynak: TEİAŞ Aylık Elektrik İstatistikleri <http://kojenturk.org/tr/teias-elektrik-uretim-istatistikleri-2019-1268>

EPIAŞ'ın 2016 yılı aylık üretim verileri

Elektrik Üretimi [MWh]



Kaynak: EPIAŞ Şeffaflık Platformu

<https://seffalik.epias.com.tr/transparency/uretim/gerceklesen-uretim/gercek-zamanli-uretim.xhtml>

Aktif enerji bedeli, bulunulan ay içerisinde elektrik piyasasında her gün, saatlik olarak ortaya çıkan fiyatlara göre belirlendiği için, elektrik üretim ve tüketim miktarlarının daha önceki gerçek veriler kullanılarak tahmin edilebiliyor olması çok büyük önem taşımaktadır.


Sonuç olarak, elektrik üretim ve tüketiminin doğru olarak tahmin edilebiliyor olması elektrik fiyatını doğrudan etkilemektedir.

Üretim ile tüketim tahmini arasındaki fark direk ***dengesizlik maliyeti*** olarak karşımıza çıkmaktadır ve elektrik enerjisi maliyetlerinin yükselmesi anlamına gelmektedir.


Bildiride sunulan çalışma, Türkiye genelindeki elektrik üretiminin saatlik temelde tahmini için, zaman serilerinden tahmin yapmada başarılı olduğu bilinen ***Uzun-Kısa Dönemli Bellek*** (LSTM: Long-Short Term Memory) ***derin öğrenme*** modelinin başarısının incelenmesine odaklanmıştır.




Elektrik yük tahminin zamansal sınıflaması ve tahminlerin kullanıldığı alanlar



Kaynak: I. Moghram, S. Rahman, “Analysis and evaluation of five short-term load forecasting techniques”, IEEE Transaction of power system, Volume 4, Issue 4, pp. 1484-1491, 1989.



Deep Learning



Kaynak:

<https://medium.com/@nyilmazsimsek/derin-%C3%B6%C4%9Frenme-deep-learning-nedir-ve-nas%C4%B1l-%C3%A7al%C4%B1%C5%9F%C4%B1r-2d7f5850782>

Kısa erimli tahminleme (doğrusal özyinelemeli modellerin hava koşulları, geçmiş yük değerleri, haftanın hangi günü olduğu ya da tatil günü olup olmadığı gibi bilgilerin de modelde kullanılması)

- **Özyinelemeli Kayan Ortalama** (**ARMA**: Auto Regressive Moving Average)
- **Özyinelemeli Tümlşik Kayan Ortalama** (**ARIMA**: Auto Regressive Integrated Moving Average)
- **Özyinelemeli Kayan Ortalama & Yapay Sinir Ağları** (**ARMA + YSA**) ile birlikte
- **Yinelemeli Sinir Ağları** (**RNN**: Recurrent Neural Network)

Türkiye için yapılan kısa dönem elektrik tüketim tahmin çalışmaları;

(MAPE: Mean Absolute Percentage Error)


- 2002 yılı elektrik tüketim verisi - 24 saatlik kısa dönem tahmini - ARMA (**MAPE %2,33**) ve Elman Yapay Sinir Ağı (**MAPE %1,6**);
- 2013-2014 yılları Türkiye tüketim verileri- Levenberg-Marguardt (LM) algoritması - Çok Katmanlı Algılayıcı (ÇKA)-YSA modeli ile **%1,76 MAPE**;
- Levenberg-Marguardt (LM) algoritması - Çok Katmanlı Algılayıcı (ÇKA) YSA modeli - **%1,8 MAPE**;
- Geçmiş tüketim verilerinin yanında fiyat ve yük tahmin planı da eklenerek tahmin sonuçları iyileştirilmiştir.
- ÇKA YSA modeli, aynı veri kümesi üzerinde Mevsimsel ARIMA (SARIMA: Seasonal ARIMA) modeli ile karşılaştırılmış ve daha iyi sonuç verdiği gösterilmiştir.

Derin öğrenme yöntemlerinin yaptığı en büyük katkı *öznitelik çıkarma ya da parametre seçme işlemlerine ihtiyaç duymaması* ve *veri ile ilgili dinamiklerin zaman serisinden en iyileme yöntemleri* ile çıkarılabilmesidir.

2018 yılında yapılan bir çalışmada yine 2013-2014 tüketim verileri ile RNN, LSTM ve basitleştirilmiş özel bir LSTM modeli olan Kapılı Yinelemeli Birim (GRU: Gated Recurrent Unit) modelleri karşılaştırılmıştır. En iyi başarımlar üç katmanlı GRU modeli ile % 0,71 MAPE olarak elde edilmiştir.

Kaynak: A. Tokgöz, G. Ünal, “A RNN based time series approach for forecasting turkish electricity load,” In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1-4). IEEE, 2018.

LSTM hücresinin blok diyagramı



Kaynak: Ö. Ö. Bozkurt, G. Biricik, and Z. C. Tayşi, “Artificial Neural Network and SARIMA based models for power load forecasting in Turkish Electricity Market,” PloS one, vol. 12, no. 4, e0175915, 2017.

Veri Kümesi

Çalışmada EPIAŞ internet sitesinde bulunan 2016-2018 yıllarına ait saatlik üretim verileri incelenmiştir.

Toplam verinin %80'ini içeren 1 Ocak 2016'dan 27 Mayıs 2018'e kadarlık kısmı eğitim için kullanılırken, 27 Mayıs 2018 02:00'dan 31 Aralık 2018 24:00'a kadar ortaya çıkan üretim değerleri test amacıyla kullanılmıştır.

Veride saatlik, günlük ve mevsimsel değişimler gözlenmektedir.

Başarım Ölçütü

Bu çalışmada tahminleme başarısını ölçmek için MAPE hata ölçütü tercih edilmiştir.

Burada MAPE, aşağıdaki sayılı denklemde tanımlı olup, gerçekleşen ve tahmin edilen değerlerin yüzdelik hata oranını göstermektedir.

$$MAPE = 100 / N \sum_{i=1}^N |Y_{\hat{t}} - Y_g| / |Y_g|$$

N örnek sayısı,

Y_g o saatteki gerçek değer,

$Y_{\hat{t}}$ de tahmin edilen değer.

Deneysel Çalışma

İlk çalışmada her saatlik verinin tahmin edilebilmesi için 24 saatlik geçmiş veri kullanılmıştır.

Tahminleme çalışmaları MATLAB ortamında yapılmıştır.

Momentum Terimli Stokastik Gradient Düşüm (SGDM: Stochastic Gradient Descent with Momentum), *Karesel Ortalamaların Kare Kökü Geriye Yayılım* (RMSProp: Root Mean Square error back Propagation) ve *Uyarlanır Moment Kestrimi* (ADAM: Adaptive Moment Estimation) öğrenme algoritmaları ile yapılan denemeler sonucunda ADAM algoritmasının en başarılı sonuçları elde ettiği görülmüştür.

İterasyon sayısı 200 ve gradyan eşiği 1 değerlerinin iyi sonuç verdiği gözlenmiştir.

İlk iterasyonda 0.005 olarak seçilen öğrenme oranı her 100 iterasyonda bir %20 oranında düşürülmüştür.

Bu sayede başlangıçta daha hızlı öğrenme sağlanırken, son iterasyonlarda ağ parametereleri hassas olarak değiştirilmiştir.


Yüzdelik hata oranını düşürmek amacıyla geçmiş 48 saat ve 72 saatlik zaman serisi girdi olarak tek katmanlı LSTM ağına verilmiştir.

Giriş olarak 24, 48 ve 72 saatlik geçmiş veriyi test amaçlı kullanan analizlerin MAPE yüzdeleri görülmektedir.


LSTM girişleri ve yüzdelik hata oranları

Giriş zaman aralığı	%MAPE
24 saat	0,81
48 saat	0,73
72 saat	0,77


LSTM ile saatlik gerçekleşen ve tahmin edilen güç üretimi değerleri



LSTM ile saatlik gerekleşen ve tahmin edilen güç üretimi değeri (1 hafta)



LSTM ile saatlik gerçekleşen ve tahmin edilen güç üretimi değerleri (48 saat)



SONUÇ

Sunulan çalışmada EPIAŞ'tan alınan güç üretimi değerleri üzerinden 1 saat ilerideki Türkiye geneli elektrik üretim değerini tahmin etmek üzere derin öğrenme modellerinden LSTM modeli kullanılmıştır.

Bilimsel yazında güç tüketim tahmini için elde edilen sonuçlar ile uyumlu başarı düzeyi elde edilmiştir.

Bu çalışmada 24, 48 ve 72 saatlik zaman dilimini girdi olarak kullanan tek katmanlı LSTM ağının başarılı tahminler yapabildiği gösterilmiştir.

Gelecek çalışmalarda Türkiye ve dünyadaki Elektrik Tüketim verileri incelenerek farklı ağ yapılarının kısa, orta ve uzun vadeli tahmin sonuçlarına etkisinin araştırılması planlanmaktadır.

Dinlediğiniz için teşekkürler

