YAPAY ZEKA İLE ATIKSU TOPLAMA SİSTEMLERİNDE GRAFİK OKUNARAK KATI MADDE BİRİKİMİNİN BELİRLENMESİ

Mehmet B. Ercan[1]

[1]*İnönü Üniversitesi, mehmetb.ercan@inonu.edu.tr*

ÖZET

Atık su toplama sistemlerinde katı atık birikimi, genellikle tıkanmalara ve akış kapasitesinin azalmasına yol açarak önemli bir sorun teşkil etmektedir. Bu sistemler tıkandığında, Ayrık veya Birleşik Sistem Atıksu Kanal Taşması (SSO veya CSO) riski artar ve bu da olası sel ve patojen kontaminasyonu yoluyla halkın güvenliğini tehlikeye atar. Bu nedenle, altyapı hizmetlerinin büyük yağışlardan önce katı atık birikimini proaktif olarak tespit edip müdahale etmesi hayati önem taşımaktadır. Mevcut durumda, bu tür sorunları tespit etmek için otomatik teknikler çok yenidir ve sadece akademik çalışmalar ile sınırlıdır ve mevcut yöntemler yalnızca derinlik gözlemlerine dayanmakta olup, doğru tespit için gerekli olan hız bileşeninden yoksundur. Bu çalışma, derinlik ve hız dağılım grafiğini yapay zekaya öğretip katı madde miktarını Derin Konvolüsyonel Sinir Ağı (CNN) ile otomatik olarak tahmin etmektedir. CNN, farklı miktarlarda katı madde ile derinlik ve hız değişkenlerini simüle etmek için tasarlanmış Yağmur Suyu Yönetim Modeli (SWMM) kullanılarak oluşturulan grafik veri seti üzerinde eğitilmiştir. Gerçek koşulları kapsamlı bir şekilde taklit etmek için 1,482,000 SWMM modeli geliştirilmiş ve CNN modelinin eğitimi için farklı seviyelerde silt birikimi ile etiketlenmiş 82,482 dağılım grafiği oluşturulmuştur. Bu grafikler ile eğitilen CNN model doğrulama grafikleri ile test edildiğinde, %99 doğrulukla silt derinliklerini %10 hata payı ile doğru bir şekilde tespit etmiştir. Bu bulgular, CNN'lerin toplama sistemlerindeki silt birikimini tespit etmek için güçlü bir araç olduğunu ve geleneksel yöntemlere kıyasla daha hızlı ve daha kesin bir alternatif sunduğunu göstermektedir. Bu yaklaşım, bakım verimliliğini artırma ve silt birikiminden kaynaklanan sistem arızası riskini azaltma potansiyeline sahiptir. Ancak, modelin performansını simüle edilmiş sistemler yerine gerçek atıksu toplama sistemlerinde doğrulamak için daha fazla araştırma gerekmektedir.

Anahtar kelimeler: *Atıksu Toplama Sistemi Modellemesi, Yapay Zeka, Katı Madde Birikimi, Convolutional Neural Network.*

GİRİŞ

Atık su toplama sistemlerinde katı atık birikimi, bu altyapıların işlevselliğini önemli ölçüde aksatan süreğen bir zorluk olmaya devam etmektedir (Türk vd., 2022; Ebtehaj vd., 2015). Alüvyon ve evsel diğer katı atıklar tıkanmalara neden olabilir ve akış kapasitesini azaltarak, Sağlıksız Ayrık Atıksu Kanal Taşmaları (SSO'lar) ve Birleşik Atıksu Kanal Taşmaları (CSO'lar) riskini artırabilir. Bu taşkın olayları, sel baskınlarına ve zararlı patojenlerle su kaynaklarının kirlenmesine neden olarak halk sağlığı için ciddi tehditler oluşturur (Muttil vd., 2023; Li vd., 2010). Hızlı şehir nüfusu artışı ve iklim değişikliği nedeniyle artan aşırı hava olayları sıklığı bu riskleri daha da artırarak, katı atık birikiminin proaktif yönetimi ihtiyacını acil hale getirir (Berggren vd., 2012; Semadeni-Davies vd., 2008).

Katı atık birikiminin tespiti için geleneksel yöntemler, örneğin Manning'in grafiği, sınırlı içgörüler sunar çünkü bu yöntemler manuel yorumlama ve mühendislik yargısına bağlıdır (Vitorino vd., 2014; Ebtehaj vd., 2015). Kanal tıkanıklıklarını otomatik olarak tespit etmek için gerçek zamanlı sensörlerin

kullanılması konusundaki güncel çalışmalar sadece derinlik sensörlerine dayanır (Faris vd., 2024; Li vd., 2023), bu da tam boru akışını tıkanıklık olarak yanlış yorumlayabilir. Dolayısıyla, Manning'in grafiğinde hem derinlik hem de hız değişkenlerinin etkili bir şekilde entegrasyonu, kanal sistemlerinde tıkanıklıkların veya alüvyon birikiminin otomatik tespiti için henüz uygulanmamıştır.

Manning denklemi (1) (Manning R., 1891) kanalın pürüzlülüğü, eğimi ve hidrolik yarıçapına göre su akış hızını hesaplar. Bu denklemde, V akış hızı, n Manning'in pürüzlülük katsayısı, R hidrolik yarıçap (akışın kesit alanının ıslak çevreye bölünmesi), ve S kanal yatağının eğimidir. Mühendisler derinlik ve hız dağılım grafiğinin üzerine Manning denklemi ile elde edilen grafiği yerleştirdiğinde, bu atıksu kanalının mansap veya memba tarafındaki sorunları hakkında veya katı madde birikip birikmediği hakkında mühendislik tecrübesi ile çıkarımlar yapabilmektedir (Stevens PL., 1995). Bu çalışma bir mühendisin grafikleri kullandığı gibi yapay zekaya grafikleri kullandırarak mühendislik tecrübesini otomatikleştirmeyi amaçlamaktadır.

$$V = \frac{1}{n} R^{2/3} S^{1/2} \quad (1)$$

Daha verimli ve otomatik tespit yöntemlerine duyulan ciddi ihtiyaçlara rağmen, bu alandaki ilerleme yetersiz kalmıştır (Faris vd., 2024; Li vd., 2023). Dolayısıyla, bu çalışma Katı Atık Birikiminin otomatik tespiti için Yapay Zeka (AI) kullanarak yeni bir yaklaşım sunmaktadır. Veri hazırlamada, Yağmur Suyu Yönetim Model'inden (SWMM) oluşturulan yaklaşık 1,5 milyon model simüle edilerek gerçekte olabilecek koşulları kapsamlı bir şekilde oluşturarak hız ve derinlik verileri elde edilmiştir. Daha sonra bu verilerle elde edilen grafikler kullanılarak Derin Konvolüsyonel Sinir Ağı (CNN) modeli eğitilmiştir.

CNN'ler, video ve resim gibi matris benzeri bir topolojiye sahip verileri işlemek için tasarlanmış uzmanlaşmış derin öğrenme modelleridir. Bu modeller, giriş verilerinden otomatik ve uyarlamalı olarak özniteliklerin mekansal hiyerarşilerini öğrenen birden çok katmanlı konvolüsyonel filtreleri kullanır (LeCun vd., 2015). CNN'lerin geleneksel derin öğrenme modellerine göre önemli bir avantajı, ağırlıkların paylaşımı yoluyla parametrelerin sayısını azaltma yetenekleridir, bu da eğitim verimliliğini artırır ve aşırı öğrenmeyi azaltma olasılığını düşürür (Krizhevsky vd., 2012). Bu özellikler, CNN'leri görüntü ve video tanıma, tıbbi görüntü analizi ve doğal dil işleme gibi çeşitli uygulamalar için uygun hale getirir (Goodfellow vd., 2016). Ayrıca, CNN'ler, atıksu kanal sistemlerindeki robotlar tarafından çekilen görüntülere dayanarak kusurları tespit etmek için kullanılmıştır (Tan vd., 2021; Xie vd., 2019; Guo vd., 2009). Ancak, CNN'ler veya herhangi bir görüntü tanıma yapay zekası alüvyon birikimlerini tespit etmek için hiç kullanılmamıştır. Bu çalışmada, 1,482,000 SWMM modeli oluşturup, ardından bu modellerden 66,679 dağılım grafiği üretip, atık su toplama sistemindeki katı madde seviyelerini tahmin etmek için CNN modelini eğitmekte kullandık.

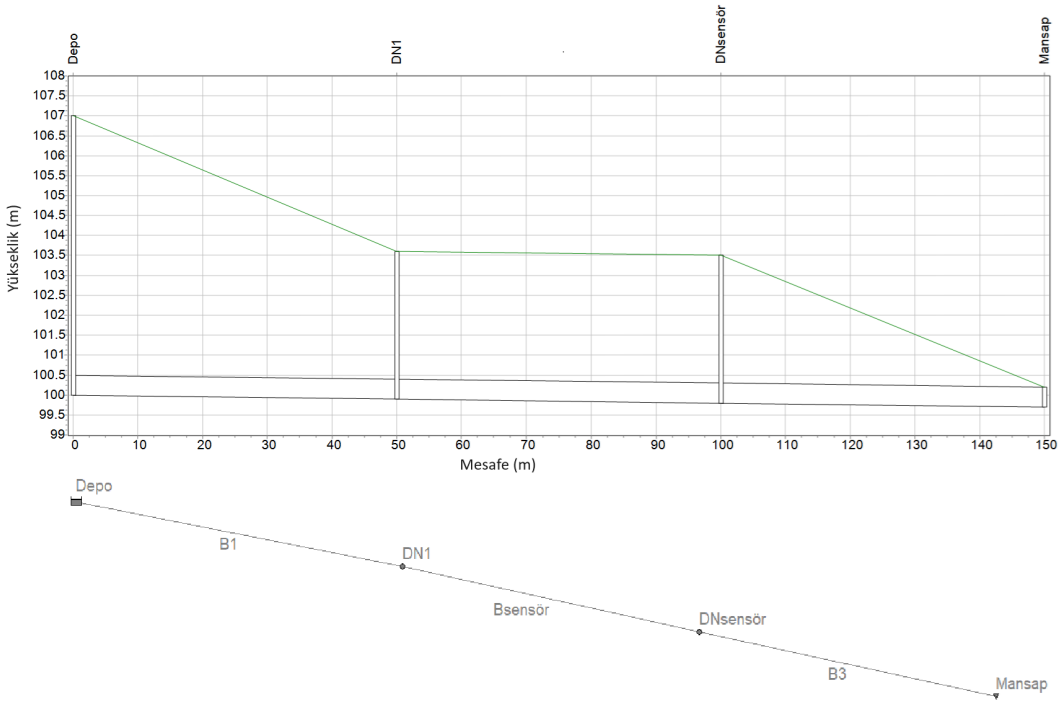
METODLAR

Gerçekte olabilecek bütün koşulları doğru bir şekilde temsil etmek için, bu çalışmada SWMM modeli kullanarak birçok farklı model kombinasyonu oluşturuldu. Bu modeller, kararlı duruma ulaşılıncaya kadar çalıştırıldı ve derinlik ile hız dağılım grafikleri oluşturmak için veriler modellerden alınarak işlendi.

Model Kurulumu ve Yapılandırma:

Şekil 1, kanal tıkanıklığı, katı madde birikimi ve taşınımına odaklanan deneysel çalışmalara (Montes vd., 2020; Vongvisessomjai vd., 2010; Enfinger vd., 2004; Ghani, 1993; Perrusquía, 1992; El-Zaemey vd., 1991) dayanarak hazırlanan SWMM modelinin profil ve genel yapısını göstermektedir. Model, *Bsensor* borusuna memba ve mansap tarafındaki akış koşullarını doğru bir şekilde iletmek için

iki aded ek boru (*B1* ve *B3*) ile tasarlanmıştır. Kanal uzunlukları ve derinlikleri, atıksu toplama ve uzaklaştırma sistemleri hakkında yönetmeliğe göre yapılandırılmıştır. Standart boru uzunluğu 70 metre olarak belirlenmiştir fakat çapları 120 cm'yi aşan boru uzunlukları 100 metre olarak kullanılmıştır. Baca derinlikleri, boru çapına göre ayarlanarak boru üzerinde 2,7 metre olarak standartlaştırılmıştır. Bu çalışmada gerçek koşullarda en çok karşılaşılan daire enkesitli borular kullanılmıştır.



Şekil 1. Genel model profili ve ağı

Model Varyasyonları:

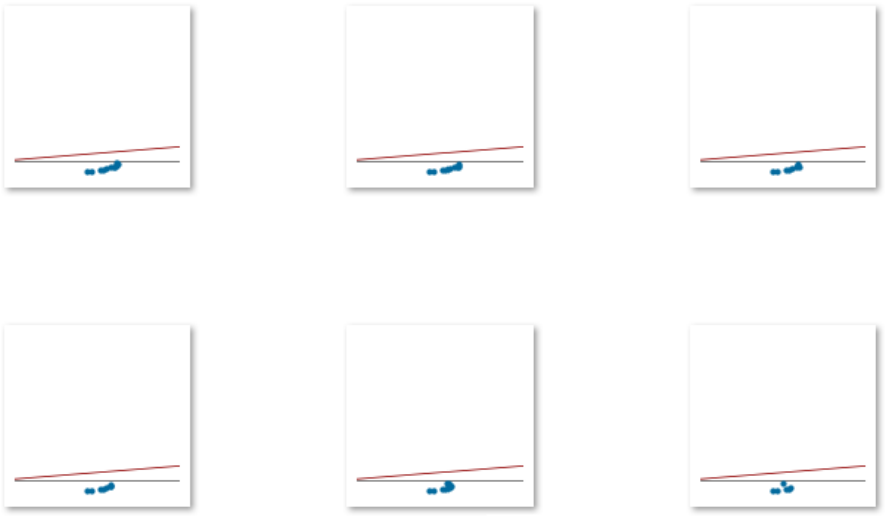
Boru çapı, eğim, memba ve mansap akış koşulları ve katı madde derinlikleri değiştirilerek, toplamda 1.482.000 benzersiz SWMM modeli oluşturuldu. Boru çapları 20 cm'den 200 cm'ye kadar 10 cm artışlarla değiştirildi. Eğim koşulları, yönetmeliğe göre minimum ve maksimum izin verilen eğimler arasında, 10 eşit aralığa dağıtıldı. Memba kısmındaki depo derinlikleri, sensör baca derinliklerine dayanarak oluşturuldu; sensör boru çapına kadar 15 eşit artış ve bir diğer 15 artış da taşkın noktasına kadar devam etti. Mansap kısmındaki akış koşulları için de benzer bir yaklaşım kullanılarak, derinlikler sensör boru çapına kadar 15 eşit artış ve bir diğer 15 artış da taşkın noktasına kadar devam etti. Katı madde derinlikleri, boru çapının yüzdeleri olarak kategorize edildi ve %0'dan %60'a kadar 13 farklı katı madde derinliği belirlendi.

Dağılım Grafiği Verileri Oluşturulması:

SWMM modelleri kararlı duruma ulaştığında, sensör bacasından tek bir kararlı durum hız ve derinlik değeri çıkarıldı. Bu değerler, farklı derinlik koşulları için dağılım grafikleri oluşturmada kullanıldı: sensör boru çapının altındaki derinlikler için *'kuru'*, boru çapının %20 ile %70 arasında olan derinlikler için *'kuru27'* ve tüm koşullar için *'tümü'*.

Şekil 2 ve 3, dağılım grafiklerini göstermektedir. Mavi veri noktaları, memba koşullarının 30 farklı varyasyonunu temsil etmekte olup, model varyasyonları bölümünde tanımlanan diğer tüm değişkenler her grafik için sabittir. Gri çizgiler boru çapını, kırmızı çizgiler ise boru eğimini göstermekte olup, bu durum CNN modelinin katı madde derinliklerini doğru bir şekilde tahmin etmesine yardımcı olmaktadır.

'Kuru' ve *'kuru27'* grafiklerinde (Şekil 2), sensör borusu derinliğinin altındaki derinlik ve hız değerleri gösterilmekte ve sonuç olarak 19.749 *'kuru'* ve 15.803 *'kuru27'* eğitim grafiği elde edilmiştir. *'Tümü'* koşul grafiklerinde ise 30 adet memba koşullarının hepsi yer almakta olup (30 adet mavi veri noktası), 46.930 grafik elde edilmiştir. *'Kuru'* ve *'kuru27'* koşullarındaki grafiklerde derinlik aralıkları -0,1 ila 3 metre ve hız aralıkları -3 ila 5 m/s arasında gösterilirken, *'tümü'* koşullarındaki grafiklerde derinlik aralıkları -0,1 ila 5 metre ve hız aralıkları -6 ila 8 m/s arasında gösterilmektedir.



Şekil 2. Boru çapının altındaki su seviyeleri için derinlik ve hız grafikleri



Şekil 3. Derinlik ve hız grafikleri

CNN Model Eğitimi:

Python tensorflow kütüphanesi (raschka, 2019) kullanılarak derin CNN modelleri geliştirildi. Eğitim sürecinde benzer özelliklerin aşırı temsilini önlemek için her 11. görüntü test, her 41. görüntü

doğrulama ve kalan görüntüler eğitim için ayrıldı. Toplam 82.482 grafik bölünerek, 73.155 eğitim, 7.498 test ve 1.829 doğrulama grafiği oluşturuldu.

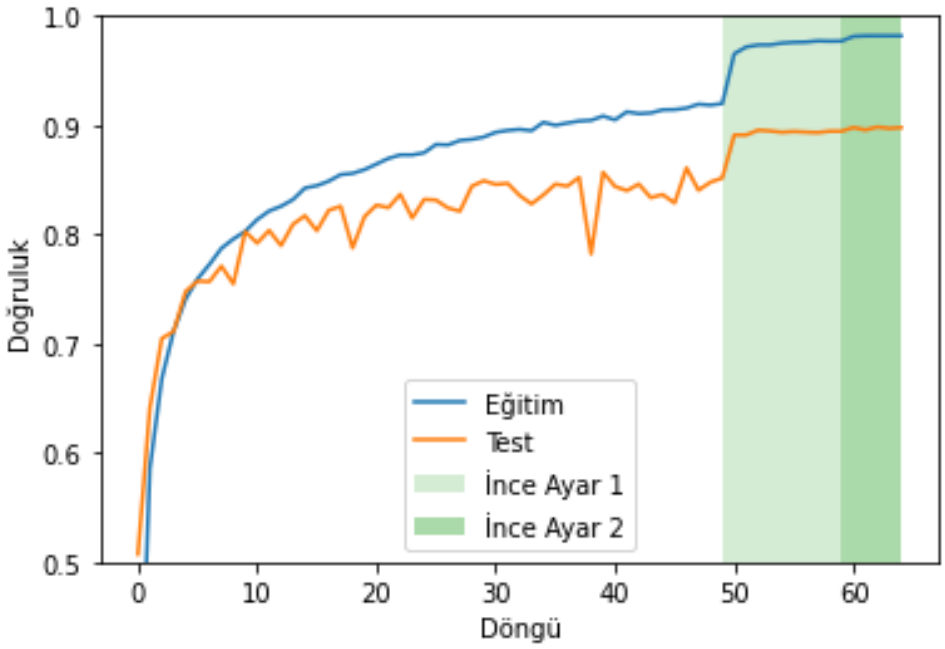
CNN modeli, doğrulama sonuçlarını optimize etmek için başlangıçta 0,001, ardından 0,0001 ve son olarak 0,00001 öğrenme hızı ile iteratif olarak eğitim ve test grafikleri kullanılarak eğitildi. Çapraz-entropy kayıp fonksiyonu boru boyutunun %0 ila %60'ı arasında değişen 13 katı madde derinliğini sınıflandırmak için kullanıldı. Bu yöntem modelin çıktılarını gerçek sınıf etiketleriyle yakından eşleşmesini sağlayarak hataları cezalandıran bir yöntemdir ve fonksiyon değeri düştükçe CNN modelin tahmin yeteneği gelişir (goodfellow ve diğerleri, 2016).

Metodik ve kapsamlı veri üretim süreci, CNN modelinin atık su toplama sistemlerindeki katı madde birikimini doğru bir şekilde tespit etmesi ve miktarını belirlemesi için iyi bir şekilde eğitilmesini sağladı.

SONUÇLAR

Eğitim ve Test Performansı:

Şekil 4, CNN modelinin eğitim ve test doğruluğu geçmişini göstermektedir. İlk 50 döngü, 0.001 öğrenme hızıyla eğitim ve test doğruluğunu göstermektedir. Bunu, 0.0001 öğrenme hızıyla yapılan ilk ince ayar (açık yeşil ile vurgulanmış 10 döngü) ve 0.00001 öğrenme hızıyla yapılan ikinci ince ayar (daha koyu yeşil ile vurgulanmış son 5 döngü) aşaması izlemektedir. Doğruluk artışı, ilk eğitim aşamasının ilk döngülerinde en belirgin düzeyde gerçekleşmiş ve 10 döngü sonrasında önemli ölçüde azalmıştır. Yine ilk ince ayar eğitiminde doğruluk birkaç döngü için hızlı artarken daha sonra doğruluk artışı azalmıştır. Test verileri için doğruluk eğitim boyunca artmış olsa da, eğitim veri doğruluğu seviyelerine ulaşamamıştır.



Şekil 4. CNN model eğitim doğruluk grafiği

Doğrulama Performansı:

Tablo 1, eğitim sürecinde kullanılmayan doğrulama grafikleri için CNN modelin tahmin doğruluğunu sunmaktadır. Daha düşük Çapraz-Entropy Kayıp değerleri, tahmin edilen ve gerçek değerler arasındaki daha iyi bir uyumu gösterirken; 1'e yakın bir Doğruluk değeri, CNN modelinin katı madde derinliği öngörme doğruluğunun daha yüksek olduğunu ifade eder.

Tablo 1. Doğrulama verileri ile CNN modelin tahmin etme yeteneği

Eğitim	Çapraz-Entropy	Doğrulama
Ana Eğitim	0.559	0.845
Birinci İnce Ayar	0.488	0.884
İkinci İnce Ayar	0.486	0.891

Tablo 1'deki sonuçlar, CNN model doğruluğunun Şekil 4'te gösterilen test sonuçlarıyla kıyaslanabilir olduğunu göstermektedir, bu da eğitim, test ve doğrulama verileri arasında iyi bir ayrım olduğunu işaret etmektedir.

Doğrulama Analizi:

İkinci ince ayar yapılmış CNN modeli, silt derinliğini tahmin etmek için 1.829 doğrulama grafiğinde test edilmiştir ve sonuçlar aşağıdaki gibidir:

- Katı madde derinlikleri, doğrulama grafiklerinin 1.810'unda %10 doğruluk aralığında (örn. doğru silt derinliği 1 cm ise, 0,9 ve 1,1 cm arasındaki değerler doğru kabul edilir) doğru bir şekilde hesaplanmış olup, bu da CNN modelin katı madde derinliğini %99 doğrulukla doğru bir şekilde tanımladığını göstermektedir.
- Doğruluk aralığı %5'e indirildiğinde (örn. doğru silt derinliği 1 cm ise, 0,95 ve 1,05 cm arasındaki değerler doğru kabul edilir), CNN modeli 1.793 doğrulama grafiği için silt derinliklerini doğru bir şekilde tanımlamış olup, %98 doğruluk ile tahmin yapabilmektedir.
- Herhangi bir doğruluk aralığı olmadan (örn. sadece tam olarak 1cm katı madde derinliği doğru kabul edilir), CNN modeli 1.546 doğrulama grafiği için silt derinliklerini doğru bir şekilde tanımlayarak %85 doğruluk oranında tahmin yapabilmektedir.

Mühendislerin bile bu grafiklere bakarak %10 doğruluk aralığında tahmin yapamayacağını ve pratik karar verme için %10 doğruluk aralığının makul üstü olduğu göz önüne alındığında, CNN modelinin derinlik ve hız grafiklerinden silt derinliklerini tanımlamada %99 doğrulukla başarılı olduğu sonucuna varabiliriz. Ancak, bu sonuçların yalnızca SWMM modeli baz alınarak elde edildiği ve gerçek atıksu sistemlerinden alınan ölçümler ile doğrulanması gerektiği önemle belirtilmektedir.

Bu sonuçlar, CNN modelinin atık su toplama sistemlerindeki silt birikimini tahmin etmede sağlam bir performans sergilediğini göstererek, bu kritik altyapıların bakım ve operasyonel verimliliğini artırmak için umut verici bir araç sunduğunu ortaya koymaktadır.

TEŞEKKÜR

Bu çalışma İnönü Üniversitesi 3284 numaralı Bilimsel Araştırma Projesi kapsamında desteklenmiştir. Bilgisayar ve diğer destekler için teşekkür ediyorum.

REFERANSLAR

Ebtehaj, I., Azimi, H., and Bonakdari, H. (2015). *Numerical analysis of sediment transport in sewer pipe*. International Journal of Engineering, 28(11), 1564-1570.

El-Zaemey, A. K. S. (1991). *Sediment transport over deposited beds in sewers* (Doctoral dissertation, Newcastle University).

Enfinger, K. L., and Kimbrough, H. R. (2004). *Scattergraph principles and practice a comparison of various applications of the manning equation*. In Pipeline Engineering and Construction: What's on the Horizon? (pp. 1-13).

Faris, N., Zayed, T., Aghdam, E., Fares, A., and Alshami, A. (2024). *Real-Time sanitary sewer blockage detection system using IoT*. Measurement, 226, 114146.

Ghani, A. A. (1993). *Sediment transport in sewers* (Doctoral dissertation, Newcastle University).

Goodfellow, I., Bengio, Y., and Courville, A. (2016). *Deep learning*. MIT press.

Guo, W., Soibelman, L., and Garrett Jr, J. H. (2009). *Automated defect detection for sewer pipeline inspection and condition assessment*. Automation in Construction, 18(5), 587-596.

Krizhevsky, A., Sutskever, I., and Hinton, G. E. (2012). *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, 25.

LeCun, Y., Bengio, Y., and Hinton, G. (2015). *Deep learning*. Nature, 521(7553), 436-444.

Li, N., Wang, X., Li, Z., Zhao, F., Nair, A., Zhang, J., and Liu, C. (2023). *Real-time identification and positioning of sewer blockage based on liquid level analysis in rural area*. Processes, 11(1), 161.

Li, T., Tan, Q., and Zhu, S. (2010). *Characteristics of combined sewer overflows in Shanghai and selection of drainage systems*. Water and Environment Journal, 24(1), 74-82.

Manning, R. (1891). *On the Flow of Water in Open Channels and Pipes*. Transactions of the Institution of Civil Engineers of Ireland.

Montes, C., Vanegas, S., Kapelan, Z., Berardi, L., and Saldarriaga, J. (2020). *Non-deposition self-cleansing models for large sewer pipes*. Water Science and Technology, 81(3), 606-621.

Muttil, N., Nasrin, T., and Sharma, A. K. (2023). *Impacts of extreme rainfalls on sewer overflows and WSUD-based mitigation strategies: A review*. Water, 15(3), 429.

Perrusquia, G. S. (1992). *An experimental study on the transport of sediment in sewer pipes with a permanent deposit*. Water Science and Technology, 25(8), 115-122.

Raschka, S., and Mirjalili, V. (2019). *Python machine learning: Machine learning and deep learning with Python, scikit-learn, and TensorFlow* 2. Packt publishing ltd.

Rossman, L. A. (2010). *Storm water management model user's manual, version 5.0*. Cincinnati: National Risk Management Research Laboratory, Office of Research and Development, US Environmental Protection Agency.

Semadeni-Davies, A., Hernebring, C., Svensson, G., and Gustafsson, L. G. (2008). *The impacts of climate change and urbanisation on drainage in Helsingborg, Sweden: Suburban stormwater*. Journal of Hydrology, 350(1-2), 114-125.

Stevens, P. L., & Sands, H. M. (1995). *Sanitary Sewer Overflows Leave Telltale Signs in Depth-Velocity Scattergraphs*. In Seminar Publication–National Conference on Sanitary Sewer Overflows.

Tan, Y., Cai, R., Li, J., Chen, P., and Wang, M. (2021). *Automatic detection of sewer defects based on improved you only look once algorith*m. Automation in Construction, 131, 103912.

Türk T., Kuşkonmaz H., and Karadağlı F. (2022). *Atıksu Toplama Sistemlerindeki İşletme Problemlerinin Tanımlanması*. Uludağ Üniversitesi Mühendislik Fakültesi Dergisi, 27(1), 205-218.

Vitorino, D., Coelho, S. T., Santos, P., Sheets, S., Jurkovac, B., and Amado, C. (2014). *A random forest algorithm applied to condition-based wastewater deterioration modeling and forecasting*. Procedia Engineering, 89, 401-410.

Vongvisessomjai, N., Tingsanchali, T., and Babel, M. S. (2010). *Non-deposition design criteria for sewers with part-full flow*. Urban Water Journal, 7(1), 61-77.

Xie, Q., Li, D., Xu, J., Yu, Z., and Wang, J. (2019). *Automatic detection and classification of sewer defects via hierarchical deep learning*. IEEE Transactions on Automation Science and Engineering, 16(4), 1836-1847.

İHA SYM VERİLERİNİN HİDRODİNAMİK MODELLEMEDEKİ KULLANIMI

Hasan Özdemir[1] Abdullah Akbaş[1]

[1] Bursa Uludağ Üniversitesi, Fen-Edebiyat Fakültesi, Coğrafya Bölümü, Fiziki Coğrafya Anabilim Dalı, Bursa.

e-mail: ozdemirh@uludag.edu.tr, abdullahakbas@uludag.edu.tr

ÖZET

Bu çalışmanın amacı; İnsansız Hava Araçları (İHA) temelli ve metre altı çözünürlükte farklı SYM grid verilerine bağlı olarak, değişen akım periyotlarında (düşük, orta, yüksek – 100, 500 ve 1000 yıllık) taşkın yayılış, derinlik ve hız değişkenliklerini ortaya koymaktır. Bu amaç doğrultusunda çalışma alanı olarak seçilen Ulus (Bartın) ilçe merkezi için temel altlık verileri; DJI Mavic 2 Pro drone ile üretilen 0.1m, 0.5m ve 1m çözünürlüklü SYM verileri, Ulus yerleşmesinde toplanan Ulus üst kolu, Süleyman, Alpı ve Eldeş akarsularının SWAT yağış-akış modeliyle üretilmiş 100, 500 ve 1000 yıllık akımları oluşturmaktadır. Mekânsal çözünürlük değişkenliğini ortaya koyabilmek için sabit Manning n değeri kullanılmış (n=0.035) ve 2 boyutlu LISFLOOD-FP hidrodinamik model çıktılarına bağlı olarak da taşkının yayılış, derinlik ve hızları üretilmiştir. Sonuç olarak 1m'den 0.1m çözünürlüğe model zamanı ve ortalama hesaplama hataları artarken, suyun yayılışı ve alansal dağılışı %0.7 ile 9 arasında azalış göstermiştir. Ancak 0.1m'den 1m'ye olan değişkenlikler çok fazla olmayıp, 0.1m çözünürlükte yapılacak hidrodinamik modellemenin maaliyet ve hata artışından dolayı 0.5 veya 1m çözünürlükte yapılmasının daha uygun olduğu tespit edilmiştir.

Anahtar kelimeler: *İnsansız Hava Aracı (İHA), Hidrodinamik Model, Lisflood-Fp, SYM.*

GİRİŞ

İHA ile üretilen yüksek çözünürlüklü SYM'lerin taşkın çalışmalarındaki kullanımı da oldukça yeni olup her geçen gün yaygınlaşmaktadır (Yalcın, 2018; Karamuz vd., 2020; Muhadi vd., 2020; Annis vd., 2020). Maliyetin LiDAR teknolojisine göre düşüklüğü, kullanım kolaylığı ve esnekliği İHA'ların daha yaygınlaşmasına neden olmaktadır. İHA teknolojileri ile elde edilen SYM verileri her ne kadar daha küçük alanları kapsasa da gerçekleşen taşkınların simülasyonu ve yayılış alanlarının tespiti, yüzeysel akış ölçümleri, su seviyesi tahminleri, yüzey suyu hızının tahmini, taşkınların jeomorfik etkileri ve taşkın tehlike belirlemesi gibi çalışmalarda kullanımı giderek artmaktadır (Abdelkader vd., 2013; Lee vd., 2013; Feng vd., 2015; Leito vd., 2015; Yalcin, 2018; Langhammer ve Vackova, 2018; Koutalakis vd., 2019; Karamuz vd., 2020; Utlu ve Ozdemir, 2020; Yalcin, 2020). Bu çalışmalardan özellikle metre altı çözünürlüklerin kullanıldığı çalışmalarda; Yalçın (2018) Kırşehir merkezde İHA tabanlı 4,85 cm çözünürlüklü SYM temelinde, ancak modellemede 5x5 m ağ üzerinden Hastane Deresinin 50, 100 ve 500 yıllık akımlara ait 2B hidrodinamik modellemelerini gerçekleştirmiştir. Bu akımlara ait taşkın derinlik, hız ve ulaşma zamanı raster verilerini üretmiştir. Bu çalışmanın amacı, İnsansız Hava Araçları (İHA) ile üretilen raster metre altı (0.1m, 0.5m ve 1m) SYM'lerin 100, 500 ve 1000 yıllık farklı taşkın akımları karşısındaki taşkın suyunun yayılış, derinlik ve hız değişkenliği ortaya koymaktır. Taşkın tehlike analizlerinde kullanılan derinlik ve hız bileşenlerinin metre altındaki SYM'ler temelinde gerçekleştirilen 2B hidrodinamik modellerdeki farklılıkları ve bunun model sonuçlarına etkisi bu çalışmada ele alınan konulardır.

VERİ ve YÖNTEM

İHA olarak DJI Mavic 2 Pro, 20MP Hasselblad L1D-20c kameralı drone kullanılmış ve 18-24 Temmuz 2021 tarihleri arasında, 120 m uçuş yüksekliğinde ve %80'lik bindirme ile görüntüler elde edilmiştir. Batarya süresine bağlı olarak 15 parçaya bölümlenen alanda çekimler yapılmış ve toplamda 4479 adet stereo görüntü elde edilmiştir. Konumsal doğruluğu arttırmak için çalışma alanı içerisine eşit şekilde dağıtımı yapılmış olan 23 adet yer kontrol noktası (YKN) kullanılmıştır. Çekilen görüntülerin işlenmesi için