Bursa Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi
Bursa Uludağ Journal of Economy and Society
Haziran / June (2026) 45(1): 1-24
e-ISSN: 2750-9190
http://www.uludag.edu.tr/iibfdergi

Makale Geliş Tarihi/Article Received: 22.05.2026 **Makale Türü/Article Type**
Makale Kabul Tarihi/Article Accepted: 14.09.2026 Araştırma Makalesi/Research Article

Hastane İç Lojistiğinde Tıbbi Malzeme Akışlarının Operasyonel Yük ve Talep-Karşılama Süresi Açısından Analizi

Alkan Durmuş[1]

Öz

Bu çalışma, bir üniversite hastanesinin ana tıbbi malzeme deposundan klinik servislere yönelen malzeme akışlarını operasyonel yük ve talep-karşılama süresi açısından incelemektedir. Hastane bilgi yönetim sisteminden elde edilen 57.542 işlem kaydı, veri temizleme ve istek-servis düzeyinde yapılandırma sonrasında 55.985 analiz kaydı üzerinden değerlendirilmiştir. Çalışmada ürün çeşitliliği, toplam miktar, hasta yükü, servis grubu, talep-karşılama süresi ve uzun talep-karşılama riski birlikte ele alınmıştır. Talep-karşılama süresi sağa çarpık dağılım göstermiş; ortalama süre 194,81 dakika, medyan 93 dakika, P90 eşiği 493 dakika ve P95 eşiği 803 dakika olarak hesaplanmıştır. P90 riski en yüksek yoğun bakım grubunda (%21,06), P95 uç gecikme riski ise hemato-onkoloji/kök hücre grubunda (%9,75) görülmüştür. Lojistik regresyon modellerinde ROC-AUC değerleri P90 için 0,8308, P95 için 0,8336 bulunmuştur. Bulgular, hastane iç lojistiğinde servis bazlı, veri temelli karar desteğinin depo iş gücü planlaması ve talep önceliklendirme açısından önemli olduğunu göstermektedir.

Anahtar kelimeler: Hastane iç lojistiği, tıbbi malzeme yönetimi, talep-karşılama süresi, operasyonel yük, lojistik regresyon.

Jel kodları: I11, M11, C44.

Analysis of Medical Supply Flows in Hospital Internal Logistics in Terms of Operational Workload and Request Fulfillment Time

Abstract

This study examines medical supply flows from the central medical supply warehouse of a university hospital to clinical services in terms of operational workload and request-fulfillment time. A total of 57,542 transaction records obtained from the hospital information management system were evaluated through 55,985 analysis records after data cleaning and restructuring at the request-service level. Product variety, total quantity, patient load, service group, request-fulfillment time and long request-fulfillment risk were considered together. Request-

[1] **Sorumlu yazar/Corresponding author:** Dr. Alkan Durmuş, Dokuz Eylül Üniversitesi Sağlık Uygulama ve Araştırma Hastanesi, alkan.durmus@deu.edu.tr ORCID: 0000-0002-5806-9962

Atıf/Citation: Durmuş, A. (2026). Hastane iç lojistiğinde tıbbi malzeme akışlarının operasyonel yük ve talep-karşılama süresi açısından analizi. *Bursa Uludağ Journal of Economy and Society*, *45(*1), 1-24.

fulfillment time showed a right-skewed distribution; the mean time was 194.81 minutes, the median was 93 minutes, the P90 threshold was 493 minutes and the P95 threshold was 803 minutes. The highest P90 risk was observed in the intensive care group (21.06%), whereas the highest P95 extreme delay risk was identified in the hemato-oncology/stem cell group (9.75%). In the logistic regression models, ROC-AUC values were 0.8308 for P90 and 0.8336 for P95. The findings indicate that service-based, data-driven decision support is important for warehouse workforce planning and request prioritization in hospital internal logistics.

Keywords: Hospital internal logistics, medical supply management, request fulfillment time, operational workload, logistic regression

Jel codes: I11, M11, C44.

1. Giriş

Hastanelerde tıbbi malzeme yönetimi, hasta bakımının sürekliliğini, hizmet güvenliğini ve kaynak kullanım etkinliğini doğrudan etkileyen temel operasyonel alanlardan biridir. Tıbbi sarf malzemeleri, cerrahi ürünler, steril malzemeler, ilaçlar ve destek ekipmanlarının doğru zamanda, doğru miktarda ve uygun klinik birimde hazır bulunması, tedavi süreçlerinin kesintisiz yürütülmesi açısından kritik öneme sahiptir. Hastane malzeme lojistiği; tedarik, stok yönetimi, dağıtım, planlama ve bütüncül tedarik zinciri yönetimi gibi birbirine bağlı süreçlerden oluşmaktadır (Volland vd., 2017). Bu nedenle hastane içi malzeme akışları yalnızca satın alma, stok veya depo çıkışı kararlarıyla değil; ana depo, servis depoları, klinik birimler, bilgi sistemleri ve insan kaynağı arasındaki etkileşimle birlikte değerlendirilmelidir.

Hastane iç lojistiğinde malzeme akışı çoğu zaman toplam tüketim miktarı veya stok seviyesi üzerinden izlenmektedir. Oysa klinik servislerin ana tıbbi malzeme deposu üzerinde oluşturduğu iş yükü yalnızca talep edilen miktarla açıklanamaz. Talebin geldiği servis, ürün çeşitliliği, hasta yükü, vizite türü ve sistemde karşılanma süresi de operasyonel yükü belirleyen önemli unsurlardır. Bu yaklaşım, hastane iç tedarik zinciri performansının yalnızca maliyet veya stok düzeyiyle değil; süreç, kalite, zaman, verimlilik ve hizmet sürekliliği göstergeleriyle birlikte değerlendirilmesi gerektiğini belirten çalışmalarla uyumludur (Moons vd., 2019; Fallahnezhad vd., 2024). Bu çok boyutlu değerlendirme gereksinimi, ana depo ile klinik servisler arasındaki iş akışının süreç düzeyinde incelenmesini gerekli kılmaktadır.

Ana tıbbi malzeme deposu ile klinik servisler arasındaki akış, hastane iç lojistiğinin en ölçülebilir alanlarından biridir. Bu süreç; klinik gereksinimin oluşması, talebin hastane bilgi yönetim sistemine yansıması, malzemelerin uygunluk ve stok açısından değerlendirilmesi, hazırlanması, kontrol edilmesi, onaylanması ve ilgili servise ulaştırılması gibi işlem adımlarını içerir. Hastane malzeme yönetimi süreçlerini modelleyen çalışmalar, klinik ihtiyaçtan kullanım noktasına kadar uzanan veri ve işlem akışının bütünleşik biçimde ele alınması gerektiğini göstermektedir (Iannone vd., 2013). Benzer şekilde, servis depoları, toplama, kayıt ve dağıtım süreçlerinde yapılacak iyileştirmelerin operasyonel performansı etkileyebileceği belirtilmektedir (Rocha ve Rego, 2023). Söz konusu iş akışının düzenli ve karşılaştırılabilir biçimde ölçülebilmesi ise büyük ölçüde bilgi sistemlerinde üretilen işlem kayıtlarına bağlıdır.

Sağlık kurumlarında bilgi sistemlerinin yaygınlaşması, malzeme istek, onay ve talep-karşılama kayıtlarının düzenli biçimde izlenmesine olanak sağlamaktadır. Bu kayıtlar yalnızca idari raporlama için değil, talep yoğunluğu, ürün çeşitliliği, hasta yükü, toplam miktar ve talep-karşılama süresi gibi göstergeler üzerinden süreç performansını değerlendirmek için de kullanılabilir. Dijital izlenebilirlik ve kullanım noktası envanter yönetimi üzerine yapılan çalışmalar, kayıt doğruluğunun ve fiili

kullanım verilerinin stok kararları ile süreç performansı üzerinde etkili olduğunu göstermektedir (Bendavid vd., 2012; Neve ve Schmidt, 2022). Bu kayıtların analitik değeri, özellikle talep-karşılama süresinin nasıl tanımlandığı ve yorumlandığı noktasında belirginleşmektedir.

Bu çalışmada süre değişkeni, yalnızca fiziksel hazırlama hızını gösteren dar bir ölçüt olarak değil, hastane bilgi yönetim sisteminde ölçülen toplam operasyonel yanıt süresi olarak ele alınmıştır. Talep-karşılama süresi; talebin sisteme girilmesi, iş akışına alınması, bekleme, hazırlama, kontrol, onay, kayıt ve teslimata hazır hale getirme gibi alt süreçleri içerebilir. Bu tür süre değişkenleri çoğu zaman sağa çarpık dağıldığından, yalnızca ortalama değerlere dayalı değerlendirme üst kuyruktaki gecikmeleri görünür kılmakta yetersiz kalabilir. Bu nedenle medyan, P90 ve P95 gibi göstergelerin birlikte kullanılması daha açıklayıcı bir yaklaşım sunmaktadır (Sun vd., 2012; Arora vd., 2023). Bu zaman odaklı yaklaşım, mevcut literatürde hangi performans boyutlarının birlikte ele alınmadığını daha görünür hâle getirmektedir.

Mevcut literatürde hastane malzeme yönetimi üzerine geniş bir birikim bulunmakla birlikte, çalışmaların önemli bir kısmı stok kontrolü, ABC-VED sınıflandırması, tedarik kararları, dijital izlenebilirlik, depo otomasyonu, SPD uygulamaları veya genel tedarik zinciri performansına odaklanmaktadır (Gupta vd., 2007; Liu vd., 2016; Cagliano vd., 2022). Buna karşılık, ana tıbbi malzeme deposundan klinik servislere yapılan gerçek işlem kayıtlarının servis bazlı talep yoğunluğu, ürün çeşitliliği, toplam miktar, hasta yükü, talep-karşılama süresi ve uzun talep-karşılama riskiyle birlikte incelendiği ampirik çalışmalar sınırlıdır.

Bu çalışma, söz konusu araştırma boşluğunu bir üniversite hastanesinin ana tıbbi malzeme deposundan klinik servislere yönelen gerçek tıbbi malzeme hareketlerini analiz ederek ele almaktadır. Ana depo-servis malzeme dağıtım süreci; talep yoğunluğu, ürün çeşitliliği, toplam miktar, hasta yükü, vizite türü, servis grubu, talep-karşılama süresi ve uzun talep-karşılama riski göstergeleriyle birlikte değerlendirilmiştir.

Çalışmanın hastane lojistik yönetimi, operasyonel performans analizi ve veri temelli karar destek sistemleri literatürüne özgün katkısı üç noktada ortaya çıkmaktadır. Birincisi, malzeme kalemi veya toplam tüketim düzeyi yerine istek-servis düzeyini temel analiz birimi olarak kullanarak klinik servislerin ana depo üzerinde oluşturduğu operasyonel yükü daha gerçekçi biçimde ölçmektedir. İkincisi, geleneksel ortalama süre değerlendirmesini medyan, P90 ve P95 göstergeleriyle genişleterek, normal işleyişten farklılaşan üst kuyruk gecikme riskini görünür hale getirmektedir. Üçüncüsü, ürün çeşitliliği, toplam miktar, hasta yükü ve servis özelliklerini açıklanabilir lojistik regresyon modeliyle ilişkilendirerek, geçmiş işlem kayıtlarını depo iş gücü planlaması, talep önceliklendirme ve servis bazlı müdahale kararlarında kullanılabilecek bir karar destek çerçevesine dönüştürmektedir. Böylece çalışma, stok ve tüketim odaklı geleneksel yaklaşımların ötesinde, operasyonel yük, süreç zamanı ve gecikme riskini bütünleştiren veri temelli bir hastane iç lojistik performans modeli sunmaktadır. Yukarıda tanımlanan araştırma boşluğu ve kavramsal yaklaşım doğrultusunda çalışma aşağıdaki araştırma sorularına yanıt aramaktadır:

AS1. Ana tıbbi malzeme deposu üzerindeki operasyonel yük; talep sayısı, toplam malzeme miktarı, ürün çeşitliliği ve hasta yükü bakımından klinik servisler arasında nasıl dağılmaktadır?

AS2. Hastane bilgi yönetim sisteminde ölçülen toplam talep-karşılama süresinin dağılımı nasıldır ve hangi servis grupları P90 ve P95 düzeylerinde daha yüksek uzun talep-karşılama riski taşımaktadır?

AS3. Ürün çeşitliliği, toplam miktar, hasta yükü, vizite türü, servis grubu ve zaman özellikleri uzun talep-karşılama riskiyle nasıl ilişkilidir ve lojistik regresyon modeli riskli talepleri ne ölçüde ayırt edebilmektedir?

2. Literatür taraması

Hastane iç lojistiği; tıbbi malzemelerin, ilaçların, sarf ürünlerinin, steril malzemelerin ve destek ekipmanlarının doğru zamanda, doğru klinik birimde ve uygun koşullarda hazır bulundurulmasını amaçlayan çok katmanlı bir süreçtir. Bu süreç; tedarik, stok yönetimi, ana depo-servis deposu dağıtımı, kullanım noktası yönetimi, kayıt doğruluğu, bilgi sistemleriyle entegrasyon ve klinik koordinasyon bileşenlerinden oluşmaktadır. Volland vd. (2017), hastane malzeme lojistiğini tedarik, stok yönetimi, dağıtım, planlama ve bütüncül tedarik zinciri yönetimi başlıkları altında sınıflandırırken; Landry ve Beaulieu (2013), merkez depo ile klinik birimler arasındaki ilişkinin günlük tedarik zinciri işleyişindeki önemini vurgulamaktadır. Benzer şekilde Moons vd. (2019) ve Fallahnezhad vd. (2024), performansın stok ve maliyet göstergeleriyle sınırlı kalmaması, süreç, kalite, zaman, verimlilik ve hizmet sürekliliğiyle birlikte ele alınması gerektiğini belirtmektedir. Bu çok boyutlu yaklaşım, genel tedarik zinciri çerçevesinden ana depo ile klinik servisler arasındaki somut iş akışına geçişi gerekli kılmaktadır.

Ana tıbbi malzeme deposu ile klinik servisler arasındaki dağıtım süreci, klinik gereksinimin oluşmasından talebin bilgi sistemine yansımasına, ürünlerin hazırlanmasından kontrol ve onay aşamasına kadar uzanan bütünleşik bir iş akışıdır. Iannone vd. (2013), bu veri ve işlem akışının kullanım noktasına kadar birlikte değerlendirilmesi gerektiğini göstermiştir. Rossetti ve Selandari (2001), hastane teslimat sistemlerinde ekonomik, teknik ve nitel göstergelerin birlikte dikkate alınması gerektiğini belirtirken; Rocha ve Rego (2023), hastane iç depolama ve dağıtım lojistiğindeki iyileştirmelerin operasyonel performansı etkileyebileceğini ortaya koymuştur. Benzer biçimde, klinik birimlerde malzeme konumlandırması, bilgi teknolojileri entegrasyonu, stok bulunabilirliği ve acil sipariş süreçleri de hizmet düzeyi ve operasyonel yönetim açısından önem taşımaktadır (Bélanger vd., 2018; Chen vd., 2013; Mustaffa ve Potter, 2009; Kim ve Sung, 2020). Bu operasyonel yapı içinde stok kontrolü, malzeme akışının sürekliliğini sağlayan temel yönetim alanlarından biri olarak öne çıkmaktadır.

Tıbbi malzeme yönetimi literatüründe stok kontrolü önemli bir yer tutmaktadır. ABC, VED ve ABC-VED analizleri, malzemelerin parasal değer ve klinik kritiklik düzeyine göre sınıflandırılmasında yaygın biçimde kullanılmaktadır. Bu yaklaşımlar tıbbi depo stoklarında daha dengeli bir kontrol yapısı sağlayabilmekte ve hastane ilaç stok kararlarına yönetsel katkı sunabilmektedir (Gupta vd., 2007; Işıkçelik vd., 2019). ABC-VEN matrisi maliyet ve kritiklik boyutlarını birlikte ele alırken, cerrahi depo çalışmalarında tedarik süresi gibi zaman değişkenlerinin de önemli olduğu gösterilmiştir (Mohammed ve Workneh, 2020; Hussain vd., 2019). Bununla birlikte, stok odaklı sınıflandırmalar klinik servislerin ana depo üzerinde oluşturduğu operasyonel yükü tek başına açıklamakta sınırlı kalmaktadır.

Yalın lojistik, Kanban ve SPD uygulamaları hastane içi malzeme akışlarının daha düzenli, izlenebilir ve standart hale getirilmesine katkı sağlamaktadır. Yalın üretim ilkeleri stok düzeyi, teslim süresi ve hizmet kalitesi açısından iyileştirme sağlayabilirken; Kanban sistemleri klinik personel ve depo işleyişi açısından yararlı sonuçlar verebilmektedir (Aguilar-Escobar ve Garrido-Vega, 2013; Aguilar-Escobar vd., 2015). SPD yaklaşımı ise tedarik, işleme, depolama, dağıtım, kullanım noktası izleme ve bilgi akışını bütünleşik biçimde ele almaktadır. Bu yaklaşımın süreç verimliliği, maliyet azaltımı, kalite kontrol ve bütünleşik tedarik zinciri yönetimi açısından katkı sağlayabileceği belirtilmektedir (Liu vd., 2016; Yang vd., 2019; Sakaguchi vd., 2025; Wang ve Chen, 2025). Süreçlerin standardizasyonu, aynı zamanda malzeme hareketlerinin dijital araçlarla izlenebilir hâle getirilmesini gerekli kılmaktadır.

Malzeme yönetiminin dijitalleşmesi, hastane iç lojistiğini daha ölçülebilir hale getirmektedir. Barkod, RFID, otomasyon ve dijital kayıt sistemleri, malzeme hareketlerinin kayıt doğruluğunu artırmakta ve

süreç performansının izlenmesine olanak sağlamaktadır. Barkod teknolojisinin ilaç uygulama süreçlerinde hata azaltma potansiyeli olduğu, RFID teknolojisinin ise yüksek değerli ve konsinye ürünlerin izlenebilirliğini güçlendirebildiği gösterilmiştir (Poon vd., 2010; Bendavid ve Boeck, 2011; Bendavid vd., 2012). RFID uygulamalarının ekipman ve malzeme takibi, maliyet kontrolü ve hasta güvenliği açısından katkı sağlayabileceği; kullanım noktası envanter yönetiminde kayıt doğruluğunun stok kararlarını etkileyebileceği belirtilmektedir (Coustasse vd., 2013; Neve ve Schmidt, 2022; Bendavid vd., 2010). Dijital kayıtların sağladığı görünürlük, fiziksel taşıma ve depo içi faaliyetlerin performans göstergeleriyle birlikte ele alınmasına zemin hazırlamaktadır.

Hastane içi malzeme dağıtımında fiziksel taşıma, otomasyon ve performans ölçümü de operasyonel yükün anlaşılması açısından önemlidir. Otomatik yönlendirmeli araçlar, teslim noktaları, bilgi paylaşımı ve ürün hareketliliği performansı etkileyebilmekte; otomasyon tekrar eden hazırlama, dağıtım, taşıma ve kayıt süreçlerinde önemli bir potansiyel taşımaktadır (Fragapane vd., 2018; Granlund ve Wiktorsson, 2013). Performans ölçümünün yalnızca finansal göstergelere indirgenmemesi, malzeme ve zaman israfının azaltılması, bilgi paylaşımı ve süreç izleme kapasitesinin güçlendirilmesi gerektiği vurgulanmaktadır (Purbey vd., 2007; Machado vd., 2014; Maestrini vd., 2017). Sağlık depolarının performans göstergelerine göre sınıflandırılması, otomasyonun depo performansına etkisi ve depo merkezileştirme kararlarında malzeme hareketleri ile insan kaynağı kullanımının dikkate alınması da bu çerçeveyi desteklemektedir (Feibert vd., 2019; Cagliano vd., 2022; Preziosa vd., 2025; Cagliano vd., 2016). Bununla birlikte, genel performans göstergelerinin gecikmelerin dağılımını ve üst kuyruk davranışını ayrıca görünür kılması gerekmektedir.

Hastane iç lojistik dağıtımının güvenilirliği ve talep-karşılama süresi performansı, üst kuyrukta biriken gecikmelerin ayrıca incelenmesini gerektirmektedir. Tortorella vd. (2021), iç lojistik dağıtım güvenilirliğinin mevcut durum haritalama, belirsizlik kaynaklarının belirlenmesi ve iyileştirme önceliklendirmesiyle değerlendirilebileceğini göstermektedir. Operasyonel süreler sağa çarpık dağılabildiğinden, yalnızca ortalamaya dayalı değerlendirme gecikme riskini yeterince açıklamayabilir. Bu nedenle kuantil temelli yaklaşımlar, medyan ve üst yüzdeliklerin ayrı ayrı yorumlanmasına olanak sağlamaktadır (Sun vd., 2012; Arora vd., 2023). Ayrıca süreç referans modelleri, elektronik sağlık kayıtları ve geçmiş işlem kayıtlarına dayalı lojistik regresyon ya da kümeleme yaklaşımları, hastane süreçlerinde gecikme ve operasyonel karar desteği açısından kullanılabilir bulgular sunmaktadır (Chanpuypetch ve Kritchanchai, 2018; King vd., 2022; Lv vd., 2025). Bu yöntemsel birikim, literatürdeki farklı araştırma eksenlerinin karşılaştırmalı olarak değerlendirilmesini mümkün kılmaktadır.

Önceki çalışmaların odakları incelendiğinde literatürün üç temel araştırma ekseninde geliştiği görülmektedir. Birinci eksen, ABC, VED ve benzeri sınıflandırmalar aracılığıyla malzeme kalemlerinin maliyet, tüketim ve klinik kritiklik bakımından yönetilmesine odaklanmaktadır. Bu çalışmalar stok kontrolüne önemli katkılar sağlamakla birlikte, klinik servislerin ana depo üzerinde oluşturduğu günlük iş yükünü ve talep-karşılama süresini doğrudan değerlendirmemektedir. İkinci eksen, yalın lojistik, Kanban, SPD, barkod, RFID ve otomasyon uygulamalarının süreç standardizasyonu, kayıt doğruluğu ve izlenebilirlik üzerindeki etkilerini incelemektedir. Ancak bu araştırmalarda bilgi sistemi kayıtlarının servis bazlı gecikme riskini açıklayan bir modele dönüştürülmesi sınırlı kalmaktadır.

Üçüncü eksende ise hastane süreçlerindeki bekleme ve gecikmeler kuantil yöntemler, lojistik regresyon, kümeleme ve makine öğrenmesi yaklaşımlarıyla incelenmektedir. Bu çalışmalar çoğunlukla acil servis, hasta kabul, laboratuvar veya diğer klinik süreçlere odaklanmakta; ana tıbbi malzeme deposundan klinik servislere yönelen malzeme akışını temel analiz alanı olarak ele

almamaktadır. Dolayısıyla literatürdeki temel boşluk yalnızca çalışma sayısının sınırlı olması değildir. Asıl boşluk; analiz birimi, performans boyutları ve sonuç değişkeni arasındaki bütünleşme eksikliğidir. Malzeme kalemi yerine istek-servis düzeyinin kullanıldığı, operasyonel yük göstergelerinin toplam talep-karşılama süresiyle birleştirildiği ve P90–P95 üst kuyruk risklerinin açıklanabilir bir modelle incelendiği araştırmalar sınırlıdır.

Bu çalışmanın kavramsal çerçevesi, hastane iç lojistik performansını birbiriyle ilişkili dört boyut üzerinden ele almaktadır: talep hacmi, talep karmaşıklığı, klinik hizmet yükü ve zaman riski. Talep sayısı ve toplam miktar talep hacmini; ürün çeşidi talep karmaşıklığını; hasta sayısı, vizite türü ve servis grubu klinik hizmet yükünü; talep-karşılama süresi ile P90 ve P95 eşikleri ise zaman performansı ve üst kuyruk riskini temsil etmektedir.

Bu çerçevede klinik servislerin ana depo üzerindeki etkisi yalnızca tüketilen malzeme miktarıyla açıklanmamaktadır. Aynı miktarda malzeme talep eden servisler; ürün çeşidi, talep sıklığı, hasta yükü ve sistemde oluşan toplam yanıt süresi bakımından farklı operasyonel yükler oluşturabilmektedir. Bu nedenle hastane iç lojistik performansı, malzeme miktarından süreç ve zaman riskine uzanan çok boyutlu bir yapı olarak değerlendirilmektedir.

Çalışmanın teorik ve kavramsal katkısı, hastane malzeme yönetimi literatüründe çoğunlukla ayrı incelenen stok ve tüketim göstergeleri, servis bazlı iş yükü ve zaman performansını aynı analitik çerçevede birleştirmesidir. Çalışma yeni ve evrensel bir teori ileri sürmekten ziyade, gerçek hastane işlem kayıtlarının operasyonel performans göstergelerine ve açıklanabilir karar desteğine nasıl dönüştürülebileceğini gösteren bütünleşik bir kavramsal ve analitik çerçeve sunmaktadır.

3. Yöntem

3.1. Araştırma tasarımı ve veri kaynağı

Bu çalışma, bir üniversite hastanesinin ana tıbbi malzeme deposundan klinik servislere yapılan tıbbi malzeme hareketlerini inceleyen retrospektif, nicel ve uygulamalı bir hastane iç lojistik performans analizidir. Araştırmada malzeme talep, onay, hazırlama ve teslimata hazır hale getirme süreci; talep yoğunluğu, ürün çeşitliliği, hasta yükü, vizite türü, servis grubu ve talep-karşılama süresi göstergeleri üzerinden değerlendirilmiştir.

Çalışmanın yaklaşımı, hastane malzeme lojistiğini yalnızca stok bulundurma veya satın alma kararlarıyla sınırlamayan daha geniş bir çerçeveye dayanmaktadır. Volland vd. (2017), hastane malzeme lojistiğini tedarik, stok yönetimi, dağıtım, planlama ve bütüncül tedarik zinciri yönetimi kapsamında ele alırken; Moons vd. (2019), iç hastane tedarik zinciri performansının maliyet ve stok düzeyinin yanında malzemenin doğru zamanda ve uygun koşullarda klinik süreçlere sunulmasıyla da ilişkili olduğunu vurgulamaktadır.

Araştırmada kullanılan veri seti, Probel Hastane Bilgi Yönetim Sistemi üzerinden elde edilen tıbbi malzeme istek, onay ve süre kayıtlarından oluşmaktadır. Veri setinde istek numarası, istek tarihi, onay tarihi, talep eden servis, vizite türü, hasta sayısı, ürün çeşidi, toplam miktar ve sistemde kayıtlı süre değişkeni yer almaktadır. Bu yapı, hastane içi malzeme dağıtım sürecinin işlem yoğunluğu, talep karmaşıklığı, servis bazlı operasyonel yük ve zaman performansı açısından incelenmesine olanak sağlamaktadır.

Bu doğrultuda araştırma modeli, talep hacmi ve karmaşıklığı ile klinik hizmet yükünün talep-karşılama süresi ve üst kuyruk gecikme riskiyle ilişkili olduğu kavramsal varsayımına dayanmaktadır. Ürün çeşidi, toplam miktar ve hasta sayısı talep düzeyindeki operasyonel yükü;

servis grubu ve vizite türü klinik bağlamı; P90 ve P95 eşiklerini aşma durumu ise operasyonel zaman riskini temsil etmektedir.

Veri setindeki süre değişkeni, çalışmada talep-karşılama süresi olarak adlandırılmıştır. Bu süre; talebin sisteme girilmesi, işleme alınması, hazırlanması, kontrol edilmesi, onaylanması, kayıt altına alınması ve teslimata hazır hale getirilmesi gibi alt süreçleri kapsayabilen toplam operasyonel yanıt süresini ifade etmektedir.

$$R_i = \left(I_i, S_i, V_i, T_i^{\text{istek}}, T_i^{\text{onay}}, H_i, U_i, M_i, \text{HS}_i\right) \quad (1)$$

Burada R_i ilgili kaydı, I_i istek numarasını, S_i isteyen servisi, V_i vizite türünü, T_i^{istek} istek zamanını, T_i^{onay} onay zamanını, H_i hasta sayısını, U_i ürün çeşidi sayısını, M_i toplam malzeme miktarını ve HS_i sistemde kayıtlı talep-karşılama süresini göstermektedir. Talep-karşılama süresi analizlerinde HS_i değişkeni dakikaya çevrilerek kullanılmıştır.

3.2. Analiz birimi ve veri ön işleme

Bu çalışmada veri seti iki düzeyde ele alınmıştır. Ham satır bazlı kayıtlar işlem hacmi ve ürün hareketliliğini tanımlamak için kullanılmış; operasyonel performans analizlerinde ise istek-servis düzeyi esas alınmıştır. Çünkü tek bir malzeme talebi birden fazla ürün kaleminden oluşabilmekte ve bu yapı, servislerin ana depo üzerinde oluşturduğu gerçek talep yoğunluğunu daha doğru yansıtmaktadır.

Analiz öncesinde veri seti biçimsel ve mantıksal kontrollerden geçirilmiştir. İstek ve onay tarihleri standart tarih-saat formatına dönüştürülmüş; servis adlarındaki yazım ve boşluk farklılıkları düzeltilmiş; hasta sayısı, ürün çeşidi, toplam miktar ve süre değişkeni sayısal analize uygun hale getirilmiştir. Saat: dakika biçimindeki süre değişkeni dakika cinsine çevrilmiş ve analizlerde talep-karşılama süresi olarak kullanılmıştır.

Talep-karşılama süresi çalışmanın temel zaman performansı göstergesi olarak ele alınmıştır. Sistem tarafından üretilen süre değişkeni ana analiz değişkeni olarak korunmuş; istek ve onay zamanları üzerinden ayrıca kontrol amaçlı süre hesabı yapılmıştır. Mantıksal olarak geçersiz veya negatif süre kayıtları analiz dışı bırakılmıştır. Veri temizleme ve istek-servis düzeyinde yapılandırma sonrasında analizler 55.985 kayıt üzerinden yürütülmüştür.

$$\text{HS}_i^{\text{kontrol}} = T_i^{\text{onay}} - T_i^{\text{istek}} \quad (2)$$

Burada $\text{HS}_i^{\text{kontrol}}$, i. kayıt için onay zamanı ile istek zamanı arasındaki hesaplanan süreyi ifade etmektedir. Bu kontrol hesabı, sistemde kayıtlı süre değişkeninin genel mantıksal tutarlılığını değerlendirmek amacıyla kullanılmıştır. Tarih-saat değişkenleri üzerinden negatif veya mantıksal olarak uyumsuz sürelerin görülmesi durumunda, bu kayıtlar doğrudan operasyonel performans göstergesi olarak yorumlanmamış; veri aktarımı, zaman damgası, vardiya geçişi, kayıt sırası veya sistemsel işlem farklılıklarından kaynaklanabilecek veri kalitesi sinyalleri olarak değerlendirilmiştir. Geçerli süre göstergesi, sistemde kayıtlı talep-karşılama süresi üzerinden aşağıdaki şekilde tanımlanmıştır:

$$G_i = \begin{cases} 1, & \text{HS}_i \geq 0 \\ 0, & \text{HS}_i < 0 \end{cases} \quad (3)$$

Talep-karşılama süresi analizlerinde temel hesaplamalar G_i=1 olan geçerli kayıtlar üzerinden yürütülmüştür. Dağılımın yapısını daha dengeli yorumlamak için ortalamanın yanında medyan, yüzdelik değerler ve üst kuyruk göstergeleri hesaplanmıştır. Bu yaklaşım, talep-karşılama süresinin

yalnızca aktif depo hazırlama hızını değil; bekleme, hazırlama, kontrol, onay ve teslimata hazır hale getirme gibi süreç bileşenlerini birlikte yansıtabileceği kabulüne dayanmaktadır. Veri ön işleme, değişken dönüşümü ve analizler Stata istatistik yazılımı ile gerçekleştirilmiştir.

3.3. Operasyonel performans göstergeleri

Çalışmada ana tıbbi malzeme deposu ile klinik servisler arasındaki malzeme dağıtım performansı dört temel gösterge grubu üzerinden değerlendirilmiştir: talep yoğunluğu, malzeme hacmi, talep karmaşıklığı ve talep-karşılama zaman performansı. Bu yapı, iç hastane tedarik zinciri performansının çok boyutlu biçimde değerlendirilmesi gerektiğini vurgulayan literatürle uyumludur (Moons vd., 2019). Hastane malzeme yönetiminde yalnızca toplam miktar ya da stok düzeyine bakmak, sürecin gerçek operasyonel yükünü açıklamakta yetersiz kalabilir. Aynı miktarda malzeme talep eden iki klinik servis, ürün çeşitliliği, hasta sayısı, talep sıklığı veya sistemde ölçülen talep-karşılama süresi bakımından oldukça farklı iş yükleri oluşturabilir.

Servis bazlı talep yoğunluğu, istek-servis düzeyinde yapılandırılmış veri seti üzerinden hesaplanmıştır:

$$\mathrm{TY}_s = \sum_{i=1}^{N^*} I\,(S_i = s) \tag{4}$$

Burada TY_s, s servisine ait talep yoğunluğunu; $I(S_i = s)$ ilgili kaydın s servisine ait olup olmadığını gösteren gösterge fonksiyonunu; N^*ise istek-servis düzeyinde toplulaştırılmış toplam kayıt sayısını ifade etmektedir. Servis bazlı toplam malzeme miktarı şu şekilde tanımlanmıştır:

$$\mathrm{TM}_s = \sum_{i:S_i=s} M_i \tag{5}$$

Burada TM_s, s servisine verilen toplam malzeme miktarını; M_i ise ilgili kayıttaki toplam miktarı göstermektedir. Ürün çeşitliliği, talebin yalnızca hacmini değil, hazırlama ve kontrol sürecindeki karmaşıklığını da temsil etmektedir. Servis bazlı ortalama ürün çeşidi aşağıdaki biçimde hesaplanmıştır:

$$\overline{U}_s = \frac{1}{n_s} \sum_{i:S_i=s} U_i \tag{6}$$

Burada $\overline{U}_s$, s servisine ait ortalama ürün çeşidi sayısını; n_s ise ilgili servise ait kayıt sayısını ifade etmektedir. Talep-karşılama süresi için ortalama değer hesaplanmış; ancak dağılımın sağa çarpık olabileceği dikkate alınarak medyan ve üst yüzdelikler yorumlarda daha belirleyici kabul edilmiştir. Servis bazlı ortalama talep-karşılama süresi yalnızca geçerli süre kayıtları üzerinden hesaplanmıştır:

$$\overline{\mathrm{HS}}_s = \frac{1}{n_s^{\mathrm{valid}}} \sum_{i:S_i=s,\, G_i=1} \mathrm{HS}_i \tag{7}$$

Burada $\overline{\mathrm{HS}}_s$, s servisine ait ortalama talep-karşılama süresini; n_s^{valid} ise ilgili serviste geçerli talep-karşılama süresi bulunan kayıt sayısını göstermektedir. Hasta yükü, talebin klinik hizmet üretimiyle ilişkisini değerlendirmek için kullanılmıştır. Bu kapsamda hasta başına malzeme miktarı ve ürün çeşidi başına miktar değişkenleri oluşturulmuştur:

$$\mathrm{HBM}_i = \frac{M_i}{H_i}, \quad H_i > 0 \tag{8}$$

$$\mathrm{UBM}_i = \frac{M_i}{U_i}, \quad U_i > 0 \tag{9}$$

Burada HBM_i, hasta başına malzeme miktarını; UBM_i, ürün çeşidi başına ortalama miktarı; H_i, hasta sayısını; U_i, ürün çeşidi sayısını göstermektedir. Hasta sayısı veya ürün çeşidi sıfır ya da eksik olan kayıtlarda bu göstergeler hesaplama dışında bırakılmıştır. Bu iki gösterge, talebin çok sayıda farklı üründen mi, yoksa daha az sayıda üründe yüksek miktarlı bir yapıdan mı oluştuğunu ayırt etmek için kullanılmıştır.

3.4. Servis bazlı yoğunlaşma ve operasyonel yük analizi

Ana tıbbi malzeme deposu üzerindeki operasyonel yükün servisler arasında nasıl dağıldığını değerlendirmek amacıyla servis bazlı talep sayısı, toplam malzeme miktarı, ortalama ürün çeşidi, ortalama talep-karşılama süresi ve uzun talep-karşılama oranları birlikte incelenmiştir. Bu kapsamda servislerin belirli ölçütlerde yoğunlaşıp yoğunlaşmadığını görmek için Pareto yaklaşımından yararlanılmıştır. Servisler her bir performans ölçütüne göre büyükten küçüğe sıralanmış ve ilk k servisin toplam içindeki kümülatif payı aşağıdaki şekilde hesaplanmıştır:

$$\mathrm{KP}_k = \frac{\sum_{r=1}^{k} X_{(r)}}{\sum_{r=1}^{S} X_{(r)}} \tag{10}$$

Burada KP_k, ilk k servisin toplam içindeki kümülatif payını; $X_{(r)}$, ilgili performans ölçütüne göre büyükten küçüğe sıralanmış r. servis değerini; S ise toplam servis sayısını göstermektedir. Bu yaklaşım, hastane malzeme yönetiminde sık kullanılan ABC mantığına benzemektedir. Ancak burada sınıflandırma malzeme kalemlerine değil, klinik servislerin ana depo üzerinde oluşturduğu operasyonel yüke uygulanmıştır.

Bu çalışmada operasyonel yük tek bir bileşik endekse indirgenmemiştir. Bunun yerine servislerin farklı yük boyutlarını görünür kılan çok boyutlu bir gösterge yaklaşımı benimsenmiştir. Böylece sık talep oluşturan, yüksek miktarda malzeme alan, daha fazla ürün çeşitliliği içeren veya uzun talep-karşılama riski taşıyan servis grupları ayrı ayrı değerlendirilebilmiştir. Bu yaklaşım, ağırlık varsayımına dayalı normatif bir skor üretmeden, servislerin farklı operasyonel risk profillerini daha açık biçimde yorumlamaya olanak sağlamaktadır.

3.5. Talep-karşılama süresi ve uzun talep-karşılama riski

Talep-karşılama süresi, çalışmanın temel zaman performansı göstergesi olarak ele alınmıştır. Bu değişken yalnızca aktif depo hazırlama süresini değil; talebin sisteme girilmesi, işleme alınması, hazırlanması, kontrol edilmesi, onaylanması ve teslimata hazır hale getirilmesi gibi alt süreçleri kapsayabilen toplam operasyonel yanıt süresini ifade etmektedir. Bu nedenle talep-karşılama süresi, depo hızının yanında talep karmaşıklığı, servis yoğunluğu ve kayıt-onay süreçlerinden etkilenen bütünleşik bir gösterge olarak yorumlanmıştır.

Operasyonel süreler çoğu zaman sağa çarpık dağıldığından, yalnızca ortalama süreye dayalı değerlendirme yeterli değildir. Bu nedenle çalışmada ortalama ve standart sapmanın yanında medyan, P75, P90, P95 ve P99 değerleri de hesaplanmıştır. Medyan tipik süreci, üst yüzdelikler ise gecikme riski taşıyan üst kuyruk davranışını göstermektedir (Sun vd., 2012; Arora vd., 2023). Talep-karşılama süresi için genel kuantil tanımı aşağıdaki gibidir:

$$Q_\tau(\mathrm{HS}) = \inf\{h : F_{\mathrm{HS}}(h) \geq \tau\} \tag{11}$$

Burada $Q_\tau(\mathrm{HS})$, talep-karşılama süresi dağılımının τ; F_{HS} ise talep-karşılama süresinin kümülatif dağılım fonksiyonunu ifade etmektedir. Bu çalışmada medyan tipik talep-karşılama süresini, P90 ve P95 ise uzun talep-karşılama davranışını göstermek için kullanılmıştır.

Uzun talep-karşılama süresi riski, talep-karşılama süresi P90 eşiğini aşan kayıtlar üzerinden ikili sonuç değişkeni olarak tanımlanmıştır:

$$\mathrm{Delay}_i^{90} = \begin{cases} 1, & \mathrm{HS}_i > Q_{0.90} \\ 0, & \mathrm{HS}_i \leq Q_{0.90} \end{cases} \tag{12}$$

Sağlamlık analizi kapsamında daha katı bir eşik olarak P95 değeri de kullanılmıştır:

$$\mathrm{Delay}_i^{95} = \begin{cases} 1, & \mathrm{HS}_i > Q_{0.95} \\ 0, & \mathrm{HS}_i \leq Q_{0.95} \end{cases} \tag{13}$$

P90 eşiği operasyonel olarak daha sık karşılaşılabilecek uzun talep-karşılama davranışını, P95 eşiği ise daha uç düzeydeki gecikmeleri temsil etmektedir. Bu iki eşik birlikte kullanılarak bulguların tek bir gecikme tanımına bağlı kalıp kalmadığı değerlendirilmiştir.

3.6. Uzun talep-karşılama riski modeli ve sağlamlık analizi

Uzun talep-karşılama riskini incelemek için temel yöntem olarak lojistik regresyon kullanılmıştır. Modelin birincil amacı açıklayıcıdır; ürün çeşidi, toplam miktar, hasta sayısı, vizite türü, servis grubu ve zaman özelliklerinin P90 ve P95 uzun talep-karşılama riskleriyle ilişkisini, diğer değişkenler sabitken odds ratio değerleri üzerinden değerlendirmeyi amaçlamaktadır. Modelin ikincil amacı ise geçmiş işlem kayıtlarının riskli talepleri ayırt etme kapasitesini test kümesi üzerinde incelemektir.

Lojistik regresyonun tercih edilmesinde bağımlı değişkenin P90 veya P95 eşiğini aşma durumuna göre ikili biçimde tanımlanması, katsayıların yönü ve büyüklüğünün doğrudan yorumlanabilmesi, odds ratio değerleri üretmesi ve model sonuçlarının hastane yöneticileri açısından izlenebilir olması etkili olmuştur. Karar ağaçları, random forest ve boosting gibi alternatif yöntemler doğrusal olmayan ilişkileri ve karmaşık etkileşimleri yakalayarak daha yüksek tahmin performansı sağlayabilmektedir. Bununla birlikte, bu çalışmanın temel amacı maksimum tahmin doğruluğuna ulaşmaktan çok, uzun talep-karşılama riskiyle ilişkili operasyonel faktörleri şeffaf ve yönetsel olarak yorumlanabilir biçimde ortaya koymaktır. Bu nedenle lojistik regresyon temel model olarak tercih edilmiş, alternatif makine öğrenmesi yöntemleri gelecekteki karşılaştırmalı doğrulama çalışmaları için tamamlayıcı yaklaşımlar olarak değerlendirilmiştir (Hosmer vd., 2013). Model aşağıdaki şekilde tanımlanmıştır:

$$\log\left(\frac{p_i}{1-p_i}\right) = \beta_0 + \beta_1 U_i + \beta_2 M_i + \beta_3 H_i + \beta_4 V_i + \beta_5 S_i + \beta_6 \mathrm{Time}_i \tag{14}$$

Burada $\log\left(\frac{p_i}{1-p_i}\right)$, i. kaydın uzun talep-karşılama süresi riski taşıma olasılığını göstermektedir. U_i ürün çeşidi sayısını, M_i toplam miktarı, H_i hasta sayısını, V_i vizite türünü, S_i servisi ve Time_i zamanla ilişkili değişkenleri göstermektedir. Vizite türü ve servis değişkenleri kategorik nitelikte olduğundan modele kukla değişkenler veya faktör değişkenler olarak dahil edilmiştir. Servis sayısının yüksek olması durumunda düşük frekanslı servisler "diğer" kategorisinde birleştirilmiş veya en yoğun servisler ayrı kategori olarak değerlendirilmiştir. Zaman değişkenleri ise verinin yapısına bağlı olarak ay, haftanın günü veya talep zamanı bileşenlerinden oluşturulmuştur. Model sonuçları odds ratio değerleri üzerinden yorumlanmıştır:

$$\mathrm{OR}_j = \exp(\beta_j) \tag{15}$$

Burada OR_j, j. değişken için odds ratio değerini ifade etmektedir. $OR_j > 1$ olması, ilgili değişkendeki artışın uzun talep-karşılama süresi olasılığıyla pozitif ilişkili olduğunu; $OR_j < 1$ olması ise negatif ilişkili olduğunu göstermektedir. Bulgular nedensel etki olarak değil, operasyonel ilişki olarak yorumlanmıştır. Bu ayrım önemlidir; çünkü çalışma gözlemsel ve retrospektif veri kullanmaktadır.

Model performansı accuracy, precision, recall, specificity, F1-score, balanced accuracy, ROC-AUC ve PR-AUC ölçütleriyle değerlendirilmiştir. P90 eşiğinde pozitif sınıfın yaklaşık %10, P95 eşiğinde ise yaklaşık %5 oranında bulunması, sınıflar arasında belirgin bir dengesizlik oluşturmaktadır. Bu yapı altında yalnızca accuracy değerine dayanılması, çoğunluk sınıfının doğru sınıflandırılmasından kaynaklanan yüksek genel başarı nedeniyle model performansının olduğundan daha güçlü görünmesine yol açabilir. Bu nedenle performans ölçütleri birbirini tamamlayacak biçimde değerlendirilmiştir.

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \tag{16}$$

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \tag{17}$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{18}$$

$$\text{Specificity} = \frac{\text{TN}}{\text{TN} + \text{FP}} \tag{19}$$

$$F1 = \frac{2 \times \text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \tag{20}$$

$$\text{Balanced Accuracy} = \frac{\text{Recall} + \text{Specificity}}{2} \tag{21}$$

Accuracy, tüm gözlemler içindeki doğru sınıflandırmaların oranını; precision, model tarafından riskli olarak sınıflandırılan talepler içindeki gerçekten riskli kayıtların payını; recall, gerçekte riskli olan taleplerin ne kadarının yakalandığını; specificity ise risksiz taleplerin ne ölçüde doğru sınıflandırıldığını göstermektedir. F1-score, precision ve recall arasındaki dengeyi harmonik ortalama üzerinden değerlendirirken, balanced accuracy recall ve specificity değerlerinin ortalamasını alarak her iki sınıfa eşit ağırlık vermektedir. Bu çalışmada recall özellikle önemlidir; çünkü uzun talep-karşılama riski taşıyan kayıtların gözden kaçırılması, depo iş gücü planlaması, önceliklendirme ve servis bazlı müdahale kararlarını olumsuz etkileyebilir. Precision ise riskli taleplerin yakalanması sırasında oluşabilecek yanlış alarm ve gereksiz müdahale yükünü değerlendirmek amacıyla kullanılmıştır.

ROC-AUC, belirli bir sınıflandırma eşiğine bağlı olmaksızın modelin riskli ve risksiz kayıtları genel olarak sıralama ve ayırt etme gücünü değerlendirmektedir. PR-AUC ise precision ve recall arasındaki ilişkiye odaklandığından, pozitif sınıfın seyrek olduğu P90 ve özellikle P95 modellerinde daha duyarlı bir performans göstergesidir. Bu nedenle ROC-AUC genel ayırt ediciliği, PR-AUC ise azınlık durumundaki riskli taleplere ilişkin sınıflandırma başarısını değerlendirmek için birlikte kullanılmıştır. Güncel makine öğrenmesi uygulamalarında da sınıf dengesizliği bulunan problemlerde accuracy değerinin recall, F1-score ve diğer sınıf-duyarlı ölçütlerle tamamlandığı görülmektedir (Çelik vd., 2025; Çelik vd., 2026). Performans ölçütlerinin seçimi sonuç değişkeninin yapısıyla uyumlu olmalıdır; bu nedenle sınıflandırma problemlerinde kullanılan ölçütler, sürekli sonuçların değerlendirilmesinde kullanılan R^2 ve MAE gibi ölçütlerden farklılaşmaktadır (Çelik ve Şaşmaz, 2026).

Burada TP, TN, FP ve FN sırasıyla doğru pozitif, doğru negatif, yanlış pozitif ve yanlış negatif sınıflandırmaları ifade etmektedir. Veri seti rastgele olarak %70 eğitim ve %30 test alt kümelerine ayrılmıştır. Model katsayıları eğitim kümesinde tahmin edilmiş; sınıflandırma eşikleri ve performans ölçütleri, modelin oluşturulmasında kullanılmayan test kümesi üzerinde değerlendirilmiştir.

$$\mathrm{HS}_i^{\mathrm{win}} = \begin{cases} Q_{0.01}, & \mathrm{HS}_i < Q_{0.01} \\ \mathrm{HS}_i, & Q_{0.01} \le \mathrm{HS}_i \le Q_{0.99} \\ Q_{0.99}, & \mathrm{HS}_i > Q_{0.99} \end{cases} \quad (22)$$

Winsorization yalnızca tanımlayıcı süre analizlerinde ve sağlamlık kontrolünde kullanılmıştır. Ana gecikme sınıflandırması P90 ve P95 eşiklerine göre orijinal geçerli süre dağılımı üzerinden yapılmıştır. Bu analizler, elde edilen bulguların veri temizleme kararlarına, uç değerlere ve gecikme eşiği seçimine karşı ne ölçüde kararlı olduğunu değerlendirmek amacıyla uygulanmıştır.

4. Bulgular

Bu bölümde, ana tıbbi malzeme deposundan klinik servislere yönelen tıbbi malzeme talepleri; operasyonel yük, talep-karşılama süresi ve uzun talep-karşılama riski açısından sunulmaktadır. Analizler, yöntem bölümünde tanımlanan istek-servis düzeyi kayıt yapısı, servis bazlı performans göstergeleri, üst kuyruk eşikleri ve lojistik regresyon modelleri doğrultusunda yürütülmüştür. Talep-karşılama süresinin sağa çarpık dağılım göstermesi nedeniyle yalnızca ortalama değerler değil, medyan, P90, P95 ve P99 gibi üst yüzdelik değerler de dikkate alınmıştır. Uzun talep-karşılama riski ise kuantil temelli ikili risk değişkenleri üzerinden incelenmiştir. Bulgular; servis bazlı operasyonel yükün dağılımına ilişkin AS1, toplam talep-karşılama süresinin üst kuyruk yapısı ve servis grubu farklılıklarına ilişkin AS2 ve uzun talep-karşılama riskiyle ilişkili faktörler ile modelin ayırt etme kapasitesine ilişkin AS3 sırasıyla ele alınarak sunulmuştur.

4.1. Veri setinin genel yapısı ve talep-karşılama süresi dağılımı

Veri seti, yöntem bölümünde tanımlanan kayıt yapısına göre düzenlenmiştir. Her kayıt; istek numarası, servis, vizite türü, istek ve onay zamanı, hasta sayısı, ürün çeşidi, toplam miktar ve sistemde kayıtlı süre değişkeninden oluşmaktadır. Veri setindeki süre değişkeni, çalışmada aktif fiziksel depo hazırlama süresi olarak değil, hastane bilgi yönetim sisteminde ölçülen toplam talep-karşılama süresi olarak değerlendirilmiştir. Bu tercih, veri setinde aktif fiziksel hazırlama aşamasını diğer işlem adımlarından ayıran bağımsız zaman damgalarının bulunmaması ve mevcut süre değişkeninin sürecin bütününü tutarlı biçimde temsil eden tek zaman göstergesi olması nedeniyle yapılmıştır. Bu değişken dakika cinsine dönüştürülmüş, ayrıca Formül (2) ile istek ve onay zamanları üzerinden kontrol amaçlı süre hesabı yapılmıştır. Geçerli süre kayıtları Formül (3)'te tanımlanan göstergeye göre belirlenmiş ve veri temizleme sonrasında analizler 55.985 istek-servis düzeyi kayıt üzerinden yürütülmüştür.

Tablo 1. veri seti ve talep-karşılama süresi tanımlayıcı bulguları

Gösterge	**Değer**
Ham kayıt sayısı	57.542
İstek-servis düzeyi analiz kaydı	55.985
Ortalama talep-karşılama süresi, dakika	194,81
Standart sapma, dakika	270,23
Medyan talep-karşılama süresi, dakika	93
P90 talep-karşılama süresi, dakika	493
P95 talep-karşılama süresi, dakika	803
P99 talep-karşılama süresi, dakika	1085,14

Tablo 1, talep-karşılama süresinde ortalama ve medyan değerleri arasında belirgin bir fark olduğunu göstermektedir. Ortalama sürenin medyandan yüksek olması, dağılımın sağa çarpık olduğunu ve bazı taleplerde uzun sürelerin oluştuğunu ortaya koymaktadır. Bu nedenle süreç performansını yalnızca ortalama süreyle değerlendirmek yeterli değildir. P90, P95 ve P99 değerleri, ana depo-servis malzeme akışında üst kuyrukta izlenmesi gereken bir gecikme alanı bulunduğunu göstermektedir. Bu süre, yalnızca aktif depo hazırlama hızını değil; talebin sisteme girilmesi, bekleme, kontrol, onay, kayıt ve teslimata hazır hale getirme gibi süreç bileşenlerini de içerebilecek toplam operasyonel yanıt süresi olarak yorumlanmalıdır.

Tablo 2'de verilen Pareto sonuçları, Formül (10) ile hesaplanan kümülatif paylara göre ana tıbbi malzeme deposu üzerindeki iş yükünün belirli klinik birimlerde yoğunlaştığını göstermektedir.

Tablo 2. Ana tıbbi malzeme deposunda pareto yoğunlaşma sonuçları

Pareto göstergesi	Sonuç
Talep sayısına göre ilk 5 servis	Ortopedi Servisi (81); Gündüz Tedavi Merkez Onkoloji, Anestezi Yoğun Bakım; Hematoloji Servisi 2; Prematüre Yoğun Bakım
Toplam talep-karşılama süresi yükünde ilk servisin payı	%8,13
İlk 5 servisin kümülatif payı	%27,10
İlk 10 servisin kümülatif payı	%42,70
İlk 20 servisin kümülatif payı	%66,90

Pareto sonuçları, Formül (10) ile hesaplanan kümülatif paylara göre ana tıbbi malzeme deposu üzerindeki iş yükünün belirli klinik birimlerde yoğunlaştığını göstermektedir. Talep sayısına göre Ortopedi Servisi (81), Gündüz Tedavi Merkez Onkoloji, Anestezi Yoğun Bakım, Hematoloji Servisi 2 ve Prematüre Yoğun Bakım ilk beş sırada yer almıştır. Toplam talep-karşılama süresi yükü açısından ise ilk servisin kümülatif payı %8,13, ilk 5 servisin payı %27,10, ilk 10 servisin payı %42,70 ve ilk 20 servisin payı %66,90 olarak hesaplanmıştır. Bu bulgu, operasyonel yükün yalnızca talep hacmiyle değil, zaman yükü ve servis bazlı yoğunlaşma düzeyiyle birlikte değerlendirilmesi gerektiğini ortaya koymaktadır. Ayrıca bu sonuç, sonraki aşamada Formül (12) ve Formül (13) ile tanımlanan P90 ve P95 uzun talep-karşılama risklerinin servis grupları düzeyinde incelenmesini desteklemektedir.

Operasyonel açıdan, ilk 20 servisin toplam talep-karşılama süresi yükünün %66,90'ını oluşturması, depo kaynaklarının tüm klinik servislere eşit biçimde dağıtılmasından ziyade, servislerin oluşturduğu zaman yüküne göre farklılaştırılmış iş gücü ve vardiya planlaması yapılabileceğini göstermektedir. Bu servisler, günlük operasyonel izleme panolarında öncelikli takip grubu olarak değerlendirilebilir.

4.2. Uzun talep-karşılama riski eşiklerinin belirlenmesi

Talep-karşılama süresinin üst kuyruk davranışını incelemek amacıyla yöntem bölümünde verilen kuantil tanımı kullanılmıştır. Bu kapsamda talep-karşılama süresi dağılımının genel kuantil değeri Formül (11) ile hesaplanmış; P90 eşiğini aşan kayıtlar Formül (12) doğrultusunda uzun talep-karşılama riski olarak sınıflandırılmıştır. Sağlamlık kontrolü için daha katı bir eşik olan P95 kullanılmış ve P95 üzeri kayıtlar Formül (13) doğrultusunda uç uzun talep-karşılama riski olarak tanımlanmıştır.

Tablo 3. P90 ve P95 uzun talep-karşılama riski dağılımı

Risk Tanımı	Eşik	Riskli Kayıt Sayısı	Risk Oranı
P90 uzun talep-karşılama riski	493 dk	5.593	%9,99
P95 uç uzun talep-karşılama riski	803 dk	2.793	%4,99

Tablo 3'e göre istek-servis düzeyindeki kayıtların yaklaşık onda biri P90 uzun talep-karşılama eşiğini aşmaktadır. P95 eşiğinde ise riskli kayıt oranı yaklaşık %5'tir. Bu oranlar, uzun talep-karşılama riskinin tüm taleplere homojen biçimde yayılmadığını, belirli servis ve talep özelliklerinde yoğunlaşabileceğini düşündürmektedir. Bu nedenle sonraki aşamada servis gruplarına göre risk dağılımı incelenmiştir.

4.3. Servis gruplarına göre uzun talep-karşılama riski

Servis bazlı analizlerde talep yoğunluğu Formül (4), toplam malzeme miktarı Formül (5), ortalama ürün çeşidi Formül (6) ve ortalama talep-karşılama süresi Formül (7) üzerinden değerlendirilmiştir. Servis sayısının yüksek olması ve bazı servislerde gözlem sayısının sınırlı kalması nedeniyle servisler klinik işlevlerine göre altı grupta sınıflandırılmıştır: yoğun bakım, hemato-onkoloji/kök hücre, cerrahi/ortopedi, dahili branşlar, günübirlik/GB ve diğer servisler. Bu gruplama, hem modelin yorumlanabilirliğini artırmış hem de ayrıntılı servis düzeyinde ortaya çıkan mükemmel tahmin sorununu azaltmıştır. Servis gruplarına göre P90 ve P95 uzun talep-karşılama oranları Tablo 4'te sunulmaktadır.

Tablo 4. Servis gruplarına göre p90 ve p95 uzun talep-karşılama riski

Servis grubu	Toplam kayıt	P90 riskli kayıt	P90 oranı	P95 riskli kayıt	P95 oranı
Yoğun bakım	8.205	1.728	%21,06	630	%7,68
Hemato-onkoloji/kök hücre	9.807	1.151	%11,74	956	%9,75
Cerrahi/ortopedi	8.175	506	%6,19	184	%2,25
Dahili branşlar	2.717	420	%15,46	134	%4,93
Günübirlik/GB	3.664	28	%0,76	17	%0,46
Diğer	23.417	1.760	%7,52	872	%3,72
Toplam	55.985	5.593	%9,99	2.793	%4,99

Tablo 4, uzun talep-karşılama riskinin servis grupları arasında belirgin biçimde farklılaştığını göstermektedir. P90 düzeyinde en yüksek uzun talep-karşılama oranı yoğun bakım grubunda görülmüştür. Bu gruptaki taleplerin %21,06'sı P90 eşiğini aşmaktadır. Dahili branşlar %15,46 ile ikinci, hemato-onkoloji/kök hücre grubu ise %11,74 ile üçüncü sıradadır. Bu bulgu, sık karşılaşılan uzun talep-karşılama riskinin özellikle klinik karmaşıklığı ve hasta bakım yoğunluğu yüksek servislerde daha belirgin hale geldiğini göstermektedir.

P95 eşiğinde ise daha farklı bir yapı ortaya çıkmaktadır. Uç uzun talep-karşılama riski açısından en yüksek oran hemato-onkoloji/kök hücre grubundadır. Bu gruptaki kayıtların %9,75'i P95 eşiğini aşmaktadır. Yoğun bakım grubunda P95 oranı %7,68 iken, dahili branşlarda bu oran %4,93'tür. Bu sonuç, yoğun bakımın sık uzun talep-karşılama riski açısından öne çıktığını; hemato-onkoloji/kök hücre grubunun ise daha uç düzeydeki gecikmeler bakımından daha kritik bir yapı sergilediğini göstermektedir. P90 ve P95 sıralamalarının farklılaşması, tüm servisler için tek bir gecikme ölçütüne dayalı önceliklendirme yapılmasının yeterli olmayabileceğini göstermektedir. Yoğun bakım grubunda sık tekrarlanan uzun talep-karşılama sürelerinin azaltılmasına yönelik günlük kapasite ve iş sırası düzenlemeleri öne çıkarken, hemato-onkoloji/kök hücre grubunda daha seyrek fakat uç düzeydeki gecikmeleri oluşturan süreçlerin ayrı olarak incelenmesi gerekmektedir. Bu nedenle servis bazlı izleme sistemlerinde P90 ve P95 göstergelerinin farklı operasyonel uyarı düzeyleri olarak kullanılması uygun olabilir.

4.4. Servis gruplu lojistik regresyon bulguları

Uzun talep-karşılama riskini açıklamak amacıyla Formül (14) ile tanımlanan lojistik regresyon modeli kullanılmıştır. Model; ürün çeşidi, toplam miktar, hasta sayısı, vizite türü, servis grubu ve zaman değişkenlerini içermektedir. Katsayılar Formül (15) doğrultusunda odds ratio değerlerine dönüştürülmüş; bulgular, çalışmanın retrospektif ve gözlemsel yapısı nedeniyle nedensel etki olarak değil, değişkenler arasındaki operasyonel ilişkiler olarak yorumlanmıştır.

Tablo 5. Servis gruplu lojistik regresyon sonuçları

Değişken	P90 OR	p	P95 OR	p
Ürün çeşidi	1,0200	<0,001	0,9805	0,001
Toplam miktar	1,0017	<0,001	1,0051	<0,001
Hasta sayısı	1,0265	<0,001	1,0141	<0,001
Hemato-onkoloji/kök hücre	0,7554	<0,001	2,3245	<0,001
Cerrahi/ortopedi	0,2951	<0,001	0,3175	<0,001
Dahili branşlar	0,6400	<0,001	0,5944	<0,001
Günübirlik/GB	0,0811	<0,001	0,2198	<0,001
Diğer servisler	0,3945	<0,001	0,7182	<0,001

Not: Referans servis grubu yoğun bakımdır. OR > 1 uzun talep-karşılama riskiyle pozitif ilişkiyi, OR < 1 ise referans gruba göre daha düşük riski göstermektedir.

Tablo 5'e göre P90 modelinde ürün çeşidi, toplam miktar ve hasta sayısı uzun talep-karşılama riskiyle pozitif ve anlamlı ilişkilidir. Ürün çeşidindeki bir birimlik artış, diğer değişkenler sabitken P90 riskini yaklaşık %2 artırmaktadır. Bu bulgu, operasyonel yükün yalnızca talep hacmiyle değil, talep karmaşıklığı ve hasta yüküyle de ilişkili olduğunu göstermektedir.

P95 modelinde ürün çeşidi değişkeninin OR değerinin 1'in altında olması, uç gecikmelerin P90 düzeyindeki daha sık gecikmelerden farklı bir yapı taşıyabileceğine işaret etmektedir. Bu nedenle P95 riskinin yalnızca ürün çeşitliliğiyle değil; servis niteliği, hasta yükü, toplam miktar ve süreç içi bekleme dinamikleriyle birlikte değerlendirilmesi gerekir.

Servis grupları açısından yoğun bakım referans alındığında, P90 modelinde diğer servis gruplarının OR değerleri 1'in altındadır. Bu durum, sık uzun talep-karşılama riskinde yoğun bakımın daha yüksek riskli grup olduğunu göstermektedir. Buna karşılık P95 modelinde hemato-onkoloji/kök hücre grubunun OR değeri 2,3245'tir. Dolayısıyla yoğun bakım sık gecikmelerde, hemato-onkoloji/kök hücre servisleri ise uç gecikme riskinde öne çıkmaktadır. Bu sonuçların operasyonel anlamı, depo iş sıralarının yalnızca talebin sisteme giriş zamanına veya toplam miktara göre izlenmemesi gerektiğidir. Ürün çeşitliliği, toplam miktar, hasta yükü ve servis grubu birlikte değerlendirilerek daha karmaşık ve uzun talep-karşılama riski taşıyan talepler erken aşamada işaretlenebilir. Bununla birlikte model gözlemsel verilere dayandığından, bu değişkenler gecikmenin doğrudan nedeni olarak değil, yönetsel izleme ve önceliklendirmede kullanılabilecek risk göstergeleri olarak değerlendirilmelidir.

4.5. Model performansı ve sınıflandırma bulguları

Model performansı; accuracy, precision, recall, specificity, F1-score ve balanced accuracy ölçütleriyle değerlendirilmiştir. Bu ölçütler, yöntem bölümünde verilen Formül (16)–(21) esas alınarak hesaplanmıştır. P90 modelinde pozitif sınıf oranının yaklaşık %10, P95 modelinde ise yaklaşık %5 olması nedeniyle yalnızca accuracy değerine dayanılmamış; recall, balanced accuracy ve PR-AUC değerleri de birlikte yorumlanmıştır.

Tablo 6. Uzun talep-karşılama riski modellerinin eşik performansı

Model	En iyi eşik	Accuracy	Precision	Recall	Specificity	F1	Balanced Accuracy
P90 ayrıntılı servis modeli	0,15	0,8453	0,3693	0,6931	0,8630	0,4819	0,7781
P95 ayrıntılı servis modeli	0,10	0,9099	0,3295	0,6947	0,9218	0,4470	0,8083

Tablo 6, P90 ve P95 modellerinde yüksek accuracy değerlerinin tek başına yeterli bir performans göstergesi olmadığını göstermektedir. Pozitif sınıf oranlarının sırasıyla yaklaşık %10 ve %5 olması nedeniyle karar eşikleri balanced accuracy ölçütü temel alınarak belirlenmiştir. P90 modelinde 0,15 eşiği riskli kayıtların %69,31'ini yakalarken risksiz kayıtların %86,30'unu doğru ayırt etmiş; P95 modelinde 0,10 eşiğinde recall %69,47 ve specificity %92,18 olarak hesaplanmıştır. Balanced accuracy değerlerinin sırasıyla 0,7781 ve 0,8083 olması, modellerin yalnızca çoğunluk sınıfındaki yüksek doğrulukla sınırlı kalmadığını ve her iki sınıfı birlikte ayırt edebildiğini göstermektedir. Bununla birlikte precision değerlerinin recall değerlerinden düşük olması, riskli taleplerin daha büyük bölümünü yakalama amacının belirli bir yanlış alarm yükü oluşturduğuna işaret etmektedir. Bu nedenle karar eşiklerinin seçiminde riskli bir talebin gözden kaçırılmasının operasyonel maliyeti ile yanlış alarm nedeniyle oluşacak ek iş yükü birlikte değerlendirilmelidir.

4.6. ROC-AUC, PR-AUC ve winsorization sağlamlık analizi

Eşik performansına ek olarak modellerin genel ayırt edicilik gücü ROC-AUC ve PR-AUC değerleriyle değerlendirilmiştir. ROC-AUC, farklı karar eşikleri altında riskli ve risksiz kayıtları ayırt etme kapasitesini; PR-AUC ise pozitif sınıf oranının düşük olduğu durumda riskli kayıtları yakalama performansını göstermektedir. Talep-karşılama süresindeki uç değerlerin genel yorum üzerindeki etkisini değerlendirmek için Formül (22) ile tanımlanan winsorization kontrolü uygulanmıştır.

Tablo 7. ROC-AUC, PR-AUC ve winsorization sağlamlık sonuçları

Model	ROC-AUC	PR-AUC	Average Precision
P90 servis gruplu	0,8308	0,3901	0,3908
P95 servis gruplu	0,8336	0,3290	0,3301
P90 winsorize	0,8308	0,3901	0,3908
P95 winsorize	0,8336	0,3290	0,3301

Tablo 7'ye göre P90 ve P95 modellerinin ROC-AUC değerleri sırasıyla 0,8308 ve 0,8336'dır. Bu değerler, modellerin farklı karar eşikleri altında riskli ve risksiz kayıtları genel olarak ayırt edebildiğini göstermektedir. PR-AUC değerleri P90 modeli için 0,3901 ve P95 modeli için 0,3290'dır. PR-AUC'nin rastlantısal temel düzeyi yaklaşık olarak pozitif sınıf prevalansına karşılık geldiğinden, bu değerler P90 modeli için 0,0999 ve P95 modeli için 0,0499 temel değerleriyle karşılaştırılmıştır. Buna göre P90 modelinin PR-AUC değeri rastlantısal temel düzeyin yaklaşık 3,9 katı, P95 modelinin PR-AUC değeri ise yaklaşık 6,6 katıdır. Bu sonuç, özellikle seyrek P95 riskli sınıfında modelin rastlantısal sınıflandırmanın belirgin biçimde üzerinde ayırt edicilik sağladığını göstermektedir. Bununla birlikte PR-AUC, seçilen tek bir karar eşiğindeki precision değerinden farklı olarak, tüm olası eşikler boyunca precision–recall ilişkisini özetlemektedir.

Winsorization kontrolünde ROC-AUC, PR-AUC ve Average Precision değerlerinde değişim gözlenmemiştir. Bu bulgu, uç talep-karşılama süresi değerlerinin genel model performansı yorumunu belirgin biçimde değiştirmediğini düşündürmektedir. Ancak bu sonuç nedensel bir sağlamlık kanıtı olarak değil, uç değer duyarlılığına yönelik tamamlayıcı bir kontrol olarak değerlendirilmelidir.

5. Tartışma

Bu çalışma, hastane iç lojistiğinde tıbbi malzeme akışlarının yalnızca toplam tüketim miktarı, talep sayısı veya stok düzeyiyle açıklanamayacağını göstermektedir. Bulgular, ana tıbbi malzeme deposu ile klinik servisler arasındaki akışın ürün çeşitliliği, toplam miktar, hasta yükü, servis grubu ve talep-karşılama süresiyle birlikte değerlendirilmesi gerektiğini ortaya koymuştur. Bu sonuç, hastane iç tedarik zinciri performansının maliyet ve stok göstergelerinin ötesinde; süreç, hizmet sürekliliği, zaman performansı ve operasyonel yanıt kapasitesiyle birlikte ele alınması gerektiğini belirten çalışmalarla uyumludur (Moons vd., 2019; Fallahnezhad vd., 2024). Bu yönüyle çalışma, hastane iç lojistik performansını yalnızca stok bulunabilirliği veya malzeme tüketimi üzerinden değerlendiren yaklaşımları genişletmektedir. İstek-servis düzeyindeki analiz birimi ile üst kuyruk gecikme göstergelerinin birlikte kullanılması, klinik servislerin depo üzerinde oluşturduğu operasyonel baskının hem hacim hem de zaman riski bakımından değerlendirilmesini sağlamaktadır. Böylece çalışma, gerçek işlem verilerinin açıklanabilir ve servis bazlı bir karar destek mekanizmasına dönüştürülebileceğini göstermektedir.

Talep-karşılama süresinde ortalama ile medyan arasındaki belirgin fark ve P90–P95 düzeylerinde ortaya çıkan uzun süreler, operasyonel zaman performansının yalnızca merkezi eğilim ölçüleriyle değerlendirilmesinin yetersiz kalabileceğini göstermektedir. Bu sonuç, sağa çarpık operasyonel sürelerde medyan ve üst yüzdeliklerin ayrı değerlendirilmesini öneren kuantil temelli yaklaşımlarla uyumludur (Sun vd., 2012; Arora vd., 2023). Tortorella vd. (2021) de hastane iç lojistik dağıtımının güvenilirliğinin değerlendirilmesinde belirsizlik kaynaklarının ve süreçteki sapmaların görünür hâle getirilmesinin önemini vurgulamaktadır. Mevcut çalışmanın bulguları bu literatürü ana tıbbi malzeme deposu-servis akışına taşıyarak, ortalama sürenin tipik işleyişi ve üst kuyruktaki gecikmeleri tek başına temsil edemediğini göstermektedir. Operasyonel açıdan bu durum, performans panolarında ortalama sürenin yanında medyan, P90 ve P95 göstergelerinin birlikte izlenmesini ve üst yüzdelikler için ayrı müdahale eşikleri oluşturulmasını gerektirmektedir.

Servis grupları arasında gözlenen risk farklılıkları, merkez depo ile klinik birimler arasındaki ilişkinin günlük hastane tedarik zinciri performansında belirleyici olduğunu vurgulayan Landry ve Beaulieu'nun (2013) yaklaşımıyla uyumludur. Moons vd. (2019) ve Fallahnezhad vd. (2024), hastane tedarik zinciri performansının stok ve maliyet göstergelerinin yanında zaman, süreç, hizmet sürekliliği ve klinik gereksinimlerle birlikte değerlendirilmesi gerektiğini belirtmektedir. Bu çalışmada yoğun bakım grubunun sık uzun talep-karşılama riski, hemato-onkoloji/kök hücre grubunun ise uç gecikme riski bakımından öne çıkması, servislerin aynı depo sistemi içinde dahi farklı operasyonel risk profilleri oluşturabildiğini göstermektedir. Bu bulgu, hastanelerin veya depoların genel performans göstergelerine göre sınıflandırılmasını ele alan çalışmaların ötesine geçerek, aynı hastane içindeki klinik hizmet gruplarının farklı gecikme örüntülerine sahip olabileceğini ortaya koymaktadır (Feibert vd., 2019; Cagliano vd., 2022). Dolayısıyla tüm servislere tek tip hizmet düzeyi ve önceliklendirme kuralı uygulanması yerine, servislerin sık gecikme ve uç gecikme profillerine göre farklılaştırılmış operasyonel müdahaleler geliştirilmelidir.

Ürün çeşitliliği, toplam miktar ve hasta yükü ile uzun talep-karşılama riski arasındaki ilişkiler, hastane malzeme akışının yalnızca stok miktarına indirgenemeyeceğini göstermektedir. Iannone vd. (2013), hastane malzeme yönetiminin klinik gereksinimden kullanım noktasına kadar uzanan veri ve işlem akışıyla birlikte modellenmesi gerektiğini belirtirken; Rocha ve Rego (2023), hastane iç depolama, toplama ve dağıtım süreçlerindeki düzenlemelerin operasyonel performansı etkileyebileceğini göstermektedir. Mevcut bulgular bu çalışmaları desteklemekte ve talep karmaşıklığının ürün çeşidi, klinik yükün ise hasta sayısı ve servis grubu aracılığıyla ölçülebilir operasyonel risk göstergelerine dönüştürülebileceğini ortaya koymaktadır. Ürün çeşidinin P90 modelinde riski artırırken P95 modelinde ters yönlü ilişki göstermesi, sık gecikmeler ile uç gecikmelerin aynı süreç dinamiklerinden kaynaklanmayabileceğine işaret etmektedir. Bu sonuç ürün çeşitliliğinin uç gecikmelere karşı koruyucu olduğu şeklinde yorumlanmamalıdır; P95 düzeyindeki gecikmelerin personel kapasitesi, vardiya, stok bulunabilirliği, onay süreci veya fiziksel depo koşulları gibi mevcut veri setinde yer almayan faktörlerden etkilenmesi mümkündür. Operasyonel olarak ürün çeşidi, toplam miktar ve hasta yükünün talep ekranlarında erken risk göstergeleri olarak birlikte izlenmesi, depo yöneticilerinin karmaşık talepleri işlem başlamadan önce belirlemesine yardımcı olabilir.

Model performansı, işlem kayıtlarının uzun talep-karşılama riskini ayırt etmede kullanılabileceğini göstermektedir. Servis gruplu modellerde ROC-AUC değerleri P90 için 0,8308, P95 için 0,8336; PR-AUC değerleri ise sırasıyla 0,3901 ve 0,3290 olarak hesaplanmıştır. Pozitif sınıf oranının düşük olduğu dikkate alındığında, bu değerler rastlantısal sınıflandırmanın üzerinde anlamlı bir ayırt ediciliğe işaret etmektedir. Winsorization kontrolünde performans değerlerinde değişim görülmemesi, uç değerlerin genel model yorumunu belirgin biçimde değiştirmediğini düşündürmektedir. Ancak bu sonuç

nedensel bir sağlamlık kanıtı değil, tamamlayıcı bir duyarlılık kontrolü olarak değerlendirilmelidir. Bu performans göstergeleri modelin ikincil ayırt etme kapasitesini temsil etmekte; çalışmanın temel açıklayıcı çıkarımları ise değişkenlerin uzun talep-karşılama riskiyle ilişkisini gösteren odds ratio bulgularına dayanmaktadır.

Bulguların yönetimsel karşılığı, bütün servislere tek tip depo hizmet standardı uygulanması yerine, servislerin operasyonel yük ve gecikme profillerine göre farklılaştırılmış yönetim politikaları geliştirilmesidir. Yoğun bakım grubunda sık uzun talep-karşılama riskinin yüksek olması, günlük talep yoğunluğunun izlenmesi, yoğun saatlerde personel kapasitesinin artırılması, standart malzeme setlerinin gözden geçirilmesi ve kritik ürünlerin kullanım noktasına daha yakın konumlandırılması gibi müdahaleleri gündeme getirmektedir. Hemato-onkoloji/kök hücre grubunda uç gecikme riskinin öne çıkması ise P95 üzerindeki talepler için ayrı uyarı mekanizmalarının kurulmasını ve bu taleplerin süreç adımlarının geriye dönük olarak incelenmesini gerektirmektedir.

Dijital izlenebilirlik ve kullanım noktası envanter yönetimi çalışmalarında kayıt doğruluğu ile fiilî kullanım verilerinin stok ve süreç kararları açısından önemi vurgulanmaktadır (Bendavid vd., 2012; Neve ve Schmidt, 2022). Benzer biçimde otomasyon, barkod ve RFID uygulamaları tekrarlanan hazırlama, kayıt ve dağıtım işlemlerinin daha görünür ve standart hâle gelmesini sağlayabilir (Fragapane vd., 2018; Granlund ve Wiktorsson, 2013). Bununla birlikte mevcut bulgular, dijital ve otomasyon yatırımlarının hastane genelinde eşit biçimde uygulanmasından ziyade, talep hacmi, ürün çeşitliliği ve P90/P95 risklerinin yüksek olduğu servis ve süreçlere öncelik verilerek planlanmasının daha uygun olabileceğini göstermektedir.

Bu çalışma, tek bir üniversite hastanesinin retrospektif işlem kayıtlarına dayandığından bulguların farklı hastanelere doğrudan genellenmesi sınırlıdır. Talep-karşılama süresi, aktif depo hazırlama süresinden ziyade bilgi sisteminde ölçülen toplam operasyonel yanıt süresini temsil etmektedir. Personel sayısı, vardiya düzeni, stok bulunabilirliği, aciliyet, malzeme kritiklik düzeyi, raf konumu ve taşıma süresi gibi operasyonel değişkenlerin veri setinde bulunmaması modelin açıklayıcılığını sınırlamaktadır. Ayrıca P90 ve P95 eşikleri kuruma özgüdür ve sonuçlar nedensel ilişki olarak yorumlanmamalıdır.

Gelecek araştırmalarda çok merkezli ve ileriye dönük tasarımlar kullanılmalı; talep, hazırlama, depo çıkışı, taşıma ve teslim aşamaları ayrı zaman damgalarıyla izlenmelidir. Modellerin farklı dönemlerde ve hastanelerde dış doğrulaması yapılmalı; süreç madenciliği ve açıklanabilir makine öğrenmesi yöntemleriyle karşılaştırılmalıdır.

6. Sonuç ve öneriler

Bu çalışma, hastane içi tıbbi malzeme akışlarının yalnızca stok düzeyi, toplam tüketim veya talep sayısı üzerinden değerlendirilemeyeceğini göstermiştir. Çalışmanın özgün bilimsel katkısı; istek-servis düzeyindeki gerçek işlem kayıtlarını, talep hacmi, ürün çeşitliliği, hasta yükü, servis grubu ve zaman riski göstergeleriyle bütünleştirmesi; talep-karşılama süresinin üst kuyruğunu P90 ve P95 eşikleriyle görünür hâle getirmesi ve bu göstergeleri açıklanabilir lojistik regresyon aracılığıyla operasyonel karar desteğine dönüştürmesidir.

Bulgular, klinik servislerin ana depo üzerinde homojen bir operasyonel yük oluşturmadığını ortaya koymuştur. Yoğun bakım grubunun daha sık tekrarlanan uzun talep-karşılama riski, hemato-onkoloji/kök hücre grubunun ise daha uç gecikmeler bakımından öne çıkması, tek bir hizmet süresi göstergesinin bütün servisler için yeterli olmayacağını göstermektedir. Ürün çeşitliliği, toplam miktar,

hasta yükü ve servis özellikleriyle ilişkili risk farklılıkları da depo performansının çok boyutlu olarak izlenmesi gerektiğini desteklemektedir.

Yönetimsel açıdan depo iş gücü, vardiya düzeni ve talep önceliklendirme kararları yalnızca talep sırasına veya toplam miktara dayandırılmamalıdır. Ortalama ve medyan sürelerin yanında P90 ve P95 göstergeleri izlenmeli; sık gecikme ile uç gecikme için farklı uyarı ve müdahale kuralları oluşturulmalıdır. Yoğun talep ve zaman yükü oluşturan servisler için personel kapasitesinin talep saatlerine göre düzenlenmesi, standart malzeme setlerinin gözden geçirilmesi, kritik ürünlerin kullanım noktasına yakın konumlandırılması ve P95 üzerindeki taleplerin süreç bazında incelenmesi önerilmektedir.

Hastane bilgi yönetim sistemi kayıtlarının düzenli biçimde işlenmesi, yöneticilere servis bazlı risk panoları oluşturma olanağı sunabilir. Bununla birlikte lojistik regresyon çıktıları otomatik karar veren kesin kurallar olarak değil, yöneticilerin değerlendirmesini destekleyen erken uyarı göstergeleri olarak kullanılmalıdır. Barkod, RFID, otomatik depo ve kullanım noktası envanter sistemleri de yüksek operasyonel yük ve gecikme riski bulunan süreçlere öncelik verilerek, süreç standardizasyonu ve veri kalitesi iyileştirmeleriyle birlikte uygulanmalıdır.

Sonuç olarak çalışma, gerçek hastane işlem kayıtlarının servis bazlı operasyonel yükü ve uzun talep-karşılama riskini izleyen açıklanabilir bir karar destek çerçevesine dönüştürülebileceğini göstermektedir. Bu yaklaşım, hastane iç lojistiğinde kaynakların risk ve iş yüküne göre yönlendirilmesi, gecikme örüntülerinin erken belirlenmesi ve klinik hizmet sürekliliğinin desteklenmesi açısından uygulanabilir bir temel sunmaktadır.

Yazar beyanları / Author statements

Makale araştırma ve yayın etiğine uygun olarak hazırlanmıştır. Çalışmanın tüm aşamaları tek yazar tarafından yürütülmüştür. Yazar, herhangi bir çıkar çatışması bulunmadığını beyan eder.

Kaynakça

Aguilar-Escobar, V. G., & Garrido-Vega, P. (2013). Lean logistics management in healthcare: a case study. *Revista de calidad asistencial: organo de la Sociedad Espanola de Calidad Asistencial*, 28(1), 42-49.

Aguilar-Escobar, V. G., Bourque, S., & Godino-Gallego, N. (2015). Hospital kanban system implementation: Evaluating satisfaction of nursing personnel. *Investigaciones Europeas de Dirección y Economía de la Empresa*, 21(3), 101-110.

Arora, S., Taylor, J. W., & Mak, H. Y. (2023). Probabilistic forecasting of patient waiting times in an emergency department. *Manufacturing & Service Operations Management*, 25(4), 1489-1508.

Bélanger, V., Beaulieu, M., Landry, S., & Morales, P. (2018, January). Where to locate medical supplies in nursing units: An exploratory study. *In Supply Chain Forum: An International Journal* (Vol. 19, No. 1, pp. 81-89). Taylor & Francis.

Bendavid, Y., & Boeck, H. (2011). Using RFID to improve hospital supply chain management for high value and consignment items. *Procedia Computer Science*, 5, 849-856.

Bendavid, Y., Boeck, H., & Philippe, R. (2012). RFID-enabled traceability system for consignment and high value products: A case study in the healthcare sector. *Journal of medical systems*, 36(6), 3473-3489.

Cagliano, A. C., Grimaldi, S., & Rafele, C. (2016). Paving the way for warehouse centralization in healthcare: a preliminary assessment approach. *American Journal of Applied Sciences*, 13(5), 490-500.

Cagliano, A. C., Mangano, G., Rafele, C., & Grimaldi, S. (2022). Classifying healthcare warehouses according to their performance. A Cluster Analysis-based approach. *The International Journal of Logistics Management*, 33(1), 311-338.

Chanpuypetch, W., & Kritchanchai, D. (2018). A process reference model for hospital supply chain of pharmaceutical products. *Industrial Engineering & Management Systems*, 17(1), 43-61.

Chen, D. Q., Preston, D. S., & Xia, W. (2013). Enhancing hospital supply chain performance: A relational view and empirical test. *Journal of operations management*, 31(6), 391-408.

Coustasse, A., Tomblin, S., & Slack, C. (2013). Impact of radio-frequency identification (RFID) technologies on the hospital supply chain: a literature review. *Perspectives in Health Information Management*, 10(Fall).

Çelik, S., Doğanlı, B., & Cengiz, A. (2026). Citation classification and key phrase extraction in legal texts using machine learning: An examination of the legal text classification dataset. *Quality & Quantity*, 60, 6645–6681.

Çelik, S., Öztürk, Ö. F., Akkucuk, U., & Şaşmaz, M. Ü. (2025). Global sustainability performance and regional disparities: A machine learning approach based on the 2025 SDG Index. *Sustainability*, 17(16), 7411.

Çelik, S., & Şaşmaz, M. Ü. (2026). Mapping latent environmental performance regimes: a spatial and explainable machine learning approach. *Quality & Quantity*, 1-43.

De Vries, J. (2011). The shaping of inventory systems in health services: A stakeholder analysis. *International Journal of Production Economics*, 133(1), 60-69.

De Vries, J., & Huijsman, R. (2011). Supply chain management in health services: an overview. *Supply chain management: An international journal*, 16(3), 159-165.

Fallahnezhad, M., Langarizadeh, M., & Vahabzadeh, A. (2024). Key performance indicators of hospital supply chain: a systematic review. *BMC Health Services Research*, 24(1), 1610.

Fawcett, T. (2006). An introduction to ROC analysis. Pattern Recognition Letters, 27(8), 861–874. https://doi.org/10.1016/j.patrec.2005.10.010

Feibert, D. C., Andersen, B., & Jacobsen, P. (2019). Benchmarking healthcare logistics processes–a comparative case study of Danish and US hospitals. *Total quality management & business excellence*, 30(1-2), 108-134.

Fragapane, G. I., Bertnum, A. B., Hvolby, H. H., & Strandhagen, J. O. (2018). Material distribution and transportation in a norwegian hospital: a case study. *Ifac-papersonline*, 51(11), 352-357.

Granlund, A., & Wiktorsson, M. (2013). Automation in healthcare internal logistics: a case study on practice and potential. *International Journal of Innovation and Technology Management*, 10(03), 1340012.

Gupta, R. K. G. R., Gupta, K. K., Jain, B. R., & Garg, R. K. (2007). ABC and VED analysis in medical stores inventory control. *Medical Journal Armed Forces India*, 63(4), 325-327.

Haszlinna Mustaffa, N., & Potter, A. (2009). Healthcare supply chain management in Malaysia: a case study. *Supply chain management: an international journal*, 14(3), 234-243.

Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). *Applied logistic regression*. John Wiley & Sons.

Hussain, M., Siddharth, V., & Arya, S. (2019). ABC, VED and lead time analysis in the surgical store of a public sector tertiary care hospital in Delhi. *Indian journal of public health*, 63(3), 194-198.

Iannone, R., Lambiase, A., Miranda, S., Riemma, S., & Sarno, D. (2013). Modelling hospital materials management processes. *International Journal of Engineering Business Management*, 5, 1-12. https://doi.org/10.5772/56607

Işıkçelik, F., Özkan, O., & Ağırbaş, İ. (2019). Hastane İlaç Stoklarının ABC, VED ve ABC-VED Yöntemleri ile Analizi. Hacettepe Sağlık İdaresi Dergisi, 22(2), 305-318.

Kim, S.-H., & Sung, D.-H. (2020). The study of healthcare supply chain management in Korea: On 5 general hospitals. *Journal of Digital Contents Society*, 21(1), 195-203. DOI: 10.9728/dcs.2020.21.1.195

King, Z., Farrington, J., Utley, M., Kung, E., Elkhodair, S., Harris, S., ... & Crowe, S. (2022). Machine learning for real-time aggregated prediction of hospital admission for emergency patients. *NPJ digital medicine*, 5(1), 104.

Landry, S., & Beaulieu, M. (2013). *The challenges of hospital supply chain management, from central stores to nursing units*. In Handbook of healthcare operations management: Methods and applications (pp. 465-482). New York, NY: Springer New York.

Liu TongZhu, L. T., Shen AiZong, S. A., Hu XiaoJian, H. X., Tong GuiXian, T. G., Gu Wei, G. W., & Yang ShanLin, Y. S. (2016). SPD-based logistics management model of medical consumables in hospitals.

Lv, S., Ye, H., Li, Y., & Zhang, J. (2025). Applying a logistic regression-clustering joint model to analyze the causes of prolonged pre-analytic turnaround time for urine culture testing in hospital wards. *Frontiers in Digital Health*, 7, 1603314.

Machado, C. M., Scavarda, A. J., & Vaccaro, G. (2014). Lean healthcare supply chain management: minimizing waste and costs. *Independent Journal of Management & Production*, 5(4), 1071-1088.

Maestrini, V., Luzzini, D., Maccarrone, P., & Caniato, F. (2017). Supply chain performance measurement systems: A systematic review and research agenda. *International journal of production economics*, 183, 299-315.

Mohammed, S. A., & Workneh, B. D. (2020). Critical analysis of pharmaceuticals inventory management using the ABC-VEN matrix in Dessie referral Hospital, Ethiopia. *Integrated Pharmacy Research and Practice*, 113-125.

Moons, K., Waeyenbergh, G., & Pintelon, L. (2019). Measuring the logistics performance of internal hospital supply chains–a literature study. *Omega,* 82, 205-217.

Neve, B. V., & Schmidt, C. P. (2022). Point-of-use hospital inventory management with inaccurate usage capture. *Health Care Management Science*, 25(1), 126-145.

Poon, E. G., Keohane, C. A., Yoon, C. S., Ditmore, M., Bane, A., Levtzion-Korach, O., ... & Gandhi, T. K. (2010). Effect of bar-code technology on the safety of medication administration. *New England Journal of Medicine*, 362(18), 1698-1707.

Preziosa, S., Cagliano, A. C., Mangano, G., & Rafele, C. (2025). *Impacts of Automation on the Performance of Hospital Warehouses.* An Italian Application. IFAC-PapersOnLine, 59(10), 1636-1641.

Purbey, S., Mukherjee, K., & Bhar, C. (2007). Performance measurement system for healthcare processes. *International Journal of Productivity and Performance Management*, 56(3), 241-251.

Rocha, L. A., & Rego, N. (2023). Reorganisation of the internal storage and distribution logistics in a hospital. *Procedia Computer Science*, 219, 1357-1364.

Rossetti, M. D., & Selandari, F. (2001). Multi-objective analysis of hospital delivery systems. *Computers & Industrial Engineering*, 41(3), 309-333.

Sakaguchi, H., Furui, K., Watanabe, R., & Arai, K. (2025). Tıbbi malzeme SPD'leri için dış kaynak kullanımının kapsamı üzerine bir çalışma: DPC/PDPS hedef hastanelerinin anket çalışmasına dayanmaktadır. *Tıp ve Sosyal* , 35 (4), 477-485.

Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. *Information processing & management*, 45(4), 427-437.

Sun, Y., Teow, K. L., Heng, B. H., Ooi, C. K., & Tay, S. Y. (2012). Real-time prediction of waiting time in the emergency department, using quantile regression. *Annals of emergency medicine*, 60(3), 299-308.

Tortorella, G., Moliner Farjas, G., & Li, W. (2021). Reliability of internal logistics distribution in a hospital. *The TQM Journal*, 33(3), 596-617.

Volland, J., Fügener, A., Schoenfelder, J., & Brunner, J. O. (2017). Material logistics in hospitals: A literature review. *Omega,* 69, 82-101.

Wang, T., & Chen, Y. (2025). Optimisation model of SPD supply chain for medical consumables under DRG background based on mixed integer programming. *Promet - Traffic & Transportation*, 37(4), 1097-1113. DOI: 10.7307/ptt.v37i4.873

Yang, C., Gu, W., & Liu, T. (2019). Application and evaluation of SPD based logistics management model for medical consumables in clinical nursing departments. *Iranian Journal of Public Health*, 48(8), 1452.

Summary

This study examines medical material flows from the central medical supply warehouse to clinical services in a university hospital, focusing on operational workload and request fulfillment time performance. In hospital internal logistics, material distribution is often evaluated through total demand volume, consumption amount, or stock-related indicators. However, such indicators may not fully capture the actual operational pressure created by clinical services on the warehouse. For this reason, this study evaluates medical material flows through a multidimensional framework that includes product variety, total quantity, patient load, service group, request fulfillment time, and long request fulfillment risk.

The analysis was based on 57,542 transaction records obtained from the hospital information system. After data cleaning and restructuring at the request-service level, 55,985 records were included in the final analysis. The request-service level was preferred because a single request may include multiple material lines, and using raw item-level records alone may overstate the actual number of service requests. In the dataset, the time variable recorded as preparation time was interpreted in this study as request fulfillment time. This concept reflects not only physical picking or preparation in the warehouse, but also the broader operational response period captured by the information system.

The findings show that request fulfillment time has a clearly right-skewed distribution. The mean request fulfillment time was 194.81 minutes, while the median was 93 minutes. This difference indicates that typical requests are fulfilled in a much shorter time than the average suggests, whereas a smaller group of requests creates a long upper tail. The P90 threshold was calculated as 493 minutes, the P95 threshold as 803 minutes, and the P99 threshold as 1085.14 minutes. These results demonstrate that mean-based evaluation alone may be misleading in hospital internal logistics and that quantile-based indicators are necessary to identify upper-tail operational delays.

Long request fulfillment risk was not distributed homogeneously across clinical service groups. Overall, 9.99% of the records exceeded the P90 threshold, while 4.99% exceeded the P95 threshold. At the P90 level, the highest long request fulfillment risk was observed in intensive care units, where 21.06% of records exceeded the threshold. Internal medicine-related branches followed with 15.46%, and the hemato-oncology/stem cell group with 11.74%. At the P95 level, however, the highest extreme delay risk was observed in the hemato-oncology/stem cell group, where 9.75% of records exceeded the threshold. This distinction suggests that intensive care units generate more frequent long fulfillment cases, whereas hemato-oncology and stem cell-related services present a more critical profile for extreme delays.

The logistic regression findings support the relationship between long request fulfillment risk, demand complexity, and clinical workload. In the P90 model, product variety, total quantity, and patient load were positively and significantly associated with long request fulfillment risk. This result indicates that the operational pressure on the central medical supply warehouse is not determined only by the total quantity requested, but also by the number of different items included in a request and the number of patients related to that demand. In the P95 model, total quantity and patient load remained significant, while the hemato-oncology/stem cell group showed a higher extreme delay risk compared with intensive care units.

The predictive performance of the models was also evaluated. In the service-group logistic regression models, the ROC-AUC value was 0.8308 for the P90 model and 0.8336 for the P95 model, indicating strong discriminatory performance. PR-AUC values were 0.3901 for P90 and 0.3290 for P95. Considering the relatively low positive class rates, these values suggest that the models performed meaningfully above random classification. Threshold optimization further showed that the default 0.50 threshold is not always suitable for operational decision-

making. Lower thresholds, such as 0.15 for P90 and 0.10 for P95, provided a more balanced performance in identifying risky requests. The winsorization robustness analysis showed no change in ROC-AUC, PR-AUC, or Average Precision values, indicating that the results were not driven by a small number of extreme time values.

Overall, the study demonstrates that hospital internal logistics should be evaluated through a multidimensional and service-based perspective. Workforce planning, shift scheduling, service prioritization, and early warning systems should consider product variety, patient load, service group, request fulfillment time, and P90/P95 risk indicators together. Intensive care units should be monitored for frequent long fulfillment risk, while hemato-oncology/stem cell services should be monitored for extreme delay risk. The study also shows that routinely collected hospital information system records can be transformed into a practical decision-support tool for monitoring warehouse performance and identifying operational risks. Future studies may extend this framework to other hospitals, include additional process timestamps, and compare logistic regression with machine learning and explainable artificial intelligence models.