



Detection of multiple bolt loosening via data based statistical pattern recognition techniques

Mahmut Pekedis*^{ID}

Department of Mechanical Engineering, Faculty of Engineering, Ege University, 35100, Bornova, Izmir, Turkey

Highlights:

- Multiple bolt loosening in a system exposed to environmental and operational uncertain conditions.
- The damage simulation scenario in system was performed by loosening the frame bolts.
- VAR model coupled with PCA technique has the highest detection performance.

Keywords:

- Bolt loosening
- Pattern recognition
- Structural health monitoring
- Environmental and operational uncertainties

Graphical/Tabular Abstract

Bolt loosening may occur on engineering systems which are exposed to operational and environmental variability conditions which sometimes can cause catastrophic consequences. This could be resulted in loss of property/time and even in some circumstances may lead to loss of life. Therefore, there is a growing need to detect the bolt loosening that could be encountered in these technological engineering structures, so that their safety and integrity can be improved. Here, we investigate to detect the presence of a single and multiple bolt loosening via pattern recognition techniques for a base excited three storey system.




Figure A. Methodological concept

Article Info:

Research Article
Received: 02.11.2020
Accepted: 04.04.2021

DOI:

10.17341/gazimmfd.820157

Acknowledgement:

Los Alamos National Laboratory, The Engineering Institute

Correspondence:

Author: Mahmut Pekedis
e-mail: mahmut.pekedis@ege.edu.tr
phone: +90 232 311 4970

Purpose: The main objective of this research is to diagnose the bolt loosening for a system exposed to environmental and operational uncertain conditions by using both vector auto regressive (VAR) model alone and VAR model coupled with singular value decomposition (SVD), Mahalanobis distance and principal component analysis (PCA).

Theory and Methods:

The research has been implemented on a three-storey system constructed with aluminum members in the laboratory medium. The damage simulation scenarios in this system have been performed by loosening the bolts on each floor which cause the nonlinear effects. The system can slide on rails that allow movement in lateral direction only and its ground storey has been excited with an electromagnetic shaker vibrating at band limited random frequencies. Accelerometers are attached to the each edge of the floor in order to acquire the dynamic response of the system and use their signals for damage diagnosis. Initially, the accelerometers' measurements collected for each state have been organized to represent related scenario. Once these measurements have been processed and evaluated in statistical pattern recognition algorithms, their performance results have been compared and presented via tables and ROC curves.

Results:

It is obtained from ROC curves that VAR model coupled with PCA technique has the highest diagnosis performance score in terms of area under curve (AUC) and optimum true positive rate (TPR).

Conclusion:

The approach it has been followed here demonstrates that the individual sensor that is most affected by the loosening can be identified which could be implemented to detect the bolt loosening.



Birden çok cıvata gevşemesinin veri tabanlı istatistikî örüntü tanıma teknikleriyle tespiti

Mahmut Pekedis*^{ID}

Ege Üniversitesi, Mühendislik Fakültesi, Makina Mühendisliği Bölümü, 35100, Bornova, İzmir, Türkiye

Ö N E Ç İ K A N L A R

- Çevresel ve operasyonel belirsizlik koşullara maruz kalan bir sistemdeki birden çok cıvata gevşemesi
- Sistemdeki hasar çerçevedeki cıvatanın gevşetilmesiyle yapılmıştır
- VOR modeli ile kullanılan ABA en yüksek hasar tespit performansına sahiptir

Makale Bilgileri

Araştırma Makalesi

Geliş: 02.11.2020

Kabul: 04.04.2021

DOI:

10.17341/gazimmfd.820157

Anahtar Kelimeler:

Cıvata gevşemesi,
örüntü tanıma,
yapı sağlığı izleme,
vektör otoregresif modeli,
tekil değer ayrışımı,
Mahalanobis uzaklığı

ÖZ

Bu araştırmanın temel hedefi, çevresel ve operasyonel belirsizlik koşullara maruz kalan bir sistemin vektör otoregresif (VOR) modeli hem tek başına, hem de tekil değer ayrışımı (TDA), Mahalanobis mesafesi ve asal bileşenler analizi (ABA) gibi tekniklerle birlikte kullanarak bir veya birden çok cıvata gevşemesini tespit etmektir. Araştırma, laboratuvar ortamında üretilen üç katlı alüminyum bir sistem üzerine uygulanmıştır. Sistemdeki hasar benzetim senaryoları her bir katta yer alan çerçevedeki cıvatanın gevşetilip doğrusal olmayan etki oluşturmasıyla yapılmıştır. Sistemin zemin katı tek eksenli ve bant genişliği sınırlandırılmış rastgele frekanslarla elektromanyetik sarstırıcı aracılığıyla titreştirilmiştir. Her bir katta yer alan elemanın kenar bölgesine sistemin dinamik tepkilerini belirlemek ve bunların ölçümlerini cıvata gevşeme tespitinde kullanmak amacıyla tek eksenli ivmeölçer yerleştirilmiştir. İvmeölçer verileri sekiz farklı cıvata gevşeme durumu için toplanmıştır. Daha sonra, bu ölçüm verileri istatistikî örüntü algoritmalarında değerlendirilerek uygulanan yöntemlerin cıvata/cıvataların gevşemesini tespit edebilme kabiliyetleri karşılaştırılmış ve elde edilen sonuçlar da tablo ve alıcı işletim karakteristik (AİK) eğrileriyle sunulmuştur. Her tekniğin sonucu AİK eğrisi altında kalan alan ve optimum doğru pozitif oranı (DPO) açısından değerlendirildiğinde en iyi başarımın VOR modelinin ABA ile birlikte kullanılması sonucu elde edilmiştir. Çalışmada uygulanan yaklaşımın en önemli özelliği, cıvata gevşemesinden en çok etkilenen sensörü efektif bir şekilde belirleyebilmesi ve cıvata gevşemesinin tespitinde kullanılabilirliğidir.

Detection of multiple bolt loosening via data based statistical pattern recognition techniques

H I G H L I G H T S

- Multiple bolt loosening in a system exposed to environmental and operational uncertain conditions
- The damage simulation scenario in system was performed by loosening the frame bolts
- VAR model coupled with PCA technique has the highest damage detection performance

Article Info

Research Article

Received: 02.11.2020

Accepted: 04.04.2021

DOI:

10.17341/gazimmfd.820157

Keywords:

Bolt loosening,
pattern recognition,
structural health monitoring,
vector-auto regressive
models,
singular value
decomposition,
Mahalanobis distance

ABSTRACT

The main objective of this research is to diagnose single or multiple bolt loosening for a system exposed to environmental and operational uncertain conditions by implementing both vector auto regressive (VAR) model alone and VAR model coupled with singular value decomposition (SVD), Mahalanobis distance and principal component analysis (PCA). The research has been deployed on a three-storey system constructed with aluminum members in the laboratory medium. The damage simulation scenarios in system have been performed by loosening the frame bolts on each floor which cause the nonlinear effects. The system's ground storey has been excited with an electromagnetic shaker vibrating at band limited random frequencies. Accelerometers are attached to each edge of the floor to acquire the dynamic response of the structure and use their signals for damage diagnosis. The accelerometers' measurements were collected for eight loosening cases. Once these measurements have been processed and evaluated in statistical pattern recognition algorithms, their performance results have been compared and presented via tables and ROC curves. It is obtained from ROC curves that the VAR model coupled with PCA technique has the highest diagnosis performance score in terms of area under curve (AUC) and optimum true positive rate (TPR). The approach it has been followed here demonstrates that the individual sensor that is most affected by the loosening can be identified which could be implemented to detect the bolt loosening.

1. GİRİŞ (INTRODUCTION)

Son 20 yıldır akademik ve endüstriyel çalışmalarda, mühendislik sistemlerinin kendilerine özgü bir sensör ağının olabileceği öngörüsü mevcuttur [1]. Böyle bir sistemle güvenilirliğin çok arttırılacağı, sadece gerektiğinde sistemlere bakım yapılacağı, malzeme ve enerji kullanımında daha etkin ve ekonomik katkılar olabileceği öngörülmektedir. Biyomedikal çalışmalarda yapılan araştırmalara göre insan derisinin bir santimetre karesinde ağrı, basınç, sıcaklık veya soğukluğu algılayabilen binlerce sinir sensörleri bulunmaktadır. Bu çok küçük sensörler durmaksızın insanın durumu hakkında hayati önem taşıyan verileri algılar ve gelişmiş bir ağ üzerinden beyne iletirler. Tıpkı insan sinir sistemindeki ağ gibi modellenmiş elektronik bir ağ uçaklardan boru hatlarına, rüzgâr türbinleri pervanelerinden barajlara, deniz altlarından gökdelenlere kadar tüm teknik mühendislik yapılarının sağlık durumları hakkında bilgi vermeyi sağlayan sisteme “Yapı Sağlığı izleme” (YSİ) adı verilmektedir [2].

Mühendislik sistemleri darbe, sıcaklık veya basınç gibi yüklere maruz kaldıklarında bazı bölgelerinde hasarlar oluşabilmektedir. Son 25 yıldır, bu sistemlerde oluşan hasarların tespiti için birçok strateji geliştirilmiştir. Canlıların dokularında yer alan sinir sistemlerine benzer olarak insan yapımı mühendislik yapıları sensörlerle donatılıp sağlık durum değerlendirmesi için veriler toplanmaktadır. Daha sonra bu sensör verileri YSİ tekniklerinde değerlendirilip hasar belirlenir [3-5]. YSİ araştırmalarında hasar tespiti sistemde oluşan değişikliklerin belirlenmesiyle yapılır [2, 6]. Geometrinin değişmesinden dolayı oluşan hasarlara örnek olarak çatlak hasarı verilebilir. Çatlak hasarı sistemin rijitliğini değiştirir. Sınır koşullarının değişmesi sonucu oluşan hasar örneğine nehir akışıyla birlikte suyun köprü ayaklarının bulunduğu toprağı zamanla aşındırması verilebilir. Değişen sınır koşulları köprünün yapısal bütünlüğünü etkilemektedir. Sınır etkileşimlerinin değişimi sebebiyle oluşan hasarlara örnek ise sistem veya yapıdaki cıvata gibi bağlantı ekipmanlarının gevşemesi verilebilir. Bu durum sistemin rijitliğini değiştirdiğinden hasar olarak değerlendirilir [2]. Bağlantı elemanlarının gevşemesi sistemin bütünlüğü açısından rijitliğini değiştirirken elemanlar bazında herhangi bir değişime neden olmaz.

Hasarın belirlenmesinde fizik kuram modelleri, tersinir yöntemler ve veri tabanlı YSİ olmak üzere üç farklı yaklaşım yaygın olarak kullanılmaktadır. Fizik kuram modellerinde önce sisteme yönelik matematiksel model kurulur. Daha sonra deneysel olarak alınan verilerin modelde değerlendirilmesiyle hasar tespitleri gerçekleştirilir. Çözüm sürecinde analitik ve sayısal simülasyon teknikleri kullanılır [7]. Bu yaklaşımda [7], doğal frekans ile mod şekillerinin değerlendirilmesiyle hasar tespitleri yapılmaktadır [8-10]. Ancak fizik kuram yönteminin özellikle erken safhalarda hasarın belirlenmesinde etkili bir yaklaşım olmadığı bazı çalışmalarda belirtilmiştir [2, 11]. Tersinir yöntemlerde ise

deneysel olarak ölçülen çıktı verilerinden (ivme, hız veya yer değiştirme vs.) girdi parametrelerinin (geometri) tahmin edilmesiyle hasar tespiti yapılır [12, 13]. Ancak kompozit yapılarda yaygın görülen tabaka ayrışmaları, mekanik sistemlerde cıvata gevşemeleri veya rulmanlarda bilye kırılması gibi hasar davranışlarının matematiksel olarak modellenip hasarı belirlemek genelde zordur. Bu sebeple, fiziksel model kurulmadan ölçümlerin istatistiksel olarak işlenmesine dayalı veri tabanlı teknik son yıllarda yaygın kullanılmaktadır [2, 4]. Bu yaklaşım fizik kuramlara bağlı olmadığı için çevresel ve operasyonel koşulları oluşturan sıcaklık veya nem ölçümleri gibi sensör verilerine gerek yoktur. Örneğin sistemde sıcaklık değişimlerinin gerçekleşmesi durumunda direkt sıcaklık ölçümü yerine ivmeölçer verileri yeterlidir. Çünkü sıcaklığın neden olduğu sistemdeki değişimler ivme ölçümlerinde yansımaktadır. Bu teknikte sağlıklı sistemden elde edilen sensör verileri üzerine istatistiksel yöntemler uygulanarak öncül öznitelik verileri elde edilir. Sistemde hasar olması durumunda bunlar değişir ve soncul öznitelik verileri olarak isimlendirilip saklanır. Öncül ve soncul öznitelik verileri örüntü tanıma adı verilen algoritmaya birbirlerinden ayırt edilir. Genel olarak istatistiksel örüntü tanıma algoritması 4 adımı kapsamaktadır. (a) Sistemi operasyonel koşullarda değerlendirme [14, 15], (b) veri alma, (c) veri indirgeme ve öznitelik çıkarma [4, 16], (d) istatistiksel model geliştirme [2-4], [14, 17]. Özet olarak bu algoritmaların temel hedefi deneysel ölçüm verileri ile yapının genel durumu arasındaki ilişkiyi öğrenmeye dayalıdır. Denetimli ve denetimsiz öğrenme olmak üzere iki farklı öğrenme tipi mevcuttur. Denetimsiz öğrenme verileri herhangi bir etikete ilişkilendirilmeyip bunlardan elde edilmek istenilen çıktı hakkında fikir sahibi olunmadığında kullanılır. Veriler arasındaki ilişkinin olup olmadığı konusu tamamen algoritmaya bırakılır. Denetimli öğrenme yönteminde ise makineyi eğitmek için bir eğitim kümesinde verilen değerlerle istenen çıktı bilinip, bu çıktılar sınıf etiketleriyle ilişkilendirilir. Algoritma bu eğitim kümesini kullanarak sonradan girilen verilere ilişkin örüntüleri tanıyıp ve sınıfları tahmin eder. Hasar tespitine yönelik uygulanan bu tür yaklaşımların kullanımı gittikçe artmaktadır. Hohn ve Farrar tarafından ivme ölçümlerinin zaman serilerinde değerlendirilmesiyle sınır etkileşimlerden kaynaklanan doğrusal olmayan davranış belirlenmiştir [11]. Çalışmalarında, sağlıklı ve hasarlı sisteme ait ivme ölçüm sinyalleri toplanmış ve her birine ilişkin otoregresif (OR) modeli kurularak hasar tespit edilmiştir. Yine aynı yazarların bir başka çalışmada, hasara hassas OR modeli uygulanmıştır [15]. Hasardan kaynaklanan etkilerin gürültü verilerinden ayrılması için giriş-çıkışı eş yapay sinir ağları (GÇYSA) kullanılmıştır. Bir başka çalışmada GÇYSA, faktör analizi, Mahalanobis mesafesi ve tekil değer ayrışımı (TDA) gibi algoritmaların hasarı belirleyebilme hassasiyetleri araştırılmıştır [18]. Kirişteki hasar Mosavi vd. tarafından Mahalanobis mesafesi ile belirlenmiştir [19]. Mevsimsel rejim geçişlerinin belirlenmesi için dönüşümlü otoregresif modeli [20], dönüşümlü yanıt yüzey metodu [21] ve rejim dönüşümlü eş tümleşme [22] yöntemleri uygulanmıştır. Bahsedilen bu çalışmaların çoğunda öznitelik

verileri olarak hasara duyarlı OR modeli kullanılmıştır. OR modeli yalnız bir sensör serisi üzerine uygulanabilir. Bu araştırmada ise birden çok sensör kullanıldığından toplanan sensör serileri arasındaki ilişkinin modellenmesinde VOR kullanılmıştır. Bu çalışmanın özgünlüğü literatürde ilk defa çevresel ve operasyonel belirsizlik koşullara maruz kalan bir sistemdeki birden çok cıvata gevşeme tespitinin VOR-TDA, VOR-Mahalanobis mesafesi ve VOR-ABA ile gerçekleştirilmesidir. Ayrıca mühendislik sistemlerinde sınır etkileşimlerden kaynaklanan bir hasarın olup olmadığının tespitine yönelik bazı çalışmalar sunulmuştur [15, 18, 20]. Bu araştırmada sistemde cıvata gevşeme hasarının var olup olmadığının tespiti yanında hasar varsa hangisi veya hangilerinde olduğu da belirlenmiştir.

Bu çalışmada ilk olarak hasar tespit sürecinde uygulanan örüntü tanıma teknikleri sunulmuştur. Daha sonra deneysel testlerde kullanılmak üzere üretilen üç katlı sistem düzeneği tanıtılmış ve buna ilişkin veri toplama aşamaları açıklanmıştır. Son olarak yöntemlerin ölçüm verileri üzerinde nasıl uygulanacağı belirtilmiş ve her bir yöntemden elde edilen hasar tespit sonuçları değerlendirilmiştir.

2. ÖRÜNTÜ TANIMA TEKNİKLERİ (PATTERN RECOGNITION TECHNIQUES)

Uygulanan her bir algoritmadaki temel yaklaşım gevşemeden kaynaklanan sistemdeki değişimleri operasyonel ve çevresel etkilerden ayırmaktır. Bu amaçla sisteme ilişkin sensör verilerinden öznitelik vektörleri belirlenir. Sonra bu vektörler örüntü tanıma algoritmalarında değerlendirilip hasar indeksleri elde edilir. Elde edilen hasar indeksleri alıcı işletim karakteristik eğrilerinde değerlendirilerek hasar tespitleri yapılır.

2.1. Vektör Otoregresif Modeli (Vector Auto Regressive Model)

YSİ sensör ağındaki bir ölçüm $\{x_1, x_2, \dots, x_T\}$ olarak kabul edilsin. Burada T ölçülen veri adetini gösterir. Birden çok sensörün olduğu durumda tüm ölçümler $\{x_{t1}, x_{t2}, \dots, x_{tm}\}$ şeklinde düzenlenip m sensör sayısını, x_{ti} ise t anında i sensöründen alınan veriyi temsil etmektedir.

p derecesine sahip bir VOR(p) modeli Eş. 1 şeklinde olup ϕ_i model katsayılarını, ε_t ise her bir zaman serisi için artık hatayı göstermektedir.

$$x_t = \sum_{i=1}^p \phi_i x_{t-i} + \varepsilon_t \quad (1)$$

Modeldeki bilinmeyen katsayılar en yüksek benzerlik yöntemi ile belirlenir [23-24]. Modelin derecesi pozitif katsayı olup bunun tahmin edilmesinde Akaike [25] ve Schwarz's [26] bilgi kriterleri kullanılır. Bu kriterler istatistiksel olarak tahmin edilen parametrelerin modele ne kadar uydukları hakkında bilgi verir. Akaike ve Schwarz's (Bayesian) bilgi kriteri sırasıyla Eş. 2 ve Eş. 3 şeklinde olup burada k modelde kullanılan p derecesine bağlı olarak

tahmin edilen parametre sayısını, T gözlemlenen veri sayısını, $L(p)$ ise benzerliği göstermektedir.

$$AIC(p) = -2 \ln L(p) + 2k \quad (2)$$

$$BIC(p) = -2 \ln L(p) + k \ln T \quad (3)$$

VOR modelinde izlenen adımlar şu şekildedir.

- Sağlıklı sistemden elde edilen ölçüm verileri için VOR(p) modeli kurulur. Modelde kullanılacak optimum p derecesi bilgi kriterinden tahmin edilir.
- Belirlenen p derecesine göre model yeniden kurulup ϕ ve ε hesaplanır. Sonra sağlıklı durum ile incelenecek durum arasında hipotez testi uygulanır. Sağlıklı durum ε_x test edilecek durum ise ε_y olarak adlandırılır. Sıfır hipotezi; $H_0 : D(\varepsilon_x^2) = D(\varepsilon_y^2)$ ise "cıvata gevşemesi yok (sağlıklı)", alternatif hipotezde $H_1 : D(\varepsilon_x^2) \neq D(\varepsilon_y^2)$ "cıvata gevşemesi (hasarlı) var" şeklinde kurulup % 99 güvenilirlik düzeyinde F istatistiğine göre hasar tespiti yapılır.

2.2. Mahalanobis Mesafesi (Mahalanobis Distance)

Bu teknik verilen grup ölçümleri arasında mesafe ölçülerek hem aykırılığın hem bunlara ait miktarlarının belirlenmesinde kullanılan bir uzaklık ölçütüdür. Sağlıklı sistemden elde edilen VOR parametreleri $m \times p$ boyutunda düzenlenir. Burada m ve p sırasıyla sensör sayısı ile model derecesini gösterir. Bunlara ilişkin çok değişkenli ortalama vektör $\mu = (\mu_1, \mu_2, \dots, \mu_p)^T$ ile kovaryans matrisi S olsun.

Test edilecek $x = (x_1, x_2, \dots, x_p)^T$ grubu ile sağlıklı grup arasındaki Mahalanobis mesafesi Eş. 4 ile hesaplanabilir.

$$D = \sqrt{(x - \mu)^T S^{-1} (x - \mu)} \quad (4)$$

Çok değişkenli istatistiğin aykırılığı D 'nin karesi açısından değerlendirilebilir.

Buna göre hasar indeksi Eş. 5 ile bulunur.

$$HI = (x - \mu)^T S^{-1} (x - \mu) \quad (5)$$

2.3. Tekil Değer Ayrışımı (Singular Value Decomposition)

Tekil değer ayrışımında (TDA) M matrisi Eş. 6 ifadesine sahiptir.

$$M = U \Lambda V^H \quad (6)$$

U ve V iki ortogonal matris olup $U^H U = V^H V = I$ eşitliğine sahiptir. Aynı zamanda, Λ ve M matrisinin köşegen değerleri büyükten küçüğe sıralanmış şekilde tekil değerleri içermektedir. Üstel H harfi eşlenik devriğini göstermektedir. Hasar tespiti sağlıklı (w_s) ile test (w_t) edilecek duruma ilişkin M matrisinin kurulmasıyla yapılır. Buna göre M matrisi Eş. 7 şeklinde yazılır.

$$M = [w_s, w_t] \quad (7)$$

TDA tekniğinde izlenen süreçler temel olarak şu şekildedir.

- Öncelikle sistemin sağlıklı durumu için VOR parametreleri hesaplanır. Sonra bu parametrelerin tekil değerleri hesaplatılıp θ_x vektörü olarak kaydedilir.
- Test edilecek durum ölçümleri için aynı şekilde VOR parametreleri hesaplanır. Bunlar M matrisine eklenir ve tekil değerleri hesaplatılıp θ_T vektörü olarak kaydedilir.
- Artık hata değeri $R = \theta_x - \theta_T$ ve hasar indeksi de $HI = R^2$ şeklinde hesaplanır.

2.4. Asal Bileşenler Analizi (Principal Component Analysis)

Asal bileşenler analizinde çok boyutlu veriler indirgenerek değişkenlerin dağılımı ve sınıflandırılması sağlanır. Bu işlem ABA'da asal bileşenler olarak adlandırılan yeni değişkenlerin analiz edilmesiyle gerçekleştirilir. Birinci asal bileşen tüm bileşenler içerisinde en büyük varyansa sahiptir. İkinci bileşen birinci bileşene ortogonal olma koşuluyla hesaplanır. Diğer bileşenler de bu şekilde hesaplanarak bulunur. Asal bileşenler (AB) analizinden türetilen değişkenler faktör skorları olarak adlandırılır.

Bu kapsamda VOR artık hata verileri X matrisinde düzenlenir. X matrisi aşağıdaki gibi tekil değer ayrışımına sahiptir [27].

$$X = P\Delta Q^T \quad (8)$$

P soldaki tekil vektörlere ilişkin $I \times L$ matrisini, Q ise sağdaki vektörlere ait $J \times L$ matrisini ve Δ ise tekil değerlerin diyagonal matrisini temsil etmektedir. Δ değeri $X^T X$ ve XX^T öz değerlerin diyagonal matrislerini oluşturur. Eş. 8'de faktör skorlarına ilişkin $I \times L$ matrisi F şeklinde gösterilip Eş. 9 gibi hesaplanır.

$$F = P\Delta \quad (9)$$

Asal bileşenler üzerindeki gözlenilecek değerlerin izdüşümleri X'in Q'yla çarpılmasıyla bulunur. Bileşenler orijinal eksenlerin döndürülmesiyle geometrik bir şekilde de gösterilebilir. Örneğin dört değişken verisi mevcutsa bunlar dört ortogonal faktör olacak şekildedir. Q matrisi ortonormal özelliğe sahip olduğundan kosinüs yönünün matrisidir. Hasar indeksi olarak bu matris kullanılmıştır.

3. DENEYSSEL TEST SETİ TASARIMI VE İMALATI (EXPERIMENTAL TEST SETUP DESIGN AND ITS MANUFACTURING)

Önce tasarımı gerçekleştirilip sonra da üretilen üç katlı alüminyum bir sistem laboratuvar ortamında test platformu olarak kullanılmıştır (Şekil 1). Bu sistemde yer alan dikey sütunlar ve ara katlar dikdörtgen elemanlardan oluşup bunlar arasındaki bağlantılar cıvata ekipmanlarıyla sağlanmıştır. Üç katlı sistemin alt tablası 25 mm çapında ve 400 cm

uzunluğundaki iki çelik ray üzerinde hareket edebilecek şekilde yatay olarak yerleştirilmiştir. Üç katlı sistemin zemin katında yer alan tablanın alt yüzeyi ile komple sistemin oturduğu plaka üzerinde çekme yönünde çalışabilen bir yay monte edilmiştir. Bu yayın amacı sistemin sarstırcıdan uzaklaşmasını engellemektir. Bunun yanında bu yaya bağlı 8 mm çapında dişli mil ve ucunda da yayın gerginliğini ayarlamak için bakalit bir topuz yerleştirilmiştir. Bu sayede farklı titreşim frekanslarında gerçekleşen sarstırcı çıkış mili ile zemin tablası arasında oluşan çarpışma etkisi azaltılıp sistemin düzgün bir şekilde sarsılması sağlanmıştır.

Raylar üzerinde yer alan zemin tablası ile bunun üzerinde monte edilen sistemin diğer parçaları yatay ve tek eksenli hareket edebilmektedir. Katlar ile dikey sütunların birleşme bölgeleri 4 adet M6 cıvatasıyla sabitlenmiştir. Nemden oluşabilecek korozyonları engellemek için bu cıvatalar A2 çeliğinden seçilmiştir. Zemin tablasının oturduğu kızak ile bağlantı ekipmanları hariç sistemin tamamı alüminyumdan imal edilmiştir. Sistemin toplam uzunluğu 750 cm, genişliği 350 cm ve katlar arasındaki mesafe 17 cm dir (Şekil 1). Burada önemli bir husus olarak, deneysel YSİ aşamasında kullanılmak üzere tasarımı gerçekleştirilip üretilen bu sistemin ölçeklendirilmiş gerçek bir mühendislik sistemini yansıtmadığıdır. Cıvata bağlantılarından herhangi birisi gevşetilerek sistem çevresel ve operasyonel koşullara maruz bırakıldığında sensörlerden bütünlük olarak hem cıvata gevşemesine bağlı doğrusal olmayan sinyaller hem de gürültü kaynaklı sinyaller elde edilir. Doğrusal olmayan bu sinyaller hasarı temsil etmektedir. YSİ'deki temel amaç hasardan kaynaklanan etkileri çevresel faktörlerden kaynaklanan gürültülü sinyallerden ayırarak bunları hasar indisi olarak kullanmaktır.

Cıvata gevşetilip somunun dokunduğu yüzeyden 0,3 mm eksenel hareketi sağlanarak hasar benzetimi oluşturulmuştur. Somunun hareket ettiği mesafe sentil ile ölçülmüştür. Kat I, II ve III'te bir hasar seçeneği olduğundan toplam $2^3=8$ adet senaryo üretilebilir. Üç katlı sistem, alt tablalara, raylar, miller, arabalar, sarstırcı ve sistemi oluşturan tüm mekanik bağlantı ekipmanları gürültüyü izole edebilen köpük üzerine monte edilmiştir. Bu köpük dış kaynaklı gürültülerin sisteme olan transferlerini azaltır.


Sistemin farklı durumlardaki dinamik tepkilerini ölçmek için zemin, kat I, II ve III için nominal hassasiyeti sırasıyla (98,6), (93,3), (97,3) ve (94,6 mV/g) olan IEPE tabanlı YMC tipi ivmeölçerler yerleştirilmiştir. Bu ivmeölçerlerin çıktıları yer çekim ivmesi ($g=9.81m/s^2$) cinsindedir. Elektrodinamik sarstırcının çıkış ucu zemin katın yana doğru olan kenar yüzeyin merkezine degecek şekilde konumlandırılmıştır. Sistemin titreşimi esnasında oluşabilecek burulma etkilerini azaltmak için üç katlı sistem, ivmeölçerler ve elektrodinamik sarstırcının ucu yanal eksenli hareket edecek şekilde montajları gerçekleştirilmiştir (Şekil 2).

Sarstırcıdan üç katlı sisteme uygulanan kuvveti ölçmek için sarstırcının 5 mm çapındaki çıkış miline nominal hassasiyeti 9,39 mV/N olan IEPE tabanlı bir kuvvet ölçer monte edilmiştir. Sistemin kurulumu tamamlandıktan sonra testler

gerçekleştirilip ölçüm verileri alınmıştır. Bu süreçte izlenen akış adımları Şekil 2’de numaralarla gösterilmiştir. Bunlara ilişkin açıklamalar aşağıda sıralanmıştır.

- Belirli bant aralığında gürültü içeren rastgele dijital sinyaller MATLAB ile üretilir. Sistemin 1’inci mod frekansında (rezonans) yüksek salınım oluşmaktadır. Bunu engellemek için birinci modun yer almadığı üstündeki frekanslarda (15-150 Hz aralığında) rastgele uyarım sinyalleri üretilir.
- Dijital sinyaller TCP/IP ağ protokolü üzerinde Agilent 33210-A tipi sinyal üreticiye gönderilerek analog sinyallere çevrilir.

- Analog sinyaller üreticinin BNC çıkış ucuyla YMCLA-100 tipinde bir yükselteci iletilir. Yükseltme seviyesi 3.4 V RMS (kök kare ortalama) olacak şekilde ayarlanır.
- Yükseltelen sinyaller sarstırıcıya gönderilir ve sistem zorlanmış titreşimle sarsılır.
- Sarstırıcının çıkış ucundaki kuvvet sensörü, zemin, kat I, II ve III’te yer alan ivmeölçerler sırasıyla cihazın NI 9234’ün 1, 2, 3, 4 ve 5’inci kanallarına bağlanır.
- Sensör kanallarından Tablo 1’de verildiği gibi 1765,517 Hz’de 8298 örnekleme noktası 4,7 s’de alınır.
- Toplanan sensör ölçümleri Labview ile işlenip ham veri olarak kaydedilir. Bunlar örüntü tanıma tekniklerinde değerlendirilerek cıvataların gevşeyip gevşememe durumları tespit edilir.



Şekil 1. Üç katlı sisteme ilişkin görünüm ve temel boyutlar [uzunluklar mm cinsindedir] (Three-storey system and its basic dimensions [lengths are in mm])

Tablo 1. Uyarım ve veri toplama parametreleri (Excitation and data acquisition parameters)

Uyarım özellikleri	Sinyal tipi ve dağılım Bant genişliği (Hz) RMS değeri (V)	Rastgele ve normal dağılım 15-150 3,4
Veri toplama özellikleri	Kanal adedi	5 (1 kuvvet sensörü, 4 ivmeölçer)
	Zaman adımı (s)	0,00056640625
	Örnekleme hızı (Hz)	1765,517
	Toplam süre (s)	4,69947265624
	Toplam veri noktası (adet)	8298


Sensörlerden alınan veriler Tablo 2’de verildiği gibi dikey konumda yer alan civataların gevşetilir gevşetilmemesi durumuna göre sınıflandırılmıştır. Her bir gevşeme durumu 8 kez test tekrarlanıp toplam 64 veri seti toplanmıştır. Veri setinin 1’inci sütunu zaman (s), 2’ncisi kuvvet (N), 3, 4, 5 ve 6’ncısı ise ivmeölçer (m/s^2) sinyallerinden oluşmaktadır.

4. SONUÇLAR VE TARTIŞMALAR (RESULTS AND DISCUSSIONS)


Sistem 15-150 Hz bant aralığında normal dağılıma sahip zorlanmış rastgele titreşimle sarsılmıştır. Kuvvet sensöründen ölçülen kuvvet verisi Şekil 3a’da ve buna ilişkin frekansa bağlı Welch güç spektral yoğunluğu Şekil 3b’de gösterilmiştir. Burada, özellikle 15 ile 150 Hz aralığındaki

frekansların daha baskın olduğu görülmektedir. Sarsıtıcının uyarılmasına bağlı olarak sistem üzerinde yer alan 4 kanal ivme kanalından ölçülen 1 adet test verisi Şekil 4’te verilmiştir. En düşük yanal salınım hareketinin zemin katta oluştuğu görülmektedir.

Girdi (kuvvet)-çıkıtı’ya (ivme) bağlı olarak elde edilen frekans tepki fonksiyonu Şekil 5’te gösterilmiştir. Daha önceki bölümde bir veya birden çok civatanın gevşetilmesi sistemde doğrusal olmayan davranışların oluşmasına neden olacağından söz edilmişti. Nitekim hasarlı sisteme ilişkin frekans tepki fonksiyonu (FTF) saçınımlarının sağlıklıya göre daha yüksek olduğu Şekil 5’te görülmektedir. Durum 1 (sağlıklı) ve durum 8 (hasarlı) için 4 farklı katta yer alan sensörlerden elde edilen ölçümlere ilişkin FTF dağılımları



Şekil 2. Deneysel test ortamı [Numaralar işlem adımlarını göstermektedir.]
(Experimental test medium. [The numbers represent the process steps])

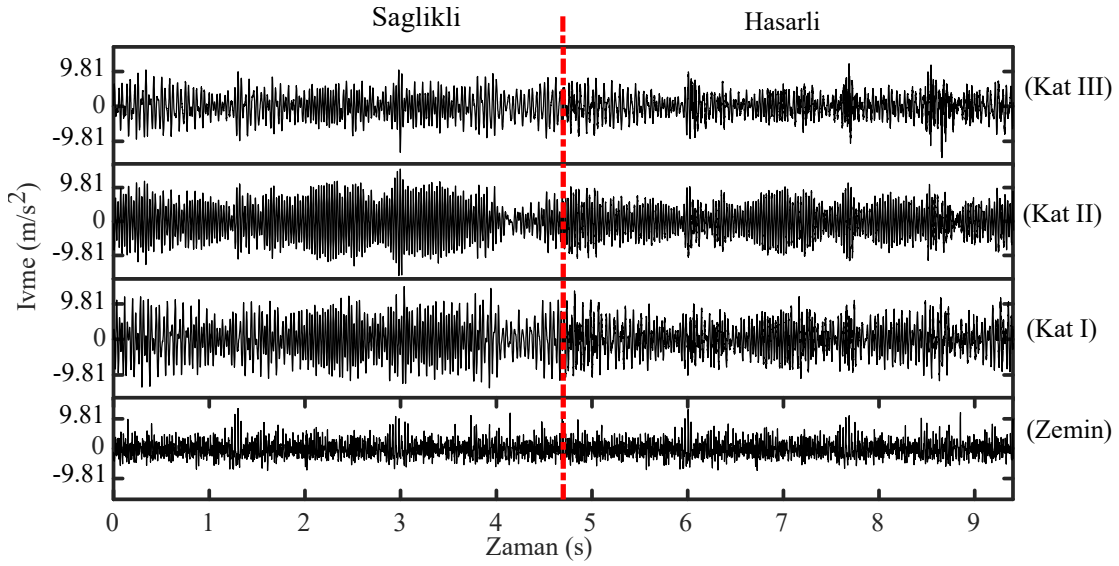
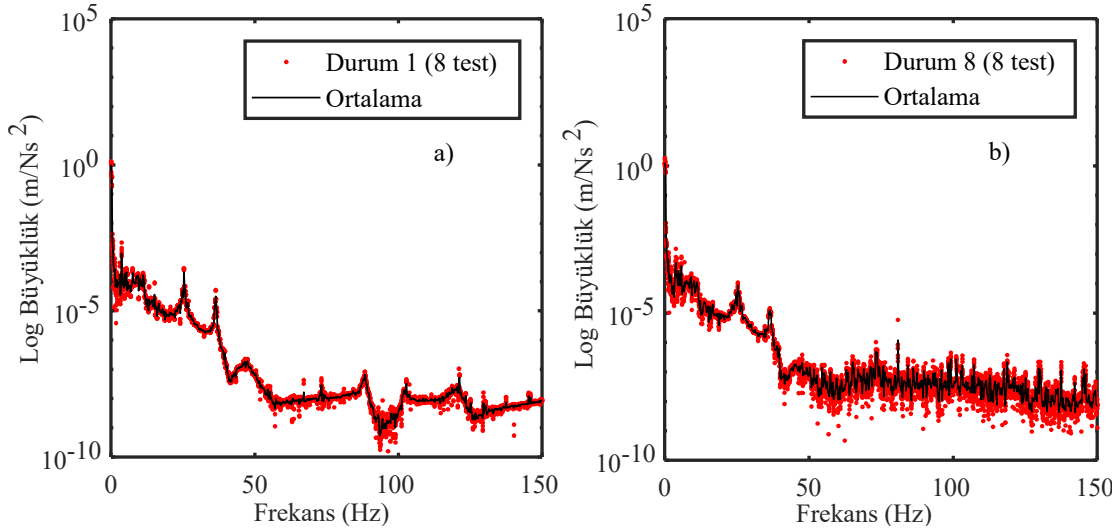


Şekil 3. Kuvvet sensör verileri a) Ham ölçümler b) Welch güç spektral yoğunluğu
(Force sensor data a) Raw measurements b) Welch power spectral density.)

Tablo 2. Sisteme ilişkin oluşturulan cıvata gevşeme durumları ["1", cıvatanın gevşetildiğini, "0" ise cıvatanın gevşetilmediğini göstermektedir.]

(Bolt loosening cases for the system ["1" represents the bolt is loosened and "0" shows the bolt is not loosened])


Durum No	Cıvata Gevşeme Durumu		
	Kat I	Kat II	Kat III
1	0	0	0
2	0	1	0
3	0	0	1
4	0	1	1
5	1	0	0
6	1	0	1
7	1	1	0
8	1	1	1

**Şekil 4.** Sağlıklı ve hasarlı durum için elde edilen ham zaman-ivme ölçümleri.
(Raw time-accelerometer measurements for both healthy and damaged cases)**Şekil 5.** Kat 3'te yer alan sensörden elde edilen ölçümlere ilişkin frekans tepki fonksiyonu dağılımları a) Durum 1 b) Durum 8 [siyah renkli çizgi, 8 tekrarlı testin ortalamasını gösterir.]

(Frequency response function distribution of the sensor located at Floor 3 a) Case 1 b) Case 8 [black line shows the average of 8 tests.]

Şekil 6'da verilmiştir. Sistemde hasarın olması durumunda özellikle 50 Hz'den sonra doğrusal olmayan davranışların oluştuğu görülebilmektedir (Şekil 6b, Şekil 6c ve Şekil 6d).
2000

Sistem çevresel ve operasyonel koşullara maruz bırakıldığında, bu sisteme iliştirilen sensörlerden bütünlük olarak hem gevşemeden hem de bu çevresel ve operasyonel



Şekil 6. Farklı katlarda yer alan sensörlerden elde edilen ölçümlere ilişkin frekans tepki fonksiyonları a) Zemin kat b) Kat I c) Kat II d) Kat III [Her bir çizgi grafiği 8 tekrarlı testin ortalamasını gösterir]


(Frequency response functions of the sensors located at various floors a) Base floor b) Floor I c) Floor II d) Floor III [Each line graph shows the average of 8 duplicated tests])

koşullardan kaynaklı doğrusal olmayan sinyaller elde edilir. Bu çalışmada rastgele sinyaller çevresel ve operasyonel koşulları, cıvata gevşemesi ise hasarı temsil etmektedir. Buradaki temel amaç, cıvata gevşemesinden kaynaklı doğrusal olmayan etkileri çevresel ve operasyonel koşul sinyallerinden ayırt edip hasarı (cıvata gevşemesini) belirlemektir. Veri tabanlı örüntü tanıma tekniklerinden öncelikle vektör otoregresif (VOR) modeli incelenmiştir. Denklem 3'te verilen bilgi kriterlerinden yararlanılarak sistemin sağlıklı durumu için optimum VOR derecesinin belirlenmesi gerekir. VOR derecesine bağlı olarak elde edilen Akaike ve Schwarz bilgi kriteri sonuçları Şekil 7'de verilmiştir. AIC ve BIC verilerinin belirli bir p derecesinden sonra düşüş eğilimlerinin az olduğu görülmektedir. Buna göre sistemin sağlıklı durumu için modelde kullanılacak derecenin 16-20 arasında seçilmesi uygun olur (Şekil 7a). Bunun yanında, bu ölçümlere ilişkin gecikmeye bağlı elde edilen kısmi otokorelasyon dağılımları Şekil 8'de gösterilmiştir. Şekil 8a'da görüldüğü gibi 16 ile 20 arası gecikmelerde kısmi otokorelasyon katsayıları düşüktür. Her bir kattaki kanaldan toplanan ölçüm verisi 8298 adettir. Bunlar için VOR(16) modeli uygulandığında bu 8298 veriden 16 tanesi modeli oluşturmak için kullanılır.


Dolayısıyla model sonucunda toplam 256 VOR parametresi ve 8282 adet artık hata değeri elde edilir. Örneğin; durum 1 ve 8 için her 4 kanal verisi üzerine VOR(16) modeli uygulanması sonucu elde edilen artık hata değerleri sırasıyla Şekil 9a ve Şekil 9b'de verilmiştir. Modeldeki artık hata değerlerinin özellikle zemin kat ölçümlerinde (kanal 2) daha yüksek olduğu görülmektedir. Nitekim bu durum zemin katın rastgele uyarımlarla titreştirildiğini gösterir.

Tablo 3'te VOR(16) modeli için 8 tekrarlı testin sonucu olarak elde edilen ortalama varyans oranları " $\sigma^2(\varepsilon_y) / \sigma^2(\varepsilon_x)$ " verilmiştir. Burada ε_x ve ε_y sırasıyla sağlıklı ve test edilecek durumun artık verilerini gösterir. Bu varyans oranı hasar indeksi olarak kullanılabilir ve tabloda koyu harfle gösterilen kısımlar ilgili katta hasarın (cıvata gevşemesi) olduğuna işaret etmektedir. Sistemde fazla cıvata gevşemesinin olması VOR modelinde daha yüksek artık değerlerin oluşmasına sebep olur (Tablo 3).


Her durumdan alınan 8 veri seti için VOR (16) modeli uygulanmış ve elde edilen artık hata verilerinin kareleri F hipotez testine tabi tutulması sonucu elde edilen alternatif



Şekil 7. Vektör otoregresif modelinde dereceye bağlı olarak elde edilen Akaike ve Schwarz’ın bilgi kriter değerleri a) Durum 1 # kanal 5 b) Durum 8 # kanal 5
(Akaike and Schwarz's information criterions of vector autoregressive model for various orders a) Case 1 # Channel 5, b) Case 8 # Channel 5)



Şekil 8. Gecikmeye bağlı olarak elde edilen kısmi otokorelasyon katsayıları a) Durum 1 # kanal 5 b) Durum 8 # kanal 5
[Kesikli çizgiler güvenilirlik düzeyini göstermektedir.]
(Partial autocorrelation coefficients of various lags a) Case 1 # Channel 5 b) Case 8 # Channel 5 [Dashed lines shows the significance limits.]



Şekil 9. Vektör otoregresif modelinde $p=16$ için elde edilen artık hata değerleri a) Durum 1 b) Durum 8
(Residual errors of vector autoregressive model for $p=16$ a) Case 1 b) Case 8)

test sayıları Tablo 4’te verilmiştir. Öğrenme aşamasında sağlıklı olan “Durum 1” seçilmiştir. Test aşamasında ise

geriye kalan 7 durum ele alınmıştır. Örneğin, durum 2’de 8 adet veri setinden her birisi ayrı ayrı olarak durum 1’de yer

alan her bir veri setiyle çapraz hipotez testi kurulması sonucu elde edilen toplam H_1 sayısı (alternatif hipotez, “Cıvata gevşemesi vardır”); kanal 2, 3, 4 ve 5 için sırasıyla 0, 2, 56 ve 10 şeklinde bulunmuştur. Burada, 64 adet çapraz testten 56’sında cıvata gevşemesi doğru bir şekilde belirlenebilmiştir. Ancak bazı durumlarda yanlış hasar tespitlerinin yapıldığı görülmektedir. Dolayısıyla artık verilerin doğrudan F hipotez testinde değerlendirip hasarı (cıvata gevşemesi) belirlemek pek elverişli olmayabilir.

Hasar belirleme ve sınıflandırma performansının daha iyi bir şekilde görselleştirmek için her teknikten elde edilen hasar indeksleri alıcı işletim karakteristik (AİK) eğrileriyle değerlendirilmiştir. AİK eğrisi, sınıflandırma süreçlerinde ayırım eşiğinin farklı olduğu durumlarda hassasiyetin kesinliğe olan oranıyla belirlenir. Bir başka deyişle, doğru pozitiflerin (doğru tespit) yanlış pozitiflere (yanlış tespit veya alarm) olan oranı olarak ifade edilmektedir [28]. Eğri, doğru pozitif oranı (DPO) eksenine doğru yaklaştıkça başarımın arttığı, yanlış pozitif oranı (YPO) eksenine yaklaşması durumunda ise skorun düştüğü anlaşılır. Dolayısıyla [0,1] noktasında en yüksek sınıflandırma değeri elde edilir. Bu eğri birçok noktadan oluşmaktadır. Eğrinin sınıflandırma başarısı tek bir sayısal değer ile belirtilmek istenildiği durumlarda eğri altındaki alan (EAA) açısından değerlendirilir. EAA verilerinin ilişkilendirildiği sınıflar Tablo 5’te verilmiştir [29].

Her bir durumdan ele alınan 8 veri setine ilişkin VOR(16) artık hata değerlerinin kareleri (ϵ^2), AİK eğrileri açısından değerlendirilmiştir. Elde edilen sonuçlar Şekil 10’da ve bunlara ilişkin EAA değerleri Tablo 6’da verilmiştir. Burada

her bir durum senaryosu 8 adet tekrarlı testi ve her senaryodaki bir sensör kanalı 66256 veriyi içerir. İncelenen her bir algoritmada, durum 1’deki veri setleri eğitim aşamasında diğerleri de test sürecinde kullanılmıştır.

Tablo 5. EAA verilerinin sınıflandırılması
(Classification of AUC data)

EAA değeri	Sınıflandırma
0,9 - 1,0	mükemmel
0,8 - 0,9	iyi
0,7 - 0,8	orta
0,5- 0,7	kötü


Gerçek mühendislik uygulamalarında test verisinin toplatıldığı sistemin sağlık durumu bilinmemektedir. Temel amaç, direkt bu test veri setinden aykırılık tespit edilip (hasarlı verileri hasarsız olanlardan ayırt edilmesiyle) hasarın belirlenmesidir. Örneğin durum 2’deki ϵ^2 verileri test aşamasında kullanıldığında kanal 2’den (zemin kat sensörü) EAA = 0,5 civarında (eşik çizgisinde) bir veri elde edilmiştir. Bu sonuç öğrenme ile test verileri arasında herhangi bir farkın olmadığını göstermektedir. Bunun yanında 2’nci kattaki cıvata gevşemesinin normal dağılıma sahip rastgele sinyalle titreştirilen zemin tablasının sinyallerini kayda değer bir şekilde etkilemediği sonucunu çıkarmak mümkündür. Dolayısıyla sadece zemin kata iliştiirilen sensör verileri incelenerek sistemde herhangi sağlık değişiminin olup olmadığı anlaşılammamaktadır. Diğer taraftan, üç katta da hasarın (cıvata gevşemesi) olması durumunda ise bu sensörlerden 0,9’dan büyük EAA değerleri elde edilmiştir. Dolayısıyla bir sensör en çok iliştiirildiği kattaki hasardan etkilenir. Hasar olmadığı halde algoritma bazen yanlış hasar

Tablo 3. Farklı cıvata gevşeme durumunda 8 tekrarlı testin uygulanması sonucu elde edilen ortalama $\sigma^2(\epsilon_x) / \sigma^2(\epsilon_y)$ değerleri (Mean $\sigma^2(\epsilon_x) / \sigma^2(\epsilon_y)$ values of 8 duplicated tests for various bolt loosening cases)

No	Test Adeti	Kanal No			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	8	1,0000	1,0000	1,0000	1,0000
2	8	1,1057	16,9085	102,6465	13,0912
3	8	2,3592	1,26660	2,8423	61,5940
4	8	1,2959	4,7017	305,5639	60,8366
5	8	1,6996	7868,4378	20,8760	8,6321
6	8	2,2714	7883,3217	13,8098	19,3874
7	8	1,3658	4431,4478	163,1998	19,4991
8	8	1,1025	5588,5517	497,3395	1019,91

Tablo 4. F Hipotez testinde elde edilen toplam H_1 sayıları (Total H_1 numbers obtained using F hypothesis test)

Durum No	Çapraz test adeti	Kanal No			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	64	0	0	0	0
2	64	0	2	56	10
3	64	0	33	36	55
4	64	1	41	58	57
5	64	0	64	52	50
6	64	1	61	49	40
7	64	2	63	57	39
8	64	2	62	60	61



Şekil 10. Her bir durum için VOR modelinin uygulanması sonucu elde edilen AİK eğrisi açısından hasar tespit sonuçları
(Damage diagnosis results of the ROC curves obtained from VAR model for each case)

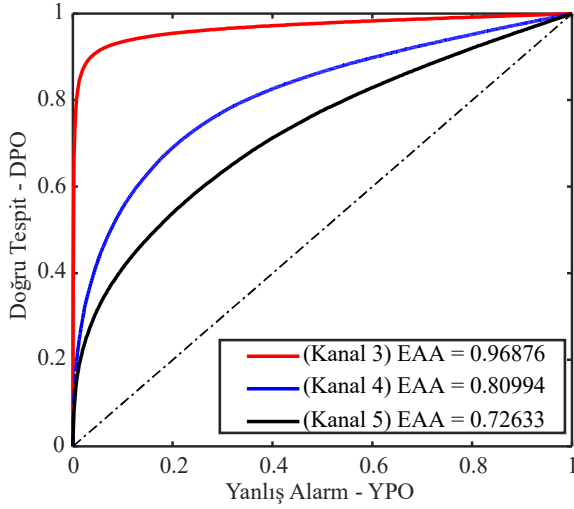
Tablo 6. VOR artık hata değerleri için elde edilen AİK-EAA sonuçları
(Damage diagnosis results of the ROC-AUC for VAR residual errors)

Durum No	Test Adeti	Kanal No			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	8	0,5000	0,5000	0,5000	0,5000
2	8	0,5218	0,7436	0,8833	0,7626
3	8	0,6179	0,5357	0,6250	0,8644
4	8	0,5396	0,6405	0,9100	0,8648
5	8	0,5865	0,9862	0,8281	0,7813
6	8	0,6195	0,9822	0,7642	0,8017
7	8	0,5548	0,9783	0,9128	0,7964
8	8	0,5266	0,9779	0,9453	0,9587

bilgisi verebilmektedir. İstatistikte bu duruma tip I hatası (yanlış pozitif) denilir. Örneğin durum 2’de, yalnızca 2’inci katta yer alan civatada gevşeme hasarı olduğu halde 1’inci katta yer alan 3’üncü kanal sensörü (EAA = 0,7436) ile 3’üncü katta yer alan 5’inci kanal sensörünün (EAA = 0,7626) bu hasardan etkilendiği ve yanlış bilgi (1’inci tip hata) verdiği görülmektedir. Ancak VOR- ε^2 tekniği genel olarak incelendiğinde ve 0,85’ten büyük skorları başarılı kabul edildiğinde civata gevşeme senaryolarını hassas bir şekilde belirleyebilmiştir. Bunun yanında, özellikle son 4 durumun daha net bir şekilde tespit edildiği ve algoritmanın performans düzeyi “mükemmel” sınıfında değerlendirilebilir. (Şekil 10, Tablo 6). Tüm hasar senaryolarının birlikte değerlendirilmesi sonucu elde edilen AİK eğrileri Şekil 11’de verilmiştir. Burada sadece durum 1 (sağlıklı) ε^2 verileri öğrenme sürecinde, kalan 7 durum verileri de birlikte ele alınıp test aşamasında kullanılmıştır. En başarılı hasar tespitleri sırasıyla kat I, II ve III’te yapılmıştır (Şekil 11). Bunun yanında alt katlarda gerçekleşen hasarların üst katlara iliştilen sensörleri


etkilediği, ancak üstteki hasarların alt katlarında yer alan sensörleri çok az etkilemiş olduğu sonucu dikkat çekicidir. Bu sebeple 3’üncü kattaki kanal 5 sensöründen daha düşük EAA verisi elde edilmiştir. Dolayısıyla sistemde tek bir sensörden aykırılığın gerçekleşip gerçekleşmediğinin belirlenmek istenildiği durumlarda sensörün en üste yerleştirilmesinde fayda vardır.

İkinci algoritmada vektör otoregresif-tekil değer ayrışımı (VOR-TDA) ele alınmıştır. VOR’dan elde edilen 4 boyutlu model parametrelerinin TDA’da işlenmesiyle hasar indeksleri bulunmuştur. Bunlara ilişkin AİK eğrileri Şekil 12’de ve EAA değerleri ise Tablo 7’de listelenmiştir. Daha önce kanal başına 64 parametrenin elde edildiği belirtilmişti. Her durum 8 tekrarlı test setini içerdiğinden 64x8 boyutundaki veriler eğitim aşamasında, geriye kalan hasarlı durumların her birinden ayrı ayrı olarak ele alınan hasar indeksleri ise test aşamasında kullanılmıştır. Dolayısıyla her bir eğri 128 adet (öğrenme + test) hasar indeks verisinden oluşmaktadır.



Şekil 11. Tüm durumlar için VAR- ϵ^2 modelinin uygulanması sonucu elde edilen AİK-EAA eğrisi hasar tespit sonuçları
(Damage diagnosis results of ROC-AUC curves obtained from VAR- ϵ^2 model for all cases)

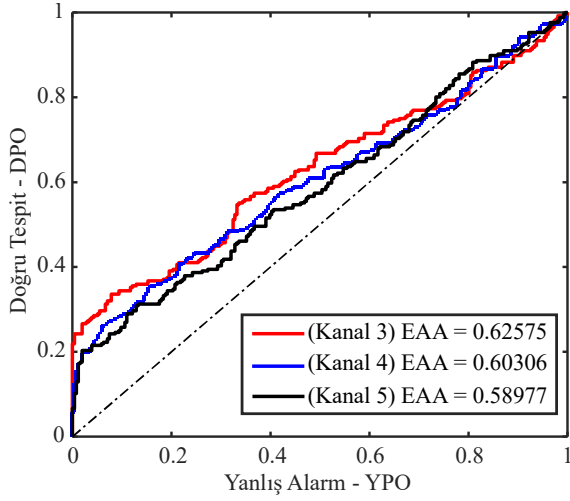
VOR-TDA algoritmasının tespit performansı özellikle hasarın olduğu bölgelerde eğrinin DPO eksenine yaklaştığı görülmektedir (Şekil 12). Ancak kat III'te hasar tespit başarısı kat I ve II'ye göre daha düşüktür. Bu durumun nedeni alt katlarda gerçekleşen hasarların, üst kat sensörlerini etkilemesindedir. Dolayısıyla, ikili sınıflandırma başarısı kat I'de "mükemmel", II'de "iyi" en üstte ise "kötü" olduğu söylenebilir (Tablo 7, Durum 8). Tüm durumlar açısından tip I hata düzeyinin (yanlış tespit) VAR- ϵ^2 algoritmasına göre daha düşük değerdedir. Tüm senaryolar birlikte ele alınıp VAR-TDA yaklaşımından elde edilen AİK eğri sonuçları Şekil 13'te verilmiştir. Önceki VAR- ϵ^2 tekniğinde olduğu gibi burada da 8 durum için verilen verilerin bir kısmı "hasarlı" bir kısmı da "sağlıklı" kat verilerini içerdiğinden iki durumlu tespitte göre daha düşük hassasiyette sonuçlar bulunmuştur. VAR-TDA tekniğinin iki sınıflı durumları birbirinden ayırt etme kabiliyetinin "iyi", çok durumlu sınıflar için ise "kötü" olduğu sonucu çıkarılabilir. 3'üncü yaklaşımda VAR-Mahalanobis tekniği ele alınmıştır. Bu teknik kullanılarak elde edilen AİK eğrileri ve EAA değerleri sırasıyla Şekil 14 ve Tablo 8'de gösterilmiştir.



Şekil 12. Her bir hasar durumu için VAR-TDA tekniğinin uygulanması sonucu elde edilen AİK eğrileri
(Damage diagnosis results of ROC curves obtained from VAR-SVD technique for each case)

Tablo 7. VAR-TDA tekniğinin uygulanması sonucu elde edilen AİK-EAA sonuçları
(ROC-AUC results of VAR-SVD technique)

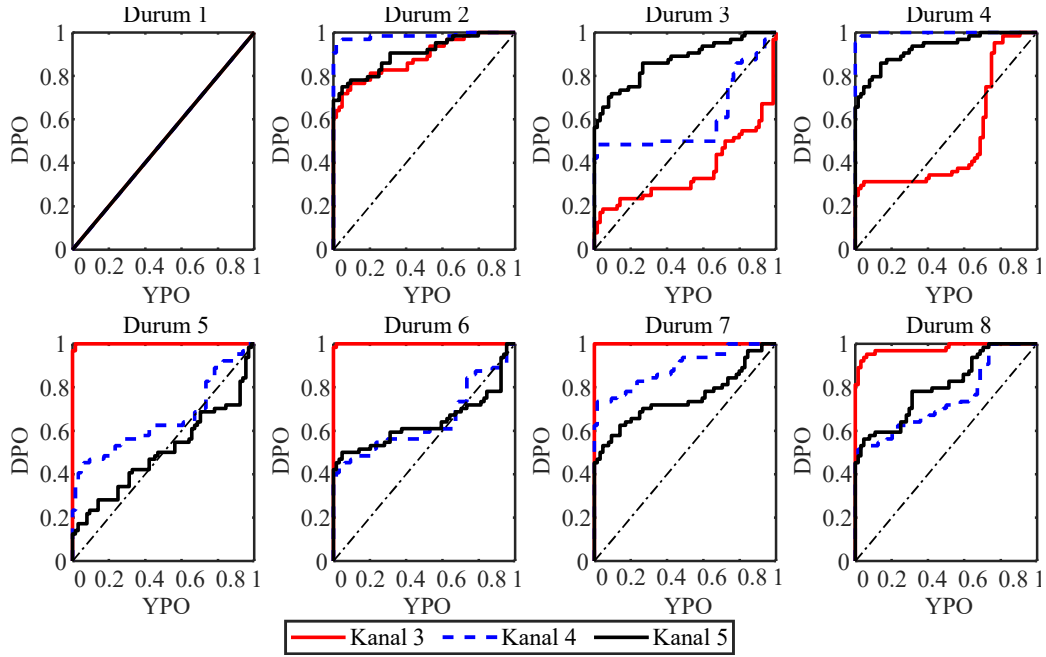
Durum No	Test Adeti	Kanal			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	8	0,5000	0,5000	0,5000	0,5000
2	8	0,5653	0,7819	0,8955	0,7766
3	8	0,541	0,3557	0,5481	0,7663
4	8	0,5356	0,4453	0,9307	0,7708
5	8	0,5201	0,9731	0,5556	0,4751
6	8	0,5430	0,9744	0,5153	0,5671
7	8	0,5257	0,9785	0,7617	0,6049
8	8	0,5661	0,9043	0,6113	0,6441



Şekil 13. Tüm durumlar için VOR-TDA tekniğinin uygulanması sonucu elde edilen AİK-EAA eğrisi hasar tespit sonuçları (Damage diagnosis results of ROC-AUC curves obtained from VAR-SVD technique for all cases)

Öznitelik vektörleri olarak VOR-TDA’da olduğu gibi her bir kanal için bulunan 64 adet VOR parametresi kullanılmıştır. Genel olarak bu tekniğin hasarlı durumları sağlıklı olandan ayırabilme kabiliyeti 2, 4, 5, 6 ve 7’nci durum için “mükemmel” 3’üncü ve son durum için ise “iyi” şeklindedir. Bunun yanında kat II ve III hasarları başarılı bir şekilde belirlenmiştir.

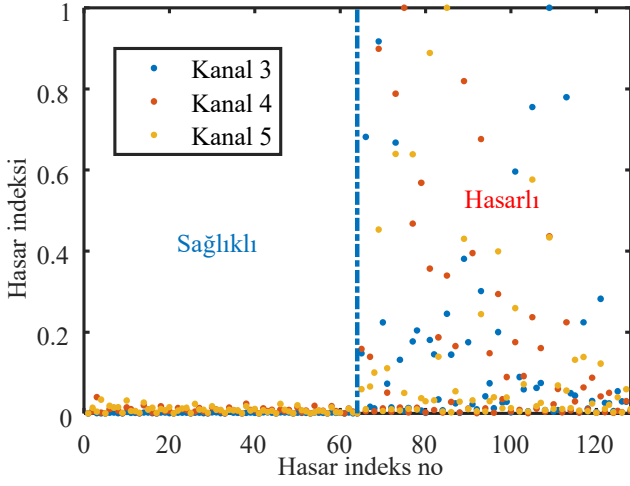
Her bir katın sağlıklı veya hasarlı olması durumunda VOR-Mahalanobis tekniğinden elde edilen normalize hasar indeks dağılımları Şekil 15’te gösterilmiştir. Her kanal 64 adet veri noktasından oluşmaktadır. Ortalama hasar indeksleri yüksekten düşüğe doğru sırasıyla Kanal 3, 4 ve 5’te görülmüştür. Dolayısıyla AİK eğrilerinde olduğu gibi önce kat I sonra kat II ve III hasarlarının daha rahat bir şekilde tespit edilebildiği görülmektedir (Şekil 15). VOR-Mahalanobis algoritmasında tüm durumların birlikte ele alınması sonucu bulunan AİK eğrileri Şekil 16’da gösterilmiştir. Her kanaldaki EAA değerinin 0,6 civarlarında, dolayısıyla hasar belirleme performansının düşük olduğu gözlemlenmiştir.




Şekil 14. Her bir durum için VOR-Mahalanobis tekniğinin uygulanması sonucu elde edilen AİK eğrileri (ROC curves obtained from VAR-Mahalanobis technique for each case)

Tablo 8. VOR-Mahalanobis tekniğinin uygulanması sonucu elde edilen AİK-EAA sonuçları (ROC-AUC results of VAR-Mahalanobis technique)

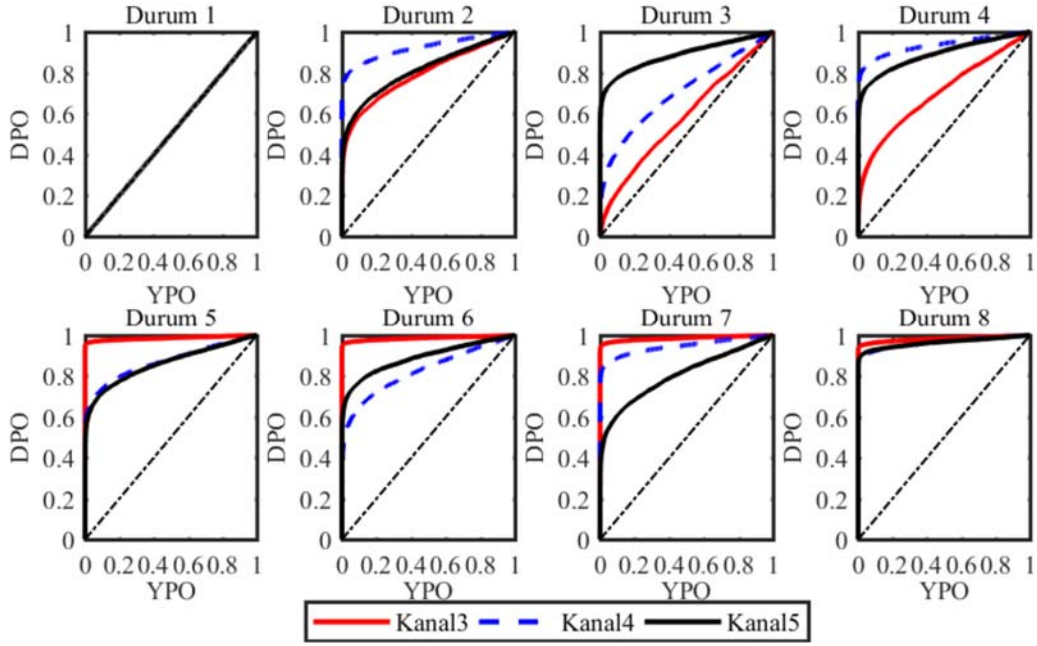
Durum No	Test Adeti	Kanal			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	8	0,5000	0,5000	0,5000	0,5000
2	8	0,5026	0,8840	0,9849	0,9030
3	8	0,5028	0,3593	0,6032	0,8718
4	8	0,5125	0,5149	0,9978	0,9292
5	8	0,5165	0,9995	0,6545	0,5002
6	8	0,4912	0,9998	0,6455	0,6406
7	8	0,5348	1,0000	0,8916	0,7519
8	8	0,5168	0,9785	0,7473	0,8047



Şekil 15. Durum 1 [sağlıklı] ve Durum 8 [hasarlı] için normalize edilmiş VOR-Mahalanobis hasar indeks büyüklüğü (Normalized VAR-Mahalanobis damage index magnitudes for Case 1 [healthy] and Case 8 [damaged])



Şekil 16. Tüm durumlar için VOR-Mahalanobis uygulanması sonucu elde edilen AİK-EAA eğrisi hasar tespit sonuçları (Damage diagnosis results of ROC-AUC curves obtained from VAR-Mahalanobis for all cases)

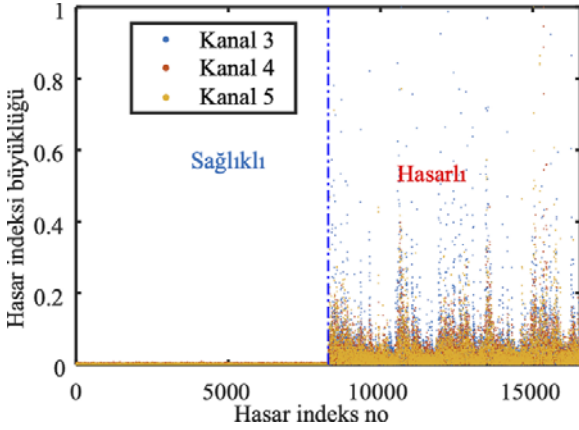


Şekil 17. Her bir hasar durumu için VOR-ABA uygulanması sonucu elde edilen AİK eğrileri (ROC curves obtained from VAR-PCA for each case)


Tablo 9. VOR-ABA tekniğinin uygulanması sonucu elde edilen AİK-EAA sonuçları (ROC-AUC results of VAR-PCA technique)

Durum No	Test Adeti	Kanal			
		Kanal 2	Kanal 3	Kanal 4	Kanal 5
1	8	0,5000	0,5000	0,5000	0,5000
2	8	0,5234	0,7944	0,9219	0,8140
3	8	0,5123	0,5825	0,7067	0,8878
4	8	0,5046	0,6997	0,9340	0,8900
5	8	0,5083	0,9863	0,8706	0,8604
6	8	0,5105	0,9859	0,8251	0,8904
7	8	0,4904	0,9854	0,9459	0,8051
8	8	0,5114	0,9820	0,9633	0,9640

Son olarak, VOR artık hata değerlerinin asal bileşenler analizinde (ABA) işlenmesiyle elde edilen AİK eğrileri Şekil 17’de ve EAA değerleri ise Tablo 9’da gösterilmiştir. VOR-ABA yaklaşımı uygulanarak durum 3’teki hasar hariç ($EAA < 0,9$) diğerleri “mükemmel” ($EAA > 0,9$) bir şekilde belirlenebilmiştir. Ancak, bazı katlarda hasar olmadığı halde bu katlarda yer alan sensörlerden (Durum 2 kanal 5; Durum 5, kanal 4-5; Durum 6, kanal 4; Durum 7, kanal 5) “yanlış hasar” bilgisi oluşmuştur. Ancak EAA’nın 0,89’dan büyük değerleri hasar eşiği olarak kabul edildiğinde hassas sonuçlar alındığı görülmüştür. VOR-ABA tekniği kullanılarak durum 1 ve 8 için elde edilen hasar indeks dağılımları Şekil 18’de gösterilmiştir. Her kanal verisi 8282 noktadan oluşmakta ve en iyi başarı sırasıyla kat I, II ve III’te görülmüştür. Son olarak, 8 durum kombinasyonunun birlikte alınıp hasarın belirlenmesine ilişkin bulunan AİK eğrileri Şekil 19’da verilmiştir. VOR-ABA algoritmasının kat I, II ve III’te olası hasar kombinasyonlarını belirleyebilme performansı açısından değerlendirildiğinde kat I ve II’de “mükemmel” ($EAA > 0,9$), III’te ise “orta düzeyde” ($0,9 > EAA$) tespit edebildiği görülmüştür.



Şekil 18. Durum 1 ve Durum 8 için normalize edilmiş VOR-ABA hasar indeks büyüklüğü (Normalized VOR- PCA damage index magnitudes for Case 1 and Case 8)



Şekil 19. Tüm durumlar için VOR-ABA uygulanması sonucu elde edilen AİK-EAA eğrisi hasar tespit sonuçları (Damage diagnosis results of ROC-AUC curves obtained from VAR-PCA for all cases)


5. SONUÇLAR (CONCLUSIONS)

Bu çalışmada veriye bağlı örutü tanıma algoritmaları kullanılarak doğrusal davranış sergilemeyen cıvata gevşeme hasarının tespit edilmesi hedeflenmiştir. Çalışma üç katlı bir sistem üzerine uygulanmıştır. Başlangıçta tasarımı ve imalatı gerçekleştirilen üç katlı sisteme ilişkin elemanların montajları yapılmıştır. Sonra döşeme katlarında yer alan elemanların bağlantıları cıvatalar ile sağlanmış ve bunlar farklı kombinasyonlarda gevşetilerek çeşitli hasar senaryoları oluşturulmuştur. Mühendislik sistem ve yapıları yük, sıcaklık, nem veya sismik koşul değişkenliği gibi geniş genlikli bir spektrum aralığında çalışmaktadır. Bu tarz değişimlerin simülasyonlarını gerçekleştirmek için sistem 15-150 Hz frekans aralığında rastgele uyarım sinyalleriyle titreştirilmiştir. Sistemde 8 farklı durum incelenmiş ve her bir durum için 8 tekrarlı veri seti toplanmıştır. Daha sonra bu verilerin her birisi için vektör otoregresif modeli kurularak VOR parametreleri ve artık hata değerleri bulunmuştur. Artık hata değerleri hem tek başlarına hem de ABA ile, VOR parametreleri ise TDA ve Mahalanobis uzaklığı gibi yöntemlerde işlenip hasar indeksleri bulunmuştur. Son olarak, bu hasar indeksleri alıcı işletim karakteristik eğrilerinde görselleştirilmiş ve uygulanan her bir tekniğin nihai EAA performansı Şekil 20’de verilmiştir.

Bu kapsamda çalışmadan elde edilen çıkarımlar aşağıda verilmiştir.

- Çoklu durumda sistemde cıvata gevşemesinin olup olmadığı araştırılmıştır. Bu amaçla durum 1 (sağlıklı) verileri öğrenme sürecinde, kalan 7 durum verileri ise test aşamasında birlikte kullanılmıştır. Ortalama EAA sonuçları açısından yukarıdan aşağıya doğru sırasıyla VOR-ABA (0,8714), VOR- ϵ^2 (0,8350), VOR-Mahalanobis (0,6089), ve VOR-TDA (0,6061) olarak gerçekleşmiştir.
- İkili durumda hangi cıvata veya cıvatalarda gevşemenin olduğu belirlenmiştir. 1’inci durum verileri öğrenme sürecinde kalan 7 durumun her biri ayrı ayrı test aşamasında uygulanmıştır. Ortalama EAA açısından büyükten küçüğe doğru sırasıyla VOR-ABA (0,9402), VOR-Mahalanobis (0,9184), VOR- ϵ^2 (0,9170) ve VOR-TDA (0,8352) şeklinde bulunmuştur.
- Her algoritmanın ikili durum sınıflandırma başarısının çoklu duruma göre daha yüksek olduğu tespit edilmiştir. Bu sonuç hasarlı durumu sağlıklıdan ayırmanın kolay olduğunu, bir diğer cıvata gevşemesinden kaynaklanan hasardan ayırt etmenin ise güçlülüğünü göstermektedir.

Her bir algoritma sistemin üç katında da hasar olma durumu için değerlendirildiğinde AİK karakteristik eğrilerinin optimum noktaları sırasıyla VOR-ABA (0,01; 0,91), VOR- ϵ^2 (0,02; 0,89) ve VOR-TDA (0,34; 0,74), VOR-Mahalanobis (0,03; 0,67) şeklindedir. Parantez içerisinde verilen ilk büyüklük “yanlış pozitif oranı” (YPO) bir başka deyişle hatalı tespiti, ikincisi ise “doğru pozitif oranı” (DPO) ya da doğru tespiti göstermektedir. Elde edilen bulgular ışığında VOR modelinin ABA ile birlikte kullanılması durumunda en başarılı hasar tespitlerinin gerçekleştirildiği görülmüştür.



Şekil 20. Hasar belirlemede VOR- ϵ^2 , VOR-Mahalanobis, VOR-TDA ve VOR-ABA tekniklerinin uygulanması sonucu elde edilen EAA verileri (Damage detection results in terms of AUC scores for VAR- ϵ^2 , VAR-Mahalanobis, VAR-SVD and VAR-PCA)

Bu çalışmada gevşemenin olduğu civatalar her ne kadar başarılı bir şekilde tespit edilmiş olsa da ilerleyen süreçlerde aşağıda sıralanan hususların göz önünde bulundurulması gerekir.

- İkinci ve üçüncü katın her birinde yer alan sensör hem kendi buldukları katlardaki hasardan hem de alt katlarındaki hasarlardan etkilenmiş olduğu görülmüştür. Örneğin kat I hasarı, kat II ve III'te yer alan sensörleri, kat II hasarı ise kat III sensörünü etkilemiştir. Bu durum bazı yanlış hasar tespitlerinin gerçekleştirilmesine neden olmuştur. İlerleyen çalışmalarda VOR artık hata verilerinin Gauss karışımı, Markov rejim geçişleri veya Copula gibi modellerde işlenmesinde yarar vardır. Böylece değişkenliğe neden olan her dış faktör algoritma tarafından ayrıştırılabilecektir.
- İncelenen sistem gerçek bir mühendislik sisteminin birebir benzeri olmayıp tamamen hasar benzetimleri için tasarlanıp imal edilmiştir. Bu sebeple kullanılan yöntemlerin gerçek bir sisteme uygulanmasında fayda vardır.

TEŞEKKÜR (ACKNOWLEDGEMENT)

Yazar, bu çalışma ile ilgili sundukları değerli fikir ve yorumlarından dolayı Ege Üniversitesi Makina Mühendisliğinden Prof. Dr. Hasan Yıldız'a, Los Alamos Araştırma Laboratuvarı Mühendislik Enstitüsünden Dr. Charles R. Farrar ve Dr. David Mascarenas'a teşekkür eder. Bu çalışmanın bir kısmı Ege Üniversitesi Bilimsel Araştırma Projeleri kapsamında 17-ÜYDAUM-001 numarası ile desteklenmiştir.

KAYNAKLAR (REFERENCES)

1. Balageas D., Fritzen C-P. and Guemes A., Structural Health Monitoring, ISTE Ltd, London, UK, 2006.
2. Farrar C.R., Worden K., Structural Health Monitoring: A Machine Learning Perspective, John Wiley & Sons Ltd., 2013.
3. Pekedis M., Mascarenas D., Turan G., Ercan E., Farrar C.R., Yıldız H., Structural health monitoring for bolt loosening via a non-invasive vibro-haptics human-machine cooperative interface, Smart Materials and Structures, 24, 085018, 2015.
4. Farrar C.R., Duffey T. A., Doebling S.W., Nix D.A., A statistical pattern recognition paradigm for vibration-based structural health monitoring, Proceedings of the 2nd International Workshop on Structural Health Monitoring, Technomic Publishing, Lancaster, PA, 764-773, 1999.
5. Pekedis M., Yıldız H., Damage diagnosis of a laminated composite beam and plate via model based structural health monitoring techniques, Journal of the Faculty of Engineering and Architecture of Gazi University, 31 (4), 813-831, 2016.
6. Hughes A.J., Barthorpe R.J., Dervilis N., Farrar C.R., Worden K., A probabilistic risk-based decision framework for structural health monitoring, Mechanical Systems and Signal Processing, 150, 107339, 2021.
7. Doebling SW., Farrar CR. ve Prime MB., A summary review of vibration-based damage identification methods, Shock Vbr Dig, 20, 91-105, 1998.
8. Pekedis M., Kompozit malzemeler için yapı izleme ve bakım sistemi, Doktora tezi, Ege Üniversitesi, Fen Bilimleri Enstitüsü, 2014.

9. Carden EP., Funning P., Vibration based condition monitoring: A review, *Structural Health Monitoring*, 3 (4), 355-77, 2004.
10. Hamey CS., Lestari W., Qiao P., Song G., Experimental damage identification of carbon/epoxy composite beam using curvature mode shapes, *Structural Health Monitoring*, 3 (4), 333-53, 2004.
11. Sohn H., Farrar C.R., Damage diagnosis using time series analysis of vibration signals, *Smart Materials and Structures*, 10, 446-451, 2001.
12. Liu G.R., Han X., *Computational Inverse Techniques In Nondestructive Evaluation*, CRC Press LLC, Boca Raton, Florida, 2003.
13. Inman D.J., *Vibration with control*, John Wiley & Sons Inc., Chichester, England, 2006.
14. Farrar C.R. ve Worden K., An introduction to structural health monitoring, *Phil. Trans. R. Soc. A*, 365, 303–315, 2007.
15. Sohn H., Worden K., Farrar C.R., Statistical damage classification under changing environmental and operational conditions, *Journal of Intelligent Material Systems And Structures*, 13, 561-574, 2002.
16. Tuncer T., A novel image authentication method based on singular value decomposition, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 32 (3) 877-886, 2017.
17. Eris E., Aksoy H., Onoz B., Cetin M vd., Frequency analysis of low flows in intermittent and non-intermittent rivers from hydrological basins in Turkey. *Water Science and Technology: Water Supply*, 19 (1), 30-39, 2019.
18. Figueiredo E., Park G., Farrar C.R., Worden K., Figueiras J., Machine learning algorithms for damage detection under operational and environmental variability, *Structural Health Monitoring*, 10 (6) 559–572, 2010.
19. Mosavi A.A., Dickey D., Seracino R., Rizkalla S., Identifying damage locations under ambient vibrations utilizing vector autoregressive models and Mahalanobis distances, *Mechanical Systems and Signal Processing*, 26, 254–267, 2012.
20. Liu A., Wang L., Bornn L., Farrar C.R., Robust structural health monitoring under environmental and operational uncertainty with switching state-space autoregressive models, *Structural Health Monitoring*, 18 (2), 435–453, 2018.
21. Worden K., Cross E.J., On switching response surface models, with applications to the structural health monitoring of bridges, *Mechanical Systems and Signal Processing*, 98, 139–156, 2018.
22. Shi H., Worden K., Cross E.J., A regime-switching cointegration approach for removing environmental and operational variations in structural health monitoring, *Mechanical Systems and Signal Processing* 103, 381–397, 2018.
23. Johansen S., *Likelihood -based inference in co integration vector auto-regressive models*, Oxford University Press Inc, Newyork, USA, 1995.
24. Krolzig H.M., *Markov-Switching vector auto regressions, Modeling, Statistical inference, and application to business cycle analysis*, Springer-Verlag, Berlin, Heidelberg, Newyork, USA, 1997.
25. Ljung L., *System identification -theory for the use*, Prentice Hall, Englewood Cliffs, NJ, USA, 1987.
26. Schwarz G., Estimating the dimension of a model. *Annals of statistics*, 6 (2), 461-464, 1978.
27. Abdi H. ve Williams L.J., *Principal component analysis* WIREs Comp Stat, 2, 433–459 , 2010.
28. Durmus G., Sogukpinar I., A novel approach for analyzing buffer overflow vulnerabilities in binary executables by using machine learning techniques, *Journal of the Faculty of Engineering and Architecture of Gazi University*, 34 (4), 1695-1704, 2019.
29. Šimundić A. M., Measures of Diagnostic Accuracy: Basic Definitions, *EJIFCC*, 19 (4), 203–211, 2009.