

<https://dergipark.org.tr/tr/pub/khosbd>

ARIMA ve LSTM Yöntemleri ile Mühimmat Tüketimi Tahminlemesi

Prediction of Ammunition Consumption with ARIMA and LSTM Methods

Gökçe Nur TAŞAĞIL ARSLAN ^{1*} İlayda KORKMAZ ¹ Kemal Gürol KURTAY ¹

¹Milli Savunma Üniversitesi, Kara Harp Okulu, Endüstri Mühendisliği Bölümü, Ankara, Türkiye

Makale Bilgisi

Araştırma makalesi
Başvuru: 01.04.2025
Düzeltilme: 01.08.2025
Kabul: 15.08.2025

Anahtar Kelimeler

Mühimmat
Savunma Sanayi
ARIMA
LSTM
Talep Tahmini


Keywords

Ammunition,
Defense Industry
ARIMA
LSTM
Demand Forecasting

Önemli Noktalar

Mühimmat, harekât alanlarında savaşların sonucunu etkileyen en önemli malzemelerden biridir. Bu nedenle savaş öncesinde mühimmat tüketiminin tahmin edilmesi, aşırı stoklama veya harekât esnasında mühimmatsız kalınmaması için büyük önem taşımaktadır. Bu çalışmada bir tip mühimmat için yapılan tahminin farklı tipteki mühimmatlar için yapılabileceği düşünülmektedir. Bu tahmin metotları sayesinde mühimmat temin planlarının ve bütçelerinin hazırlanacağı savunma sanayi faaliyetlerinde geleceğe yönelik üretim planlaması ve tesis alt yapısı oluşturulması gibi konularda önemli fayda sağlayacağı değerlendirilmektedir.

Grafiksel Özet



Özet

Günümüzde silah ve mühimmatın türleri, gelişmişlik düzeyi değişmiş olsa da tarihin her döneminde düşmanın savaşma azim ve iradesini ortadan kaldırmak için aktif olarak kullanılmaktadır. Mühimmat, harekât alanında muharebelerin sonucunu etkileyen önemli bir faktördür. Doğru mühimmat talep tahminleri sayesinde, askeri operasyonlarda ihtiyaç duyulacak mühimmatın yetersiz kalması önlenir. Bu çalışmada geçmişe ait jenerik bir senaryoya dayalı mühimmat kullanım verilerinden, gelecekte oluşacak benzer bir çatışma ortamı için mühimmat ihtiyacının bilimsel metotlarla tahminine yönelik olarak bir metodoloji sunulmuştur. Literatürde birçok alanda kullanılmış olan ancak mühimmat tüketimi tahmininde kullanılmayan farklı iki tahmin metodunun mühimmat tahmini açısından kullanımı ile literatürdeki boşluğun doldurulması amaçlanmıştır. Bu amaçla zaman serisi analizi için ARIMA ve derin öğrenme için LSTM yöntemleri mühimmat tahmini için ele alınmış ve anlamlı sonuçlar elde edilmiştir. Bu çalışmanın temel motivasyonu, mühimmat talebine yönelik öngörüler için derin öğrenme yaklaşımı kullanılarak elde edilen tahmin sonuçlarını geleneksel zaman serisi yöntemleriyle karşılaştırmaktır.

Abstract

Although the types and sophistication levels of weapons and ammunition have changed in modern times, they have continued to be actively used throughout history to eliminate the enemy's determination and will to fight. Ammunition is a crucial factor influencing the outcome of battles in the operational area. Accurate ammunition demand forecasting prevents the shortage of ammunition required for military operations. This study presents a methodology for scientifically predicting ammunition requirements for a similar conflict scenario in the future, based on historical ammunition usage data from a generic scenario. It has been used in many fields in literature, but this study aims to fill a gap in literature by applying two different forecasting methods, which have not been used in ammunition forecasting. To this end, ARIMA for time series analysis and LSTM for deep learning were applied to ammunition forecasting, and meaningful results were obtained. The primary motivation of this study is to compare the forecasting results obtained using deep learning approaches for ammunition demand with traditional time series methods.

*Corresponding author, e-mail: gokcenur.tasagil@msu.edu.tr

1. GİRİŞ (INTRODUCTION)

Savaş, devletler, gruplar veya diğer topluluklar arasında, genellikle politik, ekonomik veya ideolojik çıkarlar doğrultusunda, şiddet kullanılarak yürütülen, uzun süreli ve organize çatışmalardır. İnsanla birlikte değişen ve gelişen bu süreç, toplumsal yapıları, ekonomik sistemleri ve insan hayatını derinden etkileyebilir [1]. Savaşın kesin bir tanımı bulunamamakla birlikte çeşitli tanımlamalar yapılmıştır. Savaş Sanatı adlı eserinde Sun Tzu savaşı tanımlarken ‘Savaş ulus için önem taşıır-çünkü bu var olma ya da yok olma yolu, ölümle kalım meydanıdır.’ şeklinde tanımlamıştır [2]. Tarihsel olarak barutun keşfi ve ateşli silahların sürekli olarak gelişimi savaşın özünde olan düşmanı imha etme eğilimini daha da arttırmıştır. Ülkeler teknolojik açıdan ilerledikçe kullandıkları silah ve mühimmatın düşmanı yok etme kabiliyetini artırmaya çalışmışlardır. Günümüzde silah ve mühimmatın türleri ve gelişmişlik düzeyi değişmiş olsa da tarihin her döneminde düşmanın savaşma azim ve iradesini yok etmek için ordular tarafından aktif olarak kullanılmaya devam edilmekte hatta gelişen teknolojiye paralel olarak her geçen gün daha da artmaktadır.

Ordunun savaş gücü ‘Bir askeri birliğin istenilen yer ve zamanda kullanabileceği yıkıcı, yapıcı ve bilgi kabiliyetlerinin toplamıdır.’ şeklinde tanımlanır. Bununla birlikte savaş gücü bütün paydaşlar tarafından sağlanan ve komutanın hedefleriyle entegre edilmiş yeteneklerin tümünü kapsar [3].

Bir ülkenin askeri gücünü ön plana çıkaran ve harekât alanında muharebenin sonucunu etkileyen en önemli etmenlerden birisi ülkenin sahip olduğu mühimmatın imkân ve kabiliyetidir.

Mühimmat, Silahlı Kuvvetlerin kullandığı ve düşman kuvvetlerini yok etmek veya onlara maksimum zayıatı vermek üzere imal edilmiş olan her türlü patlayıcı maddeler olarak ifade edilebilir. Ülkelerin alacakları ve stoklayacakları mühimmatın planlanması harekât ortamının düşman birliklerin saldırılarının ve savaşın süresinin öngörülememesinden dolayı zor olmaktadır. Ülkeler mühimmat talep tahminleri sayesinde savunma bütçelerini planlayabilir, kaynakların optimal bir şekilde kullanılmasını sağlayabilir ve savunma, güvenlik politikalarını belirleyebilirler [4]. Doğru mühimmat talep tahminleri sayesinde, askeri operasyonlarda ihtiyaç duyulacak mühimmatın eksik kalması önlenir. Böylelikle bir kısmı kullanıma hazır, bir kısmı da kolay ulaşılabilecek büyük mühimmat stoklarının sayısı belirlenebilir [5]. Geçmişteki yapılan çatışmalarda kullanılan mühimmat verileri sayesinde çeşitli tahmin yöntemleri kullanılarak mühimmat talep tahminini bilimsel yöntemlerle belirlemek mümkün olmakta ve hatta doğru tahminlerin yapılabilmesi açısından bilimsel yöntemlerin kullanılması büyük önem taşımaktadır. Bu yöntemlerden bazıları, makine öğrenmesi modelleri, derin öğrenme modelleri, zaman serisi analizleri, regresyon modelleri olarak sıralanabilir.

Zamana göre sıralanmış gözlem değerlerinden oluşan veriye zaman serisi denir. Gelecekteki eğilimlerin tarihsel eğilimlere benzer olacağı varsayımıyla geçmişin eğilimlerini analiz ederek gelecekteki olayları tahmin eder. Zaman serileri analizi ile verilerdeki düzenlilikler, dalgalanmalar ve mevsimsellikler incelenerek gelecekteki değerler öngörülür. Derin öğrenme ise veri dağılımındaki değişen desenlere ve

mevsimselliklere uyum sağlayarak tahminleme yapmayı sağlar.

Bu çalışmada zaman serisi analizleri ve derin öğrenme yöntemleri kullanarak mühimmat talep tahminleri yapılmıştır. Bu amaçla, geçmişe ait jenerik ve hayali bir senaryoya dayalı mühimmat kullanım verilerinden, gelecekte oluşacak benzer bir çatışma ortamı için mühimmat ihtiyacının bilimsel metotlarla tahminine yönelik olarak bir metodoloji sunulmuştur. Mühimmat tüketimi tahmininde kullanılmayan farklı iki tahmin metodun mühimmat tahmini açısından kullanımı ile literatürdeki boşluğu doldurması amaçlanmıştır. Bu bilimsel yöntemlerle yapılacak doğru tahminler sayesinde özellikle günümüzde gerçekleşen Rusya-Ukrayna, İran-İsrail çatışmalarındaki gibi mühimmat sıkıntısı yaşanmasının da önüne geçilebileceği düşünülmektedir.

Çalışmanın ikinci bölümü literatür ile devam etmektedir. Üçüncü bölümde, Mühimmat ve mühimmat stoğunun önemi anlatılmıştır. Dördüncü bölümde araştırmanın kapsamı, veri seti ve kullanılan yöntemler hakkında bilgi verilmiştir. Beşinci bölümde ise yapılan analiz sonucunda elde edilen bulgular sunulmuştur. Çalışma, sonuç bölümü ile tamamlanmaktadır.

2. LİTERATÜR ÖZETİ (LITERATURE RESEARCH)

Literatürde tahminleme üzerine birçok farklı alanda ve farklı yöntemler kullanılarak çalışmalar yapıldığı görülmüştür. Bu çalışmaya paralel olabilecek LSTM ve zaman serisi yöntemlerinin karşılaştırıldığı çalışmalar incelenmiştir. Gencer ve Başçiftçi [6] çalışmalarında ARIMA ve Derin öğrenme yöntemleri kullanarak Android işletim sistemlerinin güvenlik açıklarını tahminlemeyi

amaçlamıştır. Uygulama sonucunda LSTM modelinin RMSE değeri 26.83 ve ARIMA modelinin ise 18.44 çıkmıştır. Çalışma sonucunda ARIMA modelinin uygulanan diğer modellere göre daha iyi sonuçlar verdiği vurgulanmıştır. Elsaraiti ve Merabet [7] rüzgâr hızını tahmin etmek için en iyi sonucu veren modeli araştırmıştır. Çalışmada ARIMA ve LSTM modellerini kullanılarak sonuçlar karşılaştırılmıştır. Çalışma sonucunda LSTM modelinin RMSE sonucu ARIMA modeline göre daha düşük çıktığı için özellikle büyük verilerin tahmin edilmesinde LSTM modelinin kullanılması gerektiği vurgulanmıştır. Bouzid ve diğerleri [8] ARIMA ve LSTM modeli kullanarak deterjan talep tahmini gerçekleştirmiştir. Çalışma sonucunda iki modelin RMSE değerleri karşılaştırılmıştır. ARIMA modelinin RMSE değeri LTSM modeline göre daha yüksek çıktığı, LTSM modelinin tahmin gücünün daha iyi olduğu vurgulanmıştır. Hua [9] ARIMA ve LSTM modeli kullanarak Bitcoin fiyatlarını tahmin etmeyi amaçlamıştır. Çalışma sonucunda hem LSTM hem ARIMA'nın fiyatları tahmin etmede iyi sonuçlar çıkardığı ortaya konmuştur. Aynı zamanda LSTM modelinin eğitilmesi için daha fazla zamana ihtiyaç olurken daha başarılı tahmin yapabileceği, ancak ARIMA modelinin daha az zamanda tahmin yapmada verimli olduğu ve zaman arttıkça tahminlerin hassasiyet oranının azaldığı vurgulanmıştır. Siami-Nami ve diğerleri [10] çalışmada borsadaki finansal verileri kullanarak ARIMA ve LSTM modeli ile tahmin yapmıştır. Çalışmada ARIMA modeli ile LSTM modelinin sonuçları karşılaştırılmıştır. Çalışma sonucunda LSTM modelinin ARIMA modeline

göre daha iyi performans gösterdiği vurgulanmıştır.

Mun ve diğerleri [11] askeri kara araçlarında arıza durumu tahminini LSTM modeli kullanarak gerçekleştirmiştir. Çalışmada tek değişkenli LSTM ve çok değişkenli LSTM model sonuçları karşılaştırılmıştır. Çok değişkenli LSTM modelinin iyi sonuçlar verdiği ve erken arıza tespitinde modelin kullanılabilir olduğu vurgulanmıştır. Malone [12] Çatışma tahmini için LSTM, Violence Early Warning System (ViEWS) ve ARIMA modellerini kullanmıştır.

MSE, TADDA değerlerine göre model sonuçlarını karşılaştırmıştır. Genel olarak sonuçlarda LSTM modelinin ARIMA modeline göre daha iyi sonuç verdiği ve ViEWS kıyaslama modeline benzer sonuçlar gösterdiği ortaya koyulmuştur. Ueno ve Calitoiu [13] Kanada Silahlı Kuvvetleri çeşitli sebeplerden dolayı (uygunsuz davranış, belirsiz, sağlık, gönüllü, hizmet tamamlama, ölüm) askeri kayıpları tahmin etmeyi amaçlamıştır. Çalışmada LSTM ve Holt-Winters tahmin modellerini kullanarak iki modelin sonuçlarını karşılaştırmış ve çalışma sonucunda LSTM modelinin Holt-Winters modeline göre daha iyi sonuçlar verdiği vurgulanmıştır. Vavliakis ve diğerleri [14] çalışmalarında satış tahmini gerçekleştirmek için bir ARIMA modelini bir LSTM sinir ağıyla birleştirerek doğrusal ve doğrusal olmayan satış eğilimlerini modellemeye uygun yeni bir hibrit model önerisi sunmuştur. Çalışma sonucunda önerilen model sonuçları, ARIMA ve LSTM model sonuçları ile karşılaştırılmıştır. RMSE, MAE ve MSE değerlerine göre önerilen hibrit model karşılaştırılan üç modele üstünlük sağladığı vurgulanmıştır.

Sharma ve Phulli [15] çalışmalarında ARIMA modeli kullanarak Hindistan'ın askeri harcamalarını tahmin etmeyi amaçlamıştır. Denenen ARIMA modelleri arasında en iyi sonucu ARIMA (0,1,6) modeli vermiştir. Kuo ve diğerleri [16] ARIMA ve ANN modeli kullanarak Çin'in savunma harcamaları tahminini gerçekleştirmiştir. Tek değişkenli model tahmininde ARIMA modeli ANN modeline göre çok daha iyi sonuç vermiştir. 4 tane çok değişkenli model önerilmiş. Çok değişkenli modeller arasında savunma harcamaları ve GSYH içeren ANN modelinin en iyi sonucu verdiği vurgulanmıştır. Borucka [17] çalışmasında askeri hava üssünden uçak gemilerine olabilecek talebi ARIMA modeli kullanarak tahmin etmeyi amaçlamıştır. Çalışma sonucunda ARIMA (1,0,1) modeli uçuş gerçekleştirme talebini yüksek olasılıkla tahmin ettiği ortaya koyulmuştur. Bu sayede komutanın, personel için görevleri daha kesin bir şekilde planlayabileceği, uçakları kontrol edebileceği ve nihayetinde sistemin hazırlık durumunu yüksek güvenilirlikle test edebileceği vurgulanmıştır.

Literatürde yapılan incelemede tahmin yöntemlerinin birçok farklı alanda kullanıldığı ancak askeri alanda yapılan çalışmaların çok az olduğu görülmüştür. Özellikle ihtiyaç duyulan mühimmat sayısının tahmini amacıyla yapılan çalışmalar incelendiğinde zaman serisi ve derin öğrenme yöntemlerinin birlikte kullanıldığı bir çalışmaya rastlanılmamıştır. Bu çalışmanın ana amacı mühimmat talep tahminlerini öngörmek için geleneksel zaman serisi yöntemleri ile derin öğrenme yaklaşımını kullanarak elde edilen tahmin sonuçlarını karşılaştırmaktır. En iyi sonucu veren yöntem kullanılarak, mühimmat

tahminleri gerçekleştirilecek ve bu tahminlere göre örnek bir jenerik senaryo için stok politika önerilerinde bulunulmuştur. Yapılan literatür çalışmasında mühimmat tahminine yönelik bir çalışmaya rastlanılamadığından sunulan analitik yaklaşım savunma planlamasının en önemli problem sahalarından olan mühimmat planları için literatüre yeni bir katkı sunmaktadır.

3. MÜHİMMAT VE MÜHİMMAT STOĞUNUN ÖNEMİ (IMPORTANCE OF AMMUNITION AND AMMUNITION STOCKPILE)

Ülkelerin stratejik önemi, mevcut terör olayları, komşu ülkelerdeki çatışma ortamları, ülke güvenliği için yürütülen operasyonlar, dünyada yaşanan savaşlar güçlü bir ordu kurulmasını zorunlu kılmaktadır [4-18]. Bu durum, bir kısmı kullanıma hazır, bir kısmı da kolay ulaşılabilecek büyük mühimmat stoklarını bulundurma zorunluluğunu doğurmaktadır [19]. Mühimmat, birliklere kendisini koruma, düşmanı imha etme, imkânı sağlamaktadır. En modern silah sistemleriyle donatılan askeri birliklerin mühimmat olmadan zafer kazanmaları mümkün değildir. Mühimmat silah sistemlerinin etkin ve verimli kullanılabilmesi için gerekli olan en önemli malzemelerden birisidir. Günümüz savaşlarının aynı anda birden fazla bölgede ve karma kuvvetlerin aynı anda kullanıldığı hibrit savaş olarak ifade edilen türden olduğu düşünüldüğünde, mühimmat yönetim sisteminin modüler, mobil ve esnek bir yapıya sahip olması büyük önem taşımaktadır [1]. Silahlı Kuvvetlerde; modern, NATO standartlarında ve tüm emniyet kriterlerine göre konuşlandırılmış depolardan harekât alanına süratli ve doğru bir akışı sağlayacak bir mühimmat sistemine sahip olmak büyük önem taşımaktadır [20]. Bunun

yanında çatışma ortamının ihtiyaç duyduğu mühimmat sayısının doğru tahmin edilmesi savaş ortamında mühimmatsız kalınmaması açısından son derece önemlidir. Günümüzde ordular Rusya-Ukrayna savaşında olduğu gibi geçmişe göre daha geniş bir alanda ve daha uzun sürelerde askeri harekatlar icra etmektedir. Bu durum geçmişe kıyasla lojistik faaliyetlerin daha detaylı planlanmasını gerektirmektedir [5]. Bu açıdan da bakıldığında ülkelerin ekonomik refahının düşmemesi için doğru tahmin yapılmasının önemi bir kez daha ortaya çıkmaktadır.

Birliklere; kriz, terörle mücadele, askeri güç kullanımı veya savaş durumunda mühimmat ikmalinin sağlanması büyük önem taşımaktadır. Bu kapsamda gerekli olan mühimmat, barış döneminden itibaren harekât planları doğrultusunda çeşitli miktarlarda ve değişik bölgelerde stok yapılmaktadır. Bu nedenle, yurt çapında “mühimmat depolarının” yerleri, sayıları, kapasitesinin belirlenmesi, çözüm bulunması gereken önemli bir problem sahası olarak karşımıza çıkmaktadır. Ancak bu problemin çözümünde ele alınması gereken en önemli girdi gerekli mühimmat sayısının belirlenerek hangi çeşit ve ne kadar mühimmatın bir çatış içinde depolanacak olmasıdır. Günümüzde çatışma ortamlarının uzun sürmesi nedeniyle çatışmanın ortasında mühimmatsız kalma durumu oluşmakta bu durumda ülkelerin bekasını tehlikeye sokmaktadır. Diğer taraftan çok fazla miktarda mühimmatın temin edilmesi durumunda da kıt kaynakların verimsiz kullanılmasına neden olunmaktadır. Kıt kaynakları halkın refahı için kullanmak yerine ihtiyacın üzerinde mühimmat alımında kullanılması gerek depolama gerekse kullanım

süresi dolan mühimmatın imha edilme zorunluluğu nedenleriyle maliyet etkin olmamaktadır [20,21].

Günümüzde ordular geçmişe göre çok daha geniş bir alanda ve çok daha uzun süreler askeri hareketler icra etmektedir. Dünyanın en gelişmiş ordusu olarak gösterilen Amerikan Ordusu lojistiği iki farklı şekilde tanımlamaktadır. Bunlardan ilki; lojistik, kuvvetlerin hareketini ve desteklenmesini planlamak ve yürütmektir [22]. İkincisi ise; ABD’de bulunan üretim üslerinde başlayan ve düşmanla temas halinde bulunan askere kadar uzanan, savaşın her çeşidinde ve seviyesinde devam eden, operasyonların ölçeği ve yoğunluğu arttıkça başarı ile icrasının öneminin de arttığı faaliyetlerin bütünüdür. Mühimmat lojistiği ise bu faaliyetlerden yalnızca bir tanesidir [23].

Mühimmat hem barışta hem de savaşta çok önemli bir ikmal maddesidir. Tarih boyunca mühimmatın boyutu ve şekli değişmiş ancak savaş alanlarında aktif olarak kullanımı değişmemiştir. Mühimmatların günümüzdeki halini alması belirli aşamalardan sonra gerçekleşmiştir. Mühimmatların gelişimi açısından tarihte yaşanan en büyük gelişmelerden birisi barutun icadıdır. Kara barut kömür, kükürt ve amonyum nitratın bir karışımıdır ve itici güç olarak ilk olarak top ve silahlarda kullanılmıştır [24]. İlk mermiler ise taş, demir ve kurşundan yapılmıştır [25]. Bu şekilde üretilen mermiler ile yapılan atışlar kısa mesafelere gitmekteydi ve istenilen derecede isabet sağlamıyordu. Ancak 1948 yılında minie mermisi adı verilen merminin icat edilmesi ile birlikte yiv ve seti bulunan silahların kullanılmasıyla yapılan atışların mesafesi ve isabet oranı yükselmiştir.

Günümüzde ordular tarafından farklı tipte birçok mühimmat kullanılmaktadır. Bu mühimmatın doğru zamanda ve yerde erişebilmek savaşların neticesini belirleyebilmektedir [26]. Erişemeyen orduların ise mağlup olacağı bilinen bir gerçektir.

Savaşların büyüklüğü arttıkça mühimmatın önemi de artmaktadır. Özellikle büyük ölçekli savaşlarda, küçük ölçekli çatışma/savaşlara oranla savaşın şiddeti ve temposu yüksek olmakta, bununla beraber malzeme, teçhizat ve mühimmat gereksinimleri de aşırı yükselmektedir [23]. Örneğin İkinci Dünya Savaşında Alman ordusu savaşın başlangıcında önemli başarılar elde etse de savaşın geniş bir coğrafyaya yayılması ile birlikte artan mühimmat ihtiyacı ve bu ihtiyacın karşılanmasında yaşanan zorluklar nedeniyle neredeyse her cephede mağlubiyete uğramıştır. Personel eksikliğinden kaynaklanan boşlukları mühimmat ikmalinin de yetersiz kalmasıyla ateş gücü olarak da telafi edilememiştir [27].


Bunun için; barıştan itibaren yeterli mühimmat stokunun harekât planlarını destekleyecek şekilde yurt genelinde dağıtılması ve bu stokların göreve hazır şekilde muhafazası, noksanlardan stokların süratle tamamlanması gerekmektedir. Son zamanlarda dünya genelinde yaşanan çatışmalar ve savaşlarda yeni teknolojik gelişmeler ve askeri taktik değişiklikler sebebiyle muharebelerin süresinin ve kullanılan mühimmat sayısının değiştiği görülmektedir [28]. Gerçekleşen harekât sürelerinin değişmesi, kullanılacak silah sistemleri gibi sarf edileceği beklenen mühimmat sayısının da bilimsel yöntemlerle hesaplanması ihtiyacını ortaya çıkarmaktadır [29].

Burada ihtiyaç duyulan mühimmat miktarının önceden tespit edilmesi önemli bir konudur.

Mühimmatı savaş esnasında üretmek veya satın almak çok uzun süre aldığından ve hatta bulunamayıp temin edilemediğinden bazı sınırlılıkları vardır. İyi bir stok planlaması yapılmaz ise süreç yönetilemez bir hal alabilmektedir. İkmal sisteminde, en az seviyede stokla, ihtiyaç duyulan miktarda mühimmatı, en etkin şekilde istenilen yer ve zamanda hazır bulundurmak esastır. Gerçekleşecek muharebede ihtiyaçları karşılamak için, ekonomik ve ihtiyaca en yakın şekilde mühimmatı tahmin ederek stok planlaması yapmak günümüzün en önemli konularından biri haline gelmiştir. Ukrayna-Rusya savaşında çatışmaların uzaması mühimmat temininde yaşanan sıkıntıların önemini bizlere bir kere daha göstermiştir. Ukrayna, savaş başladıktan birkaç ay sonra kullandığı Sovyet menşeli silahlar için mühimmat stoku sorunu yaşamaya başlamış, bu silahların mühimmatı sadece eski doğu bloku ülkelerinde bulunduğundan kısa süre içerisinde o ülkelerde bulunan mühimmat stokları da tükenmiştir [30]. Rusya Federasyonu ise Donbas'taki çatışmaların en yoğun olduğu dönemde iki günde bütün İngiliz ordusunun stokundan daha fazla mühimmat kullanmıştır [31]. İki ülkede mühimmat temininde sıkıntılar yaşamakta, dünyanın çeşitli ülkelerinden acilen mühimmat temin etmeye çalışmışlardır. Rusya-Ukrayna savaşı Almanya içinde mühimmat stoklarının yeniden gözden geçirilmesini gündeme getirmiştir. Alman basınında çıkan haberlere göre Alman ordusunun mühimmat stokları bu derece büyük bir askeri harekatta birkaç saat en fazla birkaç gün dayanabilecektir [32]. Bu nedenlerden dolayı savunma planlaması açısından mühimmat

tahmininin yapılması ve farklı senaryoların ele alınması son derece önemli hale gelmiştir.


Yıllar itibarıyla mühimmat satın almaları ve dünyanın mühimmat üretimi incelendiğinde yıllara sâri olarak mühimmat satışının artış eğiliminde olduğu görülmektedir. Ayrıca çeşitli kuruluşlar tarafından farklı yöntemlerle yapılan çalışmalarda dünyada yaşanan savaşlar ve süreleri doğrultusunda yapılan tahminlerde mühimmat ihtiyacını önümüzdeki yıllarda artmaya devam edeceği ve ülkelerin üretim kapasitelerini arttırmaya yönelik tedbirleri almayı sürdürecekleri öngörülmektedir. Bu durum Şekil 1-3'te gösterilmiştir.



Şekil 1: Mühimmat talep tahmini, 2020-2032 [33].



Şekil 2: Küresel mühimmat tahmini 2022-2029 [34].



Şekil 3: Global topçu mühimmatı talebi [33].

Şekiller incelendiğinde her üç pazar araştırmasını yapan kaynakta da yıllara sâri olarak mühimmat talebinin artacak olduğu öngörülmektedir. Yapılmış olan mühimmat talep tahminleri önümüzdeki dönemde savaşların beklendiği ve hatta çatışma sürelerinin artacağı sonucunu doğurmakta ve bu durumda mühimmat talebinin doğru yapılmasının bir ülkenin güvenliği için ne kadar hayati olduğunu göstermektedir.

Mühimmatın stok planlaması ve ihtiyaç tahmini yapılırken genel olarak aşağıda belirtilen esaslar çerçevesinde planlamanın yapılması doğru sonuçlara ulaşmak için büyük önem taşımaktadır.

- Zaman ilerledikçe muharebelerin kısa süreli olacağı, mühimmat stoğu ihtiyacının azalacağı öngörülmektedir. Ancak günümüzde yaşanan birçok savaş ve harekatlarda bunun tam tersi durum görülmektedir [30].

- Geliştirilmiş mühimmatların etkisi klasik mühimmatlara göre daha fazla olduğundan klasik mühimmata olan ihtiyacın azaldığı düşünülmektedir. Ancak son zamanlardaki savaşlar bunun tersi durumu ortaya koymuştur [35].

- Modern silahlardaki teknolojik gelişmeler ile hedefe isabet oranı artmakta bu durum mühimmata olan ihtiyacı göreceli olarak

azaltmaktadır. Rusya Ukrayna savaşı ise bunun tersi bir sonucu ortaya çıkarmıştır [31].

- Temin ve üretim süreleri arasında yaşanan farklılıklar ile yurt dışından temin edilmesindeki zorluklardan dolayı yerli mühimmatlardan daha az, yurt dışından tedarik edilen mühimmattan daha çok stok yapılması genel yaklaşımdır [36].

- Harekâtın icra edileceği bölgenin özellikleri, düşmanın imkân ve kabiliyetleri ile çatışma esnasında verilen zayıat miktarı stok planlamasını etkilemektedir. Bu nedenle mühimmat planlamasında bu durumlar detaylı şekilde dikkate alınmalıdır [32].

- Otomasyon sistemlerinin gelişmesi ve etkin şekilde kullanılmasıyla, silah mevcutları bilinmektedir. Bu durum yapılacak tahminler için önemli olumlu bir girdi oluşturmaktadır.

- Harekâtın ilk günü görev alacak personel, silah sayısı ile zayıat miktarı dikkate alınacağından tahminlerde bu verilerinde dikkate alınması yapılacak tahminlerin gerçekçiliği açısından önem taşımaktadır [5].

Yukarıda belirtilen esaslar çerçevesinde her ürün ve sistemde olduğu gibi mühimmatında belli bir doğrulukta bilimsel yöntemler ile önceden tahmin edilmesi stok fazlası duruma düşülerek stok maliyetini veya elde mühimmat kalmaması durumunda yok satma maliyetini engellemesi açısından önem taşımaktadır. Askeri stokları yönetmek çok büyük önem taşımaktadır. Fazla miktarda temin edilmesi mühimmat fiyatlarının yüksekliği nedeniyle ve depolama maliyetlerinin fazla olması nedenleriyle büyük bir ekonomik kayıp olarak karşımıza çıkmaktadır. Diğer taraftan savaş ortamında mühimmatsız kalmak


ise ülke güvenliği gibi karşılığı olmayan bir maliyet olarak karşımıza çıkmaktadır.

4. MATERYALLER VE METOT (MATERIALS AND METHOD)

Bu çalışmada ARIMA ve LSTM modelleri kullanılarak olabilecek bir harekât anında elde bulundurulması gereken mühimmat miktarlarına ilişkin tahmin değerlerinin belirlenmesine yönelik bir bilimsel metodoloji sunulmuştur. Çalışmada kullanılan yöntemler geleneksel ve modern derin öğrenme yöntemlerini karşılaştırma olanağı sunmaktadır. ARIMA, az sayıda veri ile başarılı sonuçlar sağlayabilen bir yöntemken, LSTM daha çok sayıda veriye ihtiyaç duymaktadır. Ancak, LSTM yöntemi verideki karmaşık desenleri öğrenebilmesi sayesinde daha güçlü tahmin sonuçları elde etmeyi sağlayabilmektedir. Ayrıca savaş ortamında bilimsel çalışmalarda kullanılabilecek olan değişkenlere ait verilerin bulunması zorluğundan dolayı çok değişkenli tahmin yöntemleri yerine tek değişkenle çalışabilen ARIMA ve LSTM yöntemleri kullanılmıştır. Bu nedenle, mühimmat

sayılarının tahmin edilmesinde kullanılabilecek bu iki yöntem ele alınmıştır ve bu iki yöntemin tahmin sonuçları karşılaştırılmıştır. Uygulama esnasında ARIMA yöntemi için Eviews paket programı ve LSTM yöntemi için Python kullanılmıştır.

Gerekli hesaplamalar için olası bir harekât ortamında geçmişte yaşanan ve 200 gün süren bir çatışmada bir topçu bataryasının savaş ortamında günlük bazda sarf ettiği mühimmat miktarı jenerik olarak ele alınmıştır. Bataryanın çatışma boyunca imha edilmediği ve 200 gün boyunca topçu atışı yaptığı kabullenmesiyle jenerik veriler kullanılarak bir bataryanın topçu mühimmatı ihtiyacı tahmin edilmiştir. Veri seti Şekil 4'teki gibidir. Şekilde dikey eksen adet bazında mühimmat miktarını, yatay eksen aylık bazda günleri göstermektedir. En yüksek mühimmat sarfiyatı 6 Mart 2023 tarihinde 152 adet, en az 7 Ağustos 2023 tarihinde 31 adet mühimmat sarfiyatı bulunmaktadır. Ortalama mühimmat sarfiyatı 74,15'tir.



Şekil 4: Mühimmat sarfiyatı veri seti.


4.1. Zaman Serisi

Zaman serisi saatlik, günlük, aylık, çeyreklik, yıllık gibi zamana göre sıralanarak gözlenen ve düzenli olarak kaydedilen verilere denir [37]. Zaman serileri şu anki mevcut durumların analizi,

veriler arasındaki ilişkileri incelemek ve verilerin gelecek tahminleri için kullanılır. Zaman serileri analizi geçmişteki verileri göz önünde bulundurarak ve gelecekteki davranışların tarihsel davranışlara benzeyeceğini varsayarak

gelecek verileri tahmin eder. Tahmini gerçekleştirmek için birçok zaman serisi yöntemleri bulunmaktadır. Bu yöntemlerden en

doğrusunu seçmek için zaman serisi bileşenleri dikkate alınır. Zaman serisi bileşenleri aşağıdaki Şekil 5’te gösterilmiştir.



Şekil 5: Zaman serisi bileşenleri [37].

Sistemantik bileşenler zaman içinde bir düzen ve yapı gösteren bileşenlerdir. Bu düzen ve yapı sayesinde zaman içerisinde tekrar eden hareketler tahmin edilebilir. Sistemantik olmayan bileşenler ise bir düzen göstermez ve rastgelelik içerir.

Trend: Zaman serisindeki uzun vadeli olarak gerçekleşen düzenli artış ve azalışı ifade eder. Daha açık bir ifade ile zaman serisinde artan veya azalan bir eğim olduğunda veri setinde trend gözlenir.

Mevsimsellik: Zaman serisinde verinin belirli periyotlarla belirli davranışı tekrar etmesidir.

Döngü: Zaman serisindeki uzun vadeli dalgalanmaları meydana gelmesidir.


Gürültü: Zaman serisinde doğal afet, savaş gibi aniden ortaya çıkan ve ön görülemeyen düzensiz hareketleri gösterir [38].

4.1.1. Tek Değişkenli Zaman Serisi Tahmin Yöntemleri

Zaman serisi tahmin yöntemleri tek değişkenli ve çok değişkenli model olmak üzere ikiye ayrılır.

Zaman serisi tahmini için en yaygın kullanılan tek değişkenli zaman serisi tahmin yöntemleri aşağıda Şekil 6’da gösterilmiştir.

Hareketli ortalamalar yöntemi mevcut gerçek verilerin ortalamalarını alarak bir sonraki adımın tahminlemesi için kullanılır [39]. Veri belirli kümeler halinde toplanarak aritmetik ortalaması alınır. Son m döneminin aritmetik ortalaması sonraki değer tahmini değerini vermektedir. Hareketli ortalama hesaplanırken her dönemin ağırlığının eşit olduğu varsayılırken ağırlıklı hareketli ortalama her döneme ayrı ağırlık verilir. Veride trend olması durumunda Holt’s yöntemi olarak bilinen çift üstel düzgünleştirme yöntemi kullanılır. Üstel düzgünleştirme parametresi (α) ve trend düzleştirme parametresi (β) olmak üzere iki parametreye sahiptir. Veride mevsimsellik bulunması halinde Winters üstel düzleştirme modeli kullanılır. Bu model çarpımsal ve toplamsal olarak ikiye ayrılır [40].



Şekil 6: Zaman serisi tahmin yöntemleri [39].

Verideki mevsimsellik trend ile birlikte düzenli olarak artış ve azalış gösteriyorsa çarpımsal Winter's, verideki mevsimsellik düzensiz bir şekilde hareket ediyorsa toplamsal Winter's Yöntemi kullanılır [41].

ARIMA Modeli (Otoregresif Entegre Hareketli Ortalama)

Birçok zaman serisi durağan değildir. Durağan olmayan zaman serilerinde ARIMA ve SARIMA modelleri kullanılabilir. ARIMA Modeli Box ve Jenkins tarafından 1970 yılında geliştirilmiştir [42]. Tek değişkenli zaman serilerinin gelecek tahminlerini gerçekleştirmek için kullanılır. Bu yöntemle göre gelecekteki davranışların geçmişle benzer olduğu varsayılır. ARIMA modelinin ekonometrik modellerden farkı, tek değişken ile model kurulur ve zaman serisinin kendi iç dinamiğini dikkate alınmasıdır. ARIMA modeli 3 bileşenden oluşmaktadır;

AR(Otoregresif Bileşen): AR modeller geçmiş gözlemlere dayanarak bugünkü değerleri tahmin etmek için kullanılır. AR modeli belirli bir döneme ilişkin gözlem değeri ile bir önceki gözlem değeri arasındaki ilişkiyi açıklayan bir

model olduğu için "otoregresif model" adını alır. AR modelleri içerdikleri geçmiş dönem sayısına göre isimlendirilir. Daha açık ifade etmek gerekirse bir tane geçmiş dönem değeri içeriyorsa AR(1), iki tane geçmiş dönem değeri içeriyorsa AR(2) ve p tane geçmiş dönem gözlem değeri içeriyorsa AR(p) olarak adlandırılır [43].

MA(Hareketli Ortalama bileşeni): Hata terimlerinin geçmiş dönemlerini tahmin etmek için kullanılır. Ma modeller bir zaman serisinin belirli bir dönemine ilişkin hata terimi ile bir önceki hata terimi arasındaki ilişkiyi inceler. MA modeller içerdikleri geçmiş dönem hata terimi sayısı kadar adlandırılır. Bir tane geçmiş dönem hata terimi içeriyorsa MA(1), iki tane geçmiş dönem hata terimi içeriyorsa MA(2) ve tane geçmiş dönem hata terimi içeriyorsa MA(q) olarak adlandırılır.

I(Entegrasyon Bileşeni): Zaman serisi durağan değilse durağanlaştırmak için kullanılır. Seriyeye fark alma işlemi uygulayarak seri durağan hale getirilir. I bileşeninin derecesini seriyeye durağanlaştırmak için alınan fark sayısı belirler. I bileşeninin derecesi d harfi ile simgelenir. Seri

bir defa fark alınarak durağan hale geldiyse $d = 1$ olur, seri fark alınmadan durağan haldeyse $d = 0$ olur. Bu durumda AR modelinin parametre derecesi p , hareketli ortalama parametresi q ve d kez fark alma işlemi yapılırsa bu model (p,d,q) dereceleri ile ifade edilerek ARIMA (p,d,q) şeklinde yazılır. ARIMA modelinin genel yapısı denklem 1'deki gibidir.


$$y_t = c + \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (1)$$

Burada,

- y_t :serinin t zamanındaki gözlem değeri
- c :sabit terim
- $\phi_1 \dots \phi_p$:AR bileşeninin katsayıları
- ε_t :Rastgele hata terimi
- $\theta_1 \dots \theta_q$:MA bileşeninin katsayıları
- p :AR bileşeninin derecesi
- q :MA bileşeninin derecesidir.

4.1. Derin Öğrenme


Yapay sinir ağları (YSA), biyolojik sinir sistemindekine benzer şekilde çalışan bir bilgi işleme sistemi olarak tanımlanabilir. YSA'lar, sınıflandırma, örüntü tanıma, tahminleme, optimizasyon gibi birçok alanda kullanılmaktadır [44]. Biyolojik sinir hücresinin işleyişinin matematiksel olarak modellenmesi amacı ile geliştirilen yapay sinir hücreleri bilgi işleme süreci nöron olarak adlandırılan basit elemanlardan meydana gelir. Sinyaller nöronlar arasındaki bağlantılar ile iletilir. Nöronlar arasındaki her bir bağlantı bir ağırlık değerine sahiptir [45]. YSA yapısı Şekil 7'de gösterilmiştir.



Şekil 7: YSA yapısı [44].

Mevcut yapay zekâ destekli tahmin yöntemleri, YSA ya da bir başka deyişle Çok Katmanlı Algılayıcılardan (Multilayer Perceptron) başlayarak, Tekrarlayan Sinir Ağları (Recurrent Neural Network - RNN) ve Uzun Kısa Süreli Bellek (Long Short-Term Memory-LSTM) gibi derin öğrenme yöntemlerini içerir. RNN, tahmin görevlerini gerçekleştirmek için geçmiş bilgileri depolamak amacıyla gizli katmanların kullanıldığı, özellikle zaman serisi verileriyle uğraşan sinir ağlarında kullanılan ilk yöntemlerden biridir. RNN'de çıktı yalnızca mevcut girdilere değil aynı zamanda önceki adımdaki nörona bağlıdır [46].

RNN'nin temel eksikliği, uzun bir veri geçmişini depolayamamasıdır. LSTM yöntemi, bilgilerin saklanması ve tahmin edilmesinde daha iyi performansa sahip özel bir RNN biçimidir. RNN'deki orijinal nöronların yerini LSTM'deki bellek yapıları alır [47]. Her hafıza hücresi sırasıyla bilgiyi atmak, depolamak ve aktarmak için çalışır. Genel olarak LSTM yönteminde üç kapı bulunmaktadır. Bu kapılardan unutma kapısı hangi bilginin silineceğine, girdi kapısı hangi bilginin güncelleneceğine ve son olarak çıktı kapısı girdi ve bellek bloğuna göre hangi çıktı bilgisinin üretileceğine karar verir [48]. LSTM yapısı Şekil-8'de gösterilmiştir.



Şekil 8: LSTM yapısı [49].

Bellek hücreleri C_t ile gösterilir. Bir bellek hücresinde, her t zamanı adımında durum güncellemesi ve çıktı denklem (2) – (7) ile gösterilmektedir:

$$f_t = \sigma(W_{xf}X_t + W_{hf}h_{t-1} + b_f) \quad (2)$$

$$i_t = \sigma(W_{xi}X_t + W_{hi}h_{t-1} + b_i) \quad (3)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc}X_t + W_{hc}h_{t-1} + b_c) \quad (4)$$

$$o_t = \sigma(W_{xo}X_t + W_{ho}h_{t-1} + b_o) \quad (5)$$

$$h_t = o_t \odot \tanh(C_t) \quad (6)$$

$$Y_t = \sigma(W_{hy}h_t + b_y) \quad (7)$$

Burada X_t , t zaman adımındaki giriş nöronunu, σ , sigmoid fonksiyonunu, $\odot$, skaler çarpımı temsil eder, i_t , f_t , ve o_t sırasıyla giriş, unutma ve çıkış kapılarını belirtir. W 'lar ağırlık matrisleridir ve b 'ler bias vektörleridir. Y_t 'ler, gizli vektör h_t kullanılarak bir katmanlı yapay sinir ağında hesaplanır [49-51]. ARIMA verilerdeki dalgalanmaları ve mevsimsellikleri dikkate alarak mühimmat tüketimini tahmin ederken, LSTM ise veri dağılımındaki değişen kalıplara ve mevsimselliğe uyum sağlama fırsatı sunarak tahmin yapmayı mümkün kılar.

4. ARAŞTIRMA SONUÇLARI (RESEARCH RESULTS)

Bu çalışmada ARIMA ve LSTM modelleri kullanılarak olabilecek bir harekât sürecinde elde bulundurulması gereken mühimmat miktarlarına ilişkin tahmin değerleri elde edilmiştir. Bu değerler karşılaştırılmış ve tahminler arası fark ortaya koyulmuştur. ARIMA modeli kullanarak tahmin yapmak için öncelikle serinin durağan olması gerekmektedir. Durağanlık serinin ortalama etrafında çok fazla değişmediği yani ortalama değerin zaman çerçevesinde değişmemesi anlamına gelir. Serinin durağanlığına bakmak için grafik yöntem, Augmented Dickey-Fuller (ADF) testi ve korelogram grafikleri incelenebilir [52]. Şekil 4'e göre veri seti bir ortalama etrafında dağılmadığı için seri durağan değildir. ADF testi ile serinin durağanlığı incelenmiştir. Serinin ADF test hipotezi ve sonucu aşağıdaki gibi hesaplanmış ve Tablo 1'de sunulmuştur.


H_0 : Birim kök vardır (Durağan değildir)

H_1 : Birim kök yoktur (Durağandır)

Tablo 1: ADF Test sonucu.

	t-İstatistik	Prob
ADF Test	-2,43	0,13

Prob: $0,13 > 0,05$ olduğu için H_0 hipotezi reddedilemez. Dolayısıyla seri durağan değildir. Zaman serisi analizlerinde durağan olmayan veri ile tahminler yapmak, trend ve değişen varyansa sebebiyet vereceğinden dolayı yanıltıcı tahmin sonuçları verebilir. Bu nedenle veri durağan hale getirmek oldukça önemlidir. Seri durağanlaştırmak için 1. Sıra fark alınmıştır. 1. Sıra fark alınmış serinin grafiği Şekil 9'da ve ADF test sonuçları Tablo 1'deki gibidir.



Şekil 9: Birinci sıra fark alınmış jenerik mühimmat sarfiyatı veri seti.

Birinci sıra fark alınmış hipotez testi yaptıktan sonra Tablo 2’deki sonuçlar elde edilmiştir.

Tablo 2: Birinci sıra fark alınmış serinin ADF test sonucu.


	t-İstatistik	Prob
ADF Test	-10,9	0,00

ADF testine göre Prob: $0,00 < 0,05$ olduğu için H_0 hipotezi reddedilir. Seri 1. Sıra fark alınarak durağan hale getirilmiştir. Seri durağan hale geldikten sonra çeşitli ARIMA modelleri test edilmiş ve yapılan analiz sonucunda elde edilen uygun sonuçlar veren ARIMA modelleri aşağıda verilmiştir.

Tablo 3: ARIMA modeli başarı kriterleri sonuçları.

Model	AIC	SIC	Hannan	Durbin Watson
ARIMA (0,1,1)	7,13	7,18	7,15	1,81
ARIMA (1,1,1)	7,13	7,20	7,16	1,99
ARIMA (1,1,2)	7,14	7,20	7,16	1,91

AIC, SIC ve Hannan testlerinde en düşük değere sahip modeller ve Durbin Watson sonuçlarında ise 2’ye yakın olan modeller başarılı olarak kabul edilir. Tablo 3’e göre ARIMA(0,1,1) ve ARIMA(1,1,1) modellerinden biri tercih edilebilir. Çalışmada ARIMA(1,1,1) modeli Durbin-Watson testi değeri 2’ye çok yakın olduğu ve neredeyse otokorelasyon olmadığını ifade ettiği için tercih edilmiştir. Tahmin değerleri bu model üzerinden elde edilmiştir. ARIMA ile elde edilen tahmin sonuçlarının grafiği Şekil 10’da bulunmaktadır.




Şekil 10: Mühimmat sarfiyatı değerleri ve ARIMA modeli tahmin değerleri.

Şekil 9’a göre ARIMA (1,1,1) modelinin tahmin değerleri gözlemlenen değerlere yakın sonuçlar verdiği görülmektedir. Kısıtlı sayıda ve jenerik veri kullanılmış olmasına rağmen ARIMA tahmin sonuçları mevcut sarfiyat verisindeki artış ve azalışları yakalamıştır. Çalışmanın ikinci

aşamasında, olabilecek bir harekât sürecinde elde bulundurulması gereken mühimmat miktarlarına ilişkin tahmin değerleri LSTM modeli kullanarak hesaplanmıştır. Benzer şekilde az sayıda veri kullanılmasına rağmen LSTM yönteminin verinin yapısına uyum sağladığı ve gerçek

değerlere yakın sonuçlar verdiği tespit edilmiştir.

LSTM tahmin sonuçları Şekil-11’da sunulmuştur.




Şekil 11: Gerçek mühimmat sarfiyatı değerleri ve LSTM modeli tahmin değerleri.

Tablo 4’e göre LSTM yönteminin performans metrik sonuçlarının ARIMA yöntemine göre az bir farkla daha iyi performans göstermektedir.

Tablo 4: Metotların performans metrik değerleri.

Metot	RMSE	MAE	MAPE	R ²
ARIMA	9.000	7.010	0.1091	0.916
LSTM	8.895	6.751	0.1071	0.919

ARIMA yönteminin RMSE değeri 9,000, LSTM yönteminin RMSE değeri 8,895’ten büyük olduğu için RMSE performans kriterine göre LSTM’nin daha başarılı olduğu görülmüştür. Benzer şekilde LSTM yöntemi MAE ve MAPE değerlerine göre de ARIMA yöntemine göre daha başarılı tahmin sonuçları sağlamıştır. Yine R² değeri LSTM yönteminde az farkla da olsa daha yüksek olduğundan dolayı daha başarılı olduğu görülmektedir.




Şekil 12: Yöntemlere göre tahmin sonuçları.

ARIMA ve LSTM yöntemleri kullanılarak elde edilen mühimmat tüketimi tahmin sonuçları grafiksel olarak Şekil 12’de sunulmuştur.

Şekil 13’te her iki yöntem için bulunan dağılım grafiğinde kırmızı ve yeşil noktalar sırasıyla ARIMA ve LSTM yöntemlerine aittir. Bu yöntemlerin yaklaşımlarının uyum etkilerinin ve

tahmin doğruluğunun benzer olduğu ve bu araştırmada kullanılan veri için yöntemlerin aralarında büyük farklılık olmadığını göstermektedir.



Şekil 13: Yöntemlere göre tahmin sonuçlarının saçılım grafiği.

Her iki yöntemin dağılım grafiğine göre mühimmat sarfiyatı tahminlemesinin başarılı sonuçlar verdiği tespit edilmiştir. Gerek savaş anında mühimmatsız kalınmaması gerekse çok fazla stoklayarak kaynakların israf edilmemesi amacıyla bu çalışmada iki farklı tahmin yöntemiyle mühimmat tahmini yapılmış ve elde edilen sonuçlar karşılaştırılmıştır.

Askeri alanda mühimmat tahmini ile ilgili çalışmalar incelendiğinde genel olarak eski tecrübeler esas alınarak sezgisel olarak tahmin yapıldığı bilinmektedir. Eğer veri kaydı tutulmuş ise geçmişte icra edilen operasyonlara ait veriler ile basit analitik hesaplara da başvurulmaktadır. Ancak özellikle veri setinin olmadığı ya da eksik olduğu durumlarda bu hesaplamalar yapılamamaktadır. Daha geçerli bilimsel metotlar ise hiç uygulanamamaktadır. Bu durum tahminlerin başarısını çok büyük ölçüde olumsuz etkilemektedir. Bu çalışmada ortalama, iyimser ve kötümser olmak üzere 3 farklı senaryo

üzerinde durulmuştur. İyimser senaryo için az mühimmat tüketileceği kabul edilmekte ve bu nedenle veri setinin en küçük değeri seçilmektedir. Savaşın kötümser senaryo ile icra edileceği varsayımında ise en yüksek sayıda mühimmat tüketileceği düşünülmüştür. Bu senaryolar için çalışmada kullanılan veri setinin ortalaması 74, en küçük değeri 31 ve en büyük değeri 152 alınmıştır. Örneğin aynı veri seti 30 gün sürecek bir muharebe perspektifi için yapılacak bir tahminlemede ele alınırsa mühimmat sarfiyatı basit bir hesaplama ortalama 2220, en yüksek 4560 veya en düşük 930 adet olarak bulunur. ARIMA tahmin sonuçlarına göre ise 30 gün için bulundurulması gereken toplam mühimmat miktarı 1340, LSTM'ye göre bulundurulması gereken mühimmat miktarı 1499 olarak tahminlenmiştir. Bu durum bilimsel geçerliliği ispatlanmış analitik yöntemlere başvurmanın önemini gözler önüne sermektedir. Çünkü askeri teamüllere göre sezgisel olarak kötü senaryo ile çalışılma alışkanlığı dikkate alındığında 4560 mühimmat sarf edecek birliğin matematiksel olarak üçte bir oranında mühimmat ile benzer sonuçlar elde edebileceği hesaplanmıştır. Bunun yanında fazla mühimmatın getireceği depolama, taşıma, muhafaza etme vb. ekstra iş yükü de dikkate alındığında yapılan çalışmanın ne derece kritik bir perspektif sunduğu göz ardı edilmemelidir. Bahsedilen senaryo sonuçlarının karşılaştırılması Tablo 5'te yer almaktadır.

Tablo 5: Metotların performans metrik değerleri.

LSTM	ARIMA	Ortalama	Min	Maks
1499	1340	2225	930	4560

Bu sonuçlara göre kullanılması önerilen yöntemler dikkate alınarak mühimmat sarfına dair tahminleme yapıldığında daha az seviyede mühimmata göre iş yükü paylaştırılacaktır. Bu sayede kullanılan mühimmat için tasarruf sağlanabilir ve yapılacak stoklar düzenlenebilir. Tablo 5'teki klasik senaryolarla karşılaştırıldığında ortaya çıkan fayda görülebileceği gibi Tablo 4'teki istatistiksel sonuçlarla beraber ele alındığında bu yöntemlerle yapılan tahminlerin başarısı ve anlamlılığı da ortaya konulmuştur.

6. SONUÇ (CONCLUSION)

Mühimmat, harekât alanlarında savaşların sonucunu etkileyen en önemli malzemelerden biridir ve aynı zamanda silah sistemlerinin etkili ve verimli kullanımı için olmazsa olmaz bir unsurdur. Bu nedenle savaş öncesinde mühimmat tüketiminin tahmin edilmesi, aşırı stoklama veya harekât esnasında mühimmatsız kalınmaması için büyük önem taşımaktadır. Mühimmat satın alma veya üretim maliyetinin çok yüksek olması ülkelerin kıt kaynaklarını verimli kullanması zorunluluğunu doğurmaktadır. Bunun sonucunda da mühimmat tahmininin önemi iyice ortaya çıkmaktadır. Mühimmat kullanımı çatışmanın süresi, düşman kuvvetinin büyüklüğü ve arazi yapısı gibi birçok faktöre bağlı olsa da mühimmat talebinin bilimsel yöntemlerle tahmin edilmesi günümüz teknoloji dünyasında kaçınılmaz bir sonuçtur. Günümüzde dünyanın çeşitli yerlerinde yaşanan çatışmalarda mühimmat sıkıntıları yaşanmakta ve temin edilmesinde zorluklarla karşılaşıldıkça mühimmat tahmininin önemi daha da iyi anlaşılmaktadır. Bu çalışmayla literatürde ele alınmamış olan mühimmat tahminine ilişkin farklı yöntemlerin kullanıldığı bir metodoloji

sunulmuştur. ARIMA ve LSTM yöntemleri mühimmat tahmini için ele alınmış ve anlamlı sonuçlar elde edilmiştir. Sonuçlara göre, ARIMA ve LSTM yöntemlerinin RMSE değerleri sırasıyla, 9.000 ve 8.895, MAE değerleri sırasıyla 7.010 ve 6.751, MAPE değerleri sırasıyla 0.1091 ve 0.1071, R2 değerleri sırasıyla 0.916 ve 0.919 olarak elde edilmiştir. Bu performans kriterlerinden de görüldüğü gibi sınırlı sayıda (200 gün) veri kullanılmasına rağmen günlük mühimmat tüketimi tahmini için LSTM yöntemi ARIMA yönteminden daha başarılı sonuçlar göstermiştir. Literatüre göre, az miktarda veri kullanıldığında ARIMA ve LSTM'nin benzer sonuçlar verdiği, çok miktarda veri kullanıldığında ise LSTM'nin performans ölçütleri açısından daha başarılı olduğu belirtilmiştir. Dolayısıyla çalışma literatürdeki benzer çalışmalarla bu açıdan paralellik göstermektedir. ARIMA ve LSTM sınırlı sayıda veri kullanıldığından birbirine yakın sonuçlar vermiştir. Ancak LSTM modeli daha karmaşık desenleri yakalama yeteneği nedeniyle daha yüksek doğruluk sağlamıştır. LSTM modelini eğitmek ARIMA modelinden daha fazla hesaplama süresi gerektirse de ortaya çıkan tahminlerin doğruluğu bu ek maliyeti haklı çıkarmaktadır.

Çalışma kapsamında bulunmuş olan topçu bataryasına yönelik tahminler genişletilerek istenen büyüklükteki birlikler için ihtiyaçlar belirlenebilir. Burada bir tip mühimmat için yapılan tahminin farklı tipteki mühimmatlar için yapılabileceği düşünülmektedir. Bu tahmin metotları sayesinde mühimmat temin planlarının ve bütçelerinin hazırlanacağı savunma sanayi faaliyetlerinde geleceğe yönelik üretim

planlaması ve tesis alt yapısı oluşturulması gibi konularda önemli fayda sağlayacağı değerlendirilmektedir. Bu durum, ülkelerin ekonomilerine olumlu anlamda geri dönüş sağlayacaktır.

Bu çalışmanın bazı sınırlılıkları da bulunmaktadır. Öncelikle, kullanılan veriler geçmiş muharebelere ait jenerik verilerdir. Gelecekte yapılacak çalışmalarda, daha spesifik senaryolara ve coğrafi bölgelere özgü veriler kullanılarak modelin geçerliliği ve güvenilirliği artırılabilir. Model, farklı mühimmat türlerini ve bunların özelliklerini içerecek şekilde genişletilebilir. Gelecekte, mühimmat tüketiminin tahmin doğruluğunu daha da iyileştirmek için çeşitli derin öğrenme yöntemleri, daha doğru bir model oluşturmak için CNN, BiLSTM ve GRU yöntemleri incelenebilir. Ek olarak, hibrit modellerin tahmin performansı üzerindeki etkileri, büyük miktarda veri kullanılarak araştırılacaktır ve bu tahminler simülasyon üzerinde denenerek matematiksel modele girdi olarak kullanılacaktır. Ayrıca tahmin amacıyla kullanılan bağımsız değişken sayısı artırılarak tahmin yöntemleri üzerindeki etkisi incelenecektir.

Sonuç olarak, bu çalışma, mühimmat talep tahmini için analitik yöntemlerin kullanılabileceğini ve bu yöntemlerin muharebe sahasında önemli bir lojistik avantaj sağlayabileceğini göstermektedir. Geliştirilen model, kaynakların etkin kullanımını sağlayarak, mühimmatın istenen miktarda ve kaynakların etkin kullanımını sağlamaya katkıda bulunmaktadır. Sunulan öneriler doğrultusunda yapılacak çalışmalar, mühimmat tahmininin ve muharebe sahasındaki lojistik kabiliyetlerin

geliştirilerek kaynakların etkin ve verimli kullanılmasına olanak sağlayacaktır.

TEŞEKKÜR (ACKNOWLEDGMENTS)

Bu araştırma hiçbir dış finansman almamıştır.

YAZAR KATKILARI (AUTHOR CONTRIBUTIONS)

Gökçe Nur Taşağıl Arslan: Kavramsal tasarım, metodoloji, yazma, düzenleme, görselleştirme, onaylama.

İlayda Korkmaz: Kavramsal tasarım, metodoloji, yazma, düzenleme, görselleştirme, onaylama.

Kemal Gürol Kurtay: Kavramsal tasarım, metodoloji, yazma, düzenleme, görselleştirme, onaylama.

ÇIKAR ÇATIŞMALARI (CONFLICTS OF INTEREST)

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan eder.

KAYNAKLAR (REFERENCES)

- [1] H. Ayhan DAĞISTANLI ve C. Gencer, “Hibrit Tehdit Perspektifinden Orman Yangınları ve Türkiye’nin Mücadele Politikası”, *SAVSAD Savunma ve Savaş Araştırmaları Dergisi*, sy 1, ss. 35-70, Ara. 2023, doi: 10.54078/SAVSAD.1377722.
- [2] Sun Tzu, *Savaş Sanatı*. İstanbul: Anahtar Kitaplar, 2007.
- [3] Department of the Army, *FM3-0 Operations*. Headquarters, Department of the Army, 2017. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: https://cyberwar.nl/d/20171005_US-Army-Field-Manual-FM-3-0-Operations.pdf
- [4] H. A. Dağıstanlı, A. Altundaş, K. G. Kurtay, ve Y. Gökmen, “The Optimization of Long-Term

Dynamic Defense Industry Project Portfolio Management with a Mixed and Holistic Project Prioritization Approach”, *Dyn Games Appl*, Eki. 2024, doi: 10.1007/s13235-024-00602-6.

[5] K. G. KURTAY, A. Altundaş, ve S. TAŞ, “Model Proposal for Ammunition Demand Forecasting and Ammunition Distribution Network Design: Military Unit Application”, *Journal of Intelligent Decision Making and Information Science*, c. 2, ss. 197-217, Şub. 2025, doi: 10.59543/jidmis.v2i.12753.

[6] K. Gencer ve F. Başçiftçi, “Time series forecast modeling of vulnerabilities in the android operating system using ARIMA and deep learning methods”, *Sustainable Computing: Informatics and Systems*, c. 30, s. 100515, Haz. 2021, doi: 10.1016/j.suscom.2021.100515.

[7] M. Elsaraiti ve A. Merabet, “A Comparative Analysis of the ARIMA and LSTM Predictive Models and Their Effectiveness for Predicting Wind Speed”, *Energies (Basel)*, c. 14, sy 20, s. 6782, Eki. 2021, doi: 10.3390/en14206782.

[8] I. Mejri, A. Bouzid, S. Bacha, ve S. B. Layeb, “Forecasting Demand Using ARIMA Model and LSTM Neural Network: a Case of Detergent Manufacturing Industry”, içinde *2021 International Conference on Innovation and Intelligence for Informatics, Computing, and Technologies (3ICT)*, IEEE, Eyl. 2021, ss. 346-353. doi: 10.1109/3ICT53449.2021.9581762.

[9] Y. Hua, “Bitcoin price prediction using ARIMA and LSTM”, *E3S Web of Conferences*, c. 218, s. 01050, Ara. 2020, doi: 10.1051/e3sconf/202021801050.

[10] S. Siامي-Namini, N. Tavakoli, ve A. Siامي Namin, “A Comparison of ARIMA and LSTM in Forecasting Time Series”, içinde *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)*, IEEE, Ara. 2018, ss. 1394-1401. doi: 10.1109/ICMLA.2018.00227.

[11] S. Mun, J. Hwang, L. Bian, T. C. Falls, ve W. Glenn Bond, “Ensemble learning for Fault Condition Prediction and Health Status Monitoring in Military Ground Vehicles”, *IISE Annual Conference and Expo 2023*, s. 1479, 2023, doi: 10.21872/2023IISE_1479.

[12] I. Malone, “Recurrent neural networks for conflict forecasting”, *International Interactions*, c. 48, sy 4, ss. 614-632, Tem. 2022, doi: 10.1080/03050629.2022.2016736.

[13] R. Ueno ve D. Calitoiu, “Forecasting Attrition from the Canadian Armed Forces using Multivariate LSTM”, *Proceedings - 19th IEEE International Conference on Machine Learning and Applications, ICMLA 2020*, ss. 753-758, Ara. 2020, doi: 10.1109/ICMLA51294.2020.00123.

[14] K. Vavliakis, A. Siailis, ve A. Symeonidis, “Optimizing Sales Forecasting in e-Commerce with ARIMA and LSTM Models”, içinde *Proceedings of the 17th International Conference on Web Information Systems and Technologies*, SCITEPRESS - Science and Technology Publications, 2021, ss. 299-306. doi: 10.5220/0010659500003058.

[15] D. Sharma ve K. Phulli, “Forecasting and Analyzing the Military Expenditure of India Using Box-Jenkins ARIMA Model”, Kas. 2020, Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://arxiv.org/pdf/2011.06060>

- [16] K.-C. Kuo, C.-Y. Chang, ve W.-C. Lin, “To predict military spending in China based on ARIMA and artificial neural networks models”.
- [17] A. Borucka, “Application of ARIMA Models for the Analysis of Utilization Process of Military Technical Objects”, *Logistics and Transport*, c. 37, sy 1, ss. 13-22, 2018.
- [18] J. G. Lee ve M. J. Park, “Evaluation of technological competence and operations efficiency in the defense industry: The strategic planning of South Korea”, *Eval Program Plann*, c. 79, Nis. 2020, doi: 10.1016/J.EVALPROGPLAN.2019.101775.
- [19] A. Altundaş, “An Integrated Approach for Ammunition Depot Location Selection and Ammunition Distribution Network Design Based on P-Median and Vehicle Routing Problems”, *Computer and Decision Making: An International Journal*, c. 1, ss. 170-184, Eyl. 2024, doi: 10.59543/comdem.v1i.10539.
- [20] H. A. Dağıstanlı ve K. G. Kurtay, “Facility Location Selection for Ammunition Depots based on GIS and Pythagorean Fuzzy WASPAS”, *Journal of Operations Intelligence*, c. 2, sy 1, ss. 36-49, Oca. 2024, doi: 10.31181/JOPI2120247.
- [21] K. G. Kurtay ve S. Erol, “Mühimmat geri dönüşüm problemi için depo yer seçimi ve dağıtım ağı tasarımı”, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, c. 40, sy 1, ss. 29-42, Ağu. 2024, doi: 10.17341/GAZIMMFD.1345897.
- [22] Department of the Army, *ADP3-0 Operations*. Headquarters, Department of the Army, 2019. Erişim: 21 Ağustos 2025.
- [Çevrimiçi]. Erişim adresi: <https://armypubs.army.mil/>
- [23] Department of the Army, *FM3-0 Operations*. Headquarters, Department of the Army, 2022. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://irp.fas.org/doddir/army/fm3-0.pdf>
- [24] P. Folly ve P. Mäder, “Propellant Chemistry”, *Chimia (Aarau)*, c. 58, sy 6, s. 374, Haz. 2004, doi: 10.2533/000942904777677713.
- [25] J. Bevan ve S. Pezard, *TARGETING AMMUNITION A PRIMER A Small Arms Survey publication in cooperation with partners*. Small Arms Survey, 2006. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: www.grip.org
- [26] W. Hardy. McNeill, “The pursuit of power : technology, armed force, and society since A.D. 1000”, 2008.
- [27] D. Stahel, “Operation Barbarossa and Germany’s Defeat in the East”, *Operation Barbarossa and Germany’s Defeat in the East*, Eyl. 2009, doi: 10.1017/CBO9780511732379.
- [28] H. A. Dağıstanlı, “Induced Generalized Intuitionistic Fuzzy OWA Operator on GRA Method for Evaluation of Self-Propelled Artillery System: Ammunition Based Computer Assisted Military Experiment”, *Computer and Decision Making: An International Journal*, c. 1, ss. 23-37, Tem. 2024, doi: 10.59543/comdem.v1i.10081.
- [29] H. A. Dağıstanlı, “Weapon System Selection for Capability-Based Defense Planning using Lanchester Models integrated with Fuzzy MCDM in Computer Assisted Military Experiment”, *Knowledge and Decision Systems with Applications*, c. 1, ss. 11-23, Şub. 2025, doi: 10.59543/kadsa.v1i.13601.

- [30] N. Świętochowski, “Field Artillery in the defensive war of Ukraine 2022-2023Part I. Combat potential, tasks and tactics”, *Scientific Journal of the Military University of Land Forces*, c. 210, sy 4, ss. 341-358, Ara. 2023, doi: 10.5604/01.3001.0054.1631.
- [31] M. Zabrodskyi, J. Watling, ve N. Reynolds, “Preliminary Lessons in Conventional Warfighting from Russia’s Invasion of Ukraine: February-July 2022 Special Report”, *London: Royal United Services Institute for Defence and Security Studies*, 2022.
- [32] “Luftabwehrsystem Meads - WELT”. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://www.welt.de/themen/luftabwehrsystem-meads/>
- [33] “Ammunition Market Size and Share Forecast - 2032: Acumen Research and Consulting”. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://www.acumenresearchandconsulting.com/ammunition-market>
- [34] “Global Ammunition Market Size, Share, and Analysis Report 2029”. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://www.databridgemarketresearch.com/reports/global-ammunition-market?srsId=AfmBOOpCHesJQiJYXGMxOif9gsdeOSXVVG5A2sX-KlfZrFLXvdCH5i>
- [35] Chas. W. Freeman, “What We Do, Why It Matters, What Next?”, *Middle East Policy*, c. 12, sy 2, ss. iii-iv, Haz. 2005, doi: 10.1111/j.1061-1924.2005.00208.x.
- [36] H. Aries, B. Giegerich, ve T. Lawrenson, “The Guns of Europe: Defence-industrial Challenges in a Time of War”, *Survival (Lond)*, c. 65, sy 3, ss. 7-24, May. 2023, doi: 10.1080/00396338.2023.2218716.
- [37] G. E. P. Box, G. M. Jenkins, G. C. Reinsel, ve G. M. Ljung, “Journal Of Time Series Analysis Book Review Time Series Analysis: Forecasting And Control”, *J. Time. Ser. Anal*, c. 37, ss. 709-711, 2016, Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://www.wiley.com/en-us/Time+Series+Analysis%3A+Forecasting+and+Control%2C+5th+Edition-p-9781118675021>
- [38] G. Shmueli ve K. C. Lichtendahl, “Practical Time Series Forecasting with R”, s. 232, 2018.
- [39] J. E. . Hanke ve D. W. . Wichern, “Business forecasting”, s. 551, 2009.
- [40] P. R. Winters, “Forecasting Sales by Exponentially Weighted Moving Averages”, *Manage Sci*, c. 6, sy 3, ss. 324-342, 1960, [Çevrimiçi]. Erişim adresi: <http://www.jstor.org/stable/2627346>
- [41] Dr. Majed Saleh Al-Hafid ve G. Hussein Al-maamary, “Short term electrical load forecasting using holt-winters method”, *Al-Rafidain Engineering Journal (AREJ)*, c. 20, sy 6, ss. 15-22, Ara. 2012, doi: 10.33899/RENGJ.2012.63377.
- [42] G. E. P. Box ve G. M. Jenkins, “Time Series Analysis Forecasting and Control. Holden-Day, San Francisco. - References - Scientific Research Publishing”. Erişim: 21 Ağustos 2025. [Çevrimiçi]. Erişim adresi: <https://www.scirp.org/reference/referencespapers?referenceid=2087370>

- [43] T. H. Naylor, T. G. Seaks, ve D. W. Wichern, “Box-Jenkins Methods: An Alternative to Econometric Models”, *Int Stat Rev*, c. 40, sy 2, s. 123, Ağu. 1972, doi: 10.2307/1402755.
- [44] G. Ciaburro ve B. Venkateswaran, “Neural Networks with R Smart models using CNN, RNN, deep learning, and artificial intelligence principles”, 2017.
- [45] J. Park ve S. Chang, “A particulate matter concentration prediction model based on long short-term memory and an artificial neural network”, *Int J Environ Res Public Health*, c. 18, sy 13, 2021, doi: 10.3390/ijerph18136801.
- [46] Z. Chang, Y. Zhang, ve W. Chen, “Electricity price prediction based on hybrid model of adam optimized LSTM neural network and wavelet transform”, *Energy*, c. 187, s. 115804, Kas. 2019, doi: 10.1016/j.energy.2019.07.134.
- [47] C. Zeng, C. Ma, K. Wang, ve Z. Cui, “Predicting vacant parking space availability: A DWT-Bi-LSTM model”, *Physica A: Statistical Mechanics and its Applications*, c. 599, s. 127498, Ağu. 2022, doi: 10.1016/j.physa.2022.127498.
- [48] H. Luo, M. Huang, ve Z. Zhou, “A dual-tree complex wavelet enhanced convolutional LSTM neural network for structural health monitoring of automotive suspension”, *Measurement*, c. 137, ss. 14-27, Nis. 2019, doi: 10.1016/j.measurement.2019.01.038.
- [49] G. N. Taşağıl Arslan ve S. Kılıç Depren, “Optimizing air quality predictions: A discrete wavelet transform and long short-term memory approach with wavelet-type selection for hourly PM10 concentrations”, *J Chemom*, c. 38, sy 4, 2024, doi: 10.1002/cem.3539.
- [50] N. Parvini, M. Abdollahi, S. Seifollahi, ve D. Ahmadian, “Forecasting Bitcoin returns with long short-term memory networks and wavelet decomposition: A comparison of several market determinants”, *Appl Soft Comput*, c. 121, s. 108707, May. 2022, doi: 10.1016/j.asoc.2022.108707.
- [51] L. Zhu, Z. J. B. M. Husny, N. A. Samsudin, H. Xu, ve C. Han, “Deep learning method for minimizing water pollution and air pollution in urban environment”, *Urban Clim*, c. 49, s. 101486, May. 2023, doi: 10.1016/j.uclim.2023.101486.
- [52] R. Mushtaq, “Augmented Dickey Fuller Test”, *SSRN Electronic Journal*, 2011, doi: 10.2139/ssrn.1911068.