

Kısmi gözlemlenebilir çok bileşenli sistemler için bakım politikalarının pekiştirmeli derin öğrenme yöntemleri ile belirlenmesi

Determining maintenance policies for partially observable multi-component systems with deep reinforcement learning

Oktay KARABAG^{1*}

¹İzmir Ekonomi Üniversitesi, İzmir, Türkiye.
oktay.karabag@ieu.edu.tr

Geliş Tarihi/Received: 07.01.2024
Kabul Tarihi/Accepted: 30.06.2024

Düzeltilme Tarihi/Revision: 25.06.2024

doi: 10.5505/pajes.2024.33969
Araştırma Makalesi/Research Article

Öz

Bu çalışmada, kısmi gözlemlenebilir çok bileşenli sistemler için bakım/onarım kararları incelenmiştir. Bu tip sistemler genellikle servis sağlayıcının uzakta olduğu koşullarda işletilmekte ve bileşenlerin aşınma seviyeleri genellikle sensörler yardımı ile tam olarak izlenememektedir. Rüzgâr türbinleri, bu tarz sistemlere birebir uyan bir örnek oluşturmaktadır. İlgili sistemlerde, servis sağlayıcı ne zaman bakım/onarım yapacağına, bakım kararı ile birlikte hangi parçaları bakım noktasına sevk edeceğine ve bakım noktasındaki incelemenin ardından hangi sistem bileşenlerinin değiştirilmesi gerektiğine karar vermektedir. Çalışmamızda, bahsi geçen bu komplike karar problemi kısmi gözlemlenebilir Markov karar süreci olarak modellenmiş ve ilgili nümerik çözümler aktör kritik pekiştirmeli öğrenme yöntemi kullanılarak elde edilmiştir. Yaptığımız nümerik çalışmalar, pekiştirmeli öğrenme algoritması ile elde edilen çözümlerin pratikte ve literatürde yaygın olarak kullanılan sezgisel bakım/onarım politikalarına kıyasla daha iyi sonuçlar verdiğini göstermiştir. Bazı durumlarda, bu çözümlerin ortalamada %10-%15 düzeyinde bir iyileştirme sağladığı gözlemlenmiştir. Ayrıca, düzeltici bakım maliyeti, acil sipariş maliyeti ve fazla yedek parçayı geri döndürme maliyeti arttıkça, pekiştirmeli öğrenme algoritması ile elde edilen çözümlerin diğer sezgisel politikalara kıyasla daha fazla avantaj sağladığı da belirlenmiştir.

Anahtar kelimeler: Kısmi gözlemlenebilir çok bileşenli sistemler, Kısmi gözlemlenebilir Markov karar süreçleri, Pekiştirmeli öğrenme metodları, Koşula bağlı bakım problemleri.

Abstract

In this study, maintenance decisions for partially observable multi-component systems are investigated. Such systems typically operate under conditions where the service provider is remote, and the wear levels of system components cannot be fully monitored with sensors' assistance. Wind turbines provide a good example of these systems. For such systems, besides deciding when the service provider will perform a maintenance intervention, it is also necessary to determine which parts will be taken along to the maintenance point and which components will be replaced after the inspection at the maintenance point. In our study, this complex decision problem is modeled as a partially observable Markov decision process, and related numerical solutions are obtained employing the actor-critic reinforcement learning method. Our numerical studies demonstrate that the policies obtained with the reinforcement learning algorithm outperform several heuristic maintenance policies that are frequently used in practice and well-known in the relevant literature. In some cases, compared to heuristic policies, these solutions have provided a cost reduction in the range of 10-15% on average. Additionally, it has been observed that the solution obtained with the reinforcement learning algorithm provides more advantages compared to heuristic policies, as the corrective maintenance cost, emergency order cost, and returning cost of excess spare parts increase.

Keywords: Partially observable multi-component systems, Partially observable Markov decision processes, Reinforcement learning methods, Condition-based maintenance problems.

1 Giriş

Karmaşık ve birden fazla bileşen içeren makinelerin veya sistemlerin gündelik yaşamımızdaki yerleri ve önemleri giderek artmaya başlamıştır. Örnekler enerjiden sağlığa, üretimden savunma sanayiye kadar birçok alanda kendini göstermektedir. Spesifik olmak gerekirse, enerji üretimlerinde kullanılan rüzgâr türbinleri, hastanelerde tanı için kullanılan MR, ultrason vb. araçlar ve askeri amaçlarla kullanılan radarlar, bu tarz sistemlere ve makinelere iyi birer örnek olabilir. Bu tarz sistemler çoğu zaman kullanıcıları için kritik öneme sahiptirler. Bu sistemlerdeki öngörülemeyen arıza ve bozulmalar, çeşitli performans ölçütlerinde (gelir, servis zamanı, vb.) ciddi kayıplara neden olabilmektedirler. Bu tarz kayıpları önlemek adına ilgili sistemlere/makinelere ilişkin bakım planlarının hassasiyetle ve iyi planlanarak yapılması gerekmektedir.

Koşula bağlı bakım politikaları, bu tarz sistemleri daha verimli bir şekilde yönetmek ve bakımlarını etkili bir şekilde planlamak

için geliştirilmiştir. Diğer bir deyişle, koşula bağlı bakım politikaları, bakıma bağlı maliyetlerin azaltılmasını, güvenilirliğinin artırılmasını ve bileşenlerin kullanım ömrünün olabildiğince en yüksek seviyeye çıkarılmasını hedeflemektedir. Bu politika-nın, bazı durumlarda bakım maliyetlerinde %50'den fazla tasarruf sağladığı bile görülmektedir [1].

Koşula bağlı bakım politikaları, genellikle sistemden gerçek zamanlı olarak toplanan sıcaklık, ses, titreşim ve/veya güç tüketimi gibi durum izleme bilgilerine bağlıdır. Son yıllarda gelişen internet teknolojileri sayesinde, çok bileşenli ve karmaşık sistemlerden gerçek zamanlı veri toplama ve elde edilen bu verileri başka bir ortama aktarıp onları analiz etme giderek kolaylaşmaya başlamıştır. Bu durum, koşula bağlı bakım politikalarının pratikte uygulanabilirliğine daha fazla olanak tanımış ve bu politikaları giderek daha popüler hale getirmiştir. Bunun bir sonucu olarak, akademik yazında bu konuyla ilgilenen çalışmaların sayısı giderek artmaya başlamıştır. [2] ve [3] koşula bağlı

*Yazışılan yazar/Corresponding author

bakım politikalarına ilişkin detayları ve akademik yazını kapsamlı bir şekilde derlemiş ve tartışmıştır.

Sistemde bulunan her bir bileşenin sensör ile donatılması ve her bir bileşene ilişkin bozulma durum bilgisinin toplanması, ekonomik ve/veya gizlilik gibi sebeplerden ötürü mümkün olmayabilir. Bu gibi durumlarda, koşula bağlı bakım politikaları sistemin genel durumu hakkında bilgi içeren özetlenmiş sinyaller kullanılarak uygulanır. Özet bilginin kullanıldığı durumlarda, bileşenlerin aşınma seviyelerinin bakıma gitmeden önce tam olarak gözlenmemesinden ötürü, bakım noktasına doğru yedek parça sevkiyatının yapılmaması riski ortaya çıkmaktadır. Spesifik olmak gerekirse, bakım noktasına ulaşıp sistemde gerekli incelemeler tamamlandıktan sonra hangi bileşenlerin değiştirileceğine karar verilmektedir. Alınan bu kararlar birlikte, bazı gerekli parçaların bakım noktasına sevk edilmediği fark edilebilir ve/veya bazı parçaların gereksiz yere bakım noktasına sevk edildiği gözlemlenebilir. Bu fazla ve/veya eksik parçaların her biri için de bakım sağlayıcı bazı ek maliyetlere katlanmak zorunda kalmaktadır. Dolayısıyla, böyle bir sistem için, ne zaman bakım yapılacağı, alınan bakım kararıyla birlikte hangi parçaların bakım noktasına sevk edileceği ve sistem yerinde inceledikten sonra hangi bileşenlerinin değiştirileceği kararları son derece önem arz etmektedir. Benzeri karar problemleri rüzgâr türbinlerinde, litografi makinelerinde ve medical araçlarda sıklıkla gözlenmektedir [2,4,5,6].

Bu çalışmada, kısmi gözlemlenebilir çok bileşenli bir sistem göz önünde bulundurulmakta ve bu sisteme ilişkin koşula bağlı bir bakım problemi incelenmektedir. İncelenen problemde, ilgili sistemdeki bileşenlere ilişkin aşınma seviyelerinin bakım noktasına gidilmeden tam olarak gözlemlenemeyeceği varsayılmaktadır. İncelenen sistemin genel durumu hakkında bilgi veren üç seviyeli bir sinyalin, periyodik aralıklarla toplandığı kabul edilmektedir. Diğer bir deyişle, sistemin genel durumu yeşil, sarı ve kırmızı renkte üç farklı sinyal ile özetlenmektedir. Yeşil sinyal sistemin sorunsuz çalışmakta olduğunu, sarı sinyal sistemdeki bileşenlerde kısmi bozulmaların olmasına rağmen sistemin işlevine devam etmekte olduğunu, kırmızı sinyal ise sistemin tamamen bozulup artık işlevsiz hale geçtiğini göstermektedir. Buradaki temel amaç, periyodik olarak alınan bu sinyalleri kullanarak incelenen sistem için ne zaman bakım yapılacağına, bakım kararı alınması durumunda bakım noktasına hangi yedek parçaların sevkiyatının yapılacağına ve sistem yerinde inceledikten sonra hangi bileşenlerinin değiştirilmesi gerektiğine karar vermektedir. Çalışmada ilk olarak, bu kısmi sinyalleri ileten tek bir sensör olduğu düşünülmüş ve bahsi geçen bu kararlar incelenen sistem için göz önünde bulundurulmuş ortalama uzun dönem maliyet fonksiyonunu en küçükleyecek şekilde elde edilmiştir. Daha sonrasında ise, sistemdeki bileşenlere ilişkin aşınma seviyelerini tam olarak gösterebilecek ek sensörlerin de var olduğu varsayımı göz önünde bulundurulmuş ve bu hassas sensörlerin hangi sistem bileşenlerine konuşturulmasının maliyet açısından daha verimli olacağı sorusuna nümerik analizler aracılığıyla cevap aranmıştır.

Çalışmamızda, bu karmaşık karar problemi kısmi gözlemlenebilir Markov karar süreci olarak modellenmiştir. Bu probleme ilişkin nümerik çözümler ise aktör kritik pekiştirmeli öğrenme algoritması kullanılarak elde edilmiştir. Ayrıca, bu çözüm yöntemi ile elde edilen politikalar, pratikte sıklıkla kullanılan ve nispeten uygulanması daha kolay olan sezgisel bakım politikaları ile karşılaştırılmıştır. Özetle, çalışmamızda, aşağıda listelenen araştırma sorularına cevap aranmıştır:

1. Kısmi gözlemlenebilir çok bileşenli sistemler için en-

tegre bir bakım planlama, yedek parça getirme ve bileşen değiştirme kararı aktör kritik pekiştirmeli öğrenme algoritması kullanılarak bulunabilir mi?

2. Sistemdeki bileşenlerin aşınma seviyelerini tam olarak gösterebilecek sensörlerin var olması durumunda, bunlar sistemdeki hangi bileşenlere konuşturulmalıdır? Bu durum entegre bakım politikasında maliyet açısından ne ölçüde bir iyileşme sağlayacaktır?
3. Aktör kritik pekiştirmeli öğrenme algoritması kullanılarak elde edilen entegre karara ve sistem bileşenlerine ilişkin aşınma seviyelerini tam olarak gösteren ek sensörlere sahip olmanın, bakım maliyetlerinde sağladığı iyileştirme miktarına, sistem parametrelerinin etkileri nelerdir?
4. Hangi durumlarda aktör kritik pekiştirmeli öğrenme algoritması kullanılarak elde edilen entegre kararlar, pratikte sıklıkla kullanılan sezgisel bakım politikalarına kıyasla maliyet açısından daha etkili olmaya başlar?

Çalışmamız bu soruları göz önünde bulundurarak, ilgili literatüre üç farklı açıdan katkı sağlamaktadır.

1. Literatürde, kısmi gözlemlenen çok bileşenli sistemlere ilişkin bakım problemleri benzeri varsayımlar altında daha önce incelenmiştir. Ancak, bu incelemelerde, bileşen değiştirme kararı önceden belirlenen bir eşik seviyesine bağlanmış ve bakım noktasında yapılan incelemenin ardından aşınma seviyesi ilgili eşik değerinin üzerindeki tüm bileşenlerin yenileri ile değiştirildiği göz önünde bulundurulmuştur. İlgili çalışmalardan farklı olarak, ilk defa bu çalışmada, sistemde değiştirilecek bileşenler bir optimizasyon modeli aracılığıyla belirlenmiştir.
2. İlk defa bu çalışmada, aktör kritik pekiştirmeli öğrenme metodu kısmi gözlemlenen çok bileşenli sistemlerde bakım planlama, yedek parça getirme ve bileşen değiştirme kararlarını entegre bir şekilde optimize etmek için kullanılmıştır.
3. Literatürdeki hiçbir çalışma, sistemdeki bileşenlerin aşınma seviyelerini tam olarak gösterebilecek sensörlerin var olması durumunu, kısmi gözlemlenebilir çok bileşenli sistemler için göz önünde bulundurulmuş ve bu sensörlerin bu tarz sistemlerde bulunan hangi bileşenlere konuşturulacağı problemini incelememiştir. İlgili problem ilk defa bu çalışmada ele alınmış ve literatüre bu açıdan da özgün bir katkı sağlanmıştır.

Makalenin geriye kalan kısmı şu şekilde organize edilmiştir. Literatür taraması kısmında, ilgili akademik yazın derlenmiş ve çalışmanın var olan yazından nasıl farklılaştığı tartışılmıştır. Bir sonraki başlıkta ise, geliştirilen matematiksel model sunulmuş ve kullanılan çözüm algoritmasının detayları verilmiştir. Nümerik analiz kısmında, nümerik çözümde kullanılan algoritmaya ilişkin parametrelerin nasıl belirlendiği, nümerik analizde incelenen problemlerdeki parametrelerin nasıl seçildiği ve belirtilen araştırma sorularına ilişkin nümerik analizler tartışılmıştır. Sonuç kısmında, makalenin bulguları özetlenmiş, nümerik analizden elde edilen öngörüler sunulmuş ve bu çalışmanın hangi yöne doğru genişletilebileceği tartışılmıştır.

2 Literatür taraması

Son yıllarda, koşula bağlı bakım problemleri hem pratikte hem

de akademik yazında oldukça fazla ilgi çekmeye başlamıştır. Bu bağlamda, [2], [3], [7] ve [8] ilgili yazını derleyerek, bu yazındaki çalışmalar hakkında kapsamlı tartışmalar sunmuşlardır. Ayrıca, benzeri bakım problemlerine envanter kararları da dahil edilmiş olup, literatür bu yönde de ilerleme kaydetmiştir. [9] ise bu alandaki çalışmaları özelliklerine göre gruplandırıp, kapsamlı bir derleme ortaya koymuştur. Çalışmamızda sunulan literatür taramasında, Markov karar süreçlerini, makine öğrenmesini ve/veya yapay zekâ modelleme yaklaşımlarını, bakım problemlerini ele almak üzere benimseyen çalışmalara yer verilmiştir. Bu bağlam dışındaki diğer tüm çalışmalar ve bunlara ilişkin detaylar için yukarıda bahsi geçen literatür derleme makalelerine başvurulabilir.

Markov karar süreçlerini temel alan modelleme yaklaşımları, tek bileşenli sistemlerde koşula bağlı bakım problemlerini incelemek için uzunca bir süredir sıklıkla kullanılmaktadır. Bu araştırma akışındaki öncü çalışmalardan biri olarak, [10] tek bileşenli bir sisteme odaklanmış ve bu sistemin hem sürekli bozulmaya maruz kaldığını hem de kısmi gözlemlenebilir olduğunu kabul etmiştir. İlgili çalışmada, bu tarz bir sistemin ne zaman bakıma alınacağına ve hangi aralıklarla operatörler tarafından inceleneceğine ilişkin kararlar kısmi gözlemlenebilir Markov karar modeli yaklaşımı ile incelenmiştir. [11], [10]'da ortaya atılan bakım problemine benzer bir problemi ele almıştır. Ancak, ilgili çalışmadan farklı olarak, yazarlar ele aldıkları makinenin çevrimiçi şekilde uzaktan takip edilebildiğini ve bu takip için herhangi bir operatör müdahalesine gerek duyulmadığını varsaymışlardır. Buna ek olarak, değer iterasyon ve λ -minimizasyon algoritmalarını entegre edip kısmi gözlemlenebilir Markov karar modellerine nümerik olarak çözüm sağlayan bir yöntem de geliştirmişlerdir. Bu sayede, ilgili literatür akışına metodolojik açıdan katkı sağlamayı da başarmışlardır. [12] tek bileşenli kısmi gözlemlenebilir bir sistem için hem optimal bakım politikasını bulabilecek hem de sistemin aşınma seviyesi ile ilgili tahminlemeleri iyileştirebilecek pekiştirmeli öğrenme yaklaşımına dayalı bir yöntem sunmuş ve bu entegre yaklaşımın sağlayabileceği faydaları nümerik analizler aracılığıyla incelemiştir.

Literatürde birden fazla bileşenli sistemlerde koşula bağlı bakım problemlerini, Markov karar süreçleri ile inceleyen çalışma sayısı nispeten daha az bulunmaktadır. Bunun en önemli nedenlerinden biri ise bileşen sayısının artmasıyla birlikte problemin analizinde ortaya çıkan zorluklar ve karmaşıklıklardır. Bu alanda yakın zamanda yayınlanan önemli çalışmalardan biri olarak [13] örnek verilebilir. [13] uçak filosu bakım optimizasyonu ile ilgilenmiş ve problemi literatürdeki diğer çalışmalardan farklı birkaç açıdan ele almıştır. Yazarlar, diğer çalışmalardan farklı olarak, geliştirdikleri modelde dört farklı bakım tipini göz önünde bulundurmuş ve nümerik analizlerinde çözüm elde etmek için derin öğrenme yöntemlerini kullanmışlardır. Ayrıca, bakımda kullanılacak sınırlı sayıda kaynağın var olmasını, filo kullanılabilirliğinin belirli bir seviyenin üstünde olması gerekliliğini ve filo çizelgelemelerinde bakımdan ötürü yaşanabilecek aksaklıkları ise belirli bir seviyenin altında tutma hedefini birer kısıt olarak modellerine dahil etmişlerdir. Ayrıca [14], [15], [16] ve [17]'de derin öğrenme metodlarını benimsemiş ve bu metod ve türevlerini kullanarak farklı endüstrilerden esinlenilmiş koşula bağlı bakım problemlerini incelemiştir. Bunlardan farklı olarak, [5] kısmi gözlemlenebilir çok bileşenli sistemlerde bakım ve yedek parça kararına odaklanmış ve modelleme aracı olarak da kısmi gözlemlenebilir Markov karar süreçlerini benimsemiştir. Yazarlar, ilgilendikleri bu probleme ilişkin nümerik çözümleri elde edebilmek için [18] tarafından geliştiren

uzgara tabanlı bir çözüm algoritması kullanmışlardır. Yazarların kullandıkları çözüm algoritması "boyutsallık laneti" sebebiyle ancak iki bileşenli sistemler için makul sürelerde çözüm sağlamıştır. İlgili çalışmada, üç bileşenli sistemler için nümerik çözümlerin süper bilgisayarlar kullanılmasına rağmen ancak bir haftada elde edildiği vurgulanmıştır. Bir devam çalışması olarak [4], [5]'te incelenen problemi tekrar ele almak ancak daha önceki girişimlerinden farklı olarak ilgili problemi bir Markov karar süreci olarak modellemiştir. Yazarlar, ilgilendikleri probleme ilişkin nümerik çözümleri ise doğrusal programlama yardımı ile elde etmişlerdir. Bu sayede, kısmi gözlemlenebilir Markov karar süreçlerinin kullanılması yüzünden ortaya çıkan boyutsallık lanetinden kurtulmayı başarmış ve kullanılan bu yeni çözüm ve modelleme yaklaşımı sayesinde daha büyük problem boyutlarını makul sürelerde inceleyebilmişlerdir. Aynı literatür akışında, [19] kısmi gözlemlenebilir Markov karar süreçlerinde kullanılan farklı çözüm yaklaşımlarını gözden geçirmiş ve bunlara ilişkin kapsamlı bir derleme sunmuştur. Buna ek olarak, çalışmada erişimi ve kullanması kolay "al-kullan" tipi çözüm yaklaşımlarından bazıları seçilmiş; seçilen bu yaklaşımlar, durum uzay boyutu farklı karmaşıklıklara sahip kısmi gözlemlenebilir bakım problemlerinde uygulanmış ve bu yaklaşımların ilgili bakım problemlerinde sergiledikleri performanslar zaman ve çözüm kalitesi açısından değerlendirilmiştir.

Veri toplama ve işleme süreçlerinin son yıllarda gelişen internet teknolojileri ile daha kolay erişebilir ve daha ucuz olması sebebiyle makine öğrenmesi ve yapay zekâ metodları, kestirimci bakım problemlerinde de sıklıkla kullanılmaya başlanmıştır. Bu alanda yakın zamanda yapılmış çalışmalardan biri olarak [20] örnek verilebilir. Bu çalışmada, yazarlar bir döküm fabrikasında kullanılan makine için kestirimci bakım politikası uygulamaya çalışmıştır. Bu amaç doğrultusunda, yazarlar, yaklaşık 6 aylık bir veri seti toplamış ve elde edilen verileri temel bileşen analizi ve rastgele orman makine öğrenmesi yöntemlerini kullanarak incelemiştir. Uygulanan bu yöntem sayesinde, bakım zamanı tahminlerinde %85,17'lik bir başarı oranı yakalanmıştır. [21], [20]'de incelenen kestirimci bakım problemine benzer bir problemi destek vektör makineleri yöntemini kullanarak incelemiştir. [22] metro trenlerinin bakım planlamasına yönelik bir yapay sinir ağı modeli geliştirmiş ve Ankara metrosundan elde ettikleri veriye bu modeli uygulayarak servis oranlarında yaklaşık %40'lık bir iyileştirme sağlanabileceğini göstermiştir. [23] ise toplu taşıma için kullanılan otobüslerde makine öğrenmesine dayalı kestirimci bakım problemine odaklanmış ve analizlerinde rastgele orman ve bulanık mantık modelleme tekniklerini benimsemiştir. [20], [21], [22] ve [23] tam gözlemlenebilir sistemler için kestirimci bakım problemlerine odaklanmış, [24] ise bunlardan farklı olarak kısmi gözlemlenebilir sistemlere ilişkin kestirimci bakım problemleri üzerinde çalışmıştır. Diğer bir deyişle, [24] sistem durumuna ilişkin direkt bilgileri çeşitli sebeplerden ötürü analizlerinde kullanamamıştır. Yazarlar analizlerinde, sisteme ilişkin direkt bilgilerin yerine sıcaklık, nem ve ses sensörlerinden elde edilen dolaylı verileri; sıralı örüntü madenciliği ve makine öğrenme algoritmaları kullanarak incelemeye çalışmış ve bu çalışma ile akış tipi üretim yapan fabrikalarda kullanılan makinelerle ilişkin bakım problemlerinin analizinde kullanılacak bir karar destek sistemi oluşturmuşlardır. Son olarak, [25] farklı klasik makine öğrenmesi yöntemlerinin ve derin öğrenme tekniklerinin performanslarını karşılaştırmalı olarak incelemiştir. Bu inceleme için bir kestirimci bakım problemine odaklanılmış ve gerekli veri setleri *University of California Irvine Makine Öğrenmesi Ambarları*'ndan sağlanmıştır. Yazarlar, ilgili veri setlerinde en başarılı sonuçların rastgele orman yöntemi ve geçitli tekrarlayan birim

mimarisi ile alındığını raporlamışlardır.

Markov karar süreçlerini kullanan ve literatür taramasında ele alınan çalışmalar, çalışmamız ile farklı açılardan karşılaştırılmış ve bu karşılaştırmaya ilişkin özet, Tablo (1)'de sunulmuştur. Tablo(1)'den de görüleceği üzere, çalışmamızı diğerlerinden ayıran temelde üç ana farklılık bulunmaktadır. Spesifik olmak gerekirse, literatür taramasında belirtilen [4] ve [5] numaralı çalışmalar, incelenen problem açısından bu çalışmaya en yakın olanlardır. Bu çalışmaların her ikisinde de bakıma gitme kararı verildikten sonra, aşınma seviyesi belirli bir eşik seviyesinin üzerindeki tüm bileşenlerin hepsinin istisnasız değiştirildiği kabul edilmiştir. Bu durum bileşenlerin ekonomik ömürlerinin dolmadan değiştirilebileceği dolayısıyla ciddi maddi kayıplara

yol açabileceği durumları ortaya çıkarmaktadır. Bu sorun ile başa çıkabilmek için, ilk defa bu çalışmada, ilgili karar bir optimizasyon modeli aracılığıyla belirlenmiştir. Ayrıca, literatürde ilk defa, bakım planlama, yedek parça getirme ve bileşen değiştirme kararlarını kısmi gözlemlenebilir çok bileşenli bir sistemde optimize etmek için aktör kritik pekiştirmeli öğrenme metodu kullanılmıştır. Son olarak, literatür taramasında verilen çalışmalardan farklı olarak, ilk defa bu çalışmada, sistemdeki bileşenlerin aşınma seviyelerini tam olarak gösterebilecek sensörlerin varlığı göz önünde bulundurulmuş ve bu sensörlerin sistemdeki hangi bileşenlere konuşturulması mali açıdan en fazla faydayı sağlar sorusuna nümerik analizler vasıtasıyla cevap aranmıştır.

Tablo 1. Literatür taramasında sunulan çalışmalara ilişkin bir özet

Table 1. A summary table for the reviewed studies

Çalışma	Sistem tipi			Bileşen gözlem durumu		Karar/Amaç	Model tipi		Çözüm yaklaşımı
	Çok Bileşenli	Tek Bileşenli	Her ikisi	Kısmi	Tam		POMDP	MDP	
[4]	✓			✓		Bakım zamanı ve Yedek parça sevkiyat	✓		GBS
[5]	✓			✓		Bakım zamanı ve Yedek parça sevkiyat		✓	LP
[10]		✓		✓		Bakım zamanı & Bakım aralığı	✓		GBS
[11]		✓		✓		İnceleme & Bakım zamanı	✓		VI
[12]		✓		✓		Bakım zamanı & Aşınma seviyesi tahmini	✓		RL
[13]	✓			✓		Bakım çizelgeleme	✓		DRL
[14]			✓	✓		POMDP'lere özgü çözüm algoritması	✓		DRL
[15]			✓	✓		POMDP'lere özgü çözüm algoritması	✓		DRL
[16]	✓				✓	Bakım zamanı		✓	DRL
[17]	✓				✓	Bakım zamanı		✓	DRL
[19]	✓			✓		Bakım zamanı	✓		DRL
Bu çalışma	✓			✓		Bakım zamanı, Yedek parça sevkiyat ve Bileşen değişim	✓		ACRL

Not: Tabloda kullanılan kısaltmaların anlamları şu şekildedir: *POMDP*: Kısmi gözlemlenebilir Markov Karar Süreci, *MDP*: Markov Karar Süreci, *GBS*: Izgara tabanlı çözüm yöntemi, *LP*: Doğrusal Programlama, *VI*: Değer Yineleme Algoritması, *RL*: Pekiştirmeli öğrenme algoritması, *DRL*: Derin pekiştirmeli öğrenme algoritması, *ACRL*: Aktör kritik pekiştirmeli öğrenme algoritması.

3 Matematiksel model ve çözüm algoritması

Bu bölümde, ilk önce, çalışmada ele alınan problem sözel olarak tanımlanmıştır. Daha sonrasında ise, bu problem için önerilen matematiksel modelin detayları sunulmuştur.

3.1 Problem tanımı

Bu çalışmada, kısmi gözlemlenebilir çok bileşenli bir sistem göz önünde bulundurulmakta ve sistemin, bakım merkezinden uzakta bir yerde operasyonlarını yürüttüğü varsayılmaktadır. Sistem operasyonlarını yürütmeye devam ettiği süre boyunca bileşenleri aşınmaktadır. Bileşenlere ilişkin aşınmaların kesik zamanlı kesik durum uzaylı bir Markov zincirine uyduğu bilinmektedir. Sistemde bulunan her bir bileşen için önceden belirlenmiş bir "bozulma seviyesi" bir de "arıza seviyesi" vardır. Bileşene ait aşınma seviyesinin önceden belirlenen bu bozulma seviyesine ulaşması, bileşenin artık bozulmaya başladığını ancak operasyonlarına halen devam edebileceği anlamına gelmektedir. Sistemdeki bileşenlerden en az birinin aşınma seviyesi belirtilen bu arıza seviyesine ulaştığında ise hem ilgili bileşen hem

de sistem işlev göremez hale gelir ve sisteme ilişkin tüm operasyonlar durmak zorunda kalır.

Sistem üzerinde tek bir sensör bulunmaktadır ve bu sensör her zaman için hatasız çalışmaktadır. İlgili sensör aracılığıyla, sistemdeki her bir parçanın aşınma seviyesini tam olarak görmek mümkün değildir. Diğer bir deyişle, sistemdeki bileşenlerin aşınma seviyeleri sadece bakım için sisteme gidildiğinde gözlemlenebilmektedir. Bu sensör, sistemin genel durumunu temsil eden yeşil, sarı ve kırmızı gibi üç farklı renkten oluşan bir sinyali periyodik aralıklarla uzaktaki bakım merkezine iletmektedir: i) Sensörün merkeze yeşil sinyal iletmesi, sistemdeki bileşenlerin hiçbirinde aşınma olmadığını ve sistemin operasyonlarına kusursuz biçimde devam ettiğini göstermektedir. ii) Sensörün merkeze sarı sinyal iletmesi, sistemdeki bileşenlerden en az birinin bozulmaya başladığını ve hiçbirinin de henüz arıza seviyesine ulaşmadığını temsil etmektedir. Bu durumda, sistem halen operasyonlarına devam edebilmektedir. iii) Sensörün kırmızı sinyal iletmesi ise; sistemdeki bileşenlerden en az birine ait aşınma seviyesinin ilgili arıza seviyesine ulaştığını ve bu yüzden de sistemin artık operasyonlarına devam edemez hale geldiğini göstermektedir.

Sisteme ilişkin bakım ve değişim kararları iki aşamalı bir süreç içermektedir ve bu kararlar, sistemdeki sensörden gelen sinyallere dayanarak alınmaktadır. Sensörden kırmızı sinyal alındığında, sisteme bakım/onarım için gidilmesi zorunludur. Bu tür bir bakım literatürde “*düzeltilici bakım*” olarak bilinmektedir. Öte yandan, sistemden yeşil veya sarı sinyal alındığında, sisteme bakım/onarım için gidilmesi servis sağlayıcının kararına bağlıdır. Bu bakım türü de literatürde “*önleyici bakım*” olarak bilinmektedir. Her iki bakımı yapmak için de servis sağlayıcı sabit bir maliyete katlanmak zorundadır.

Her iki bakım türünde de servis sağlayıcı; bakım için sisteme gitmeden önce hangi yedek parçaları bakım noktasına sevk edeceğine karar vermektedir. Bakım noktasına ulaşıp sistemi inceledikten sonra ise, sistemdeki bileşenlerden hangilerinin

değişeceğini belirlemektedir. Servis noktasına getirilen (getirilmeyen) ve kullanılmayan (ihtiyaç duyulan) her bir fazla (eksik) yedek parça için de servis sağlayıcı ekstra masraflara katlanır.

Servis sağlayıcının buradaki esas amacı, periyodik aralıklarla gelen sinyalleri kullanarak beklenen toplam indirgenmiş maliyeti en küçükleyecek entegre bir bakım planlama, yedek parça sevkiyat ve bileşen değiştirme politikası elde etmektir.

3.2 Kısmi gözlemlenebilir Markov karar modeli

Bu bölümde, ele aldığımız problem için önerdiğimiz Markov karar modeline ilişkin detaylar kapsamlı bir şekilde tartışılmıştır. Buna ek olarak, okuyucuya kolaylık sağlama amacıyla, modelde kullanılan tüm notasyonlar Tablo (2)'de sunulmuştur.

Tablo 2. Matematiksel modelde kullanılan notasyonlar

Table 2. A list of notations used in the mathematical model

Notasyon	Tanım	Notasyon	Tanım
N :	Sistemde bulunan toplam bileşen sayısı	C^c :	Düzeltilici bakım sabit maliyeti
i :	Bileşen indeksi, $i \in I = \{1,2,3, \dots, N\}$	C^p :	Önleyici bakım sabit maliyeti
F_i :	i . bileşene ait son aşınma seviyesi (arıza seviyesi)	C_f^i :	i . bileşeni değiştirme maliyeti
S_i :	i . bileşene ilişkin gerçek aşınma seviyesi, $s_i \in S_i = 0,1,2, \dots, F_i$	C^e :	Bakım noktasına getirilmemiş ancak bakım esnasında gerekli parçanın bakım noktasına acilen getirilme maliyeti
Y_i :	i . bileşene ilişkin bozulma seviyesi, $0 < Y_i < F_i$	C^b :	Bakım noktasına getirilmiş parçayı bakımda kullanmadan merkeze geri götürülme maliyeti
\mathbf{s} :	Sisteme ilişkin çekirdek durum uzayını gösteren N -boyutlu vektör	$C^v(\mathbf{g}, \mathbf{r})$:	Toplam değişken maliyet fonksiyonu
θ :	Sinyal tipi, $\theta \in \Theta = \{0 \text{ (yeşil)}, 1 \text{ (sarı)}, 2 \text{ (kırmızı)}\}$	$C^f(\mathbf{b}, \theta)$:	Toplam sabit maliyet fonksiyonu
S_0 :	Yeşil sinyal veren çekirdek durumlar, $S_0 = \{\mathbf{s} \in \mathcal{S} : s_i < Y_i, \forall i \in I\}$	$A(\mathbf{b})$:	\mathbf{b} durumunda alınacak bakım/onarım kararı
S_1 :	Sarı sinyal veren çekirdek durumlar, $S_1 = \{\mathbf{s} \in \mathcal{S} : \exists i \in I, Y_i \leq s_i < F_i \text{ ve } s_i < F_i, \forall i \in I\}$	\mathbf{G} :	Yedek parça sevkiyat kararlarını gösteren N -boyutlu karar vektörü
S_2 :	Kırmızı sinyal veren çekirdek durumlar, $S_2 = \{\mathbf{s} \in \mathcal{S} : \exists i \in I, s_i = F_i\}$	g_i :	i . bileşene ilişkin yedek parçanın bakım noktasına sevk edilip edilmeyeceğini gösteren \mathbf{G} vektörünün i . elemanı, $g_i \in \{0 \text{ (} i \text{. bileşen için yedek parça sevk edilmez)}, 1 \text{ (} i \text{. bileşen için yedek parça sevk edilir)}\}$
W :	Çekirdek durumlara ilişkin tek adım geçiş matrisi	\mathbf{R} :	Sistem bileşenlerinden hangilerinin değiştirilip değiştirilmeyeceğine ilişkin kararları gösteren N -boyutlu karar vektörü
$w_{\mathbf{s}, \tilde{\mathbf{s}}}$:	\mathbf{s} çekirdek durum uzayından $\tilde{\mathbf{s}}$ çekirdek durum uzayına tek adımda geçiş olasılığını gösteren W matrisinin $w_{\mathbf{s}, \tilde{\mathbf{s}}}$ elemanı	r_i :	i . bileşenin değiştirilip değiştirilmeyeceğini gösteren \mathbf{R} vektörünün i . elemanı, $r_i \in \{0 \text{ (} i \text{. bileşen değiştirilmez)}, 1 \text{ (} i \text{. bileşen değiştirilir)}\}$
p_{s_i, \tilde{s}_i} :	i . bileşenin s_i aşınma seviyesinden \tilde{s}_i aşınma seviyesine tek adımda geçme olasılığı	$\eta(\mathbf{s}, \mathbf{r})$:	Bulunulan \mathbf{s} çekirdek durumunda alınan değiştirme kararları sonrası yeni çekirdek durumunu belirleyen fonksiyon
\mathbf{b} :	Sisteme ilişkin düşünülen durum uzayını gösteren $ \mathcal{S} $ -boyutlu vektör, $\mathbf{b} \in B_\theta = \{\mathbf{b} \in \mathbb{R}_+^{ \mathcal{S} } : b(\mathbf{s}) = 0, \forall \mathbf{s} \notin S_\theta \text{ ve } b(\mathbf{s}) \geq 0, \forall \mathbf{s} \in S_\theta, \sum_{\mathbf{s} \in \mathcal{S}} b(\mathbf{s}) = 1\}$	$V_n(\mathbf{b})$:	Beklenen toplam indirgenmiş maliyeti en küçükleyecek politikanın n dönem kaldığında kullanılması ile oluşacak değer fonksiyonu
$T_{\tilde{\mathbf{s}}}(\mathbf{b}, \theta)$:	Düşünülen durum uzayı güncelleme fonksiyonu	Γ^0 :	Bakım/onarım kararının alınmamasını temsil eden operatör
$P(\theta \mathbf{b})$:	\mathbf{b} durumunda θ tipi sinyal alma olasılığı	Γ^1 :	Bakım/onarım kararının alınmasını temsil eden operatör
γ :	İndirgenme faktörü, $0 < \gamma < 1$	Υ^1 :	Yedek parça sevk ve bileşen değişim kararlarını temsil eden operatör

3.2.1 Çekirdek durum uzayı

Sistemde N adet bileşen bulunmaktadır ve sistemdeki bileşenler $i \in I = \{1,2,3, \dots, N\}$ ile temsil edilmektedir. Bileşen i 'nin $(F_i + 1)$ adet farklı aşınma seviyesi vardır ve bileşen i 'nin bulunmuş olduğu gerçek aşınma seviyesi $s_i \in S_i = \{0, 1, 2, \dots, F_i\}$ ile temsil edilmektedir.

Her bir bileşen için önceden tanımlanmış bir “*bozulma seviyesi*” bulunmaktadır. Bu seviye Y_i ile temsil edilmiştir ve her zaman $0 < Y_i < F_i$ arasında olacağı kabul edilmiştir. Bileşene ait aşınma seviyesinin “*bozulma seviyesinden*” büyük ya da eşit olması aynı zamanda da “*arıza seviyesinden*” küçük olması duru-

munda, yani $Y_i \leq s_i < F_i$ eşitsizliği sağlandığında, ilgili bileşende bozulmanın başladığı ancak operasyonlarına halen devam edebileceği bilinmektedir. Öte yandan, bileşen i 'ye ait aşınma seviyesi “*bozulma seviyesinden*” küçükse, yani $s_i < Y_i$ eşitsizliği sağlanıyorsa, bileşende hiçbir bozulma olmadığı kabul edilir. Son olarak, eğer $s_i = F_i$ ise, bileşen i 'nin tamamıyla bozulduğu, dolayısıyla da artık operasyonlarını sürdüremediği düşünülür.

Tüm bileşenlere ilişkin aşınma seviyeleri, yani s_i 'ler, birleşerek sistemin çekirdek durum uzayını oluşturmaktadır. Dolayısıyla, çekirdek durum uzayı N -boyutlu bir vektör ile temsil edilmektedir ve bu vektörün elemanı olan s_i ise i . bileşene ait aşınma

seviyesini göstermektedir. Sisteme ilişkin çekirdek durum uzayı \mathbf{s} ile gösterilmektedir. Bu problem özelinde, toplamda $|\mathcal{S}| = \prod_{i=1}^N (F_i + 1)$ adet farklı çekirdek durum uzayı mevcuttur.

3.2.2 Gözlemler

Sensöre ilişkin sinyaller θ ile temsil edilmiştir ve θ 'nın $\theta \in \Theta = \{0, 1, 2\}$ setinden değerler aldığı kabul edilmiştir. Sistemdeki her bir bileşene ait aşınma seviyesi kendi "bozulma seviyesinden" küçükse, sensör yeşil sinyal, yani $\theta = 0$ değerini, iletir. Bu sinyali verebilecek çekirdek durumlar matematiksel olarak Denklem (1)'deki gibi ifade edilmiştir.

$$S_0 = \{\mathbf{s} \in \mathcal{S} : s_i < Y_i, \forall i \in I\} \quad (1)$$

Sistemdeki bileşenlerden en az bir tanesinin aşınma seviyesi ilgili "bozulma seviyesinden" büyük veya eşit ise ve sistemde arıza durumuna ulaşan hiçbir bileşen bulunmuyorsa, sensör sarı sinyal, diğer bir deyişle $\theta = 1$, göstermektedir. Denklem (2)'de bu sinyali verebilecek çekirdek durumlar matematiksel olarak ifade edilmiştir.

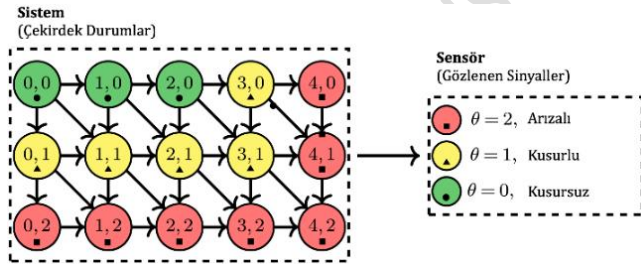
$$S_1 = \{\mathbf{s} \in \mathcal{S} : \exists i \in I, Y_i \leq s_i < F_i \text{ ve } s_i < F_i, \forall i \in I\} \quad (2)$$

Son olarak, sistemdeki bileşenlerden en az bir tanesi arıza durumuna geçmişse, sensör kırmızı sinyali, yani $\theta = 2$ değerini, vermektedir. Denklem (3) bu sinyali verebilecek tüm çekirdek durumları matematiksel olarak ifade etmektedir.

$$S_2 = \{\mathbf{s} \in \mathcal{S} : \exists i \in I, s_i = F_i\} \quad (3)$$

3.2.3 Geçiş matrisleri

Sisteme ilişkin çekirdek durumlardaki geçişler tek adım geçiş matrisi W 'ya göre gerçekleşmektedir. Bu matrisin elemanları bir çekirdek durumdan diğer bir çekirdek duruma tek adımda geçiş olasılıklarını temsil etmektedir. Diğer bir deyişle, matrisdeki $w_{s,\tilde{s}}$ elemanı, \mathbf{s} çekirdek durum uzayından $\tilde{\mathbf{s}}$ çekirdek durum uzayına tek adımda geçiş olasılığını göstermektedir. Ayrıca, bileşen i 'nin s_i aşınma seviyesinden \tilde{s}_i seviyesine tek adımda geçiş olasılığı ise p_{s_i,\tilde{s}_i} ile temsil edilmiştir.



Şekil 1. İki bileşenli bir sistem örneği.

Figure 1. An illustration of a system with two components.

Bu problem özelinde, bileşenlerin aşınma seviyelerindeki artışların birbirlerinden bağımsız olduğu kabul edilmiştir. Bu varsayım altında, W matrisinin her bir elemanı, bileşenlerin tek adımda aşınma olasılıkları kullanılarak Denklem (4)'teki gibi ifade edilebilir.

$$w_{s,\tilde{s}} = \prod_{i \in I} p_{s_i,\tilde{s}_i} \quad (4)$$

Şekil (1), bu bölümde tanımlanan sistemi okuyucunun zihninde canlandırabilmek için örnek olarak verilmiştir. Şekilde verilen sistemde iki bileşen bulunmakta ve ilk bileşenin toplamda 5

ikinci bileşenin ise toplamda 4 adet aşınma seviyesi bulunmaktadır. Birinci bileşen 3. aşınma seviyesine kadar, yani $s_1 = Y_1 = 3$ olana kadar, kusursuz çalışırken; 2. bileşen 1. aşınma seviyesine kadar, yani $s_2 = Y_2 = 1$ olana kadar, kusursuz çalışmaktadır. Şekildeki örnekte gösterildiği gibi $\mathbf{s}=(2,0)$ çekirdek durumunda, sensör yeşil sinyal, diğer bir deyişle $\theta = 0$ değerini, verir. Öte yandan, $\mathbf{s}=(2,1)$ çekirdek durumunda ise 2. bileşen artık bozulmaya başlamış ancak halen operasyonlarını yerine getiriyor olmasından ötürü, sensör sarı sinyal, yani $\theta = 1$, değerini iletir.

Aynı örneği çekirdek durum uzay vektörlerine ilişkin tek adımda geçiş olasılıklarının nasıl hesaplandığını, yani Denklem (4)'ün nasıl işletildiğini, açıklamak için de kullanabiliriz. Sistemin çekirdek durum uzay vektörü (3,1) olsun ve bir sonraki periyotta (3,2) durumuna geçiş olasılığı hesaplanmak istensin. Bu durumda, ilk bileşen için anlık aşınma seviyesi 3'tür ve bir sonraki periyotta da 3 olması istenmektedir. İlk bileşenin aşınma seviyesine ilişkin bu geçiş olasılığı $p_{3,3_1}$ ile temsil edilmektedir. Öte yandan, ikinci bileşen için ise anlık aşınma seviyesi 1 iken takip eden periyottaki aşınma seviyesinin 2 olması istenmektedir. İkinci bileşenin aşınma seviyesine ilişkin bu geçiş olasılığı $p_{1,2_2}$ ile temsil edilmektedir. Her iki bileşen birbirinden bağımsız aşındığı için, sistemin (3,1) çekirdek durum vektöründen (3,2) çekirdek durum vektörüne tek adımda geçme olasılığı $w_{(3,1),(3,2)} = p_{3,3_1} \times p_{1,2_2}$ ile ifade edilmektedir.

3.2.4 Düşünülen durumlar

Kısmi olarak gözlemlenebilir Markov karar süreçleri, bilindik Markov Karar süreçlerinin özel bir halidir. Bu süreci diğer Markov Karar süreçlerinden ayıran temel fark ise sistemin içinde bulunduğu mevcut durumun tam olarak gözlemlenemiyor olmasıdır. Bu noktada, sistemin olabileceği muhtemel durumlar ve bu durumlarda bulunma olasılıkları karar sürecinin durum uzayını oluşturur. Bu durum uzayına da literatürde "düşünülen durumlar" adı verilmektedir. Doğası gereği, düşünülen durumlar kesikli zaman ve sürekli durum uzayına sahiptirler.

Modelimizde, düşünülen durumlar $|\mathcal{S}|$ -boyutlu bir vektör ile temsil edilmektedir ve bu vektör \mathbf{b} ile gösterilmektedir. Bu vektörün elemanları, karşılık gelen çekirdek durum uzayında bulunma olasılığını ifade etmektedir. Bu vektörün alabileceği değerleri içeren küme, Denklem (5)'te matematiksel olarak ifade edilmiştir.

$$B_\theta = \{\mathbf{b} \in \mathbb{R}_+^{|\mathcal{S}|} : \mathbf{b}(\mathbf{s}) = 0, \forall \mathbf{s} \notin S_\theta \text{ ve } \mathbf{b}(\mathbf{s}) \geq 0, \forall \mathbf{s} \in S_\theta, \sum_{\mathbf{s} \in \mathcal{S}} \mathbf{b}(\mathbf{s}) = 1\} \quad (5)$$

Bulunulan durum uzayı ve sensörden gelen sinyaller kullanılarak, düşünülen durum uzayı her periyot başında güncellenmektedir. Düşünülen durum uzayı vektörünü güncellemek için Denklem (6)'da verilen ifade kullanılmaktadır.

$$T_{\tilde{\mathbf{s}}}(\mathbf{b}, \theta) = \begin{cases} \frac{\sum_{\mathbf{s} \in \mathcal{S}} \mathbf{b}(\mathbf{s}) w_{s,\tilde{s}}}{P(\theta|\mathbf{b})}, & \tilde{\mathbf{s}} \in S_\theta \\ 0, & \tilde{\mathbf{s}} \notin S_\theta \end{cases} \quad (6)$$

Denklem (6)'da verilen $P(\theta|\mathbf{b})$ esasen bir normalleştirme faktörü olarak düşünülebilir. Bu ifade, mevcut düşünülen durum göz önüne alındığında bir sonraki dönemde sensörden θ sinyalini alma olasılığını göstermektedir.

3.2.5 Karar vektörleri ve ilgili maliyetler

Sensörden yeni bir sinyal alındığında, servis sağlayıcı sinyalin tipini gözlemler ve bakım/onarım için sistemin bulunduğu yere

gidip gitmeme kararı verir. Eğer sensör kırmızı renkte bir sinyal veriyorsa, servis sağlayıcı bakım/onarım kararını kesinlikle alır. Bu durumda, servis sağlayıcı yapacağı "düzeltici bakım" için C^c gibi bir masrafa katlanmaktadır. Öte yandan, sensör sarı veya yeşil renkte bir sinyal veriyorsa, bakım/onarım kararı opsiyoneldir. Servis sağlayıcı bu durumda bakım kararı alırsa, yapacağı "önleyici bakım" için C^p gibi bir miktar ödemektedir. Burada bahsi geçen her iki masrafla literatürde *sabit bakım* masrafları olarak bilinmektedir ve genellikle C^c 'nin C^p 'den büyük veya eşit olduğu kabul edilmektedir [2, 4, 5]. İlgili bakım/onarım kararı ve buna ilişkin maliyetler matematiksel olarak Denklem (7) ve Denklem (8)'deki gibi ifade edilmektedir.

$$A(\mathbf{b}) = \begin{cases} \{1\} & \text{eğer } \mathbf{b} \in B_2 \\ \{0, 1\} & \text{eğer } \mathbf{b} \in B_0 \cup B_1 \end{cases} \quad (7)$$

$$C^f(\mathbf{b}, \theta) = \begin{cases} C^c, & \text{eğer } \theta \in \{0, 1\} \\ C^p, & \text{eğer } \theta \in \{2\} \end{cases} \quad (8)$$

Servis sağlayıcı aldığı her bakım/onarım kararıyla birlikte servis noktasına hangi yedek parçaları sevk edeceğine de karar verir. Bu karar için N -boyutlu bir karar vektörü oluşturulmuş ve G ile temsil edilmiştir. Bu karar vektöründeki g_i elemanı, ilgili i bileşeni için servis noktasına yedek parça sevk edilip edilmeyeceğini gösterir. Vektördeki g_i elemanının 1 olması ilgili yedek parçanın bakım noktasına sevk edileceği, 0 olması ise bu parçanın sevk edilmeyeceği anlamına gelir. Bu vektörün değer alabileceği kümedeki toplam eleman sayısı, $|G| = \sum_{i=1}^N \{0, 1\} = 2^N$ ile ifade edilmektedir. Bu vektör matematiksel olarak Denklem (9)'daki gibi ifade edilmektedir.

$$G = \{g_1, g_2, g_3, \dots, g_N\} \quad (9)$$

Servis sağlayıcı, bakım/onarım noktasına vardıkdan sonra, sistemi inceler ve sistemdeki bileşenlerin aşınma seviyelerini tam olarak tespit eder. Ardından, sistemdeki bileşenlerden hangilerinin değiştirileceğine karar verir. Bu karar için, N -boyutlu bir vektör oluşturulmuş ve ilgili vektör R ile temsil edilmiştir. Bu karar vektöründeki r_i elemanı, ilgili i bileşenin değiştirilip değiştirilmeyeceğini gösterir. Vektördeki r_i elemanının 1 olması ilgili bileşenin değiştirileceği, 0 olması ise değiştirilmeyeceği anlamına gelir. Bu vektörün değer alabileceği kümedeki toplam eleman sayısı, $|R| = \sum_{i=1}^N \{0, 1\} = 2^N$ ile ifade edilmektedir. Bu vektör matematiksel olarak Denklem (10)'daki gibi temsil edilmiştir.

$$R = \{r_1, r_2, r_3, \dots, r_N\} \quad (10)$$

Servis sağlayıcı, değiştirilecek her bir bileşen için bileşenin tipine göre C_i^r gibi bir ödemeye katlanmaktadır. Bileşen i 'nin değiştirilmesine karar verildiğinde ilgili parça bakım yerine getirilmemişse, servis sağlayıcı acil sipariş opsiyonunu kullanır ve ilgili parçayı bakım alanına ek bir ödeme yaparak getirir. Acil sipariş ile getirilen her bir parça için servis sağlayıcı C^e gibi bir maliyete katlanmaktadır. Öte yandan, bileşen i için yedek parça bakım noktasına getirilmiş ancak ilgili bileşenin değiştirilmesi kararlaştırılmışsa, bakım noktasına getirilen yedek parça merkeze geri götürülür ve bunun için de servis sağlayıcısı ekstra bir maliyete katlanır. Diğer bir deyişle, servis sağlayıcı bakım noktasına getirilip ancak bakım esnasında kullanılmayan her bir parça için C^b gibi bir ek masrafa katlanmaktadır. Buradaki ödeme kalemlerinin tamamı literatürde "*değişken bakım masrafları*" olarak bilinmektedir. Problemdeki toplam değişken bakım masrafı matematiksel olarak Denklem (11)'deki gibi ifade edilmiştir.

$$C^v(\mathbf{g}, \mathbf{r}) = \sum_{i \in I} C_i^r r_i + \sum_{i \in I} C^b g_i (1 - r_i) + \sum_{i \in I} C^e r_i (1 - g_i) \quad (11)$$

3.2.6 Değer fonksiyonu ve operatörler

Beklenen toplam indirgenmiş maliyeti en küçükleyecek politikanın $n \geq 0$ dönem kaldığında kullanılması ile oluşacak değer fonksiyonu, $V_n(\mathbf{b})$ ile temsil edilmektedir. Bu fonksiyona ilişkin başlangıç değerlerinin sıfır olduğu kabul edilmiştir. Matematiksel olarak ifade etmek gerekirse, $V_0(\mathbf{b}) = 0$ olduğu düşünülmektedir.

Modelimizde, bakım/onarım kararının alınmamasını temsil eden operatör Γ^0 ile gösterilmektedir. İlgili operatör matematiksel olarak Denklem (12)'deki gibi tanımlanmaktadır.

$$\Gamma^0 V_n(\mathbf{b}) = \gamma \sum_{\theta \in \Theta} P(\theta | \mathbf{b}) V_n(T(\mathbf{b}, \theta)), \forall \mathbf{b} \in B_0, B_1 \quad (12)$$

Bu karar sadece sarı veya yeşil sinyalin gözlemlendiği durumlarda alınabilmektedir. Dolayısıyla, ilgili operatör sadece bu durumlar için tanımlanmıştır. Ayrıca, Denklem (12)'de kullanılan γ indirgenme faktörünü temsil etmektedir. Bu faktörün her zaman için 0 ve 1 ($0 < \gamma < 1$) arasında olduğu kabul edilmiştir.

Sistemin mevcut çekirdek durumunun \mathbf{s} olduğu kabul edilsin. Servis sağlayıcı sistemi yerinde inceleyip, değiştirilecek bileşenlere karar verdikten sonra uğranacak çekirdek durum ise $\eta(\mathbf{s}, \mathbf{r})$ vektörü ile temsil edilsin. Bu durumda, $\eta(\mathbf{s}, \mathbf{r})$ vektörünün elemanları matematiksel olarak Denklem (13)'deki gibi ifade edilebilir.

$$\eta_i(\mathbf{s}, \mathbf{r}) = s_i - s_i r_i, \forall i \in I \quad (13)$$

Bileşen i için değiştirme kararı alınmışsa, yani $r_i = 1$ ise, ilgili bileşen bir sonraki periyota aşınma seviyesi sıfır olacak şekilde başlar. Aksi halde, yani $r_i = 0$ olduğunda, ilgili bileşenin aşınma seviyesi bir önceki periyotta kaldığı yerden devam eder.

Modelde, en iyi değişim ve yedek parça sevk kararları ise Υ^1 operatörü ile temsil edilmektedir. Bu operatör, matematiksel olarak Denklem (14)'deki gibi tanımlanmıştır.

$$\Upsilon^1 V_n(\mathbf{b}) = \min_{\mathbf{g} \in G, \mathbf{r} \in R} \left\{ \sum_{\mathbf{s} \in S_\theta} (b(\mathbf{s}) C^v(\mathbf{g}, \mathbf{r}) + b(\mathbf{s}) \Gamma^0 V_n(\eta(\mathbf{s}, \mathbf{r}))) \right\}, \forall \mathbf{b} \in B_\theta, \forall \theta \in \Theta \quad (14)$$

Ayrıca, bakım/onarım kararının alınması ise Γ^1 ile temsil edilmektedir. Bu operatör matematiksel olarak Denklem (15)'deki gibi tanımlanmıştır.

$$\Gamma^1 V_n(\mathbf{b}) = C^f(\mathbf{b}, \theta) + \Upsilon^1 V_n(\mathbf{b}), \forall \mathbf{b} \in B_\theta, \forall \theta \quad (15)$$

Son olarak, Γ^0 ve Γ^1 operatörleri kullanılarak ifade edilen beklenen değer fonksiyonu matematiksel olarak Denklem (16)'daki gibi tanımlanmıştır.


$$V_{n+1}(\mathbf{b}) = \min_{\mathbf{a} \in A(\mathbf{b})} \{\Gamma^a V_n(\mathbf{b})\} \quad (16)$$

Bu bölümde tanımlanan problemde sınırlı sayıda alınabilecek karar olduğu aşikardır. Ayrıca, problem mutlak pozitif ve sınırlı maliyetleri içermektedir. Maliyetlerin de hepsi γ terimi ile indirgenmektedir. Bu özelliklerin hepsi bu problem özelinde aynı

anda sağlanarak, deterministik bir politikanın varlığını garanti etmektedir [26, 27].

3.2.7 Ekstra sensör

Detayları 3.1.1 ve 3.1.6 arasında verilen problem, makalenin bundan sonraki kısmında baz problem olarak adlandırılacaktır. Baz problemde tek bir sensör olduğu ve bu sensörün sistemdeki bileşenlerin aşınma seviyelerini tam olarak göstermediği, bunun yerine sistemin genel durumu hakkında kısmi bir bilgi verdiği kabul edilmiştir.



Şekil 2. Aktör-kritik pekiştirmeli öğrenme metoduna ilişkin mimari

Figure 2. Architecture of the actor-critic reinforcement learning method

Bu kısmi bilgi veren sensöre ek olarak, başka bir sensörün daha kullanılabilme fırsatının da var olduğu göz önünde bulundurulmuştur. Bu fazladan sensör sistemde bulunan herhangi bir bileşene takılabilmekte ve takıldığı bileşenin aşınma seviyelerini tam ve kesin bir şekilde uzaktaki servis sağlayıcısına iletebilmektedir. Bu niteliklerdeki fazladan bir sensör Şekil (1)'de tanımlanan sistemin ikinci bileşenine takılmış olsun ve bu bileşenin aşınma seviyesi 1 olsun. Bu durumda, sisteme ilişkin olası düşünülen durumlar sadece (0,1), (1,1), (2,1), (3,1) ve (4,1) olacaktır. Örnekten de anlaşılacağı üzere, sistemde böyle bir sensörün varlığı, düşünülen durumların boyutunda ciddi bir azalmaya yol açar ve bu sebeple servis sağlayıcı sistemdeki bileşenlerin aşınma seviyeleri hakkında daha net bir bilgiye sahip olur. Bu nitelikteki ekstra sensörlerin var olması durumu ve bunların sistemdeki hangi bileşenlere takılmasının mali açıdan en fazla faydayı sağlayacağı sorusu, çalışmamızda nümerik olarak analiz edilmiştir.

Ek sensörlerin nümerik olarak incelenmesi modelin genel çerçevesini bozmamış, sadece minör değişikliklere yol açmıştır. Modeldeki tek majör değişiklik, Denklem (6)'da verilen güncelleme fonksiyonunda gerçekleşmiştir. İlgili fonksiyon Denklem (17)'deki gibi değişmiştir ve diğer bütün rutinler baz problemde olduğu gibi korunmuştur.

$$T_{\tilde{s}}(\mathbf{b}, \theta) = \begin{cases} \frac{\sum_{s \in S} b(s) w_{s, \tilde{s}}}{P(\theta, \tilde{s}_i = k_{\tilde{s}_i} | \mathbf{b})}, & \tilde{s} \in S_{\theta} \text{ ve } \tilde{s}_i = k_{\tilde{s}_i} \\ 0, & \text{aksi halde} \end{cases} \quad (17)$$

Denklem (17)'de verilen $k_{\tilde{s}_i}$ sensörün takıldığı bileşenin tam olarak hangi aşınma seviyesinde olduğunu göstermektedir.

3.2.8 Aktör kritik pekiştirmeli öğrenme metodu

Pekiştirmeli öğrenme, bir ajanın kendi davranışlarını çevresiyle etkileşime girerek optimize etmeye çalıştığı bir yöntemdir. Spesifik olarak, ajan bulunduğu herhangi bir durumda önce hangi eylemi yapacağına karar verir ve bu eylem kararını uyguladıktan sonra çevresinden ilgili kararın kalitesini gösteren bir cevap, diğer bir deyişle bir "ödül", alır. Bu sayede, bir "politika" oluşturmaya, yani hangi durumda hangi eylemin yapılmasının

en iyi karar olduğunu belirlemeye çalışır. Belirli bir politikayı takip ederek ve bu politika ile alacağı ödülleri sürekli olarak işleyerek, ajan geri dönüşlerin tahminlerini oluşturabilir. Bu tahminlenen geri dönüşleri temsil eden fonksiyona ise "değer fonksiyonu" denir. Değer fonksiyonu, ajanın geçmiş deneyimlerden yola çıkarak gelecekte alacağı eylemleri belirlemesine olanak tanır. Bunun için literatürde sıklıkla uygulanan "temporal fark metodu", diğer bir deyişle geçmiş deneyimler arasındaki ödül farklarına odaklanan bir yaklaşımdır, kullanılır. Pekiştirmeli öğrenme metoduna ilişkin bu adımlar ve adımlar arasındaki ilişkiler Şekil (2)'de görsel olarak özetlenmiştir.

Aktör kritik metodu temelde iki ana kısımdan oluşmaktadır. İlk kısım literatürde aktör olarak bilinmektedir. Aktörün kararlarını politika fonksiyonu ile verdiği düşünülür. İkinci kısım ise literatürde kritik olarak bilinmektedir ve değer fonksiyonlarını kullanarak aktörün aldığı aksiyonlara geri bildirimlerde bulunur. Bu metotta, politika, gradyan teoremi geri bildirimlerden yararlanarak aktör fonksiyonunun parametrelerini güncellemek için kullanılırken; temporal farklar da metodun kritik olarak adlandırılan kısmını güncellemede kullanılır. Aktör ve kritik kısımları ise genellikle iki ayrı yapay sinir ağı kullanılarak yakınsanır. Bu algoritmaya ilişkin daha detaylı tartışmalar [28] ve [29]'da bulunabilir.

Aktör kritik pekiştirmeli öğrenme yöntemine ilişkin sözde algoritma

```

Ön değer atama
Yörüngelerin saklandığı vektörü yarat
Aktör ( $\theta_A$ ) ve kritik fonksiyonlarını ( $\theta_C$ ) yakınsamak için yapay sinir ağlarını yarat
Çevre ve düşünülen durumlara ilişkin matrisleri yarat
for t=1:T
Keşfetme olasılığını kullanarak rastgele bir bakım ve yedek parça sevkiyat politikası yarat ( $\mathbf{a}_t, \mathbf{g}_t$ )
Eğer  $a_t = 1$  ise, yani bakım kararı alınmışsa
En iyi bileşen değiştirme kararını aşağıdaki matematiksel ifadeye göre bul:

$$\mathbf{r}_t = \text{argmin}\{C^*(\mathbf{g}_t, \mathbf{r}) + \gamma V_{\theta_C}(\eta_t(\mathbf{s}, \mathbf{r}))\}$$

Aksi halde
 $\mathbf{r}_t$ 'nin tüm elemanlarını sıfıra eşitle
Eğer bitiş
Çekirdek uzay durumunu güncelle ve gerekli maliyetleri hesap et
Düşünülen durum vektörünü güncelle
Durum ve çekirdek uzayları ile birlikte alınan karar ve ödülleri yörünge vektöründe sakla
En son aksiyon ve harekete ilişkin avantaj skorunu hesapla
En son aksiyon ve harekete ilişkin önem skorunu hesapla
Aktör için yaratılan yapay sinir ağını politika gradyan yöntemini kullanarak güncelle
Kritik için yaratılan yapay sinir ağını gradyan yöntemini kullanarak güncelle
for bitiş

```

Şekil 3. Çalışmada kullanılan aktör-kritik pekiştirmeli öğrenme metoduna ilişkin sözde algoritma.

Figure 3. Pseudo algorithm for the actor-critic reinforcement learning method employed in this work.

İlgili algoritma Şekil (3)'te belirtildiği gibi uyarlanmış ve çalışmamızda Python dili kullanılarak gerçekleştirilmiştir. Şekil (3)'te de görüldüğü üzere, ilk önce bir ön değer atama süreci mevcuttur. Bu süreçte, algoritmayla alakalı bazı parametreler belirlenir, çevre ve düşünülen durumlar oluşturulup bunların saklanacağı vektörler yaratılır ve aktör ve kritik fonksiyonlarını yaklaşık olarak değerlendirmek için iki yapay sinir ağı oluşturulur. Daha sonrasında, algoritmanın aktör kısmı devreye girer ve politika fonksiyonu yardımıyla alınması gereken kararları belirler. İlgili kararlar belirlendikten sonra algoritmanın kritik kısmı devreye girer ve alınan kararı değer fonksiyonları yardımıyla irdeler. Son olarak, sistem durumunda gerekli tüm güncellemeler yapılır ve algoritma tekrar başa döner. Bu döngü durdurma kriterleri sağlanana kadar devam eder.

4 Nümerik analiz

Bu başlık altında, sistem parametrelerinin sisteme ilişkin performans ölçütlerini nasıl etkiledikleri nümerik olarak incelenmiştir. Ayrıca, aktör kritik pekiştirmeli öğrenme metodu ile

elde edilen politikalar, pratikte sıklıkla kullanılan sezgisel politikalarla karşılaştırılmıştır. Bu sayede, yöntemin ürettiği politikaların kalitesine ilişkin bir analiz de sunulmuştur. Benzeri analiz ve karşılaştırmalar, sisteme ek bir sensörün takılması durumu göz önünde bulundurularak tekrarlanmış ve yine bu başlık altında raporlanmıştır.

Nümerik analizlerle ilgili detaylara girmeden önce, ilk olarak, göz önünde bulundurulacak sezgisel politikalar ve performans ölçütleri sunulmuş; daha sonrasında ise, hem aktör kritik pekiştirmeli öğrenme metoduna ilişkin parametrelerin hem de nümerik analizde ele alınacak problemlere ilişkin parametrelerin nasıl belirlendiği tartışılmıştır.

4.1 Sezgisel bakım/onarım politikaları ve performans ölçütleri

Aktör-kritik pekiştirmeli öğrenme metodu ile elde edilen sonuçlar pratikte sıklıkla kullanılan çeşitli sezgisel bakım/onarım metodları ile elde edilen sonuçlarla karşılaştırılmıştır. Bu karşılaştırmalarda, toplamda beş farklı sezgisel politika kullanılmıştır. Bu politikalara ilişkin detaylar, takip eden paragraflarda tartışılmıştır.

Bu politikaların ilkinde bakım/onarım ve yedek parça seçim kararlarının optimize edildiği; ancak bileşen değişim kararının optimize edilmediği varsayılmıştır. Bu politikada, bakım/onarım kararı sonrasında yapılan incelemede ortaya çıkan bozulmuş ve/veya arızalı olan bileşenlerin tamamının istisnasız değiştirildiği kabul edilmiştir. Literatürde benzeri politikalar sıklıkla kullanılmaktadır [4, 5, 6]. Bu politika makalenin hem de kalandında SP-1 (Sezgisel Politika-1) olarak temsil edilmiş ve nümerik analizlerde incelenen politika karşılaştırmalarında baz politika olarak kullanılmıştır. Bu politika kullanılarak yapılan karşılaştırmalar aracılığıyla, bileşen değiştirme kararının optimize edilmesinin servis sağlayıcıya maliyet açısından ne kadar fayda sağlayacağı belirlenmesi hedeflenmiştir.

İkinci politikada ise hangi yedek parçaların götürüleceği kararı, değişken maliyet fonksiyonu ayrı bir maliyet fonksiyonuyuş gibi göz önünde bulundurularak belirlenir. Diğer bir deyişle, bu kısım orijinal problemden koparılır ve ayrılmış gibi kabul edilerek çözülür. Bu politika ile problemdeki karar değişkeni sayısının azaltılması hedeflenmiş ve sezgisel çözümlerin büyük problem boyutları için daha makul sürelerde elde edilmesi planlanmıştır. İlgili politika makalenin geri kalanında SP-2 (Sezgisel Politika-2) olarak temsil edilmiştir.

Bu iki sezgisel politikaya ek olarak, literatürde sıklıkla kullanılan önleyici (SP-3) ve düzeltici bakım (SP-4) politikaları da göz önünde bulundurulmuştur. Her iki sezgisel politika literatürde sıkça kullanılmaktadır [4, 5, 11]. Önleyici bakım politikasında servis sağlayıcının sarı sinyali alır almaz bakım için gittiği ve bozulmuş olan tüm bileşenleri değiştirdiği düşünülür. Öte yandan, düzeltici bakım politikasında ise servis sağlayıcının kırmızı sinyali alana kadar herhangi bir bakım/onarımda bulunmadığı kabul edilmiştir. Diğer bir deyişle, bu politika altında, servis sağlayıcı ancak ve ancak kırmızı sinyali aldıktan sonra bakıma gitmektedir. Bu ziyaret sırasında da bozulmuş ve arızalı tüm bileşenleri değiştirir. Bu her iki sezgisel bakım politikasında da götürülecek parçalar, indirgenmiş maliyeti en küçükleyecek şekilde belirlenir. Her bir problem özelinde bu iki politikanın en küçüğü bulunmakta ve SP-5 (Sezgisel politika-5) olarak temsil edilmektedir. Bahsi geçen sezgisel politikalar ile yapılan karşılaştırmalar sayesinde, hangi şartlar altında bu basit politikaların uygulanabilirlik açısından karmaşık optimal politikaların makul birer alternatifi olabileceği araştırılmaktadır.

Son olarak, pekiştirmeli öğrenme metodu ile elde edilen sonuçlar ise ORP (optimal reinforcement learning policy) ile temsil edilmiştir. Bu politika ile çalışmamızda bahsi geçen tüm kararlar, maliyet fonksiyonumuzu en küçükleyecek biçimde belirlenmiştir.

Bu politikaları uygulayarak elde edilen uzun dönem ortalama maliyetler ($EC^{(C)}$) hesaplanmış ve bunlar Denklem (18)'de verilen ölçüt kullanılarak kıyaslanmıştır.

$$\%RD^{(C)} = \frac{EC^{(C)} - EC^{SP-1}}{EC^{SP-1}} \times 100 \quad (18)$$

Nümerik analizlerde sisteme ek sensörlerin ekleneceği durumlar da ele alınmıştır. Bu analizler için ise baz politika olarak ORP alınmış ve ilgili deneyler için Denklem (18)'e benzer bir ölçüt tanımlanarak Denklem (19)'da verilmiştir. İlgili denklem kullanılarak, ORP politikası ile elde edilen uzun dönem ortalama maliyeti ile ek sensörlerin var olması varsayımı altında elde edilen uzun dönem ortalama maliyeti, problem bazında karşılaştırılmış ve raporlanmıştır.

$$\%RD'^{(C)} = \frac{EC^{(C)} - EC^{ORP}}{EC^{ORP}} \times 100 \quad (19)$$

4.2 Aktör kritik pekiştirmeli öğrenme metoduna ilişkin parametrelerin belirlenmesi

Aktör kritik pekiştirmeli öğrenme metodunu kullanmak için katman sayısı, her bir katmandaki nöron sayısı, öğrenme katsayısı, örneklem büyüklüğü, keşif gürültü katsayısı ve tekrar kapasite büyüklüğü gibi parametrelerin belirlenmesi gerekmektedir. Bu parametrelerin her biri ilgili metodunun öğrenme eğrisini etkilemekte, dolayısıyla çözüm kalitesi üzerinde etkisi olmaktadır. Bu parametreler belirlenirken [29] rehber olarak alınmıştır.

İlgili çalışmadan yola çıkılarak, öncelikle katman seviyesi iki ve üç olarak düşünülmüş ve her katmanda 8, 16, 32 ve 64 nöron olabileceği kabul edilmiştir. Bu parametreler öncül problemlerde denenerek, 2 katman (*layer*) ve 32 nöron (*neuron*) sonra çözümde çok fazla iyileşme elde edilmediği gözlemlenmiştir. Dolayısıyla, nümerik analizde ele alınan problemlerin çözümünde bu iki parametre 2 ve 32 olarak ayarlanmıştır. Öğrenme katsayısı ise Python'da bulunan TensorFlow gradyan azaltma en iyileştiricisi kullanılarak belirlenmiştir ve ilgili parametre 0,05 olarak ayarlanmıştır. Algoritma için, maksimum iterasyon sayısı ise 250.000 olarak kabul edilmiştir. Bunlara ek olarak, parti büyüklüğü (*batch size*) 64, keşif gürültü katsayısı (*exploration noise weight*) 0,02 ve tekrar kapasite büyüklüğü (*reply buffer*) ise 800.000 olarak belirlenmiştir.

Algoritma gerçekleştirilirken iki adet durdurma koşulu göz önünde bulundurulmuştur. İlk olarak, değer fonksiyonlardaki değişim her periyot için hesaplanmış ve bunlar 0,001 altında kaldığında algoritma durdurulmuştur. Bu şartın sağlanmadığı koşulda ise algoritmanın 250.000 periyot çalışmasına izin verilmiştir.

4.3 Nümerik analizde kullanılacak senaryolar

Bu çalışmadaki nümerik analizde kullanılan senaryolar tasarlanırken, daha önce kısmi gözlemlenebilir çok bileşenli makine-lerin bakım/onarım problemlerine odaklanmış olan [4], [5] ve [6] baz alınmıştır. Yazarlar çalışmalarında kullandıkları parametreleri gerçek bir probleme dayandırarak belirlemişlerdir. Bu parametrelerin seçimlerine ilişkin daha fazla detay ilgili çalışmalarda bulunabilir.

Tablo 3. Nümerik analiz için yaratılan toplam 108 adet örneğe ilişkin özet istatistiksel bilgiler.

Table 3. Summarized statistics on the 108 problem instances we examined in the numerical analysis.

	<i>Ort.</i>	<i>Min.</i>	<i>Maks.</i>	Amaç Fonksiyonu Bileşenleri	SP-1 politikası altında amaç fonksiyonu bileşenlerine ait uzun dönem ortalamalarının ortalaması	ORP politikası altında amaç fonksiyonu bileşenlerine ait uzun dönem ortalamalarının ortalaması
%RD ^{SP-2}	-%1,4	-%6,3	%4,2	<i>Sabit Maliyet</i>	13,0	10,3 (-%20,4)
%RD ^{SP-3}	%9,5	-%4,6	%31,4	<i>Değiştirme Maliyeti</i>	10,2	12,4 (%22,0)
%RD ^{SP-4}	%18,2	-%3,4	%80,5	<i>Parçayı Geri Döndürme Maliyeti</i>	2,2	1,5 (-%32,4)
%RD ^{SP-5}	-%0,7	-%4,6	%4,1	<i>Parçayı Acil Getirtme Maliyeti</i>	1,3	0,5 (-%59,8)
%RD ^{ORP}	-%7,5	-%22,2	-%1,8	<i>Toplam</i>	26,7	24,8 (-%7,5)

Nümerik analizlerde, önleyici bakım maliyeti olan C^p 'nin 100 olduğu düşünölmüş, düzeltici bakım maliyeti C^c için ise $C^c \in \{200, 300, 600\}$ olacak şekilde üç farklı durum göz önünde bulundurulmuştur. Değişim maliyetlerinin bileşenlere göre farklılaşmadığı varsayılmış ve bileşen değişim maliyeti C^r için $C^r \in \{50, 100, 150\}$ üç farklı durum ele alınmıştır. Bunlara ek olarak, acil sipariş ve fazla yedek parçayı geri gönderme maliyetleri için ise $C^e \in \{30, 50\}$ ve $C^b \in \{60, 90\}$ seviyeleri göz önünde bulundurulmuştur.

Sistemde üç, dört ve beş bileşenin var olduğu durumlar ele alınarak üç farklı sistem konfigürasyonu kurgulanmıştır. Üç bileşenli sistemlerdeki birinci ve ikinci bileşenler için, aşınma seviyesinin bir adımda artma olasılığı 0,10 olarak kabul edilmiştir. Üçüncü bileşen için ise aynı olasılık 0,05 seviyesine ayarlanmıştır. Dört ve beş bileşenli sistemlerde ise aynı olasılık dördüncü ve beşinci bileşenler için 0,05 olarak düşünölmüştür.

Nümerik analizdeki tüm problemlerde, toplam beş farklı aşınma seviyesinin var olduğu düşünölmüş ve bunlardan ikisinin kusursuz çalışma durumlarına denk geldiği varsayılmıştır. Diğer bir deyişle, bu çalışmada incelenen problemlerdeki bütün bileşenler için $F_i = 4$ ve $Y_i = 2$ olarak belirlenmiştir.

Bu alternatif parametrelerin hepsi göz önünde bulundurularak farklı sayıda bileşen içeren her bir konfigürasyon için 36 adet problem, toplamda ise 108 adet problem oluşturulmuş ve elde edilen sonuçlar takip eden paragraflarda raporlanmıştır. Nümerik analizlerde ele alınan tüm problemler Intel i7 2,80Ghz işlemciye ve 16 GB belleğe sahip kişisel dizüstü bilgisayarda koşturulmuştur.

4.4 Analiz sonuçları

Bu kısımda, oluşturulan 108 adet farklı probleme ilişkin sonuçların tamamı incelenmiştir. Oluşturulan her bir problem, 4.1'de tanımlanan tüm politikalar göz önünde bulundurularak çözülmüş ve ilgili özet istatistikler Tablo (3)'ün ilk dört kolonunda verilmiştir.

Tablo (3) SP-1'in ortalamada SP-3 ve SP-4'ten daha iyi çalıştığını ortaya koymuştur. Ayrıca, SP-1'in bakım/onarım masraflarını SP-3 ve SP-4'e göre ortalamada %9,5 ve %18,2 oranında azalttığı da gözlemlenmiştir. Öte yandan, SP-2'nin performansının da SP-1'den daha iyi olduğu tespit edilmiş ve bakım/onarım maliyetlerini SP-1'e göre ortalamada %1,4 kadar düşürdüğü gözlemlenmiştir. Bu durum SP-2 politikasının bize sadece daha düşük karmaşıklık ile uğraşma avantajı sağlamadığını bunun üzerine ortalamada maliyetleri düşürmemize de yardımcı olduğunu göstermiştir. Son olarak, bulgularımız ORP'nin çözümü anlamlı bir şekilde iyileştirdiğini ve SP-1'e kıyasla %7,5 daha düşük bakım/onarım masrafı ortalamasına sahip olduğunu ortaya koymuştur.

SP-1 ve ORP politikaları altında amaç fonksiyonu bileşenlerinin uzun dönem ortalamalarının ortalamaları da hesaplanmış ve hesaplanan bu değerler Tablo (3)'te beşinci ve yedinci kolonlar arasında sunulmuştur. Ayrıca, bahsi geçen ortalamalar arasındaki göreceli farklar da Tablo (3)'ün son kolonunda parantez içinde verilen yüzdellikler ile rapor edilmiştir. Raporlanan bu yüzdellikler, ORP'nin SP-1'e göre sağlamış olduğu iyileştirmelerin hangi kısımlarda ve hangi büyüklüklerde olduğunu göstermektedir.

Beklenildiği üzere, ORP politikasının kullanımı ile en belirgin iyileştirme gereksiz parçaları merkeze geri götürme ve gerekli parçaları acil bir şekilde bakım noktasına getirme masraflarında gözlemlenmiştir. Bunlara ek olarak, ORP'nin kullanımı ile bakım/onarım için ödenen sabit maliyetlerde ortalama %20,4 gibi bir düşüş yaşandığı da görölmektedir.

Tablo 4. Düzeltici bakım maliyetlerinin performans ölçütlerine etkileri

Table 4. Effects of corrective maintenance cost on the system performance measures

	$C^c = 200$	$C^c = 300$	$C^c = 600$
	<i>Ort.</i>	<i>Ort.</i>	<i>Ort.</i>
%RD ^{SP-2}	-%0,9	-%1,2	-%2,0
%RD ^{SP-3}	%27,3	%3,2	-%2,0
%RD ^{SP-4}	-%0,5	%1,0	%54,2
%RD ^{SP-5}	-%0,5	%0,4	-%2,0
%RD ^{ORP}	-%4,5	-%7,5	-%10,4

4.4.1 Düzeltici bakım maliyetinin etkileri

Bu kısımda, elde edilen bütün çözümler düzeltici bakım maliyetlerine göre filtrelenmiş ve düzeltici bakım maliyeti seviyesine göre gruplara bölünerek, her grup için ilgili performans ölçüsünün ortalaması ayrı ayrı bulunmuştur. İlgili sonuçlar Tablo (4)'te sunulmuştur.

Tablo (4) ORP'nin bakım/onarım maliyetleri üzerindeki pozitif etkisinin düzeltici bakım maliyetinin artmasıyla birlikte arttığını göstermiştir. Düzeltici bakım maliyeti 200 iken, ORP'nin bakım/onarım maliyetlerinde sağladığı ortalama düşüş %4,5 civarındadır; düzeltici bakım maliyeti 600 olduğunda bu oran %10,4'lere kadar tırmanmıştır.

Düzeltici bakım maliyeti arttıkça, servis sağlayıcı bakım/onarım kararlarını daha erken ve daha sık almaya başlamaktadır. Bu durum, bileşen değişim ve yedek parça sevkiyat kararlarını daha önemli kılmakta, dolayısıyla da ORP'nin faydasını arttırmaktadır.

4.4.2 Bileşen değiştirme maliyetinin etkileri

Bu kısımda elde edilen bütün çözümler, bileşen değiştirme ma-

liyetlerine göre filtrelenmiş ve bileşen değiştirme maliyeti seviyesine göre gruplara bölünerek, her grup için ilgili performans ölçüsünün ortalaması ayrı ayrı bulunmuştur. Elde edilen bu sonuçlar Tablo (5)'te verilmiştir.

Tablo 5. Bileşen değiştirme maliyetlerinin performans ölçütlerine etkileri

Table 5. Effects of replacement cost on the system performance measures

	C ^r = 50	C ^r = 100	C ^r = 150
	Ort.	Ort.	Ort.
%RD ^{SP-2}	-%2,2	-%0,7	-%1,3
%RD ^{SP-3}	%7,9	%10,1	%10,4
%RD ^{SP-4}	%24,3	%17,7	%12,7
%RD ^{SP-5}	-%1,0	-%0,6	-%0,6
%RD ^{ORP}	-%15,2	-%5,4	-%1,7

Bileşen değiştirme maliyetleri artmaya başladıkça, servis sağlayıcı bakım/onarım kararını daha seyrek almaya başlamaktadır. Bu durum, en iyi politikanın SP-4'e benzemesine, yani giderek *düzeltilici bakım* politikasına benzemesine, neden olmaktadır. Servis sağlayıcının bileşen değiştirme maliyetlerinin artmasıyla beraber izlediği bu strateji, %RD^{SP-4}'de azalmaya %RD^{SP-3}'de ise artışa yol açmıştır. Tablo (5)'te sunulan sonuçlardaki trendler de bu olguyu doğrular niteliktedir.

Ayrıca, Tablo (5)'te bileşen değiştirme maliyetlerinin artmasıyla birlikte ORP'den elde edilen pozitif faydanın azaldığı da gözlemlenmektedir. Daha önce belirtildiği üzere, bileşen değiştirme maliyetleri artmaya başladıkça sistem için olası en iyi politika SP-4'e benzemektedir. Bu durum değişken bakım/onarım maliyetlerinde iyileştirme şansını azaltmakta ve ORP'nin pozitif etkisinin azalmasına yol açmaktadır.

4.4.3 Acil sipariş ve fazla yedek parçayı geri gönderme maliyetleri

Bu kısımda, elde edilen bütün çözümler acil sipariş ve fazla yedek parçayı geri gönderme maliyetlerine göre filtrelenmiş ve bu iki maliyete ilişkin seviyelere göre gruplara bölünmüştür. Daha sonrasında, her bir grup için ilgili performans ölçüsünün ortalaması ayrı ayrı bulunmuştur. Sonuçlar Tablo (6)'da sunulmuştur.

Tablo 6. Acil sipariş ve fazla yedek parçayı geri gönderme maliyetlerinin performans ölçütlerine etkileri

Table 6. Effects of emergency order and return costs on the system performance measures

	C ^e = 50	C ^e = 100	C ^b = 30	C ^b = 50
	Ort.	Ort.	Ort.	Ort.
%RD ^{SP-2}	-%1,4	-%1,4	-%1,0	-%1,8
%RD ^{SP-3}	%8,8	%10,2	%9,2	%9,8
%RD ^{SP-4}	%19,3	%17,1	%19,6	%16,8
%RD ^{SP-5}	-%0,6	-%0,9	-%0,5	-%0,9
%RD ^{ORP}	-%6,7	-%8,2	-%6,3	-%8,6

Acil sipariş maliyetinin artmasıyla birlikte SP-1'in SP-3'e kıyasla bakım/onarım maliyetlerinde sağlamış olduğu pozitif etki artmış, SP-4'e kıyasla sağladığı pozitif etki ise azalmıştır. Acil durum sipariş miktarı yükselmeye başladıkça, servis sağlayıcı bakım/onarım kararlarını olabildiğince ertelemekte ve sisteme ilişkin gerçek durumlardan emin olduğunda bakıma gitmek istemektedir. Bu sayede, ödeyeceği yüksek acil sipariş maliyetlerinden korunmaya çalışmaktadır. Bu durum, en iyi bakım/onarım stratejisinin giderek SP-4'e benzemesine, yani giderek *düzeltilici bakım* politikasına benzemesine, neden olmakta ve SP-1

ve SP-4 arasındaki göreceli farkın azalmasına yol açmaktadır.

Tablo (6)'nın ikinci kısmında, yani geri gönderme maliyetleri ile ilgili olan kısımda, ORP kullanımını bakım/onarım maliyetlerinde SP-1'e göre ciddi bir düşüş sağlamış ve geri gönderme maliyetleri arttıkça bu düşüş oranı da artmıştır. Bu oranın yaklaşık %8,6 değerine kadar çıkmış olduğu gözlemlenmiştir.

4.4.4 Ek sensörler

Bu başlık altında, sistemdeki bileşenlerin aşınma seviyelerini uzaktaki servis sağlayıcıya tam ve net bir biçimde iletebilen ek sensörlerin var olması durumunun performans ölçütlerine etkileri incelenmiştir. Diğer bir deyişle, bileşenlerin aşınma seviyelerine ilişkin bilgi sahibi olmanın maddi kıymeti nümerik analizler yardımı ile irdelenmiştir.

Bu analiz için ele alınan senaryoların tümünde iki bileşenli sistemler göz önünde bulundurulmuş ve bu bileşenlerden birinin yüksek güvenilirliğe diğerinin ise düşük güvenilirliğe sahip olduğu kabul edilmiştir. Buna ek olarak, acil sipariş maliyetinin 60 ve bileşen değiştirme maliyetinin 100 olduğu düşünülmüştür. Gerekli olan diğer tüm parametreler ise 4.3'te verilen senaryolardaki gibi değiştirilmiş ve bu sayede toplamda 24 farklı örnek elde edilmiştir.

Ayrıca, ilgili ek sensörlerin sisteme 3 farklı şekilde takılabileceği üzerine odaklanılmıştır. Diğer bir deyişle, bu ekstra sensörün i) güvenilirliği düşük olan bileşene (yani, aşınma seviyesinin artma olasılığı 0,10 olan), ii) güvenilirliği yüksek olan bileşene (yani, aşınma seviyesinin artma olasılığı 0,05 olan) ve iii) her ikisine birden konuşlandırıldığı göz önünde bulundurulmuştur.

Tablo 7. Ek sensöre sahip olmanın yarattığı pozitif etkiyi ölçmek için incelenen 24 adet örneğe ilişkin özet bilgiler.

Table 7. Summarized statistics on the 24 problem instances considered to analyze the positive effects of having extra, more precise sensors.

	Ort.	Min.	Maks.
%RD ^{DG}	-%7,8	-%12,6	-%4,0
%RD ^{YG}	-%5,1	-%8,4	-%2,6
%RD ^{HI}	-%13,3	-%20,1	-%8,3

Bölümün başında da bahsedildiği gibi bir gruplandırma yapıp her bir grup için çözümler elde edildikten sonra, ek bilgi sahibi olmanın ORP'ye kıyasla ne kadarlık bir iyileştirme sağladığı Denklem (19) ile hesaplanmış ve ilgili sonuçlar Tablo (7)'de sunulmuştur. Tablo (7)'deki ilk satır, diğer bir deyişle, %RD^{DG} ek sensörün düşük güvenilirliğe sahip bileşene takıldığındaki faydaya ilişkin özet değerleri; ikinci satır, yani %RD^{YG} ek sensörün yüksek güvenilirliğe sahip bileşene takıldığındaki faydaya ilişkin özet değerleri; son satırdaki %RD^{HI} ek sensörün her iki bileşene de takıldığındaki faydaya ilişkin özet değerleri göstermektedir.

Tablo (7)'deki sonuçlar, ek sensörün düşük güvenilirliğe sahip bileşene takıldığındaki faydanın (%7,8) yüksek güvenilirliğe sahip bileşene takıldığındaki faydadan (%5,1) daha yüksek olduğunu göstermiştir. Düşük güvenilirliğe sahip bileşenin daha sık bakım/onarımdan geçmesi gerektiği göz önünde bulundurulduğunda, bu bileşene ilişkin daha net bilgiye sahip olmak servis sağlayıcının maliyet açısından daha iyi sonuçlar almasına yardımcı olmaktadır. Öte yandan, sistemdeki her iki bileşene de bu ek sensörler takıldığında sistem bütünüyle uzaktan takip edilebilmekte ve bileşenlerin aşınma seviyeleri net bir biçimde gözlemlenebilmektedir. Böylesi iki sensörün varlığı sisteme ilişkin bakım/onarım maliyetini ortalama %13,3 azaltmayı

başarmıştır. Bu oran aynı zamanda sisteme ilişkin tam bilgi sahibi olmanın da mali olarak kıymetini göstermektedir.

5 Sonuçlar

Karmaşık ve birden fazla bileşen içeren makineler veya sistemler gündelik hayatımızın ayrılmaz bir parçası haline gelmiş ve çoğu zaman kullanıcıları için kritik bir öneme sahip olmaya başlamıştır. Dolayısıyla, bu tarz sistemlerde çoğu zaman yüksek kullanılabilirlik ve güvenilebilirlik oranları talep edilmektedir. Pratikte ilgili performans ölçütlerine ilişkin istekleri karşılayabilmek için koşula bağlı bakım politikaları sıklıkla kullanılmaktadır. Koşula bağlı bakım politikaları, sistemin ve/veya bileşenlerinin durumuna ilişkin anlık veriye dayanarak bakım/onarım planlaması oluşturmaya çalışır. İnternet teknolojilerinin gelişmesiyle beraber ilgili verilerin toplanması ve işlenmesi her ne kadar kolay hale gelse de bazı sistemlerde ekonomik, tasarım ve gizlilik nedenleri ile bileşenlerin anlık durumları tam ve net bir biçimde servis sağlayıcılara iletilmez. Bu tarz durumlarda, servis sağlayıcıları koşula bağlı bakım politikalarını sistem hakkında elde ettikleri kısmi bilgiler (*arızalı, çalışıyor* vb. gibi) ile yürütmeye çalışır. Kısmi bilgi kullanımı nedeniyle, servis sağlayıcıyı ne zaman bakım/onarım için gidileceğine karar vermesinin yanı sıra, bakım için gittiğinde hangi parçaları beraberinde götürüleceğine ve bakım noktasındaki incelemeden sonra hangi bileşenlerin değiştirileceğine de karar vermesi gerekir.

Çalışmamız yukarıda bahsi geçen sisteme benzer bir sistemden esinlenmiş ve kısmi gözlemlenebilir çok bileşenli sistemler için entegre bir bakım/onarım, yedek parça sevkiyat ve bileşen değiştirme karar problemi üzerine odaklanmıştır. İlgili karar problemi kısmi gözlemlenebilir Markov karar süreci olarak modellenmiş ve bu modele ilişkin nümerik çözümler aktör-kritik pekiştirmeli öğrenme metodu aracılığıyla elde edilmiştir.

Nümerik analizlerde, pratikte sıklıkla kullanılan çeşitli sezgisel bakım/onarım politikaları da göz önünde bulundurulmuş, bunlardan elde edilen çözümler, pekiştirmeli öğrenme algoritması ile elde edilen çözümler ile ortalama maliyet kıstası göz önünde bulundurularak kıyas edilmiştir. Buna ek olarak, sistemdeki bileşenlere ait aşınma seviyelerini, uzakta bulunan servis sağlayıcıya tam ve net bir şekilde iletebilen ek sensörlerin var olma durumu ve bunları servis sağlayıcıya maliyet açısından getireceği fayda da nümerik olarak ele alınmıştır. Bu analizler yardımıyla elde edilen öngörüler ise aşağıdaki gibi özetlenmiştir.

- i. Düzeltici bakım maliyetinin önleyici bakım maliyetine göre yüksek olduğu sistemler göz önüne alınmıştır. Bu durum, pratikte sistemin arızaya geçip durduğunda, servis sağlayıcının veya sistem kullanıcısının yüksek maliyetlere katlanmasına denk gelmektedir. Yapılan analizler; düzeltici bakım maliyetinin artmasıyla birlikte, bakım/onarım, yedek parça sevkiyat ve bileşen değiştirme kararlarını entegre bir şekilde belirleyip kullanmanın, servis sağlayıcıya getireceği mali faydanın artacağını ortaya koymuştur. Ayrıca, bu durumda, "*önleyici bakım*" sezgisel politikasının, uygulayıcılar için makul bir alternatif olabileceğini de göstermiştir.
- ii. Bakım noktasında bileşen değiştirme, acil sipariş opsiyonu ile herhangi bir yedek parçayı bakım noktasına getirtme ve bakım noktasına getirilmiş ancak bakımda kullanılmayan herhangi bir yedek parçayı merkeze geri götürme maliyetlerinin artmasıyla birlikte, ilgilendığımız entegre bakım/onarım, yedek parça sevkiyat ve bileşen değiştirme kararının "*düzeltici bakım*" politikasına benzemeye başladığı gözlemlenmiştir.

tir. Bu bulgu, ilgili maliyetler arttıkça, "*düzeltici bakım*" politikasının uygulayıcılar için makul bir sezgisel politika olabileceğini de ortaya koymuştur.

- iii. Sistemdeki bileşenlere ait aşınma seviyelerini, uzakta bulunan servis sağlayıcıya tam ve net bir şekilde iletebilen ek sensörlerin var olması durumunda, bu sensörlerin sistemde düşük güvenilirlik gösteren bileşenlere takılması ve onlarda kullanılmasının servis sağlayıcıya mali açıdan daha fazla fayda sağlayacağı gözlemlenmiştir. Bu gözlemin, yeni sistemlerin tasarım aşamasındaki güvenilirlik mühendisleri için önemli bir öngörü sağladığı düşünülmektedir. Bu sayede, ilgili bileşenlere bu ve benzeri sensörlerin takılabileceği bir tasarım yaratılabilir veya buralardan gelecek verilerin takibinin yapılmasının hem servis sağlayıcıya hem de kullanıcıya faydası olduğu gösterilebilir.
- iv. Son olarak, sistemin tam gözlemlenebilir olmasının servis sağlayıcıya/kullanıcıya ciddi bir fayda sağlayabileceği, bu faydanın sistemin karakteristiklerine bağlı olarak %20,1 ile %8,3 arasında değişebileceği de görülmektedir. Bu sayede, servis sağlayıcı için bileşenlerin aşınma seviyeleri hakkındaki bilginin kıymeti mali açıdan da ölçülmüştür.

Bu çalışma gelecekte farklı açılardan ilerletilebilir ve bu sayede literatüre daha farklı yönlerden katkılarda da bulunulabilir. İlk olarak, bu çalışmada ele alınan sistemdeki sensörün kusursuz çalıştığı ve hiç bozulmadığı kabul edilmiştir. Bu varsayım genişletilerek sensör kusurlu bir hale getirilebilir ve zamanla onun da aşındığı bir durum göz önünde bulundurulabilir. Öte yandan, buradaki yedek parçalara ilişkin herhangi bir envanter kararı ve/veya durumu göz önünde bulundurulmamış, ilgili yedek parçaların envanterde her zaman için yeteri kadar bulunduğu düşünülmüştür. Sistem durumu ve karar politikaları böyle bir durumu içerecek şekilde genişletilebilir; ancak bunun problemi daha da karmaşık hale getireceği unutulmamalıdır.

6 Conclusions

Multi-component and complex machines or systems have become an integral part of our daily lives, and they have critical importance for their users. Therefore, for such systems, high levels of availability and reliability are frequently demanded. In practice, condition-based maintenance policies are often used to meet these demands on performance criteria. Condition-based maintenance policies attempt to create maintenance/repair plans based on real-time data about the condition of the system and/or its components. Despite the advancements in internet technologies, making data collection and processing easier, in some systems, the real-time statuses of components are not fully and clearly communicated to service providers due to economic, design, and privacy reasons. In such cases, service providers attempt to execute condition-based maintenance policies based on partial information they obtain about the system (such as malfunctioning, operational, etc.). Given the use of partial information, the service provider not only needs to decide when to go for maintenance but also needs to decide which parts to take along for maintenance and which components to replace after inspection at the maintenance point. Our study is inspired by such a system and focuses on an integrated maintenance, spare parts shipment, and component replacement decision problem for partially observable multi-component systems. The relevant decision problem is modeled as a partially

observable Markov decision process, and numerical solutions to this model are obtained through the actor-critic reinforcement learning method.

In our numerical analysis, we consider various heuristic maintenance policies that are commonly used in practice and compare the solutions obtained under these policies with the ones obtained from through the reinforcement learning algorithm, considering the long-run average criterion. Furthermore, the presence of additional sensors capable of accurately and clearly conveying the levels of wear of components in the system to a remote service provider and the benefit they would bring to the service provider in terms of cost have been numerically addressed. The industrial and academic gains obtained through these analyses can be summarized as follows:

- i. In our numerical analysis, we consider systems where corrective maintenance costs are higher than preventive maintenance costs. These scenarios, indeed, correspond to situations where the service provider or system user incurs high costs when the system fails. Our results reveal that with the escalation of corrective maintenance costs, the adoption of an integrated policy governing maintenance, spare parts logistics, and component replacement decisions yields greater benefits for service providers. Moreover, with this scenario, it has been demonstrated that the "*preventive maintenance*" policy could be a reasonable heuristic alternative for practitioners when the corrective maintenance cost is reasonably high.
- ii. As the expenses linked with component replacement at the maintenance site, the utilization of emergency orders to deliver spare parts to the maintenance site, and the transportation of any unused spare parts from the maintenance site back to the central facility rise, the approach of integrated maintenance, spare parts logistics, and component replacement decisions begins to mirror the principles of the "*corrective maintenance*" policy. This observation implies that as these pertinent costs escalate, adopting the "*corrective maintenance*" policy becomes a viable heuristic strategy for practitioners.
- iii. With the analysis of the scenarios where additional sensors capable of accurately transmitting the wear levels of components in the system to a remote service provider exist, we show that installing and utilizing these sensors on components exhibiting low reliability in the system would provide greater cost benefits to the service provider. We believe this observation holds significant implications for reliability engineers during the design phase of new systems. As a result, the creation of a design where such sensors can be installed on relevant components or demonstrating the advantages of monitoring data from these sources can be beneficial for both the service provider and the end-user.
- iv. Finally, it has been observed that having full information on the system could provide significant benefits to the service provider/user, with this benefit ranging from 8.3% to 20.1% depending on the system characteristics. Thus, the value of information regarding the wear levels of components has been quantified financially for the service provider.

This study can be extended in several ways. Firstly, in this study, it is assumed that the sensor in the system works perfectly and never falls down. This assumption can be expanded by considering a case where the sensor becomes imperfect and also undergoes wear over time. On the other hand, no inventory decision regarding the spare parts here has been considered; it is assumed that the relevant spare parts are always sufficiently available. The problem can be expanded to include such a decision, either; however, it should be noted that this would further complicate the problem.

7 Yazar katkı beyanı

Gerçekleştirilen çalışmada, Yazar 1 fikrin oluşması, tasarımın yapılması, literatür taraması, elde edilen sonuçların değerlendirilmesi, kullanılan malzemelerin temin edilmesi, sonuçların incelenmesi, yazım denetimi ve içerik açısından makalenin kontrol edilmesi başlıklarında katkı sunmuştur.

8 Etik kurul onayı ve çıkar çatışması beyanı

Hazırlanan makalede etik kurul izni alınmasına gerek yoktur. Ayrıca, hazırlanan makalede herhangi bir kişi/kurum ile çıkar çatışması bulunmamaktadır.

9 Kaynaklar

- [1] Zhang M, Revie M. "Continuous-observation partially observable semi-Markov decision processes for machine maintenance". *IEEE Transactions on Reliability*, 66(1), 202-218, 2016.
- [2] Alaswad S, Xiang Y. "A review on condition-based maintenance optimization models for stochastically deteriorating system". *Reliability Engineering & System Safety*, 157, 54-63, 2017.
- [3] De Jonge B, Scarf PA "A review on maintenance optimization". *European Journal of Operational Research*, 285(3), 805-824, 2020.
- [4] Karabağ O, Bulut Ö, Toy AÖ, Fadiloğlu MF. "An efficient procedure for optimal maintenance intervention in partially observable multi-component systems". *Reliability Engineering & System Safety*, 244, 109914, 2024.
- [5] Karabağ O, Eruguz AS, Basten R. "Integrated optimization of maintenance interventions and spare part selection for a partially observable multi-component system". *Reliability Engineering & System Safety*, 200, 106955, 2020.
- [6] Karabağ O, Bulut Ö, Toy, AÖ. "Markovian decision process modeling approach for intervention planning of partially observable systems prone to failures". *International Conference on Intelligent and Fuzzy Systems (INFUS)*, İzmir, Türkiye, 19-21 July 2022.
- [7] Quatrini E, Costantino F, Di Gravio G, Patriarca R. "Condition-based maintenance—an extensive literature review". *Machines*, 8(2), 31, 2020.
- [8] Gürsoy MÜ, Çolak UC, Gökçe MH, Akkulak C, Ötleş S. "Endüstri için kestirimci bakım". *International Journal of 3D Printing Technologies and Digital Industry*, 3(1), 56-66, 2019.
- [9] Van Horenbeek A, Buré J, Cattrysse D, Pintelon L, Vanssteenwegen P. "Joint maintenance and inventory optimization systems: A review". *International Journal of Production Economics*, 143(2), 499-508, 2013.
- [10] Nguyen KT, Do P, Huynh KT, Bérenguer C, Grall A. "Joint optimization of monitoring quality and replacement decisions in condition-based maintenance". *Reliability Engineering & System Safety*. 189(1), 177-95, 2019.

- [11] Liu X, Sun Q, Ye ZS, Yildirim M. "Optimal multi-type inspection policy for systems with imperfect online monitoring". *Reliability Engineering & System Safety*. 207(1), 107335, 2021.
- [12] Zhao Y, Smidts C. "Reinforcement learning for adaptive maintenance policy optimization under imperfect knowledge of the system degradation model and partial observability of system states". *Reliability Engineering & System Safety*. 224(1), 108541, 2022.
- [13] Tseremoglou I, Santos BF. "Condition-Based Maintenance scheduling of an aircraft fleet under partial observability: A Deep Reinforcement Learning approach". *Reliability Engineering & System Safety*. 241(1), 109582, 2024.
- [14] Andriotis CP, Papakonstantinou KG. "Managing engineering systems with large state and action spaces through deep reinforcement learning". *Reliability Engineering & System Safety*. 191(1), 106483, 2019.
- [15] Andriotis CP, Papakonstantinou KG. "Deep reinforcement learning driven inspection and maintenance planning under incomplete information and constraints". *Reliability Engineering & System Safety*. 212(1), 107551, 2021.
- [16] Zhang N, Si W. "Deep reinforcement learning for condition-based maintenance planning of multi-component systems under dependent competing risks". *Reliability Engineering & System Safety*. 203(1), 107094, 2020.
- [17] Mohammadi R, He Q. "A deep reinforcement learning approach for rail renewal and maintenance planning". *Reliability Engineering & System Safety*. 225(1), 108615, 2022.
- [18] Lovejoy WS. "Computationally feasible bounds for partially observed Markov decision processes". *Operations Research*, 39(1), 162-175, 1991.
- [19] Kıvanç İ, Özgür-Ünlüakın D, Bilgiç T. "Maintenance policy analysis of the regenerative air heater system using factored POMDPs". *Reliability Engineering & System Safety*, 219, 108195, 2022.
- [20] Ceyhan H, Kasapbaşı MC. "Üretim sistemlerinde makine öğrenmesi ile kestirimci bakım uygulaması ve modellenmesi". *Avrupa Bilim ve Teknoloji Dergisi*, 33, 167-175, 2022.
- [21] Calayır GN, Kabak M. "Bakım için makine öğrenme tekniklerinin analizi ve bir uygulama". *Journal of Turkish Operations Management*, 5(1), 662-675, 2021.
- [22] Gençer MA, Yumuşak R, Özcan E, Tamer E. "An artificial neural network model for maintenance planning of metro trains". *Politeknik Dergisi*, 24(3), 811-820, 2021.
- [23] Güven Ö, Şahin H. "Predictive maintenance based on machine learning in public transportation vehicles". *Mühendislik Bilimleri ve Araştırmaları Dergisi*, 4(1), 89-98, 2022.
- [24] Soylu B, Yiğiter H, Sarıkaya V, Sandıkçı Z, Asena U. "Kestirimci bakım planlama için makine öğrenmesi temelli bir karar destek sistemi ve bir uygulama". *Verimlilik Dergisi*, 48-66, 2022.
- [25] Hatipoğlu A, Güneri Y, Yılmaz E. "Makine ve derin öğrenme temelli karşılaştırmalı bir öngörücü bakım uygulaması". *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 39(2), 1037-1048, 2023.
- [26] Bertsekas DP. *Dynamic Programming and Optimal Control, Volume-II*. 4th ed. Belmont, USA, Athena Scientific, 2012.
- [27] Puterman ML. *Markov Decision Process: Discrete Stochastic Dynamic Programming*. Hoboken, USA, John Wiley & Sons, 2014.
- [28] Sutton RS, Barto AG. *Reinforcement learning: An introduction*. Massachusetts, USA, MIT press, 2018.
- [29] Estanjini RM, Li K, Paschalidis IC. "A least squares temporal difference actor-critic algorithm with applications to warehouse management". *Naval Research Logistics*, 59(3-4), 197-211, 2012.