



YSA Ve DVM Yöntemlerinin Bir Metro Hattında Gerilim Düşümünün Tahmini İçin Karşılaştırılması

The Comparison of the ANN and SVM Methods for the Prediction of Voltage Drop on a Subway Line

İlhan KOCAARSLAN¹, Mehmet Taciddin AKÇAY², Abdurrahim AKGÜNDOĞDU¹, Hasan TİRYAKİ¹

¹*İstanbul Üniversitesi Mühendislik Fakültesi Elektrik-Elektronik Mühendisliği Bölümü, 34320 İstanbul, TÜRKİYE*

²*İstanbul Büyükşehir Belediyesi Raylı Sistem Daire Başkanlığı, 34010 İstanbul, TÜRKİYE*

Başvuru/Received: 01/08/2017

Kabul/Accepted: 14/11/2017

Son Versiyon/Final Version: 29/01/2018

Öz

Bu çalışmada, 1500 V DC beslemeli bir raylı sistemde cer gücünün meydana getirdiği gerilim düşümünün maksimum değeri Yapay Sinir Ağları (YSA) ve Destek Vektör Makineleri (DVM) yardımıyla belirlenmiştir. YSA ve DVM yöntemleriyle hatta oluşan gerilim düşümü işletmesel parametrelere bağlı olarak hesaplanmıştır. YSA ve DVM teknikleri açıklanarak elde edilen sonuçlar karşılaştırılmıştır. YSA modeli için levenberg marquardt (LM) algoritması kullanılmıştır. Levenberg-Marquardt algoritması yapay sinir ağlarının eğitiminde sağladığı hız ve kararlılık nedeni ile tercih edilmektedir. Raylı sistemlerde elektrifikasyon sistemi işletmesel verilere ve hat parametrelerine bağlı olarak tasarlanmaktadır. Elektrifikasyon sistemi oluşturulurken işletme esnasında cer gücünün gereksinimi olan minimum besleme gerilim değerinin sağlanması gerekmektedir. Cer gücü geriliminin en düşük değerini hatta oluşan gerilim düşümünün en yüksek değeri belirlemektedir. Bu değer işletme sürekliliği için belirli limitler içinde tutulması gerekmektedir. Benzetim için tek yönlü ve çift yönlü beslenme durumlarına ait oluşturulan veriler incelenmiştir. Bu çalışma ile demiryolu elektrifikasyon sistemine ait cer gücü simülasyonuna ait sonuçlar yapay zeka yoluyla tahmin edilmektedir. Bu sayede sisteme ait değişkenler farklı olsa dahi tekrar tekrar benzetim yapılmasının önüne geçilmektedir. Tasarlanan sistem ile %95 üzeri başarı oranı elde edilmiştir.

Anahtar Kelimeler

“Cer Gücü, DVM, Elektrifikasyon, Hat, Raylı Sistem, YSA”

Abstract

In this study, the determination of the maximum value of the voltage drop created by the traction force was performed for a 1500 V DC-fed rail system by means of the artificial neural networks (ANN) and support vector machines (SVM). The voltage drop occurring on the line was calculated with regard to the operating parameters by means of the ANN and SVM. The ANN and SVM were explained and a comparison was made. The Levenberg-Marquardt (LM) algorithm was used for the ANN model. The Levenberg-Marquardt algorithm was preferred due to the speed and stability it provides for the training of artificial neural networks. The electrification system in the rail systems is designed with regard to the operating data and design parameters. The minimum voltage rating that the traction force requires during the operation needs to be provided in the electrification system. The highest value of the voltage drop on the line determines the lowest value of the traction force voltage. This value must be in certain limits for the continuity of the operation. The created datas regarding one-way and two-way supply conditions were examined for simulation. In this way railway electrification traction power simulation was done by artificial intelligence methods and traction power simulation results were predicted without doing traction simulation. With the designed system, the success rate is over %95.

Key Words

“ANN, Electrification, Line, Rail System, SVM, Traction Force”

1. GİRİŞ

Elektrikli demiryollarında elektrifikasyon sisteminin ana hedefi araç trafiği ve cer gücü sistemi için gerekli olan enerjinin karşılanmasıdır. Cer gücünün yükünü hatta kullanılan araçların elektrik tüketimi oluşturmaktadır. Araç işletmesinin etkin ve verimli bir şekilde yapılması için araca iletilen besleme geriliminin belirli limitler içerisinde kalması istenmektedir. Bu limitler TS EN 50163 tanımlanmış olup tablo 1 ile verilmektedir.

Tablo 1: 1500 V DC Beslemeli demiryolu uygulamalarında kullanılan cer sistemlerine ait besleme gerilim limitleri (TS EN 50163)


Elektrik Sistemi	En küçük Süreksiz Gerilim	En küçük Sürekli Gerilim	Nominal Gerilim	En büyük Sürekli Gerilim	En büyük Süreksiz Gerilim
1500 V DC	1000 V DC	1000 V DC	1500 V DC	1800 V DC	1950 V DC

Tablo 1 ile verilen limit değerler aynı zamanda işletme sırasında elektrik iletim hattında oluşacak gerilim düşümünün limitlerini de belirlemektedir. Hatta oluşan gerilim düşümü kontrol altında tutulmadığı zaman araç performans kayıpları ve işletmenin durması gibi istenmeyen durumlar yaşanmaktadır. Demiryollarında cer gücü tasarımı yapılırken besleme geriliminin bu limitlerin içinde tutulması ve sistem analizi için cer gücü simülasyonu yapılmaktadır. Cer gücü simülasyonu yapıldıktan sonra iletim hattında gerçekleşen gerilim düşümü belirlenmektedir. Sistemde oluşan gerilim düşümü diğer yüklere etki ederek güç sisteminde ciddi problemlere sebep olmaktadır (Limpong, 2016). Sistem tasarımı esnasında gerilim düşümü hesaba alınarak tüm sistemin daha verimli çalışması sağlanmaktadır (Nuzzo, Galea, Gerada & Brown, 2016). DC beslemeli demiryollarında geri dönüş akımı raylar üzerinden tamamlanmakta olup rayın direncinden dolayı aracın çekeceği 1200 A'ye kadar ray üzerinde 60-100 V civarı gerilim düşümü oluşmaktadır (İbrahim, Elrayyah, Sozer, & Abreu, 2017). Gerilim düşümünde meydana gelecek yüksek değerler sistemde arıza olduğunu belirtmektedir (Meghwani, Chakrabarti, Srivastava, 2016). Literatürde YSA ile orta gerilim asenkron motorunun kalkışında gerçekleşen gerilim düşümünün tahmin edilmesi, çıkık kutuplu senkron generatörün tahrik sistemine ait diyot komutasyon işleminde oluşan gerilim düşümünün tahmini, DC raylı sistemde kaçak akım ve dokunma geriliminin tahmin edilmesi ve mikro şebekelerde arıza tespiti için gerilim düşümü tahmini bazlı hızlı bir yöntem yayınları bulunmaktadır. Bu çalışmada cer gücü simülasyonu ile elde edilen veriler kullanılarak cer gücü iletim hattına ait gerilim düşümü değeri yapay zeka yöntemleri kullanılarak tahmin edilmiştir. DC beslemeli demiryollarında çeşitli besleme gerilimleri tercih edilmektedir. Bunlar 600-750-1500 ve 3000 V DC gerilimleridir. Bu seçim teknik ve ekonomik koşullara da bağlı olmak üzere ülkelere göre değişiklik arz edebilmektedir. DC beslemeli demiryollarında geri dönüş iletkeni olarak ray hattı kullanılmaktadır (Abrahamsson, Kjellqvist, Ostlund, 2012), (Tian at al., 2014), (He, Yu., Wang, & Song, 2013), (Xu, Li, & Wang, 2013), (Lao, Wong, Dai, Wong, & Lam, 2016). Ülkemizde yaygın olarak 750 ve 1500 V DC besleme gerilimleri kullanılmaktadır.

2. MATERYAL VE METOD

DC beslemeli demiryollarında tek yönlü ve çift yönlü olmak üzere iki tip besleme durumu bulunmaktadır. Tek yönlü beslenme durumunda cer gücü tek yönlü olarak beslenmektedir. Çift yönlü beslenme durumunda her iki yönden besleme gerçekleşmekte olup bu tip beslemede cer gücü iki uçtan paylaşımlı olarak beslenmektedir. Bu tip besleme sistemi DC beslemeli demiryollarında daha yaygın olarak kullanılmaktadır (Takagi, 2012), (Alamuti, Nouri, & Jamali, 2011), (Tzeng & Lee, 2010), (Lao, Wong, Dai, Liu, & Wong, 2013), (Jia, Yang, Lin, & Fang, 2014), (İbrahim, Elrayyah, Sozer, & Abreu, 2017), (Ogunsola, Sandrolini, & Mariscotti, 2015), (Calderaro at al., 2015).


Aşağıda tek bölgeden ve çift bölgeden beslenme durumlarına ait eşdeğer devre modelleri şekil 1 ve şekil 2 ile verilmektedir.



Şekil 1: Tek yönlü beslenme durumu

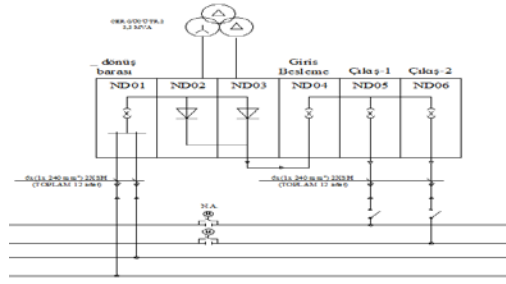
Tek yönlü beslenme durumuna ait denklem (1) ile verilmekte olup R1 ve R3 katener ve raya ait dirençleri temsil etmektedir. R1 ve R3 değerlerine fider ve geri dönüş kablolarına ait dirençler de ilave edilmiştir. R1 ve R3 değerleri aracın konumuna bağlı olarak değişmektedir. V1 araca ait gerilim olup Vn1 nominal besleme gerilimini belirtmektedir. I_{araç} araç akımını belirtmektedir.

$$V_1 = V_{n1} - I_{araç} \times R_1 - I_{araç} \times R_3 \quad (1)$$



Şekil 2: Çift yönlü beslenme durumu

Denklem (2)'de ise çift yönlü beslenme durumuyla ilgili formül verilmektedir. R1,R2,R3 ve R4 katener ve raya ait dirençleri temsil etmektedir. R1, R2, R3 ve R4 değerlerine fider ve geri dönüş kablolarına ait dirençler ilave edilmiştir. R1,R2,R3 ve R4 değerleri aracın konumuna bağlı olarak değişmektedir. V1 araca ait gerilim olup Vn1 ile Vn2 ise nominal besleme gerilimlerini belirtmektedir. DC beslemeli bir demiryolu hattında DC gerilim çift sekonderli üç fazlı trafo üzerinden 24 darbeli doğrultucu vasıtasıyla elde edilmektedir. Besleme kabloları ile orta gerilim şebekesi üzerinden temin edilen 34.5 kV orta gerilim besleme trafo merkezlerine getirilerek cer gücünün ihtiyacı olan enerji buradan elde edilmektedir. (Smidl, Janous, & Peroutka, 2015), (Jung at al., 2013), (Wang at al., 2014), (Takagi & Amano, 2014), (Torreglosa, García, & Fernández, 2014), (Park, 2015).Şekil 3 ile DC demiryolu cer gücü besleme diyagramına ait tek hat şeması verilmektedir.



Şekil 3: DC beslemeli bir hatta ait tek hat şeması

$$I_{araç} = \left[\begin{matrix} [Vn1 & Vn2] - [V1 & V1] \\ \frac{1}{R1+R3} \\ \frac{1}{R2+R4} \end{matrix} \right] \quad (2)$$

Aracın çektiği aktif güç araç gerilimine ve araç akımına bağlı olarak belirlenmektedir. Araç cer kuvveti (F_{cer}), araç hareketine karşı direnç kuvveti (F_{hareket}), eğim direnci kuvveti (F_{eğim}), kurp direnci kuvveti (F_{kurp}) ve aracın ivmesi ile kütlelerinin çarpımının toplamından oluşmakta olup (3), (4), (5) ve (6) eşitlikleri ile verilmektedir. Eşitliklerde V araç hızını, m aracın kütleliğini, A, B ve C katsayıları araç karakteristiğine bağlı değerleri, g yerçekimi ivmesini, γ eğim açısını, R kurp yarıçapını, C₁, C₂ ve C₃ kurp kuvvetini hesaplamak için kullanılan katsayıları ifade etmektedir. İvme ile kütle çarpımı (ma) ile gösterilmiştir. Denklem (6) ile Araç cer kuvveti hesaplanmaktadır.

$$F_{hareket} = a + B \times v + C \times v^2 \quad (3)$$

$$F_{eğim} = m \times g \times \sin(\gamma) \quad (4)$$

$$F_{kurp} = (m \times g \div 1000) \times (C_1 - C_2 \times R) \div (R - C_3) \quad (5)$$

$$F_{cer} = F_{hareket} + F_{eğim} + F_{kurp} + ma \quad (6)$$

Denklem (7) ile araca ait güç denklemi aracın cer kuvvetine ve hızına bağlı olarak hesaplanmaktadır.

$$P_{araç} = F_{cer} \times v \quad (7)$$

Aracın gücü aracın cer kuvveti ve hızı arttıkça artmaktadır. Farklı işletme durumlarına ait 1000 adet veri dizisi şekil 1 ve şekil 2 ile verilen eşdeğer devrelerin farklı işletme parametreleri ile benzetimi yapılarak elde edilmiştir. Besleme yönü sayısı, araç sayısı, aracın cer kuvveti, aracın ivme-kütle değeri, kurp yarıçapı, eğim, besleme hattının uzunluğu, aracın iç tüketim akımı, hattın elektriksel direnci ve endüktansı benzetimde kullanılan parametreler olup hesaplanan değer ise hatta oluşan en yüksek gerilim düşümü

değeridir. Benzetimde kullanılan tüm giriş parametreleri için random değerler atanmıştır. Benzetim için 0-5 arasında değişen araç sayısı kullanılmış olup maksimum gerilim düşümü durumu gözönünde bulundurularak araç yerleşimi yapılmıştır.

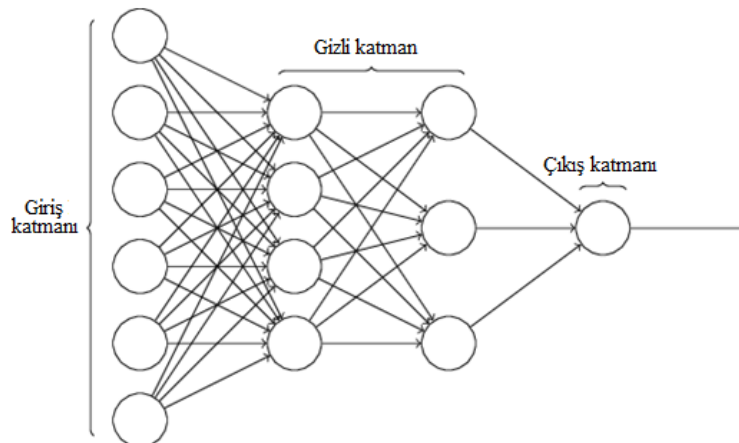
Parametre çeşitliliği ve işletme koşullarındaki değişkenlik bu problemin çözümünü karmaşık bir hale getirmektedir. Yapay zeka makinelerin karmaşık problemlere insanlar gibi çözümler üretmesini sağlama ile ilgilenen bir bilim dalıdır. Bu genellikle insan zekâsının karakteristiğini alıp, bilgisayar algoritması uygulanarak gerçekleştirilir. Talep edilen veya arzulanan ihtiyaçlara göre, hangi etkiye karşı hangi akli tavır sergilenecekse, az veya fazla esnek ya da etkili yaklaşımlar sergilenebilir. Bu çalışmada belirtilen avantajlarından dolayı yapay zeka tercih edilmiştir.

Bu çalışmada benzetim için yapay zeka uygulamalarından Yapay Sinir Ağları (YSA) ve Destek Vektör Makinaları (DVM) kullanılmıştır. YSA basit biyolojik sinir sisteminin çalışma şeklini taklit ederek çalışan bir yöntemdir. DVM sınıflandırma konusunda kullanılan oldukça etkili ve basit yöntemlerden birisidir. Sınıflandırma için bir düzlemde bulunan iki grup arasında bir sınır çizilerek iki grubu ayırmak mümkündür. Bu sınırın çizileceği yer ise iki grubun da üyelerine en uzak olan yer olmalıdır. DVM bu sınırın nasıl çizileceğini belirler. Benzetim için WEKA programı kullanılmıştır.

2.1 Yapay Sinir Ağları

Yapay Sinir Ağları, biyolojik sinir sistemi yapısından esinlenerek geliştirilmiş, ağırlıklı bağlantılar aracılığıyla birbirine bağlanan ve her biri kendi belleğine sahip işlem elemanlarından oluşan paralel bilgi işleme yapılarıdır. YSA, eğitilerek kendi kendine öğrenebilen düzeneklerdir. YSA insan doğasını araştırma ve taklit etme çabalarının en son ürünlerinden bir matematiksel yöntem olarak ortaya çıkmıştır. Bilim adamları, beynin nörofiziksel yapısını göz önüne almışlar, beynin davranışlarını tam olarak modellemeye çalışmışlardır. Yapay sinir hücresi, insan beyninin ve gerçek sinir hücrelerinin bilgi işleme teknolojilerinden esinlenerek, biyolojik sinir sisteminin çalışma şekli simüle edilmek suretiyle geliştirilmiş bir bilgi işlem teknolojisidir. İnsan beynindeki nöronlara benzer olarak, yapay nöronların değişik bağlantı geometrisi ile birbirlerine bağlanmasıyla oluşan karmaşık sistemlerdir. Modelleme için çeşitli yapay hücre ve ağ modelleri geliştirmişler. Yapay sinir ağları, hesaplama ve bilgi işleme gücünü, paralel dağılmış yapısından, öğrenebilme ve genelleme yeteneğinden almaktadır. Genelleme, eğitim ya da öğrenme sürecinde karşılaşılmayan girişler için de yapay sinir ağlarının uygun tepkileri üretmesi olarak tanımlanır. Bu özellikler, yapay sinir ağlarının problemleri çözebilme yeteneğini gösterir (Cakir, Ertunc, & Ocak, 2009), (Ozdemir, 2013), (Sahin, Buyuktumturk, & Oguz, 2013).

Biyolojik nöron, çekirdek, gövde ve iki uzantıdan oluşmaktadır. Bunlardan kısa ve dallanmış olan dentrit giriş bilgilerini alır, uzun ve tek olan akson ise çıkış bilgilerini diğer nöronlara taşır. Akson ve dentritin birleşim yerine sinaps denir. Her bir hücrenin bir eşik değeri vardır. Sinapslar nöronlardan aldığı sinyalleri değerlendirir ve eşik değeri üzerinde bir giriş varsa bir sonraki hücreye iletirler. En genel anlamda sinir ağları, insan beynindeki nöronlara benzer olarak meydana getirilen yapay nöronların değişik bağlantı geometrileri ile birbirlerine bağlanmasıyla oluşan kompleks sistemlerdir. Şekil 4 ile yapay sinir ağının yapısı verilmektedir. 1. tabaka giriş tabakasıdır. Bilgiler buradan alınır ve sisteme girilir. 2. tabaka ise gizli tabakadır. Kullanımı benzetime bağlıdır. 3. tabaka ise çıktı tabakasıdır. Girdiler işlenerek buradan alınır. Her bir yuvarlağın (sinirin) bir fonksiyonu ve eşik değeri vardır. İçi dolu ufak daireler ise bağlantı ağırlıklarını gösterirler (Bayindir, Sesveren, 2008), (Askin, Iskender, & Mamızadeh, 2011), (Dalkiran & Danisman, 2010), (Ceylan, Ozbay, Ucan, & Yildirim, 2010).



Şekil 4: Yapay sinir ağı yapısı (Bayindir, Sesveren, 2008).

Bir nöronun çıktısı giriş verilerinin belirli ağırlıklarda toplamına bias değerinin eklenmesi ile oluşan fonksiyon şeklinde (8) ile verilmektedir. I 'ler girişi göstermekte olup, W 'lar giriş değerlerinin aldığı ağırlıklı katsayılarıdır.

$$\text{Çıkış} = f(i_1W_1 + i_2W_2 + i_3W_3 + \text{bias}) \quad (8)$$


Bir sinir ağı modeli oluşturmak için nöronların bağlantı şekli, işlemci elemanlarının kullandıkları toplama ve aktivasyon fonksiyonları, öğrenme metodu, öğrenme kuralı ve algoritması belirlenmektedir. Eldeki veriye göre model tasarlanmaktadır. Kurulan modelin başarısı modelin mimarisinin doğru oluşturulması ile doğrudan ilgilidir. Bunun için yapay sinir ağı tasarımcısının, ağı yapısına ve işleyişine ilişkin aşağıdaki kararları vermesi gerekmektedir.

Levenberg Marquardt algoritması maksimum komşuluk üzerine kurulmuş en az kareler hesaplama metodudur. Bu algoritma Gauss-Newton ve gradient-descent algoritmalarının en iyi özelliklerinden oluşur ve bu iki metodun kısıtlamalarını kaldırır. Bu yöntem yavaş yakınsama probleminden etkilenmez. Gauss-Newton algoritmasının kombinasyonu olan Levenberg-Marquardt algoritması optimizasyon problemlerinde eğimli düşüş algoritmasına göre daha etkindir ve daha hızlıdır (Partal, Senol, Bakan, & Bekiroglu, 2011), (Jashfar, Esmaceli, Jahromi, & Rahmanian, 2013), (Afsharizadeh & Mohammadi, 2016).

2.2 Destek Vektör Makineleri

DVM, sınıflandırma ve regresyon problemlerinde çalıştırılan bir yöntemdir. DVM regresyon metodundaki temel fikir, eldeki eğitim verilerinin karakterini mümkün olduğunca gerçeğe yakın bir şekilde yansıtan ve istatistiksel öğrenme teorisine uyan doğrusal ayırıcı fonksiyonun bulunmasıdır. Sınıflandırmaya benzer bir şekilde regresyonda da doğrusal olmayan durumların işlenebilmesi için çekirdek fonksiyonları kullanılmaktadır. Destek Vektör Makineleri'nin en önemli avantajı, sınıflandırma problemini kareli optimizasyon problemine dönüştürüp çözmesidir. Böylece problemin çözümüne ilişkin öğrenme aşamasında işlem sayısı azalmakta ve diğer teknik/algoritmalara göre daha hızlı çözüme ulaşılmaktadır. Bu teknik özelliğinden dolayı, özellikle büyük hacimli veri setlerinde büyük avantaj sağlamaktadır. Optimizasyon temelli olduğundan sınıflandırma performansı, hesaplama karmaşıklığı ve kullanılabilirlik açısından diğer tekniklere göre daha başarılıdır (Ayhan & Erdogmus, 2014), (Yakut, Elmas, & Yavuz, 2014).

Bir destek vektör makinesi, verileri optimal olarak iki kategoriye ayıran n – boyutlu bir hiperdüzlem oluşturmaktadır. DVM modelleri yapay sinir ağlarıyla yakından ilişkili olup, sigmoid bir kernel fonksiyonu kullanan DVM; iki katmanlı, ileri beslemeli bir yapay sinir ağına sahiptir. DVM'nin ilgi çekici özelliği; veri seti üzerinde ortalama hata karesini minimize ederek türetilen ampirik risk minimizasyonu prensibinden ziyade, istatistiksel öğrenme teorisindeki yapısal risk minimizasyonu niteliğinde çalışmasıdır. DVM'nin temel varsayımlarından biri, eğitim kümesindeki tüm örneklerin bağımsız ve benzer olarak dağılmış olmasıdır. DVM, sınıflandırma ve regresyon problemlerinde çalıştırılmaktadır. Destek Vektör Makinelerinde karşılaşılabilecek iki durum, verilerin lineer olarak ayrılabilirlikleri bir yapıda olması veya lineer olarak ayrılamayan yapıda olmasıdır. (Kavzaoglu & Colkesen, 2010), (Guran, Uysal, & Dogrusoz, 2014). DVM ağ yapısı şekil 5 ile verilmektedir.



Şekil 5: Destek vektör makinesi yapısı (Ayhan & Erdogmus, 2014).

Destek Vektör Makineleri (DVM) istatistiksel öğrenme teorisine dayalı bir kontrollü sınıflandırma algoritmasıdır. DVM'nin sahip olduğu matematiksel algoritmalar başlangıçta iki sınıflı doğrusal verilerin sınıflandırılması problemi için tasarlanmış, daha sonra çok sınıflı ve doğrusal olmayan verilerin sınıflandırılması için geliştirilmiştir.

DVM regresyonu benzetim için bir takım çekirdek fonksiyonları kullanılmaktadır. Bu çalışmada normalized polynomial kernel seçilmiş olup denklemi (9) ile verilmektedir.

$$K(x, y) = \frac{\langle x, y \rangle}{\sqrt{\langle x, x \rangle \langle y, y \rangle}} \quad (9)$$

$$\langle x, y \rangle = \text{PolyKernel}(x, y) \quad (10)$$

2.2.1 Ortalama Mutlak Hata

Ortalama mutlak hata ölçülen değerlerle tahmin edilen değerler arasındaki farkın mutlak değerinin ölçüm sayısına bölünmesidir. Denklem (11) ile verilmekte olup n ölçüm sayısını, e ise gerçek değer ile tahmin edilen değer arasındaki farkı göstermektedir (Yurtcu & Ozocak, 2016), (Willmott & Matsuura, 2005), (Chai & Draxler, 2014).

$$MAE = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (11)$$

2.2.2 Karesel Ortalama Hata

Karesel ortalama hata, bir ölçü dizisinin gerçek hatalarının kareleri toplamı ölçü sayısına bölünür ve hesaplanan bu değer karekökü alınarak bulunur. Ölçülerin doğruluk derecesi hakkında en doğru yaklaşımı yapmaktadır. Bu hesaplamada hataların kareleri alındığı için ölçüm içindeki büyük hataların ortalama üzerindeki etkisi daha büyük olmakta ve bu sayede büyük hataların tüm ölçüm üzerindeki etkisi belirlenebilmektedir. (12) eşitliği ile verilen RMSE denkleminde x_{obs} gerçek değerler olup, x_{model} tahmin edilen değerler, n ise ölçüm sayısıdır (Yurtcu & Ozocak, 2016), (Willmott & Matsuura, 2005), (Chai & Draxler, 2014).

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (X_{obs,i} - X_{model,i})^2}{n}}, \quad (12)$$

3. BULGULAR

Demiryolu Cer gücü sisteminde oluşan gerilim düşümü hesaplamaları için birbirinden farklı 1000 adet veri dizisi kullanılmıştır. Bu veri dizileri kullanılarak simülasyon ile hesaplanan gerilim düşümü değerlerinin yapay zeka yöntemleri kullanılarak tahmini yapılmıştır. Kullanılan verilerden bir kısmı tablo 2 ile verilmektedir.

Tablo 2: Kullanılan verilere ait bir bölüm (1/2)


Veri türü	Besleme Yönü Sayısı	Araç Sayısı	Ma değeri (kN)	Araç Hareket Direnci (kN)	Kurp Yarıçapı (m)
giriş 1	1	5	270	69	879
çıkış 1	-	-	-	-	-
giriş 2	1	4	258	69	822
çıkış 2	-	-	-	-	-
giriş 3	2	3	295	76	931
çıkış 3	-	-	-	-	-
giriş 4	2	5	260	77	992
çıkış 4	-	-	-	-	-
giriş 5	2	3	241	74	851
çıkış 5	-	-	-	-	-

Kullanılan verilere ait bir bölüm (2/2)

Eğim	Besleme Hattının Uzunluğu (km)	Aracın İç Tüketim Akımı (A)	Katener Direnci (Ω)	Ray Direnci (Ω)	Gerilim Düşümü (V)
0,0034	1,9	236	0,0272	0,03	-
-	-	-	-	-	832
0,0168	3	236	0,0215	0,0236	-
-	-	-	-	-	897
0,0178	3,4	151	0,0154	0,0259	-
-	-	-	-	-	202
0,0303	3,1	227	0,0294	0,0347	-
-	-	-	-	-	425
0,0021	3,7	241	0,0271	0,0312	-
-	-	-	-	-	257

3.1 YSA İle Benzetim

Tablo 2 de görüldüğü gibi sistem 10 adet giriş ve 1 adet çıkış parametresinden oluşmaktadır. WEKA programı ile tasarlanan YSA mimarisi şekil 6 ile verilmektedir.



Şekil 6: Tasarlanan YSA mimarisi


Tasarımda kullanılan YSA mimarisi için 10 adet giriş verisi, 5 adet gizli nöron, 1 adet çıkış nöronu kullanılmıştır. Benzetimde 10-katlı-çapraz doğrulama yöntemi seçilmiştir.

3.1 DVM İle Benzetim


Benzetimde daha iyi sonuç almak için çeşitli varyasyon denenerek en sonunda DVM parametreleri aşağıdaki şekilde seçilmiştir. complexity parameter olan “c=1” seçilmiştir. Çekirdek fonksiyonu normalized polynomial kernel olarak seçilmiş ve exponent değeri “e=3” alınmıştır. Benzetim olarak WEKA programı kullanılmış ve 10-katlı-çapraz doğrulama yöntemi seçilmiştir.

3.3 YSA ile DVM Sonuçlarının Karşılaştırılması

Şekil 7 ile YSA simülasyon sonuçlarına ait gerçekleşen değerler ve hesaplanan değerler gösterilmektedir. R ile regresyon değeri gösterilmekte olup şekilde görüldüğü gibi bu değer 0,99 olmaktadır. Bu değer 1'e yaklaştıkça sistem tarafından hesaplanan verilerin doğruluğu artmaktadır. Şekil 8'de DVM simülasyonuna ait gerçekleşen değerler ile hesaplanan değerler görülmektedir. R ile regresyon değeri gösterilmekte olup şekilde görüldüğü gibi bu değer DVM yönteminde 0,95 olmaktadır.




Şekil 7: YSA regresyon grafiği




Şekil 8: DVM regresyon grafiği

Şekil 9 ve şekil 10 ile gerçekleşen veriler, hesaplanan veriler ve hata değerleri gösterilmektedir. Mavi renk ile gerçekleşen veriler, kırmızı renk ile hesaplanan veriler sarı renk ile de hata değerleri verilmektedir.



Şekil 9: YSA benzetimine ait çıkış, tahmin ve hata değerlerine ait grafik (Daire içine alınan bölüm defalarca büyütülerek aradaki fark gösterilmeye çalışılmıştır).



Şekil 10: DVM benzetimine ait çıkış, tahmin ve hata değerleri grafiği (Daire içine alınan bölüm defalarca büyütülerek aradaki fark gösterilmeye çalışılmıştır).

YSA ile hesaplanan değerler DVM ile hesaplanan değerlere göre daha iyi olmaktadır. Aşağıda tablo 3 ile iki yöntem ile tahmin edilen sonuçlara ait performans ölçüm değerleri verilmektedir.

Tablo 3: İki metoda ait sonuçlar

Yöntem	Korelasyon katsayısı	Ortalama mutlak hata (MAE)	Ortalama karesel hata (RMSE)	Görelî mutlak hata (RAE)	Görelî karesel hata (RRSE)	Toplam örnekleme sayısı
YSA	0.9989	12.1091	15.4955	4.7392 %	4.7916 %	1000
DVM	0.9541	49.1112	97.7306	19.2207 %	30.2211 %	1000

4. SONUÇ

Bu çalışma ile DC beslemeli bir demiryolunda cer gücünün oluşturduğu en yüksek gerilim düşümünün işletme verilerine bağlı olarak tahmini yapılmıştır. Benzetim için 1000 adet random giriş veri dizisi ile hesaplanan çıkış verileri kullanılmıştır. Yapay zeka yöntemlerinden YSA ve DVM tekniği kullanılmıştır. Gerilim düşümü değeri başarılı bir şekilde tahmin edilmiştir. YSA ve DVM teknikleri kullanılarak yapılan simülasyonlar neticesinde elde edilen veriler sayesinde demiryolu elektrifikasyon sistemine ait cer gücü simülasyonuna ait gerilim düşümü yapay zeka yoluyla tahmin edilmektedir. Bu sayede sisteme ait değişkenler farklı olsa da yeni duruma ait sonuçlar tahmin yoluyla elde edilerek tekrar tekrar benzetim yapılmasının önüne geçilmektedir.

Yapılan hesaplamalarda DVM için elde edilen verilerde RRSE değeri %30,2 olup bu değer YSA'de %4,8 olmaktadır. RMSE değerleri ise YSA benzetimi için 15 V olup DVM için 98 V olmaktadır. YSA'de elde edilen MAE değeri ise 12 V olup DVM'de bu 49 V olmaktadır. YSA'de RAE değeri %4,7 olup bu değer DVM'de %19,2 olmaktadır. Benzetimlerden elde edilen veriler karşılaştırıldığında YSA ile üretilen tahmin değerlerinin daha iyi olduğu görülmektedir. İki teknik için de üretilen tahmin verileri gerçek verilerle karşılaştırıldığında hataların YSA tekniği için kabul edilebilir oranda olduğu ve üretilen tahmin verilerinin kullanılabilir olduğu görülmektedir.

Tasarlanan sistem ile %95 üzeri başarı oranı elde edilmiştir. Bu sayede sisteme ait girdiler değişse bile sistem çıktıları tahmin edilerek sistem davranışı hakkında öngörüle bulunularak ek cer merkezlerini devreye alınması, araç sayısında kısıtlama, sefer sıklığı düzenleme gibi bir takım gerekli tedbirlerin alınması sağlanacaktır.

REFERANSLAR

IEEE, Limbong, F., G., 2016. The use of neural network (NN) to predict voltage drop during starting of medium voltage induction motor. 3rd International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE), Semarang, Indonesia.

- IEEE, Nuzzo, S., Galea, M., Gerada, C., Brown, N., L., 2016. Prediction of the voltage drop due to the diode commutation process in the excitation system of salient-pole synchronous generators. 19th International Conference on Electrical Machines and Systems (ICEMS), Chiba, Japan
- Ibrahim, A., Elrayyah, A., Sozer, Y., Garcia, J., A., A., 2017. DC Railway System Emulator for Stray Current and Touch Voltage Prediction. IEEE Transactions on Industry Applications, 53, pp. 439-446.
- IEEE, Meghwani, A., Chakrabarti, S., Srivastava, S., C., 2016. A fast scheme for fault detection in DC microgrid based on voltage prediction. National Power Systems Conference (NPSC), Bhubaneswar, India
- Abrahamsson, L., Kjellqvist, T., Ostlund, S., 2012. High-voltage DC-feeder solution for electric railways. IET Power Electronics, 5, pp. 1776-1784.
- Afsharizadeh, M., Mohammadi, M., 2016. Prediction-Based Reversible Image Watermarking Using Artificial Neural Networks. Turk J Elec Eng & Comp Sci., 24, pp. 896-910.
- Alamuti, M., M., Nouri, H., Jamali, S., 2011. Effects of earthing systems on stray current for corrosion and safety behaviour in practical metro systems. IET Electrical Systems in Transportation, 1, pp. 69-79.
- Askin, D., Iskender, I., Mamizadeh, A., 2011. Dry Type Transformer Winding Thermal Analysis Using Different Neural Network Methods. Journal of the Faculty of Engineering and Architecture of Gazi University, 26, pp. 905-913.
- Ayhan, S., Erdogmus, S., 2014. Kernel Function Selection for the Solution of Classification Problems via Support Vector Machines. Eskisehir Osmangazi University Journal of IIBF, 9, pp. 175-198.
- Bayindir, R., Sesveren, Ö., 2008. Design Of A Visual Interface For Ann Based Systems. Pamukkale University Engineering Faculty Journal of Engineering Science, 14, pp. 101-109.
- Cakir, S., Ertunc, H., M., Ocak, H., 2009. A Case Study For Identification of Texture in Carbonate Rocks Using Artificial Neural Networks: Akveren Formation. Journal of Earth Science With Application, 2, pp. 71-79.
- Ceylan, M., Ozbay, Y., Ucan, O., N., Yildirim, E., 2010. A Novel Method For Lung Segmentation On Chest CT Images: Complex-Valued Artificial Neural Network With Complex Wavelet Transform. Turk J Elec Eng & Comp Sci, 18, pp. 613-623.
- Chai, T., Draxler, R., R., 2014. Root Mean Square Error (RMSE) Or Mean Absolute Error (MAE), Geoscientific Model Development Discussions, 7, pp. 1247-1250.
- Dalkiran, İ., Danisman, K., 2010. Artificial Neural Network Based Chaotic Generator For Cryptology. Turk J Elec Eng & Comp Sci, 18, pp. 225-240.
- Guran, A., Uysal, M., Dogrusoz, O., 2014. Effects Of Support Vector Machines Parameter Optimization On Sentiment Anaylsis. DEÜ Engineering Faculty The Journal of Engineering Sciences, 16, pp. 86-93.
- He, J., Yu, L., Wang, X., Song, X., 2013. Simulation of Transient Skin Effect of DC Railway System Based on MATLAB/Simulink. IEEE Transactions On Power Delivery, 28, pp. 145-152.
- IEEE, Calderaro, V., Galdi, V., Graber, G., Piccolo, A., Capasso, A., Lamedica, R., Ruvio, A., 2015, November. Energy Management of Auxiliary Battery Substation Supporting High-Speed Train on 3 kV DC Systems. Renewable Energy Research and Applications (Icrera), Palermo, Italy.
- IEEE, Jia, Z., Yang, Z., Lin, F., Fang, X., 2014, September. Dynamic Simulation of the DC Traction Power System Considering Energy Storage Devices. Transportation Electrification Asia-Pacific (ITEC Asia-Pacific), Beijing, China.
- IEEE, Tian, Z., Hillmansen, S., Roberts, C., Weston, P., Chen, L., Zhao, N., Su, S., Xin, T. 2014, October. Modeling and Simulation of DC Rail Traction Systems for Energy Saving. 17th International Conference on Intelligent Transportation Systems (ITSC), Qingdao, China.
- Jashfar, S., Esmaeili, S., Jahromi, M., Z., Rahmaniyan, M., 2013. Classification of Power Quality Disturbances Using S-Transform And TT-Transform Based On The Artificial Neural Network. Turk J Elec Eng & Comp Sci., 21, pp. 1528-1538.
- Jung, S., Lee, H., Song, C., S., Han, J., H., Han, W., K., Jang, G., 2013. Optimal Operation Plan of the Online Electric Vehicle System Through Establishment of a DC Distribution System. IEEE Transactions On Power Electronics, 28, pp. 5878-5889.

- Kavzaoglu, T., Colkesen, I., 2010. Investigation of the Effects of Kernel Functions in Satellite Image Classification Using Support Vector Machines. *Gebze High Technology Institute The Journal of Map*, 144, pp. 73-82.
- Lao, K., W., Wong, M., C., Dai, N., Y., Liu, W., G., Wong, M., C., 2013. Hybrid Power Quality Compensator With Minimum DC Operation Voltage Design for High-Speed Traction Power Systems. *IEEE Transactions On Power Electronics*, 28, pp. 2024-2036.
- Lao, K., W., Wong, M., C., Dai, N., Y., Wong, C., K., Lam, C., S., 2016. Analysis of DC-Link Operation Voltage of a Hybrid Railway Power Quality Conditioner and Its PQ Compensation Capability in High-Speed Cophase Traction Power Supply. *IEEE Transactions On Power Electronics*, 31, pp. 1643-1656.
- Ogunsola, A., Sandrolini, L., Mariscotti, A., 2015. Evaluation of Stray Current From a DC Electrified Railway With Integrated Electric–Electromechanical Modeling and Traffic Simulation. *IEEE Transactions On Industry Applications*, 51, pp. 5431-5441.
- Ozdemir, H., 2013. Artificial Neural Networks and Their Usage in Weaving Technology. *Electronic Journal of Textile Technologies*, 7, pp. 51-68.
- Park, J., D., 2015. Ground Fault Detection And Location For Ungrounded DC Traction Power Systems. *IEEE Transactions on Vehicular Technology*, 64, pp. 5667-5676.
- Partal, S., Senol, İ., Bakan, A., F., Bekiroglu, K., N., 2011. Online Speed Control of a Brushless AC Servomotor Based On Artificial Neural Networks. *Turk J Elec Eng & Comp Sci.*, 19, pp. 373-383.
- Sahin, M., Buyuktumturk, F., Oguz, Y., 2013. Light Quality Control with Artificial Neural Networks. *Afyon Kocatepe University Journal of Science and Engineering*, 13, pp. 1-10.
- Smidl, V., Janous, S., Peroutka, Z., 2015. Improved Stability of DC Catenary Fed Traction Drives Using Two-Stage Predictive Control. *IEEE Transactions On Industrial Electronics*, 62, pp. 3192-3201.
- Takagi, R., 2012. Preliminary evaluation of the energy-saving effects of the introduction of superconducting cables in the power feeding network for DC electric railways using the multi-train power network simulator. *IET Electrical Systems in Transportation*, 2, pp. 103-109.
- Takagi, R., Amano, T., 2014. Optimisation of reference state-of-charge curves for the feed-forward charge/discharge control of energy storage systems on-board DC electric railway vehicles. *IET Electrical Systems in Transportation*, 5, pp. 33-42.
- Torreglosa, J., P., García, P., Fernández, L., M., 2014. Predictive Control for the Energy Management of a Fuel-Cell–Battery–Supercapacitor Tramway. *IEEE Transactions On Industrial Informatics*, 10, pp. 276-285.
- Tzeng, Y., S., Lee, C., H., 2010. Analysis of Rail Potential and Stray Currents in a Direct Current Transit System. *IEEE Transactions On Power Delivery*, 25, pp. 1516-1525.
- Wang, W., Cheng, M., Wang, Y., Zhang, B., Zhu, Y., Ding, S., Chen, W., 2014. A Novel Energy Management Strategy of Onboard Supercapacitor for Subway Applications With Permanent-Magnet Traction System. *IEEE Transactions On Power Electronics*, 63, pp. 2578-2588.
- Willmott, C., J., Matsuura, C., 2005. Advantages Of The Mean Absolute Error (MAE) Over The Root Mean Square Error (RMSE) In Assessing Average Model Performance, *Climate Research*, 30, pp. 79-82.
- Xu, S., Y., Li, W., Wang, Y., Q., 2013. Effects of Vehicle Running Mode on Rail Potential and Stray Current in DC Mass Transit Systems. *IEEE Transactions On Vehicular Technology*, 62, pp. 3569-3580.
- Yakut, E., Elmas, B., Yavuz, S., 2014. Predicting Stock-Exchange Index Using Methods Of Neural Networks And Support Vector Machines. *Suleyman Demirel University The Journal of Faculty of Economics and Administrative Sciences*, 19, pp. 139-157.
- Yurtcu, S., Ozocak, A., 2016. Prediction Of Compression Index Of Fine-Grained Soils Using Statistical And Artificial Intelligence Methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 31, pp. 597-608.