

ÇOK BOYUTLU TURBOFAN MOTORU DURUM İZLEME VERİLERİNDE PROGNOSTİK UYGULAMALARININ DEĞERLENDİRİLMESİ

Dr Oğuz Bektaş *
Yükseköğretim ve Yurt Dışı
Eğitim Genel Müdürlüğü, Uçak
Gövde-Motor Bakımı Alanı
Resmi Mezun Bursiyer

ÖZET

Prognostik terimi; önbilisel, öngörümse, kestirimsel anlamında kullanılan ve kritik sistemlerin kondisyon esaslı bakımları konusunda yeni uygulanmaya konulmuş bir kavramdır. Bu disiplin kalan faydalı ömrü tahmin edebilme kapasitesinin yanı sıra, sistem güvenilirliği ve operasyon maliyetleri açısından kritik önem teşkil etmektedir. Geçtiğimiz son on yılda, prognostik ve kullanışlı hayat tahmin uygulamalarının rolü modern mühendislik alanında giderek yaygınlaşmaya başlamış ve önem kazanmıştır. Gelişmiş prognostik modellemeler kompleks sistemler için istenen bir hedeftir ve aynı zamanda maliyetleri azaltmak için umut verici bir seçenektir. Ancak, prognostik uygulamaların teknik yöntemleri genel olarak veri işlemenin evrimi ve kalan faydalı ömür tahminleri üzerindeki kritik nitelikleri dikkate alınmadan tasarlanmıştır. Özellikle, bu eksiklikler çok boyutlu veri analizi ve bu veriden kullanışlı hayat tahmini yapma konusunda daha belirgindir. Verinin ön analizi, doğrudan prognostik tahmin güvenilirliği ile ilintilidir ve operasyon karakteristikleri göz önüne alınarak tasarlanmalıdır.

Bu çalışmada, dinamik veri analizi ve kalan faydalı ömür uygulamaları ile birlikte, tahmin performans düzeylerinin ilişkisi incelenmektedir. Çok boyutlu veri analizinde ve gelecek tahminlerinde kullanılan metotların karşılaştırılması yapılmış ve farklı senaryolarda hangi model veya model bileşimlerinin uygulanabileceği ileri sürülmüştür. Değerlendirilen uygulamalar NASA prognostik merkezinin turbofan motoru durum izleme verileri için yapılan sıralamada (PHM08 data challenge) en yüksek skor alan metotlar arasından seçilmiştir.

Anahtar Kelimeler: Prognostik, Veri analizi, Kalan Faydalı Ömür Tahmini, Çok Boyutlu Veri

*PhD, T.C. MİLLÎ EĞİTİM BAKANLIĞI, Uçak Gövde-Motor Bakımı Alanı Resmi Mezun Bursiyer, E-posta: oguz.bektas@warwickgrad.net

GİRİŞ

Doğru ve güvenilir prognostik tahminleri gerçekleştirebilme, kondisyon temelli bakım (KtB) uygulamalarında kritik bir kavram olmakla beraber bakım planlaması, düşük maliyetler ve daha az çalışma süreleri için kilit bir değere sahiptir [Peng et al., 2010]. KtB stratejilerinin başarısı, bakım personeline ekipman yetersizliği hakkında önceden bildirim gönderilmesine bağlıdır ve literatürde en basit anlamıyla bir sistemin ve ya bileşenlerin kullanışlı hayatını tahmin etmek olarak tanımlanan prognostik, bu bağlamda yeterli süre önermek için gerekli otomasyon prosedürlerine tabi olmalıdır. [Butler, 2012].


Prognostik bir yöntemin geliştirilmesinde asıl hedef, bir bileşenin veya sistemin tamamının istenen işlevlerini yerine getiremediği hasar anını tahmin edebilmektir [Pecht, 2008]. Tahminler, mevcut sistem durum izleme verilerini ve sistemin gelecekteki davranışını etkileyecek olan evrimsel koşullarını anlamak suretiyle yapılabilir [Goebel et al., 2013]. Tahmin yapmak gelecekteki kesin olmayan bir olayla ilgili olması nedeniyle, prognostik yaklaşımlar temel varsayımlar üzerine kuruludur ve prognostik bilimi dört temel kavrama dayanmaktadır [Uckun et al., 2008]:

- Bütün sistemler, kullanımın ve çevresel koşulların bir fonksiyonu olarak zamanla bozulurlar.
- Yaşlanma semptomları, başarısızlıktan önce saptanabilir.
- Yaşlanma ve hasar birikimi, sistemlerin fiziksel ve kimyasal bileşiminde var olan monoton süreçlerdir.
- Yaşlanmanın evrimsel belirtileri bir sistemin bozulma modeli ile ilişkilendirilmesi mümkündür ve bu nedenle, tek tek sistemlerin kalan faydalı ömürleri tahmin edilebilmektedir.

Bu varsayımlarla ilgili olarak, bir sistemin tipik bir “başarısızlık evrimleşme zaman aralığı”, düşünüldüğünde, prognostiklerin rolü ve tanı koyma (diagnostik) ile arasındaki bağlantı incelenebilir. Bir sistem, operasyonların ilk başlangıcında, tüm bileşenleri ile düzgün bir şekilde çalışır durumdadır ve beklenildiği üzere bakım gerektirmez. Her operasyonel yörünge, kullanımın erken aşamalarında genellikle stabil olan kendi özel sağlamlık seviyesine sahiptir. Bu, başlangıçtaki bir erken arıza durumunun görüldüğü kritik bir döneme kadar devam eder. Zaman ilerledikçe ve operasyonlar ilerledikçe, sistemin bozulmasına ve sonuç olarak bir felaket arızasına neden olabilecek sistem hatası riski zamanla artar. Sistem başarısızlığının ve ağır hasar durumunun zaman içinde iki farklı nokta olduğu unutulmamalıdır. Bu arızaların ve hasarların başlangıçta tespit edilmesi, kalan faydalı ömrün tahmini için her zaman önemlidir. Durum değişiklikleri ve arıza karakteristiklerinin saptanması prognostikler ile teşhis arasındaki etkileşimi gerektirir. Prognostik uygulamadaki asli amaç, durum farkındalığının algılanmasının mümkün olan en yakın aralıktaki ilk arıza noktasına getirmektir.

Şekil 1’de görüldüğü üzere, bir sistemdeki ilk arızadan kaynaklanan bir bozulma süreci artmaya devam eder ve sonunda sistem hasar durumuna neden olan kritik bir duruma gelir. Sistem, üretiminden sonra normal kabul edilebilen bir sağlamlık seviyesinde operasyonlara başlar, yani bir arıza durumu yoktur. Buradaki tanısız gösterim, baştaki semptomun doğrudan bir sonucu olan hasarın tahmin edilmesi ile ilgilidir. Bu semptomun yerine göre, prognostik uygulamalar gelecek ömür tahminlerini yerine getirir.

Prognostik uygulamalar, başarısızlığın ilk tespiti ile fiili arıza (hasar) koşulları arasında uygulanırken, diagnostik (tanı koyma, teşhis) uygulamaları arıza koşulları esnasında uygulanır [Lee et al., 2014]. Sonuç olarak, prognostik ve teşhis uygulamaların hedefleri farklıdır, ancak aynı alanda uygulanmakta ve benzerlikler göstermektedir. Her iki sağlamlık hesaplama uygulaması da KtB




Şekil 1: Sistem bozulma süreci (Lee et al. [2014]'dan adapte edilmiştir)

alanında uygulandığı için, her ikisi de kondisyon temelli veri toplama ve sinyal işleme ile ilgili benzer aşamalar içerir.


YÖNTEMLER

Bu çalışmada, dinamik veri analizi ve kalan faydalı ömür uygulamalarının değerlendirilmesi, NASA prognostik merkezi tarafından yapılan sıralama (PHM08 data challenge) ve C-MAPSS veri tabanları göz önüne alınarak yapılmıştır.

C-MAPSS uygulaması, Turbo fan Motor simülasyonlarını gerçekleştirmek için kullanılmıştır Saxena and Goebel [2008b,a]. Şekil 2 ve 3'de bu uygulamaya ait diyagramlar verilmiştir. Bu taslaklarda gösterildiği üzere; modeli yapılan sistem orta ve büyük boyutta uçaklar tarafından kullanılan bir tür gaz türbini motorudur.




Şekil 2: Basitleştirilmiş C-MAPSS seması Frederick et al. [2007]



Şekil 3: Örnek C-MAPSS planlaması Frederick et al. [2007]

Sistem, itiş gücünü egzozdan çıkan havayla ve ön kısımda görülen fanla sağlar. İtişi artırmak için ön kısım büyük, arka kısım ise görece daha küçük ve koni şeklinde tasarlanmıştır. Güvenilirliği, bakım kolaylığı ve ticari uçuşlara elverişliliği nedeni ile bu tip motorlar genel olarak yolcu uçaklarında kullanılır.

NASA tarafından sağlanan C-MAPSS simülasyonlarındaki ham değerlerde, tek bir döngü sırasında alınan parametrelerin bir anlık görüntüsü verilmiş ve her sütun, farklı bir değişkene karşılık gelecek biçimde kondisyon izleme veri tabanı oluşturulmuştur. Şekil 4'de tek bir operasyonel yörünge boyunca yüksek basınç kompresöründen alınan statik basınç değerleri gösterilmiştir.




Şekil 4: Yüksek basınç kompresörü statik basınç değerleri

Burada gösterilen her bir anlık görüntü 6 farklı operasyonel rejimden birine aittir. Şekil 5'de bu veriler bulundukları rejime göre farklı bir renkte boyanmıştır ve tanımlı verilerin kendi rejim alt ve üst sınırlarında bulundukları gözlemlenmiştir. Bu rejim farkları uçuş esnasında oluşan kalkış, iniş,


cruise ve diğer benzer operasyon rejimlerindeki farklılıklardan kaynaklanmaktadır. Turbofan motor sisteminin genel sistem performansı değişmemekle birlikte rejim farklılıklarında sistemden okunan değerler ve bu değerlerin içinde bulunduğu operasyonel değer aralıkları farklılık göstermektedir.

Sistemin genel performans bozunması bulabilmek için bu rejim aralıkları ayrı olarak incelenmeli ve sistemden alınan çok rejimli verilerin tek bir aralığa indirgenmesi gerekmektedir. Böylece, genel performans rejim farklılıkları olmaksızın tek bir operasyonel düzende izlenebilir.



Şekil 5: Rejimlerine ayrılmış zaman serisi

Turbo fan motorlardan alınan kondisyon verileri, farklı rejimlerden ötürü çok boyutludur. Verinin kendi ölçümleri dışında; rejim, rejim aralığı ve zaman da dikkate alınmalıdır. Şekil 6'da üç boyutlu düzlemde bu değerler gösterilmiştir. Her bir verinin kendi rejimindeki alt ve üst sınırlarda bulundu göz önüne alındığında, araştırmacılar için ana sorun bu rejimlerin ortak bir düzleme indirgenmesi olarak tanımlanabilir.



Şekil 6: Üç boyutlu düzlemde verinin sunumu

2008'de ilk yayımlanışlarından beri, yukarıda grafiklerle gösterilen ve incelenen C-MAPSS verileri binlerce kez indirilmiş ve 2018 yılı itibarıyla yayınlanan literatürde bu veri tabanını kullanan 200'den fazla bildiri bulunmuştur. Sıralamada en yüksek yöntemler, gelecek metotların geliştirilmesinde değerli olabileceklerinin yanı sıra, en iyi sonuçların daha ayrıntılı bir analizini yapmak için burada özetlenecektir.

Yörünge Benzerlik Esaslı Yaklaşım

Wang et al. [2008] faydalı ömür tahminleri için benzerlik temelli bir yaklaşım ileri sürmüştür. Bu yaklaşım, hatırı sayılır miktarda kondisyon temelli veriye erişilebildiği durumlarda özellikle uygundur. Aynı sistemin birden fazla ünitesinden gelen yörüngeler, bir eğitim kütüphanesi oluşturmak için ortak bir şekilde kullanılır. Test ünitelerinin kalan ömrünü tahmin etmek için, test yörüngelerinin bozunma yörüngeleri, kütüphanedeki filtrelenmiş eğitim modelleriyle eşleştirilir. Eğitim ve test çiftleri arasındaki mesafe, en uygun konumu bulmak için kullanılır. Eşleşen birimlerin gerçek kalan ömürleri daha sonra omur tahmini için temel olarak kullanılır.

Bozulma yörüngeleri, çeşitli operasyonel rejimlere ait verileri işleyerek "Sağlamlık Göstergeleri" olarak hesaplanır. Başlangıçta veri seti, çok rejimli bir sağlık değerlendirmesine tabi tutmak için rejim bölümlenmesine maruz bırakılır. Bir kümeleme yöntemi kullanarak, veriler her rejime karşılık gelen altı kümeye gruplanır. Ardından, bu kümeler birbirlerine göre normalize edilir ve orijinal konumlarına yeniden monte edilir. Veri setindeki 2, 3, 4, 7, 11, 12 ve 15 numaralı sensörler, davranışlarındaki uygunluk nedeniyle prognostik değerlendirmesi için manuel olarak seçilir. Sağlamlık Göstergeleri dizisi, sağlıklı durumdan başarısızlık durumuna gelişimi açıklayan bozunma modelini tahmin etmek için filtrelenir. Kütüphane için eğitim yörüngeleri aşağıdaki (doğrusal olmayan) regresyon modeli ile donatılmıştır:

$$h(t) = 1 - d - \exp(at^b) \quad (1)$$

d aşınma alanındaki rasgele bir noktadır, a ve b model parametreleridir ve t zaman endeksidir.

Tekrarlı Sinir Ağı Yaklaşımı

[Heimes, 2008], kullanışlı hayat tahminleri için tekrarlayan sinir ağı modelini uygulamıştır. Ağ, doğru bir süreç oluşturmak için zaman eğim hesaplamaları, Kalman süzgeç yöntemi ve evrimsel algoritmalar ile beraber tasarlanmıştır. Algoritma adaptasyon, filtreleme ve sınıflandırma problemlerini çözmek için geliştirilmiştir. Başlangıçta, sağlam bir sistem ile başarısız bir sistem arasındaki farkın etkili bir şekilde sınıflandırılabilceğini belirlemek için çok katmanlı bir sinir ağı tasarımı gerçekleştirilmektedir.

Bu çok katmanlı sinir ağının işlevi, arıza öncesinde kalan çevrim sayısını öngörür. Her bir eğitim yörüngesindeki en erken 30 numunenin sağlam olduğu ve son 30 numunenin bozulmuş olduğu varsayılmıştır. Veriler daha sonra iki farklı veri grubuna kümelenebilir: sağlam bir ünite ve bozulmuş bir ünite. Çok katmanlı sinir ağı tabanlı bir sınıflandırıcı bu birimleri % 1 hata oranı ile ayırt edebilmiştir.

Çok Katmanlı Algılayıcı ve Kalman Filtresine Dayalı Yaklaşım

Peel [2008], regresyon için çok katmanlı algılayıcı ve radial temelli fonksiyon ağlarını beraber olarak uygulamıştır. Kalman süzgeç yöntemi, bu ağların uygun bir seçimi ile birleştirilir. Tasarlanan algoritma, Kalman süzgecini ve çoklu sinir ağı modeli tahminlerini zamanla kaynaştırmak için bir mekanizma sunar.

Birinci bölümde, ön işleme ve veri araştırmasının temel başlangıç aşamaları tartışıp, nörolojik-ölçek haritalama gibi görselleştirme teknikleri anlatılır. Bu aşamalar sensörlerde var olan altı rejiminin tanımlanmasına neden olur. Standart skor fonksiyonu, veri kümesindeki bileşen bazlı normalleşmeyi gerçekleştirmek için bir ön işlem adımı olarak kullanılır. Bu standardizasyon, veri kümelerinin tüm farklı özelliklerinde ortak bir ölçek sağlayabilir.

Kullanışlı kalan ömür birden fazla parametreleştirme ve sinir ağlarının işbirliğiyle tahmin edilir. Kalman süzgeci, sensor gürültüsünü azaltmak ve geçmiş bilgileri birleştirmek için kullanılır. Bir sürecin durumunu tahmin etmek için özyinelemeli bir yöntem olarak tasarlanmıştır ve tahmin ve güncelleme aşamalarından oluşur.

Benzerlik Esaslı Kalan Faydalı Ömür Tahminleri için Sinir Ağı Filtreleme Yaklaşımı

Bektas et. al [2018] karmaşık sistemlerin operasyonel yörüngeleri için veri normalleştirme ve filtreleme yöntemlerinin etkin bir şekilde kullanılmasına olanak sağlayan benzerlik temelli bir prognostik algoritma tasarlamıştır. Birden fazla rejim normalizasyonu ve ileri beslemeli sinir ağlarına dayanan, veri tabanlı bir prognostik teknik, karmaşık bir sistemin performansını hesaplar. Özellikle, bu çalışma ön işleme yöntemlerinin algoritma performansını nasıl etkilediğine yakından bakmaktadır. Bu çalışma, kısa vadeli test veri setleri tarafından sunulan zorlukların üstesinden gelen ve prognostik ölçümlerle ilgili tahmin performansını arttıran kavramsal bir prognostik çerçeve göstermektedir.

Veri işleme ve kullanışlı kalan ömür hesaplaması için kullanılan diğer yaygın adımlar

C-MAPSS veri tabanlarını kullanan yayınların çoğu veri işleme, problem formülasyonu ve sistem davranışı tanımlama gibi kalan faydalı ömür tahmini amacıyla çeşitli hesaplama aşamalarını sunmuştur. Bununla birlikte, önemli sayıda yayın, "hata tespiti" için sadece "rejim sınıflaması" ve "kümeleme" yoluyla veri setlerini kullanmıştır. Bu geliştirilen yöntemlerin, daha sonra kalan faydalı ömür tahmini aşamaları için gerekli arıza tespiti ile de ilgilendiğine dikkat edilmelidir. Çalışma koşullarına bağlı olarak, sınıflandırma ve kümeleme adımları, genellikle, sensörlerin hangi rejime ait olduğunu bulmak için bir süreç olarak tasarlanır. Wang et al. [2008]; Wang [2010]; Ramasso and Gouriveau [2010]; Peng et al. [2012]; Javed et al. [2013]'nın eserlerinde, sınıflandırmayı prognostikler için bir ön işlem adımı olarak kullanılır. Rejimler tanımlanır ve sensörler bu rejimlere göre sınıflandırılır.

Veri setlerindeki çok boyutlu rejim sorunuyla başa çıkmak için, yayınlar iki ana kategoride sınıflandırılabilir: gözetimli veya gözetimsiz. Gözetimli sınıflandırma teknikleri, her sınıflandırıcı bir "ana yapılandırıcı" olarak bilinen temsili bir veri yörüngesi tarafından eğitildiğinden daha doğru olma eğilimindedir. Bunun aksine, gözetimsiz öğrenme sınıflandırmayı işlemek için önceden eğitime gerek duymaz. Sağlık göstergesi algılaması için uygulanan gözetimli sınıflandırma aşamalarını kullanan uygulamalar Ramasso [2009]; Ramasso and Gouriveau [2010]; Bektas and Jones [2016]'ın yayınlarını kapsar.

[Wang et al., 2008; Wang, 2010; Peng et al., 2012; Rigamonti et al., 2016] yayınlarında sınıflandırma için gözetimsiz öğrenme algoritmalarını, verinin rejimlerine bölünmesi ve filtrelenmesi için kullanmıştır. Bu yöntemler, veri trendleri içindeki gizli kalıpları tanımlamak için rejimi analizi ve boyut indirgeme yöntemleri olarak kabul edilebilir. Bu yöntemler, tüm veri kümesindeki popülasyon parametreleriyle ilgili olduğundan, ilk aşınma seviyesi ve hata noktası gibi karakteristik yörünge özelliklerini ortak bir ölçekte standart hale getirilebilir.

Sinyal işleme ve öznitelik çıkarma adımları için kullanılan başlıca yöntemler, Gaussian kernel düzlemesi [Wang, 2010], temel bileşenler analizi [Zhao et al., 2011], regresyon analizi [Ramasso, 2014a; Bektas et al., 2017], z-test [Rigamonti et al., 2016] ve polinom eğrisi filtrelemesi [Bektas

Tablo:1 Prognostik Metrikler

Metric	Formula	
Ortalama Mutlak Hata [Hyndman and Koehler, 2006]	$MAE = \frac{1}{n} \sum_{i=1}^n e_i = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	e =hata y =gerçek kalan faydalı ömür $\hat{y}$ =tahmin edilen kalan faydalı ömür n =tahmin sayısı
Ortalama Mutlak Yüzde Hatası [Saxena et al., 2008a]	$MAPE = \frac{100}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $	
Ortalama Hata karesi [Hyndman and Koehler, 2006]	$MSE = \frac{1}{n} \sum_{i=1}^n e_i^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	
Yanlış Pozitif Oran [Goebel et al., 2011]	$FP(i) = \begin{cases} 1 & \text{error} > t_{FP} \\ 0 & \text{otherwise} \end{cases}$	t_{FP}, t_{FN} =Kabul edilebilir geç/erken tahmin limitleri
Yanlış Negatif Oran [Goebel et al., 2011]	$FN(i) = \begin{cases} 1 & -\text{error} > t_{FN} \\ 0 & \text{otherwise} \end{cases}$	
Anormallik Korelasyonu Katsayısı [Goebel et al., 2011]	$ACC = \frac{\sum (\pi(i j) - z_{\#}(i)) (z_{*}(i) - z_{\#}(i))}{\sqrt{\sum (\pi(i j) - z_{\#}(i))^2 \sum (z_{*}(i) - z_{\#}(i))^2}}$	$z_{*}(i)$ =tahmin değişkeni $z_{\#}(i)$ =karşılık gelen geçmiş veri değeri
Standart sapma [Hyndman and Koehler, 2006]	$s = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (y_i - \mu_e)^2}$	μ_e =ortalama
Örnek Medyan Değerden Ortalama Mutlak Sapma [Saxena et al., 2008a]	$MAD_i = \frac{1}{n} \sum_{i=1}^n e_i - M $	$M = median(e)$
Örnek Medyan Değerden Medyan Mutlak Sapma [Saxena et al., 2008a]	$MdAD = median(e_i - M)$	

and Jones, 2016] uygulamalarını içerir. Bu yöntemler, çeşitli gürültü faktörleri içeren veri setlerini normalize etmede kullanılır.

Çok adımlı gelecek tahminlerinde ise en çok uygulanan yaklaşımlar, tahmin esnasında önceden bilginin yavaş yavaş dahil edilmesini [Coble, 2010], başarısızlık eşiklerini belirlenmesi [Ramasso and Gouriveau, 2010; Javed et al., 2012] ve sağlamlık endekslerini gösterilmesini [Wang et al., 2008; Wang, 2010; Lam et al., 2014; Ramasso, 2014a] içeren uygulamalardan oluşur.

UYGULAMALAR

C-MAPSS veri setinin en önemli özelliklerinden biri, performans metrikleri ile prognostik yöntemlerini değerlendirmesidir. Geliştirilen bir model tahmin edici sonuçlar verirse, geliştiriciler Saxena et al. [2008a] tarafından sunulan kalan faydalı ömür performans ölçütlerinin taksonomisini kullanabilir. Yayınların geçerliliğini ve karşılaştırılmasını sağlamak için, belirli çalışmalarla elde edilen metrikler Tablo 1’de özetlenmiştir.

Sıralama ise kalan faydalı ömür tahmininde yapılan hataların üstel çarpımının bir toplamı olan PHM Skorlama fonksiyonuna dayanılarak oluşturulmuştur [Saxena et al., 2008a; Goebel et al., 2011] Aşağıdaki denklemler asimetrik olan puanlama fonksiyonunu tanımlar.


$$s = \begin{cases} \sum_{i=1}^n e^{-\left(\frac{d}{a_1}\right)} & \text{for } d < 0 \\ \sum_{i=1}^n e^{\left(\frac{d}{a_2}\right)} & \text{for } d \geq 0 \end{cases} \quad (2)$$

Tablo:2 Geliştirilen Modellerin Sıralaması

	Skor F.	MSE	FPR	FNR	MAPE	MAE	Corr.	Std Dev.	MAD	MdAD
1 Bektas et. al [2018]	5530.12*	515.35	48.51	50.8	20.68	15.93	0.92	1.07	16.63	10.2
2 [Wang et al., 2008]	5636.06	546.6	64.83	31.72	19.99	16.23	0.93	1.01	16.33	11
3 [Peel, 2008]	6691.86	560.12	63.68	36.32	17.92	15.38	0.94	1.03	16.29	8.08
4 [Heimes, 2008]	8637.57	672.17	61.38	23.45	20.72	17.69	0.92	1.09	17.79	11
5 —	9530.35	741.2	58.39	39.54	34.93	20.19	0.9	1.22	20.17	15
6 —	10571.58*	764.82	58.85	41.15	32.6	20.05	0.91	1.22	20.41	14.23
7 [Ramasso, 2014a]	11572	-	-	-	-	-	-	-	-	-
8 —	14275.6	716.65	59.77	37.01	21.61	18.16	0.9	1.17	18.57	11
9 —	19148.88	822.06	56.09	41.84	30.25	20.23	0.88	1.29	20.89	13
10 —	20471.33	1000.06	51.95	48.05	33.63	22.44	0.88	1.42	24.05	14.78
11 —	22755.85	1078.19	62.53	35.4	39.9	24.51	0.86	1.45	24.08	20
12 —	25921.26	854.57	34.25	64.83	51.38	22.66	0.86	1.36	21.49	16

* 2008'deki sıralamadan sonra

burada s hesaplanan skor, n tahmin edilen birimlerin sayısı ve d ise hata terimidir. Skorlama işlevi, geç tahminleri, erken tahminlerden daha fazla cezalandıran asimetrik bir metriktir. $a_1 = 13$ ve $a_2 = 10$. Tahminler için herhangi bir üst ceza limiti yoktur ve bu nedenle, veri kümesindeki öngörüler arasındaki tek bir yüksek hata oranı son puanı domine edebilir. Şekil 7'de bu fonksiyonun asimetrik erken ve geç puanlama sistemi gösterilmiştir.



Şekil 7: Skor fonksiyonu

Tablo 2, veri setlerini kullanan yaklaşımların performansını ve sıralamasının göstermektedir. Her ne kadar araştırmacılar, çalışmalarını 2008'deki modellere karşı geliştirebilme olanağına sahip olsa da, bu tabloda sadece iki yaklaşım sıralanabilmektedir Bektas et. al [2018]; Ramasso [2014a].

SONUÇ

Bu çalışmanın temel amacı, son yıllarda gittikçe önemi artan prognostik uygulamalar için Türkçe literatür oluşturmaktır. Kullanılan metotlar kategorize edilmiş ve incelenmişlerdir. Literatürdeki yüksek performanslı uygulamalar çok boyutlu veri uygulamaları alanında özel olarak incelenmiştir.

Bu çalışmada, ayrıca C-MAPSS veri setlerini prognostik amaçlarla kullanan algoritmalar değerlendirilmiştir. Veri tabanlı yaklaşımlar ve benzerlik esaslı kalan faydalı ömür hesaplamalarının diğerlerine göre daha başarılı olduğu gözlemlenmiştir. Çoklu rejim normalizasyonu ile eğitilmiş sinir ağı tarafından filtreleme uygulandığından, tüm veri kümesinin bir kerede standardize edilebilmesi sağlanabilmektedir. Böylece hem eğitim hem de test yörüngeleri, ilk aşınma düzeylerini göz önüne alarak tek tek işlenebilir.

Bununla birlikte, C-MAPSS veri setlerini kullanan yayınların çoğu veri işleme, problem formülasyonu ve sistem davranışı tanımlama gibi farklı hesaplama aşamalarını da sunmuştur. Yüksek sıralama alan uygulamalarla beraber bu hesaplamalarda prognostik çalışmaları için önemli bir literatür oluşturmuştur.

Kaynaklar

- An, D., Choi, J.-H., and Kim, N. H. (2013). *Prognostics 101: A tutorial for particle filter-based prognostics* algorithm using matlab. *Reliability Engineering & System Safety*, 115:161–169.
- Batko, W. (1984). *Prediction method in technical diagnostics*. Unpublished doctoral dissertation, Cracov Mining Academy.
- Bayes, T., Price, R., and Canton, J. (1763). *An essay towards solving a problem in the doctrine of chances*. C. Davis, Printer to the Royal Society of London.
- Bektas, O., Alfudail, A., and Jones, J. A. (2017). *Reducing dimensionality of multi-regime data for failure prognostics*. *Journal of Failure Analysis and Prevention*, 17(6):1268–1275.
- Bektas, O. and Jones, J. A. (2015). *A degradation prognostic framework for gas turbine engines*. In *The Twelfth International Conference on Condition Monitoring and Machinery Failure Prevention Technologies*.
- Bektas, O. and Jones, J. A. (2016). *Narx time series model for remaining useful life estimation of gas turbine engines*. In *Third European Conference of the Prognostics and Health Management Society*.
- Bektas O. (2018). *An Adaptive Data Filtering Model for Remaining Useful Life Estimation*. PhD thesis, University of Warwick.
- Biagetti, T. and Sciubba, E. (2004). *Automatic diagnostics and prognostics of energy conversion processes via knowledge-based systems*. *Energy*, 29(12-15):2553–2572.
- Bishop, C. M. (1995). *Neural networks for pattern recognition*. Oxford university press.
- Butler, K. L. (1996). *An expert system based framework for an incipient failure detection and predictive maintenance system*. In *Intelligent Systems Applications to Power Systems, 1996. Proceedings, ISAP'96., International Conference on*, pages 321–326. IEEE.
- Butler, S. (2012). *Prognostic Algorithms for Condition Monitoring and Remaining Useful Life Estimation*. PhD thesis, National University of Ireland.
- Cempel, C. (1987). *Simple condition forecasting techniques in vibroacoustical diagnostics*. *Mechanical Systems and Signal Processing*, 1(1):75–82.
- Coble, J. B. (2010). *Merging data sources to predict remaining useful life—an automated method to identify prognostic parameters*. PhD thesis, University of Tennessee.

- Dmitry, K. and Dmitry, V. (2004). *An algorithm for rule generation in fuzzy expert systems*. In Pattern Recognition, 2004. ICPR 2004. Proceedings of the 17th International Conference on, volume 1, pages 212–215. IEEE.
- Dong, M. and He, D. (2007). *A segmental hidden semi-markov model (hsmm)-based diagnostics and prognostics framework and methodology*. Mechanical Systems and Signal Processing, 21(5):2248–2266.
- Frederick, D., DeCastro, J., and Litt, J. (2007). *User's guide for the commercial modular aero-propulsion system simulation (c-mapss)*. (tech. rep.), Cleveland, Ohio, 44135.
- Galati, F. A., Forrester, D., and Dey, S. (2008). *Application of the generalised likelihood ratio algorithm to the detection of a bearing fault in a helicopter transmission*. Australian Journal of Mechanical Engineering, 5(2):169–176.
- Goebel, K., Saha, B., Saxena, A., Mct, N., and Riacc, N. (2008b). *A comparison of three data-driven techniques for prognostics*. In 62nd Meeting of the Society For Machinery Failure Prevention Technology (MFPT), pages 119–131.
- George, V., Frank, L., Michael, R., Andrew, H., and Biqing, W. (2006). *Intelligent fault diagnosis and prognosis for engineering systems*. John Wiley & Sons, Inc.
- Goebel, K., Saxena, A., Saha, S., Saha, B., and Celaya, J. (2011). *Prognostic performance metrics*. Machine Learning and Knowledge Discovery for Engineering Systems Health Management, 147.
- Goebel, K., Vachtsevanos, G., and Orchard, M. E. (2013). *Prognostics*. NASA, Prognostics - Intelligent Systems Division.
- Guo, Q., Wu, W., Massart, D., Boucon, C., and De Jong, S. (2002). *Feature selection in principal component analysis of analytical data*. Chemometrics and Intelligent Laboratory Systems, 61(1):123–132.
- Heimes, F. O. (2008). *Recurrent neural networks for remaining useful life estimation*. In Prognostics and Health Management, 2008. PHM 2008. International Conference on, pages 1–6. IEEE.
- Heng, A., Zhang, S., Tan, A. C., and Mathew, J. (2009). *Rotating machinery prognostics: State of the art, challenges and opportunities*. Mechanical Systems and Signal Processing, 23(3):724–739.
- Hu, C., Youn, B. D., and Chung, J. (2012a). *A multiscale framework with extended kalman filter for lithium-ion battery soc and capacity estimation*. Applied Energy, 92:694–704.
- Hyndman, R. J. and Koehler, A. B. (2006). *Another look at measures of forecast accuracy*. International journal of forecasting, 22(4):679–688.
- Javed, K., Gouriveau, R., Zemmouri, R., and Zerhouni, N. (2012). *Features selection procedure for prognostics: An approach based on predictability*. IFAC Proceedings Volumes, 45(20):25–30.
- Javed, K., Gouriveau, R., and Zerhouni, N. (2013). *Novel failure prognostics approach with dynamic thresholds for machine degradation*. In Industrial Electronics Society, IECON 2013-39th Annual Conference of the IEEE, pages 4404–4409. IEEE.
- Juesas, P., Ramasso, E., Drujont, S., and Placet, V. (2016). *On partially supervised learning and inference in dynamic bayesian networks for prognostics with uncertain factual evidence: Illustration with markov switching models*.

- Kim, N.-H., An, D., and Choi, J.-H. (2017). *Prognostics and Health Management of Engineering Systems*. Springer.
- Lam, J., Sankararaman, S., and Stewart, B. (2014). *Enhanced trajectory based similarity prediction with uncertainty quantification*. In Annual Conference of the Prognostics and Health Management Society 2014.
- Lee, J., Wu, F., Zhao, W., Ghaffari, M., Liao, L., and Siegel, D. (2014). *Prognostics and health management design for rotary machinery systems—reviews, methodology and applications*. Mechanical systems and signal processing, 42(1):314–334.
- Li, Y., Billington, S., Zhang, C., Kurfess, T., Danyluk, S., and Liang, S. (1999). *Adaptive prognostics for rolling element bearing condition*. Mechanical systems and signal processing, 13(1):103–113.
- Li, C. J. and Choi, S. (2002). *Spur gear root fatigue crack prognosis via crack diagnosis and fracture mechanics*. In Proceedings of the 56th Meeting of the Society of Mechanical Failures Prevention Technology, pages 311–320.
- Li, C. J. and Lee, H. (2005). *Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics*. Mechanical systems and signal processing, 19(4):836–846.
- Li, Y., Kurfess, T., and Liang, S. (2000). *Stochastic prognostics for rolling element bearings*. Mechanical Systems and Signal Processing, 14(5):747–762.
- Liao, L. and Köttig, F. (2014). *Review of hybrid prognostics approaches for remaining useful life prediction of engineered systems, and an application to battery life prediction*. IEEE Transactions on Reliability, 63(1):191–207.
- Orchard, M. E. and Vachtsevanos, G. J. (2009). *A particle-filtering approach for on-line fault diagnosis and failure prognosis*. Transactions of the Institute of Measurement and Control.
- Orchard, M., Wu, B., and Vachtsevanos, G. (2005). *A particle filtering framework for failure prognosis*. In World Tribology Congress III, pages 883–884. American Society of Mechanical Engineers.
- Oppenheimer, C. H. and Loparo, K. A. (2002). *Physically based diagnosis and prognosis of cracked rotor shafts*. In AeroSense 2002, pages 122–132. International Society for Optics and Photonics.
- Paris, P. C. and Erdogan, F. (1963). *A critical analysis of crack propagation laws*. ASME.
- Peel, L. (2008). *Data driven prognostics using a kalman filter ensemble of neural network models*. In Prognostics and Health Management, 2008. PHM 2008. International Conference on, pages 1–6. IEEE.
- Pecht, M. (2008). *Prognostics and health management of electronics*. Wiley Online Library.
- Peng, Y., Dong, M., and Zuo, M. J. (2010). *Current status of machine prognostics in condition-based maintenance: a review*. The International Journal of Advanced Manufacturing Technology, 50(1-4):297–313.
- Peng, Y., Wang, H., Wang, J., Liu, D., and Peng, X. (2012). *A modified echo state network based remaining useful life estimation approach*. In Prognostics and Health Management (PHM), 2012 IEEE Conference on, pages 1–7. IEEE.

- Ramasso, E. (2009). *Contribution of belief functions to hidden markov models with an application to fault diagnosis*. In Machine Learning for Signal Processing, 2009. MLSP 2009. IEEE International Workshop on, pages 1–6. IEEE.
- Ramasso, E. (2014a). *Investigating computational geometry for failure prognostics*. International Journal of Prognostics and Health Management, 5(1):005.
- Ramasso, E. (2014b). *Investigating computational geometry for failure prognostics in presence of imprecise health indicator: Results and comparisons on c-mapss datasets*. European conf. on prognostics and health management., 5(1):005.
- Ramasso, E. and Saxena, A. (2014). *Performance benchmarking and analysis of prognostic methods for cmapss datasets*. International Journal of Prognostics and Health Management, 5(2):1–15.
- Ramasso, E. and Gouriveau, R. (2010). *Prognostics in switching systems: Evidential markovian classification of real-time neuro-fuzzy predictions*. In Prognostics and Health Management Conference, 2010. PHM'10., pages 1–10. IEEE.
- Rigamonti, M., Baraldi, P., Zio, E., Roychoudhury, I., Goebel, K., and Poll, S. (2016). *Echo state network for the remaining useful life prediction of a turbofan engine*. In Proceedings of the Third European Prognostic and Health Management Conference, PHME.
- Saxena, A., Celaya, J., Balaban, E., Goebel, K., Saha, B., Saha, S., and Schwabacher, M. (2008a). *Metrics for evaluating performance of prognostic techniques*. In Prognostics and Health Management, 2008. PHM 2008. International Conference on, pages 1–17. IEEE.
- Saxena, A. and Goebel, K. (2008a). *Phm08 challenge data set*. NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA.
- Saxena, A. and Goebel, K. (2008b). *Turbofan engine degradation simulation data set*. NASA Ames Prognostics Data Repository (<http://ti.arc.nasa.gov/project/prognostic-data-repository>), NASA Ames Research Center, Moffett Field, CA.
- Satish, B. and Sarma, N. (2005). *A fuzzy bp approach for diagnosis and prognosis of bearing faults in induction motors*. In Power Engineering Society General Meeting, 2005. IEEE, pages 2291–2294. IEEE.
- Schwabacher, M. and Goebel, K. (2007). *A survey of artificial intelligence for prognostics*. In Aai fall symposium, pages 107–114.
- Sikorska, J., Hodkiewicz, M., and Ma, L. (2011). *Prognostic modelling options for remaining useful life estimation by industry*. Mechanical Systems and Signal Processing, 25(5):1803–1836.
- Swanson, D. C. (2001). *A general prognostic tracking algorithm for predictive maintenance*. In Aerospace Conference, 2001, IEEE Proceedings., volume 6, pages 2971–2977. IEEE.
- Uckun, S., Goebel, K., and Lucas, P. J. (2008). *Standardizing research methods for prognostics*. In Prognostics and Health Management, 2008. PHM 2008. International Conference on, pages 1–10. IEEE.
- Wang, T. (2010). *Trajectory similarity based prediction for remaining useful life estimation*. PhD thesis, University of Cincinnati.
- Wang, T., Yu, J., Siegel, D., and Lee, J. (2008). *A similarity-based prognostics approach for remaining useful life estimation of engineered systems*. In Prognostics and Health Management, 2008. PHM 2008. International Conference on, pages 1–6. IEEE.

- Zaidan, M. A. (2014). *Bayesian Approaches for Complex System Prognostics*. PhD thesis, University of Sheffield.
- Zhao, D., Georgescu, R., and Willett, P. (2011). *Comparison of data reduction techniques based on svm classifier and svr performance*. In *SPIE Optical Engineering+ Applications*, pages 81370X–81370X. International Society for Optics and Photonics.