

Lojistik Regresyon ve Perseptron Modelleri Kullanılarak Rüzgar-Güneş Enerji Santral Modelinin Güç Üretim Durumunun Analizi

MEHMET KURBAN^{1*}, YELİZ MERT KANTAR², FATİH ONUR HOCAOĞLU¹

¹Anadolu Üniversitesi, Mühendislik-Mimarlık Fakültesi, Elektrik-Elektronik Mühendisliği Bölümü / ESKİŞEHİR

²Anadolu Üniversitesi, Fen Fakültesi, İstatistik Bölümü / ESKİŞEHİR

Alınış tarihi: 03.10.2006, Kabul: 23.05.2007

Özet: Bu çalışmada, Anadolu Üniversitesi İki Eylül Kampusu 'nde kurulmuş olan hibrit (rüzgar-güneş) enerji santral modelinin, rüzgar hızı, güneş ışınım şiddeti, izlenen saat verilerine dayalı olarak belirlenen günlük yük talebini karşılayacak enerji üretip üretmeyeceği lojistik regresyon modelleri olan logit ve probit regresyon ve tek katmanlı perseptron kullanılarak sınıflandırılmıştır. Yapılan analizler sonucunda logit ve probit regresyon modellerinin yaklaşık %87 doğruluk oranıyla, perseptronun ise yaklaşık olarak %70 doğruluk oranıyla sistemin çalışma durumunu tespit ettiği görülmüştür.

Anahtar Kelimeler: Lojistik regresyon, Rüzgar-güneş enerjisi, Logit, Probit, Yapay Sinir Ağları, Perseptron.

Analysis of the Power Generation States of Wind-Solar Power Plant Model by Using Logistic Regression and Perceptron Models

Abstract: In this paper, Wind-PV (Photovoltaic) hybrid energy generation system constructed at İki Eylül campus of Anadolu University, Eskişehir is studied. By using solar radiation and wind speed data the electrical energy generations of the system per hours of days are calculated. Hourly load demands are taken into account and the states of the system for each hours of days are determined. For each hour a data set is formed that includes solar radiation, wind speed and hours. The system is statistically modelled by using logit and probit which are logistic regression models and by using a single layer perceptron. By these models the states of the system are examined. in conclusion the probit-logit model is detected the working states of the system with about 87% truth degree and perceptron model is with about %70 truth degree.

Keywords: Logistic regression, Wind-solar energy, Logit, Probit, Neural Networks, Perceptron.

Giriş

Yenilenebilir enerji kaynakları çevre dostu olmaları ve bakım gerektirmemeleri nedeniyle özellikle şebekeden uzak yerlerde sıklıkla tercih edilmektedir. Sürekli gelişen teknoloji sayesinde verimleri artmakta ve ilk kurulum maliyetleri azalmaktadır. Günümüzde en yaygın kullanılan yenilenebilir enerji kaynakları rüzgar ve güneştir. Rüzgar enerjisinden rüzgar türbinleri sayesinde türbinin kanatlarına çarpan havanın mekanik enerjiye dönüştürülmesi ve oluşan mekanik enerjinin elektrik enerjisine dönüştürülmesiyle dolaylı olarak, güneş enerjisinden ise foto-voltaik paneller ile panel üzerine düşen ışınlardan direk olarak elektrik enerjisi üretimi gerçekleştirilmektedir. Bir yörede gerek rüzgardan gerekse güneşten elektrik enerjisi üretmek amacıyla faydalanabilmek için yörenin geçmiş yıllara ait rüzgar hızı, yönü, güneş ışınım şiddetleri, güneşlenme süreleri, sıcaklık, basınç, nem gibi verilerinin istatistiksel olarak analiz edilerek yöreyle ilgili fizibilite çalışmalarının yapılması gereklidir. Bu aşamada değerlendirilecek olan verilerin güvenilirliği ve kullanılacak olan istatistiksel metotların doğru seçilmesi ileriye yönelik yapılacak olan çalışmaların doğruluğu açısından oldukça önemlidir. Güneş enerjisinden günün belli saatlerinde faydalanılabilmekte ve mevsimlere göre ışınım şiddetleri ve güneşlenme süreleri değişmektedir. Rüzgar esme hızları da doğrusal olmayan bir yapıda sürekli

değişmektedir. Rüzgar ve güneş verilerinin mevsimsel olması ve kararsız bir yapı göstermeleri, bu enerji kaynaklarını kullanarak elektrik enerjisi üreten sistemlerin enerji güvenilirliği açısından sakıncalara sebep olabilmektedir. Bu sakıncalar akla bu sistemlerin hibrit kullanımlarını getirmektedir. Rüzgar ve güneş sistemlerinin birbirini tamamladığı ve hibrit kullanımları sonucunda üretilen enerjinin güvenilirliğinin arttığı yapılan birçok çalışmayla gösterilmiştir (Ai vd., 2003; Borowy ve Salameh, 1996; Groumpos vd., 1987; Markvart, 1997; Muselli vd., 1999)

Bir yörede kurulacak olan hibrit (Rüzgar-Güneş) enerji üretim sisteminin boyutlandırılması yapılırken yük talebi dikkate alınmalıdır. Bu tür sistemlerde yükün enerjisiz kaldığı saat sayısı en önemli faktördür. Bu sayının mümkün olduğu kadar azaltılması istenilir.

Yapılan bu çalışmada, Eskişehir bölgesinin rüzgar hızları ve güneş ışınım verileri analiz edilmiştir. Yörede ufak bir ofisin günlük enerji ihtiyacını karşılaması amacıyla hibrit (Rüzgar-Güneş) enerji üretim sistemi düşünülmüş, düşünülen ofisin gün içinde saatlere göre enerji talebinin değiştiği varsayılmıştır. Öğle ve akşam saatlerinde sadece ofiste bulunan güvenlik ve aydınlatma sistemini çalıştığı ve az bir enerji talep ettiği, diğer zamanlarda ise

bilgisayar, aydınlatma, radyo gibi cihazların kullanıldığı varsayılarak bir, saatlik yük talep grafiği oluşturulmuştur.

Oluşturulan saatlik yük talep grafiği dikkate alınarak kurulacak olası sistemin saatler bazında bu talepleri karşılayıp karşılayamayacakları tespit edilmiştir. Sistemin günün her saati için hesaplanan üretiminin o saatteki yükün talebinden büyük olması durumu sistemin yük talebini karşılıyor olması anlamına gelmekte ve bu durum lojik-1 şeklinde, bu durumun tersi ise lojik-0 şeklinde ifade edilmektedir. Ele alınan bu sistem istatistiksel analiz yöntemlerinden olan logit ve probit ile modellenmiştir. Bu modelleme bir ay için yapılmış ve başka bir aydaki rüzgar hızları ve güneş ışınım şiddetleri kullanılarak oluşturulan model kontrol edilmiştir.

Ayrıca, seçilen yöntemler dışında çok katmanlı yapay sinir ağları ve bulanık tabanlı sinir ağları gibi adaptif yöntemler de kullanılabilir.

Materyal ve Yöntem

Fen, sosyal ve tıp bilimleri araştırmalarından devlet yönetimine, üretim sektöründen mühendisliğe kadar pek çok alanda istatistiksel modeller kullanılmaktadır. Özellikle tahmin edilmek istenen değişken iki durum alıyorsa yani başarılı-başarısız, hasta-sağlıklı, makine çalışır-çalışmaz, bu durumlarda lojistik regresyon modelleri kullanılmaktadır. Literatürde bu modellerin kullanıldığı pek çok çalışma mevcuttur. (Fırat ve Onay, 1999; Gujarati, 1999; Jalkanen ve Mattila, 2000; Kosmeli ve Vandal, 2003; Srivastava, 2005; Thomas vd., 2006) çalışmalarında, lojistik regresyonun farklı farklı alanlarda uygulamaları bulunmaktadır.

Bağımlı değişken (yanıt değişkeni) 0 ve 1 gibi ikili değerler alıyorsa, bu ikili cevap değerleri ile bağımsız değişkenler arasındaki ilişkiyi araştırılırken lojistik regresyon kullanılır. Lojistik regresyon daha çok durum kontrolü çalışmalarında kullanılmaktadır.

Genel regresyon aşağıdaki formda yazılabilir (Akkaya ve Pazarlıoğlu, 1998; Dobson, 2001; Gujarati, 1999; Montgomery vd., 2000):

$$y_i = x_i' \beta + \varepsilon_i \quad (1)$$

Burada, $x_i' = (1, x_{i1}, x_{i2}, \dots, x_{ik})$ açıklayıcı değişken, $\beta = (\beta_0, \beta_1, \dots, \beta_k)$ açıklayıcı değişken ile bağımsız değişken arasındaki ilişki katsayısı ve ε_i hata terimidir. Burada y_i yanıt değişkeni 0 ve 1 olmak üzere ikili değer almakta ve y_i , Bernoulli dağılımı $P(y_i)$ olmaktadır:

$$P(y_i) = \begin{cases} p_i, & y_i = 1 \\ 1 - p_i, & y_i = 0 \end{cases} \quad (2)$$

ε_i nin beklenen değeri 0 olduğu için yanıt değişkeninin beklenen değeri p_i dir.

$$E(y_i) = x_i' \beta = p_i \quad (3)$$

Genellikle, yanıt değişkeni ikili değer olduğunda, yanıt fonksiyonu lineer olmamaktadır. Bu yanıt fonksiyonuna lojistik yanıt fonksiyonu denilmekte ve şöyle ifade edilmektedir:

$$E(y) = \frac{\exp(x_i' \beta)}{1 + \exp(x_i' \beta)} \quad (4)$$

$$E(y) = \frac{1}{1 + \exp(-x_i' \beta)} \quad (5)$$

Lojistik yanıt fonksiyonu (6) eşitliği kullanılarak lineerleştirilebilir.

$$\eta = \exp(-x_i' \beta) \quad (6)$$

Lineer tahminci ve dönüşüm

$$\log \frac{p_i}{1 - p_i} = \beta_0 + \beta_1 x_{i1} + \dots + \beta_k x_{ik} = x_i' \beta \quad (7)$$

şeklinde bulunur.

Eğer yanıt fonksiyonu normal kümülatif dağılım fonksiyonu seçilirse, bu durumda elde edilen regresyon modeli probit regresyondur

$$p_i = \int_{-\infty}^{\eta_i} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{1}{2}u^2\right) du \quad (8)$$

(8) denklemini çözüldüğünde

$$p_i = F(\eta_i) \quad (9)$$

$$\eta_i = F^{-1}(p_i)$$

Böylece probit model


$$p_i = F\left(\sum_{k=0}^K \beta_k x_{ik}\right) \quad (10)$$

$$x_i' \beta = F^{-1}(p_i) \quad (11)$$

şeklinde yazılır. Lojistik regresyonda parametreler maksimum likelihood metodu kullanılarak belirlenir (Akkaya ve Pazarlıoğlu, 1998; Dobson, 2001; Gujarati, 1999; Montgomery vd., 2000):


Sınıflandırma problemlerinde kullanılan ve yapay sinir ağlarının temelini oluşturan tek katmanlı bir perseptron girdi birimleri, her girdi birimi için birer ağırlık toplama birimi ve çıktısında bulunan bir transfer fonksiyonundan oluşur. Perseptronlarda genellikle eşik değer transfer fonksiyonu kullanılır. Genel bir eşik değer transfer fonksiyonu şekil 1'de görülmektedir.

Girdi birimleri kendilerine karşılık gelen ağırlıklarla çarpılarak toplama birimine verilir. Genellikle tek katmanlı bir perseptronun çıkışı kullanılan transfer fonksiyonuna bağlı olarak 0,1 veya -1 olabilir. Bir hibrit (Rüzgar-Güneş) enerji üretim modelinin çalışma durumları lojik-0 veya lojik-1 ile gösterildiği için çıkışında eşik değer transfer fonksiyonu bulunan tek katmanlı bir perseptronun kullanılmasının daha uygun olacağı düşünülmüş ve Şekil 2'deki perseptron modeli oluşturulmuştur.



Şekil 1. Eşik Değer Fonksiyonu

Oluşturulan ağa, toplam 1344 adet veri sunulmuştur. Tek katmanlı bir perseptron kullanılmış, kullanılan perseptronun çıkışına eşik değer transfer fonksiyonu bağlanmıştır.



Şekil 2. Kullanılan Perseptron Modeli

Basit bir perseptron öğrenme algoritması şu şekilde özetlenebilir: Verilerle oluşturulan modelde 3 adet giriş ve bu girişlere karşılık gelen gerçek çıkış değerleri mevcuttur. Bu çıkış değerleri, hedef olarak alınmalıdır; başka bir deyişle oluşturulacak perseptron modelinin de bu çıkış değerlerini vermesi sağlanmaya çalışılmalıdır.

Gerçek çıkış değerleri h ile, ağın bulacağı çıkış değerleri de a ile gösterilirse, amaçlanan strateji $h-a$ farkını minimize etmek olarak belirlenebilir. Bu fark, eşitlik (12)'deki gibi e ile gösterilebilir:

$$e = h - a \quad (12)$$

e 'yi minimize etmek için güncellenebilecek parametreler, giriş verilerinin toplama birimine bağlayan ağırlık değerleri ve bias terimidir. Bu parametreleri güncellemek amacıyla geliştirilecek optimizasyonda aşağıdaki üç durumu dikkate almak gerekmektedir:

1.Durum: Giriş verilerinin ağa sunulmasından sonra ağın mevcut w ve bias terimlerini kullanarak yaptığı hesaplamaların sonunda ağ çıkışını 1 bulmuş olabilir ve gerçekte de 1 bulması gerekiyor olabilir. Bu durumda mevcut w ve bias terimlerinde herhangi bir değişiklik yapılmamalıdır.

2.Durum: Giriş verilerinin ağa sunulmasından sonra ağın mevcut w ve bias terimlerini kullanarak yaptığı hesaplamaların sonunda ağ çıkışını 1 bulmuş olabilir; ancak bulması gereken hedef değeri 0 olabilir. Burada hata değeri $e=1$ olacaktır. Bu durumda, girdi vektörü w 'lara eklenerek ağırlıkların yeni değerleri elde edilmelidir.

3.Durum: Giriş verilerinin ağa sunulmasından sonra ağın mevcut w ve bias terimlerini kullanarak yaptığı hesaplamaların sonunda ağ çıkışını 0 bulmuş olabilir ancak bulması gereken hedef değeri 1 olabilir. Burada hata değeri $e=1$ olacaktır. Bu durumda, girdi vektörü w 'lardan çıkartılarak w 'ların yeni değerleri bulunur. Bias terimi girişi hep 1'e eşit olan bir sinir hücresi gibi düşünebilir ve yukarıdaki durumlar göz önünde bulundurulabilir.

Yukarıda belirtilen durumlar eşitlik haline getirilecek olursa, perseptron için basit bir öğrenme kuralı (13) ve (14) eşitlikleri ile özetlenebilir (Haykin, 1994):

$$W^{yeni} = W^{eski} + ep^T \quad (13)$$

$$B^{yeni} = b^{eski} + e \quad (14)$$

Bulgular ve Tartışma

Hibrit sistemden ölçülen veriler Çizelge 1'deki gibi düzenlenerek analizlere uygun hale getirilmiştir. X_1 ölçümün yapıldığı saati göstermektedir. X_2 değişkeni, X_1 saatinde gözlenen güneş ışınım şiddetini, X_3 ise X_1 saatinde gözlenen rüzgar hızı değişkeninin gözlenen değerini göstermektedir.

Sistemden gözlenen değişkenler şunlardır:

- X_1 : Günün zaman dilimleri
- X_2 : Rüzgar hızı
- X_3 : Güneş ışınım şiddeti

Ele alınan sistem için bu değişkenlerin bağımsızlığı incelenerek kurulan logit ve probit modelleri (15) ve (16) eşitliklerinde sırasıyla verilmiştir.

$$Y_1 = 6,68300 - 0,02246X_1 - 0,00282X_2 - 1,54787X_3 \quad (15)$$


$$Y_p = 3,670403 - 0,012669X_1 - 0,001876X_2 - 0,840187X_3 \quad (16)$$

Çizelge 1'deki çıkış değişkenleri sistemin durumlarını göstermektedir ve bu değişkenler giriş değişkenleri kullanılarak oluşturulmuştur. Burada, X_2 ve X_3 değişkenleri kullanılarak hibrit enerji üretim sisteminden üretilen saatlik güçler hesaplanmıştır.

Çizelge 1. Ölçülen dataların düzenlenmesi

Gözlenen Durum	X ₁	X ₂	X ₃
1	1	0	4,7132
1	2	0	4,1988
1	3	0	4,1774
0	4	0	3,2343
0	5	0	3,3693
0	6	10,467	2,1433
0	7	83,736	0,68373
0	8	223,3	1,8733
0	9	327,97	1,6139
0	10	404,72	2,6042
0	11	467,53	2,722
0	12	502,42	2,0469
1	13	516,37	2,692
1	14	502,42	4,859
1	15	460,55	5,8428
1	16	383,79	6,7687
1	17	300,05	7,1395
1	18	125,6	7,6989
1	19	48,846	6,5801
1	20	3,489	6,7837
1	21	0	3,978
1	22	0	4,1624
1	23	0	4,2481
0	24	0	2,8014
1	1	0	4,2567
1	2	0	5,4484
1	3	0	4,7046
.....

Sistemde bulunan yüklerin gün içinde talep ettikleri enerjinin saatlere göre değişimi Şekil 3'te verilmiştir. Hibrit sistemin beslediği yükün günün herhangi bir saatinde toplam üretimden fazla enerjiye gereksinim duyması durumunda sistemin çalışmayacağı düşünülmüş ve bu durum, Çizelge 1'de görüldüğü gibi Lojik-1 ile bu durumun tersi ise Lojik-0 ile belirtilmiştir.

**Şekil 3.** Yük Talep Grafığı

Oluşturulan perseptron modeli Matlab programında yazılan yazılım kullanılarak eğitilip test edilmiş ve doğru sınıflandırma oranı bulunmuştur. Çizelge 2'de, lojistik modellerin ve perseptron modelinin doğru sınıflandırma oranları verilmiştir. Bu çizelge dikkate alındığında lojistik

modellerin, sistemin güç üretip üretmemesine ilişkin tahminlerinin %87 civarında doğru olduğu, perseptronun ise %70 civarında doğru sonuç verdiği görülmektedir. Bunun lojistik modeller açısından oldukça iyi bir sonuç olduğu söylenebilir.

Çizelge 2. Modeller için tüm gözlenen değişkenler kullanıldığında doğru sınıflandırma oranı

Modeller	Veri Cinsi	Doğru Sınıflandırma Oranı
Probit	Tüm veri	0.8609
Logit	Tüm veri	0.8668
Probit	Test verisi	0.8807
Logit	Test verisi	0.8879
Perseptron	Tüm veri	0.7046
Perseptron	Test verisi	0.6235

Sonuç

Bu çalışmada, Anadolu Üniversitesi Bilimsel Araştırma Projesi kapsamında İki Eylül Kampusu 'nde kurulmuş olan hibrit (güneş-rüzgar) enerji üretim modelinde rüzgar hızı, güneş ışınım şiddeti izlenen saat verilerine dayalı olarak sistemin enerji üretip üretmeyeceği, perseptron ve lojistik regresyon modelleri yardımıyla incelenmiştir. Yapılan analizler sonucunda logit ve probit regresyon modellerinin, tüm veriler kullanıldığında enerji üretim durumunu yaklaşık %87 doğruluk derecesinde tahmin ettiği, test verisini kullanıldığında ise %88 oranında doğru sınıflandırdığı; fakat oluşturulan Perseptron modelinin sistemin enerji üretim durumunu tüm verilerde %70 oranında, test verilerinde ise %62 oranında doğru sınıflandırma yaptığı görülmüştür. Gelecekteki çalışmalarda çok katmanlı yapay sinir ağları ve bulanık tabanlı sinir ağları gibi farklı yöntemler kullanılarak analiz tekrarlanabilir.

Kaynaklar

- Ai, B., Yang, H., Shen H., Liao, X. 2003. Computer-aided design of PV/wind hybrid system. Renewable Energy, 28, 1491-1512.
- Akkaya, Ş., Pazarlıoğlu M.V. 1998. Ekonometri II, erkam Yayınevi, İzmir.
- Borowy, B.S., Salameh, Z. M. 1996. Methodology for Optimally Sizing the Combination of a Battery and PV Array in a Wind/PV. Hybrid System, 11, 367-375.
- Dobson, A.J. 2001. An Introduction to generalized Linear models, Chapman&Hall/Crs., London and Boca Raton.
- Fırat, M.Z., Onay, A. 1999. Bitki Doku Kültürü Çalışmalarında elde edilen binom verilerinin geliştirilmiş lineer modeller kullanarak analizi. Tr.J.Biology, 23, 261-267.

- Groumpos, P. P., Papageorgiou, G., 1987. An optimal sizing method for stand-alone photovoltaic power systems. *Solar Energy*, 38, 341-351.
- Gujarati, D.N., 1999. *Basic Econometrics*, Mcgraw-Hill Inc., New York.
- Haykin, S. 1994. *Neural networks*. Macmillan College Publishing Company, New York:
- Jalkanen, A., Mattila, U. 2000. Logistic regression models for wind and snow damage in the northern Finland based on the national Forest Inventory data. *Forest Ecology and management*, 135, 315-330.
- Kosmeli K., Vandal, K. 2003. Comparison of two generalized logistic regression models: a case study, 25th Int. Conf. Information technology Interfaces ITI, June16-19, Cavrat.
- Markvart, T. 1997. Sizing of hybrid photovoltaic-wind energy systems. *Solar Energy*, 57, 277-281.
- Montgomery, D.C., Pect, E.A., Vining, G.G. 2000. *Introduction to Linear regression analysis*, John Wiley & Sons, New York.
- Muselli, M., Notton, G., Louche A. 1999. Design Of Hybrid-Photovoltaic Power Generator, with Optimization of Energy Management. *Solar Energy*, 65, 143-157.
- Srivastava, N. 2005. A logistic regression model for predicting the occurrence of intense geomagnetic storms. *Annales Geophysicae*, 23, 2969-2974
- Thomas, L.C., Jung, K.M., Thomas, S.D., Wu, Y. 2006. Modelling consumer acceptance probabilities. *Expert Systems with Applications*, 30, 499-506.