

Güç Sistemlerinde Geçici Hal Kararsızlığının Ağaç Tabanlı Makine Öğrenmesi Yöntemleri ile Erken Tespiti

Early Prediction of Transient Instabilities in Power Systems Using Tree Based Machine Learning Techniques

Mert Kesici¹, Can Berk Saner¹, Mohammed Mahdi¹, Yusuf Yaslan², V. M. İstemihan Genç¹

¹Istanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi / Elektrik Mühendisliği Bölümü
kesicim16@itu.edu.tr, sanerc@itu.edu.tr, mahdi@itu.edu.tr, gencis@itu.edu.tr

²Istanbul Teknik Üniversitesi, Elektrik-Elektronik Fakültesi / Bilgisayar Mühendisliği Bölümü
yyaslan@itu.edu.tr

Özet

Elektrik güç sistemlerinde sistem güvenliğini tehdit eden kritik arızalar sonrasında oluşan geçici hal kararsızlıkları, hızla gelişen geniş çaplı sistem çökmelerine neden olabilmektedir. Bu çalışmada, arıza giderildikten sonra oluşabilecek geçici hal kararsızlığının erken tespit edilebilmesi için karar ağaçları ve rastgele ağaçlar algoritmaları kullanılmıştır. Rastgele orman algoritması ile önceki çalışmamızda kullanılan, yığınlı seyrek oto kodlayıcı ve çok katmanlı algılayıcılara göre hem doğruluk oranı hem de çevrimdışı eğitim süresi olarak daha iyi sonuçlar elde edilmiştir. Önerilen makine öğrenmesi modellerinin başarımları ve etkinlikleri 29 jeneratörlü 127 baralı Batı Eyaletleri Koordinasyon Kurulu (Western States Coordination Council – WSCC) test sisteminde uygulanarak gösterilmiştir.

Anahtar kelimeler: Karar ağaçları, geçici hal kararlılığı, sınıflandırma, tahmin, fazör ölçüm birimleri

Abstract

Catastrophic faults that lead to transient instability in electrical power systems may trigger fast evolving widespread outages such as blackouts. In this study, decision tree based machine learning algorithms are used to predict the transient instabilities. The success and the effectiveness of the proposed machine learning models are demonstrated as it is applied to the 127-bus WSCC test system. With the random forest algorithm, better results are obtained both in terms of accuracy and offline training time compared to multilayer perceptron and stacked sparse autoencoder which are used in our previous study.

Keywords: Decision tree, transient stability, classification, prediction, phasor measurement units

1. Giriş

Güç sistemleri, depremler, kasırgalar, insan kaynaklı işletme hataları, kontrol sistemi arızaları, koruma sisteminde tespit edilemeyen arızalar, kasıtlı saldırılar, zayıf bağlantılar gibi çeşitli sorunlara maruz kalmakta ve kararlılığın bozulmasına, hatta enerji kesintilerine yol açabilecek birçok diğer etkeni bünyesinde barındırmaktadır. Güç sisteminde ciddi bir arıza meydana geldiğinde, oluşturduğu etkiler, şebekenin enterkonnekte yapısından dolayı, sistemde yayılabilir ve güç sisteminin büyük bir kısmının kararlılığını tehlikeye atarak geniş çapta bir enerji kesintisine yol açabilir. Son birkaç on yıllık zaman zarfında, dünya genelindeki farklı şebekelerde, birbirine benzer sebeplerle birçok geniş çaplı enerji kesintisi meydana gelmiş, bu kesintiler milyonlarca tüketiciyi olumsuz etkilemiş ve ciddi miktarda mali zararlara sebep olmuştur. Türkiye’de Mart 2015’te meydana gelen geniş çaplı enerji kesintisi de bu tür sistem çökmelerine örnek olarak verilebilir. Oldukça yüklenmiş bir 400 kV’luk iletim hattının planlı bir bakım sebebiyle devreden çıkarılmasının sebep olduğu bu sorun, 76 milyon tüketiciyi 9 saatten uzun bir süre boyunca elektriksiz bırakmıştır. Başlangıçta, bu hattın devreden çıkarılması, Türkiye elektrik şebekesinin batı ve doğu kısımlarının birbirinde ayrılmasına sebep olmuştur. Sonrasında, Türkiye elektrik şebekesinin Avrupa şebekesi ile bağlantısı kesilmiş ve doğu ile batı kısımları, kararlılıklarını kaybederek çökmüştür.

Sistemin kararlılığını kaybederek felaket boyutunda arızalara ve enerji kesintilerine sebep olabilecek olayların önlenmesi için kapsamlı şebeke izleme ve kontrol yöntemlerinin tasarlanmasına duyulan ihtiyaç gün geçtikçe artmaktadır. Buna yönelik olarak, güç sisteminin durumsal farkındalık kabiliyetlerinin iyileştirilmesi gerekmektedir. Son yıllarda fazör ölçme biriminin (FÖB) hızla gelişmesi, güç sistemi operatörlerine sistemi izleme, koruma, işletme ve kontrol etme gibi uygulamalarda FÖB kullanma esnekliği

sağlamıştır. FÖB'ler güç sisteminde durumsal farkındalığın geleceği için en önemli teknoloji olarak kabul edilmektedir. FÖB'lerin ölçümleri, belirli bir zaman dilimine senkronize oldukları için, sistem işletmecilerinin tüm şebekenin gerçek zamanlı isabetli bir görünümünü oluşturmalarına yardımcı olabilmektedir.

Türbinlerin hızlı valf kontrolü, dinamik frenleme, manyetik enerji depolama sistemlerinin kullanımı, sistemi adalara ayırma, üretim ve yük atımı gibi acil durum kontrol yöntemleri, art arda meydana gelen sistem arızalarının etkilerini azaltmak için kullanılmaktadır. Yukarıda belirtilen kontrol eylemlerinin etkinliği, geçici hal kararsızlığının erken tespiti ile geliştirilebilmektedir. Bu kapsamda, araştırmacılar bir dizi çalışma ortaya koymuştur.

Geçici hal kararlılığının erken tespiti için literatürde çeşitli çalışmalar önerilmiştir. [1]'de yapılan çalışmada, güç sisteminin doğrusal olmayan diferansiyel denklemler modelini çözerek geçici hal kararsızlığının tahmini için bir zaman alanı (time domain) simülatörü önerilmiştir. Bu amaç doğrultusunda zaman alanı simülasyonlarının kullanımı, kararsızlıkların tespiti açısından doğruluğu yüksek bir yaklaşım olarak kabul edilebilir. Buna karşın, zaman alanında yapılan bu ve benzeri çalışmalar [2]-[4] için gerekli sistem parametrelerinin arıza öncesi, sırası ve sonrasında tam olarak bilinmesi, gerçek zamanda gerçekleşmesi her zaman kolay olmayan bir gereksinimdir. Güç sisteminin kararlılık durumu makine öğrenmesi yöntemleri yardımıyla da erken tespit edilebilmektedir. [5]'te önerilen çalışmada, örüntü tanıma kullanarak hızlı bir geçici hal kararlılığı tahmin yöntemi önerilmiştir. Bu yöntemde, çeşitli arızalar sonrası oluşan sistem dinamikleri için benzetim yapılarak rotor açısı yörüngelerinden oluşan kapsamlı bir veri tabanı oluşturulmuştur. Gerçek zamanlı olarak FÖB'lerden alınan rotor açısı bilgisi ve eğri uyurma tabanlı bir yöntem kullanılarak rotor açısının yörüngesi ve sistemin kararlılık durumu tahmin edilmiştir. [6]'da yapılan çalışmada, geçici hal kararlılık analizi için veri madenciliğine dayalı bir çerçeve oluşturulmuştur. Burada geçici hal kararsızlığının erken tespitine ilişkin doğruluğun ve güvenilirliğin artırılması için destek vektör makinesi (SVM) ve torbalama (bagging) algoritmaları kullanılmıştır. Bu çalışmalara ilave olarak yapay sinir ağları [7]-[10] ve karar ağaçlarının [11] kullanıldığı benzer çalışmalar da literatürde mevcuttur. Bu çalışmalar kapsamında, derin öğrenme algoritmalarının ve arıza öncesi, sırası ve sonrası bara gerilimleri yörüngelerinden seçilen noktaların kullanımlarının önerildiği yeni bir çalışmamız [12], ilgili literatürde ayrıca yer almaktadır.

Bu makalede sunulan çalışmada, önceki çalışmamıza [12] paralel olarak, geçici hal kararsızlıklarının, karar ağacı ve rastgele orman algoritmaları yardımıyla erken tespit edilmesi önerilmektedir. Ele alınan makine öğrenmesi modellerinin doğrulukları ve etkinlikleri [12]'de elde edilen sonuçlar ile karşılaştırılmış, aynı zamanda, makine öğrenmesi modellerinde girdi olarak

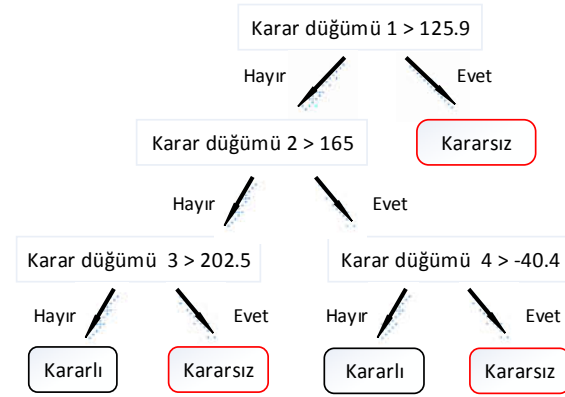
kullanılan arıza sırası ve sonrası FÖB gerilim ölçümlerinin, modellerin doğruluklarına olan etkileri incelenmiş ve tartışılmıştır.

2. Karar ağacı tabanlı sınıflandırma

2.1. Karar Ağaçları

Karar ağaçları, veri tabanı sistemleri ile kolayca entegre edilebilmeleri, yorumlanmalarının kolay olmasından dolayı sınıflama algoritmaları içerisinde en yaygın kullanıma sahip olan yöntemlerden biridir. Karar ağaçları aynı zamanda, çeşitli disiplinlerde, geniş yelpazedeki görevlere başarıyla uygulanan bir sınıflandırıcı türüdür. Karar ağaçlarında eğitimin amacı, diğer veri madenciliği tekniklerine benzer şekilde, hem gözlemleri hem de ilgili kararları içeren bir eğitim veri kümesi temelinde yeni bir gözlemi bir kararla eşleştirebilen bir tahmin modeli oluşturmaktır [13].

Karar ağacı böl ve yönet yaklaşımını gerçekleyen hiyerarşik bir yapıya sahiptir. Şekil 1'de görüldüğü gibi karar ağaçları iç karar düğümleri ve uç yapraklardan oluşmaktadır. Her karar düğümü, kesikli değeri dallara karşılık gelen bir denetim işlevi gerçekleştirmektedir. Bir girdi için her düğümde denetim işlevi uygulanır ve sonuca göre dallardan biri seçilir. Bu süreç kökte başlar ve bir yaprak düğümüne gelene dek özçağrılı (recursively) olarak devam eder; yaprakta yazılı değer çıktıyı oluşturmaktadır [14].



Şekil 1 Örnek bir karar ağacı modeli

Karar ağacı, verinin dağılımından bağımsızdır ve ağaç yapısı en baştan sabit değildir, verinin altında yatan işlevin karmaşıklığına göre dallar ve yapraklar eklenerek ağaç büyümektedir.

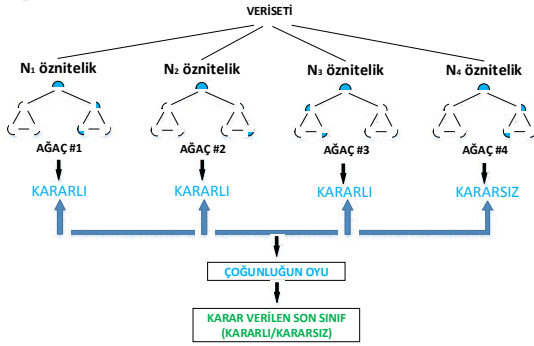
2.2. Rastgele Orman Algoritması

Rastgele orman algoritması bir topluluk (ensemble) öğrenme algoritmasıdır. Bu yöntemin temelinde yine karar ağaçları vardır. Tekil olarak oluşturulan karar ağaçları birleşerek karar ormanını oluştururlar ve ağaçların yapmış olduğu tahminler bir araya getirilerek nihai tahmin yapılmaktadır [15].

Rastgele orman yöntemi, torbalama (bagging) ve rastgele altküme (random subspace) tekniklerinin birleştirilmesi ile elde edilmiştir. Torbalama yöntemi ile girdi verilerinden bağımsız, zorlama (bootstrap) tekniği ile örneklem oluşturulur. Rastgele altküme yönteminde ise karar ağacına ait her bir düğümde en iyi dallara ayrılan değişken, tüm değişkenler arasından rastgele seçilen az sayıdaki değişkenin içinden seçilir [16].

Girdi verisinin her biri bu karar ağaçlarının hepsinden geçirilmektedir. Karar ağaçları ile girdi verinin her bir elemanı sınıflandırılmaktadır. Şekil 2'de görüleceği gibi her bir girdi verisi bütün karar ağaçlarına girip oylandıktan sonra ağaç yapılarından çıkan sonuçlardan en fazla oyu alan sınıfa atamalar yapılmaktadır.

Bu şekilde rastgele tahminci seçmenin avantajı, topluluktaki ağaçlar arasında daha az korelasyon elde edildiği için oluşan modelin doğruluğu daha yüksektir [17].



Şekil 2 Rastgele ağaçlar algoritması çalışma prensibi

3. Geçici hal kararsızlığının erken tespiti için önerilen yöntem

Bu çalışmada, daha önceki çalışmamızda [12] geçici hal kararlılığının erken tespiti için arıza öncesi, sırası ve sonrası ölçümlerden seçilmiş özel noktalara dayalı çok katmanlı algılayıcı ve derin öğrenme algoritması (seyrek oto kodlayıcı) uygulamalarına paralel olarak, benzer bir yaklaşımın, karar ağaçları ve rastgele orman algoritmaları aracılığıyla gerçekleştirilmesi sağlanmış ve elde edilen makine öğrenmesi modellerinin doğrulukları karşılaştırılmıştır.

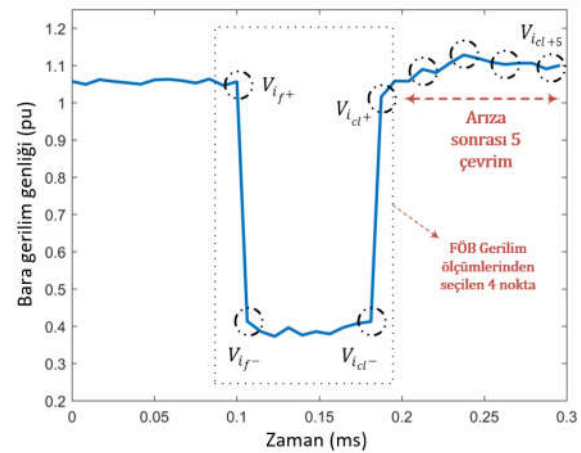
Önerilen arıza sonrası geçici hal kararsızlıklarının erken tespiti yöntemi, iki aşamadan oluşmaktadır: ilk aşamada, önceden oluşturulmuş olan veri kümesi ile makine öğrenmesi modelleri eğitilir ve ikinci aşamada ise eğitilen modeller çevrimiçi erken tespit için kullanılır. Makine öğrenmesi algoritmalarının eğitilmesinin amacı, arızanın temizlenmesinden sonra sistemin kararlı ya da kararsız olacağına dair bir kestirimin ele edilmesidir. Eğitim sırasında, modele giriş olarak uygulanan FÖB gerilim ölçümleri ile sistemin bu değerlere karşılık gelen kararlılık durumu arasındaki ilişki makine öğrenmesi modelleri tarafından öğrenilecek ve çevrimiçi uygulama için hazır olacaktır. Çevrimiçi uygulamada, sistemde kritik bir arızanın giderildiğinin tespit edilmesinin ardından, sistemden alınan arıza öncesi, sırası ve sonrası

gerilim ölçümleri, makine öğrenmesi modellerine girdi olarak verilecektir.

3.1. Veri kümesinin üretilmesi

Veri kümesi, güç sisteminin dinamik modeline uygulanan zaman alanlı simülasyonlar kullanılarak oluşturulmuştur. Veri kümesi, sistemdeki farklı konumlarda meydana gelen ve olası herhangi bir durum için makine öğrenmesi modellerini eğitmek ve güç sisteminin çalışma koşullarındaki değişikliklere karşı toleranslı hale getirmek için sistemdeki farklı durumlara ilişkin yanıtı içermektedir.

Veri kümesi, temel bir durumdan başlanarak, çok çeşitli farklı çalışma koşulları ve güç sisteminin işletilebileceği olası sistem topolojilerini kapsayan çok sayıda çalışma noktası üretilir. Veri kümesinin oluşturulması sırasında göz önünde bulundurulmuş olan sistem topolojileri, toplanan tarihsel verilere dayanarak, iletim hatlarının ve jeneratörlerinin planlı kesintileri nedeniyle olası sistem konfigürasyonlarını kapsamaktadır. Bu şartların sağlandığı, sistemin istenen güvenlik seviyesine uyan, kararlı durumlar (steady-state), yük akışı çözümlerinde elde edilir. Oluşturulan yakınsamış çalışma koşullarının her biri, herhangi bir kararlı durum güvenliğini ihlal etmemelidir. Daha sonra, güç sisteminin dinamik modeli kullanılarak, güvenilir koşullar altında sistemin zaman alan simülasyonları gerçekleştirilir. Bu çalışmada ele alınan arızalar, arızanın türüne, konumuna ve temizlenme sürelerine göre değişmektedir. Arıza türleri olarak, tek-faz-toprak, iki-faz-toprak ve üç-faz arızalarıdır. Arızalar bağlı olan ilgili hat açılarak giderilmektedir. Dikkate alınan arızalar 4-12 çevrim arasında değişen farklı sürelerde temizlenirler.



Şekil 3 Arıza sırası ve sonrasında alınan bir FÖB gerilim ölçümünün gösterimi

2 farklı veri kümesi içeren bu çalışmada, ilk olarak sistemin kararsızlığı ile ilgili bilgi verdiği tespit edilen FÖB gerilim yörüngesinden alınan dört nokta kullanılmıştır. Arıza öncesi FÖB gerilim ölçümü olan V_{if-} arıza öncesi sistemin çalışma durumunu, V_{if+} , arızanın yerini, arıza temizlenmeden hemen önceki gerilim ölçümü V_{ict-} , V_{if+} ile birlikte arızanın süresini, son

olarak $V_{i_{ct+}}$ ise arıza sonrası çalışma durumunu temsil etmektedir. İkinci veri kümesi olarak kullanılan arıza sonrası FÖB gerilim ölçümleri ise arıza temizlendikten sonra $V_{i_{ct+}}$ ile başlayarak beş çevrim boyunca sürmektedir. Şekil 3'te FÖB gerilim ölçümlerinden seçilen dört nokta ve arıza sonrası beş çevrim boyunca alınan gerilim ölçümleri temsili olarak gösterilmiştir.

3.2. Makine öğrenmesi algoritmalarının eğitilmesi

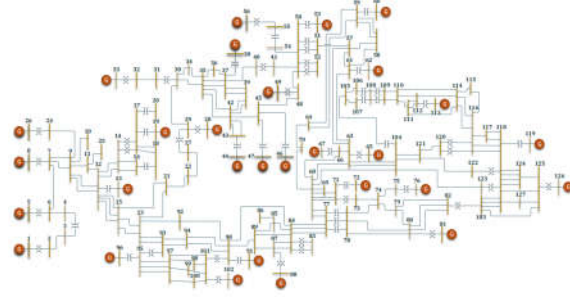
Karar ağacı ve rastgele orman algoritmalarının iyi bir şekilde eğitilmesi ve çevrimiçi uygulamada en iyi doğrulukla karar verebilmeleri için algoritmaların en iyi parametreleri rastgele arama (randomized search) yöntemi kullanılarak belirlenmiştir. Rastgele arama yöntemi ile veri kümesinin %90'ı eğitim, %10'u ise test verisi olarak ayrılmıştır. En iyi parametreler eğitim kümesi kullanılarak, algoritmaların performansları ise test kümesi üzerinden elde edilen doğruluk değerleri karşılaştırılarak elde edilmiştir. Makine öğrenmesi modellerinden karar ağaçları ve rastgele orman algoritmalarının eğitimleri, Intel i7-6700 @3.40 GHz ve 8 GB RAM'e sahip bilgisayarda gerçekleştirilmiştir. Önceki çalışmamızda [12] eğitilen yığınlı seyrek oto kodlayıcı ve çok katmanlı algılayıcı algoritmaları ise Intel XEON W-2123 @3.6 GHz ve 36GB RAM'e sahip bilgisayarda eğitilmişlerdir.

3.3. Önerilen yöntemin çevrimiçi uygulaması

Kabul edilebilir bir doğruluk düzeyi elde edilene kadar, önceden oluşturulmuş veri kümesi kullanılarak makine öğrenmesi modelleri eğitildikten sonra, eğitilen makine öğrenmesi modelleri daha sonra güç sistemindeki çevrimiçi uygulamalar için kullanılabilir duruma gelmektedirler. Çevrimiçi uygulama için, veri kümesinden ayrılan ve makine öğrenmesi algoritmalarının eğitimi sırasında görmediği test kümesi kullanılmıştır.

4. Simülasyon sonuçları

Makine öğrenmesi modellerini eğitmek ve test etmek için ihtiyaç duyulan veri kümeleri TSAT güç sistemi analiz programı [18] kullanılarak oluşturulmuştur. Önerilen arıza sonrası geçici hal kararlılığının erken tespiti yöntemlerinin performansı, 37 jeneratörlü ve 127 baralı test sisteminde gösterilmiştir. Test sistemi, Batı Devletleri Koordinasyon Konseyi (WSCC) güç sisteminin basitleştirilmiş bir eşdeğer modelidir. Test sisteminin tek hat diyagramı, Şekil 5'te gösterilmektedir. Önerilen sistemdeki baraların %25'inin FÖB'e sahip olduğu ve bunlardan da bir çoğunun generator barası yada generatör barasına yakın baralar olduğu varsayılmıştır. Bu test sistemi için olası yük profillerini ve sistem topolojisi temsil edebilmek adına 50 farklı çalışma noktası üretilmiştir.



Şekil 4 127 baralı WSCC test sisteminin tek hat şeması

[12]'de yapılan çalışmada çok katmanlı algılayıcı (ÇKA) ve derin öğrenme algoritmalarından biri olan yığınlı seyrek oto kodlayıcı (YSOK) kullanılmıştır. Bu çalışmada sırası ile karar ağaçları ve rastgele orman algoritmalarının performansları ve FÖB'e dayalı üretilen iki farklı veri kümesinin algoritmalar üzerindeki etkisi incelenmiştir.

Tablo 1 Makine öğrenmesi algoritmalarının test kümesi üzerindeki doğruluklarının karşılaştırılması


Arıza sonrası ölçümler (5 çevrim FÖB gerilim ölçümü)			
Karar Ağaçları	Rastgele Orman	ÇKA	YSOK
%99.20	%99.83	99%	%99.2

Arıza sırası ölçümler (dört nokta FÖB gerilim ölçümü)			
Karar Ağaçları	Rastgele Orman	ÇKA	YSOK
%98.98	%99.53	%98.3	%99.5


Tablo 2 Makine öğrenmesi modellerinin test kümesi üzerindeki eğitim sürelerinin karşılaştırılması

Eğitim Süreleri			
Arıza sonrası ölçümler			
Karar Ağaçları	Rastgele Orman	ÇKA	YSOK
4.43 s	11.86 s	10.2 dk	75 dk
Arıza sırası ölçümler			
Karar Ağaçları	Rastgele Orman	ÇKA	YSOK
2 s	2 dk	5.4 dk	30 dk


Tablo 1'de verilen sonuçlar incelendiğinde, bu çalışmada uygulanan rastgele orman algoritmasının arıza sonrası gerilim ölçümleri kullanarak daha iyi sonuç verdiği görülmektedir. Kullanılan veri kümesindeki çalışma noktalarında, kararlı durumların sayısının (23,630) kararsız durumlardan (5890) sayıca çok fazla olması, veri kümesini dengesiz yapmaktadır. Dengesiz bir veri kümesinde, doğruluğun sadece tablo 1'de verilen şekilde toplam doğru tahmin edilen durumların, toplam durumlara oranı şeklinde hesaplanması sağlıklı sonuçlar vermemektedir. Bu sebeple bahsedilen makine öğrenmesi algoritmalarından en iyi performans gösteren YSOK ve Rastgele orman modellerine ait hata matrisleri (confusion matrix) şekil 5, şekil 6 ve Şekil 7'de sırasıyla verilmiştir.



Şekil 5 YSOK'nun, FÖB gerilim ölçümlerinden seçilen 4 nokta ile oluşturulan test ve tüm (test + eğitim) küme için hata matrisleri



Şekil 6 Rastgele orman algoritmasının, FÖB gerilim ölçümlerinden seçilen 4 nokta ile oluşturulan test ve tüm (test + eğitim) küme için hata matrisleri



Şekil 7 Rastgele orman algoritmasının, FÖB gerilim ölçümlerinden arıza sonrası 5 çevrim alınarak oluşturulan test ve tüm (test + eğitim) küme için hata matrisleri

Acil durumlar altında yanlış kararlar, istenmeyen sonuçlara neden olabilmektedir. Kararlı durumları kararsız olarak tahmin etmek gereksiz kontrol eylemlerini tetikleyecektir fakat kararsız durumları kararlı olarak tahmin etmek ise kontrolsüzlüğe veya kontrol aksiyonunun gecikmesine ve sonuçta sistemin kararsızlığına yol açacaktır. Bu sebeple hata matrisinde verilen kararsız durumların kararlı olarak tahmin edilmesi, daha riskli bir durum oluşturmaktadır.

Şekil 5, Şekil 6 ve Şekil 7'deki hata matrisleri incelendiğinde, YSOK algoritması tüm veri kümesinde 5890 adet kararsız çalışma noktasından 114 adet kararsız çalışma durumunu kararlı olarak tahmin ederken, rastgele orman algoritması bu sayıyı aynı veri kümesini kullanarak 28'e, arıza sonrası alınan beş çevrim ölçümü kullandığında ise 10'a düşürmektedir. YSOK tarafından kararsız olarak tahmin edilen kararlı çalışma noktalarının sayısı ise arıza sonrası veri kümesi kullanıldığında 12'ye, arıza sonrası ölçümler kullanıldığında ise 4'e

düşürülmüştür. Genel doğruluk oranlarına bakıldığında ise, YSOK yerine rastgele orman algoritması kullanıldığında arıza sonrası veri kümesi ile doğruluk oranı %99.5'ten %99.53'e, arıza sonrası ölçümler ile de doğruluk oranı %99.2'den %99.83'e yükseltilmiştir.

Tablo 2'de incelendiğinde, daha hızlı bir bilgisayarda eğitilmelerine rağmen YSOK ve ÇKA'nın eğitim süreleri dakikalar mertebesinde iken, karar ağaçları ve rastgele orman algoritmaları maksimum iki dakika içerisinde eğitimlerini tamamlamaktadır. Veri kümesinin güncellenmesi gerektiği zamanlarda, bu çalışmada önerilen algoritmalar çok daha hızlı bir şekilde tekrardan eğitilebileceklerdir.

5. Sonuçlar

Bu çalışmada, ağaç tabanlı iki farklı makine öğrenmesi modeli, arıza sonrası geçici hal kararlılığının erken tespiti probleminde uygulanmış ve daha önceki çalışmalarımızda uygulanan çok katmanlı algılayıcı ve yığınlı seyrek oto kodlayıcı algoritmalarının doğrulukları ile karşılaştırılmıştır. Rastgele orman algoritması kullanılan her iki veri kümesinde de diğer algoritmalara hem doğruluk oranı hem de eğitim süresi açısından üstünlük sağlamıştır. Ayrıca fazör ölçüm biriminden alınan arıza sonrası gerilim ölçümlerinin, arıza sonrasında alınan ölçümlere göre, rastgele orman algoritmasının doğruluğunu arttırdığı görülmüştür. Arıza sonrası alınacak olan FÖB gerilim ölçümleri ile geçici hal kararlılığının erken tespitinin çevrimiçi olarak başarı ile gerçekleştirilebileceği, 127 baralılı WSCC sisteminde gösterilmiştir.

Teşekkür

Bu çalışma, 118E184 numaralı proje kapsamında Türkiye Bilimsel ve Teknolojik Araştırma Kurumu (TÜBİTAK) tarafından desteklenmiştir.

6. Kaynaklar

- [1] A. M. La Scala, R. Sbrizzai, F. Torelli, and P. Scarpellini, "A tracking time domain simulator for real-time transient stability analysis," IEEE Trans on Power Systems, vol. 13, no. 3, pp. 992–998, 1998.
- [2] S. C. Savulescu, Real-Time Stability Assessment in Modern Power System Control Centers, Hoboken, New Jersey, Wiley-IEEE Press, 2009.
- [3] H. Bevrani, M. Watanabe, and Y. Mitani, Power System Monitoring and Control, New Jersey, Wiley-IEEE Press, 2014.
- [4] C. W. Liu, and J. S. Thorp, "New methods for computing power system dynamic response for real-time transient stability prediction," IEEE Trans. Circuits Syst. I, Fundam., vol. 47, no. 2, pp. 324–337, Mar. 2000.
- [5] X. D. Liu, Y. Li, Z. J. Liu, Z. G. Huang, Y. Q. Miao, Q. Jun, Q. Y. Jiang, and W. H. Chen, "A novel fast transient stability prediction method based on pmu," in Power & Energy Society General Meeting, 2009, pp. 1–5.

- [6] X. Tao, H. Renmu, W. Peng, and X. Dongjie, “Applications of data mining technique for power system transient stability prediction,” in Proceedings of the 2004 IEEE International Conference on Electric Utility Deregulation, Restructuring and Power Technologies, 2004, pp. 389–392.
- [7] N. Amjadi, and S. F. Majedi, “Transient stability prediction by a hybrid intelligent system,” IEEE Trans. Power Syst., vol. 22, no. 3, pp. 1275– 1283, Aug. 2007.
- [8] D. Q. Zhou, U. D. Annakkage, and A. D. Rajapakse, “Online monitoring of voltage stability margin using an artificial neural network,” IEEE Trans. Power Syst., vol. 25, no. 3, pp. 1566–1574, Aug. 2010.
- [9] A. N. Al-Masri, M. Z. A. Ab Kadir, H. Hizam, and N. Mariun, “A novel implementation for generator rotor angle stability prediction using an adaptive artificial neural network application for dynamic security assessment,” IEEE Trans. Power Syst., vol. 28, no. 3, pp. 2516–2525, Aug. 2013.
- [10] Y. Xu, R. Zhang, J. Zhao, Z. Y. Dong, D. Wang, H. Yang, and K. P. Wong, “Assessing short-term voltage stability of electric power systems by a hierarchical intelligent system,” IEEE Trans. Neural Netw. Learn. Syst., vol. 27, no. 8, pp. 1686–1696, Aug. 2016.
- [11] T. Guo, and J. V. Milanovic, “Probabilistic framework for assessing the accuracy of data mining tool for online prediction of transient stability,” IEEE Trans. Power Syst., vol. 29, no. 1, pp. 377–385, Aug. 2010.
- [12] Mahdi M. and Genc İ. “Post-fault prediction of transient instabilities using stacked sparse autoencoder,” Electric Power Systems Research Volume 164, November 2018, Pages 243-252
- [13] Köktürk F. “K-en yakın komşuluk, yapay sinir ağları ve karar ağaçları yöntemlerinin sınıflandırma başarılarının karşılaştırılması, Bülent Ecevit Üniversitesi, Sağlık Bilimleri Enstitüsü, 2012
- [14] Alpaydın E. “Yapay Öğrenme”, Boğaziçi Üniversitesi Yayınevi, 2011
- [15] Atasever, Ü. H., “Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (Boosting), Destek Vektör Makinaları, Rastgele Orman (Random Forest) ve Regresyon Ağaçları Yöntemlerinin Kullanılması”, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, Ocak, 2011
- [16] Akman, M., Veri Madenciliğine Genel Bakış ve Random Forests Yönteminin İncelenmesi: Sağlık Alanında Bir Uygulama, Yüksek Lisans Tezi, Ankara Üniversitesi, Ankara, 2010.
- [17] Suchetana, B., Rajagopalan, B., Silverstein, J., 2017. Assessment of wastewater treatment facility compliance with decreasing ammonia discharge limits using a regression tree model. Science of the Total Environment, 598: 249-257.
- [18] P. LabsInc, DSATools, Dynamic Security Assessment Software, (2017) <http://www.dsatools.com/>.