

## Eşdeğer Sirkülasyon Basıncının Yapay Zeka Yöntemleri ile Tespiti ve Performans Karşılaştırması

Murat A. Özbayoğlu <sup>a\*</sup>, Öney Erge <sup>b</sup>, Evren M. Özbayoğlu <sup>c</sup>,

a TOBB Ekonomi ve Teknoloji Üniversitesi, Bilgisayar Mühendisliği Bölümü, Ankara, Türkiye

b University of Texas at Austin, Austin, Texas, USA

c University of Tulsa Oklahoma, Tulsa, Oklahoma, USA

\* İlgili yazar. Tel: +90-312-292 4073;

E-posta adresleri: [mozbayoglu@etu.edu.tr](mailto:mozbayoglu@etu.edu.tr), [oneverge@gmail.com](mailto:oneverge@gmail.com), [evren-ozbayoglu@utulsa.edu](mailto:evren-ozbayoglu@utulsa.edu)

### ÖZ

Sondaj operasyonlarında kuyu dibi basıncının hassas bir şekilde tespiti, operasyonların emniyeti ve operasyonlarla doğrudan ilişkili birtakım mühendislik tasarımları açısından kritik bir öneme sahiptir. Kuyu dibi basıncı, “eşdeğer sirkülasyon yoğunluğu” (equivalent circulating density) değerinin doğru bir şekilde hesaplanması suretiyle tespit edilebilir. Ancak, eşdeğer sirkülasyon yoğunluğu, içiçe borulardaki halkasal yapının geometrik özelliklerine, dizinin kuyu içerisindeki pozisyonuna, dizinin dönüş hızına, akışkanın özelliklerine, dizinin burkulma nedeniyle meydana gelen geometrik değişimine bağlı davranmaktadır. O halde, eşdeğer sirkülasyon yoğunluğunun hassas ve doğru bir şekilde hesaplanabilmesi için yukarıda bahsi geçen unsurların gözönüne alındığı bir model veya yöntem gerekmektedir.

Bu çalışmada, eşdeğer sirkülasyon yoğunluğunu hesaplamak için üç parametrelilik reolojik akışkan modeli temel alınarak; dizinin dönüş hızı, dizinin eksantrik pozisyonu ve dizinin burkulma-bükülme davranışı da dikkate alınarak bir model oluşturulmuştur. Bunun yanında, problemin karmaşıklığı da gözönünde bulundurularak, iki farklı yapay zeka modeli (yapay sinir ağları (neural networks) ve Rastgele Orman (Random Forest) oluşturulmuştur. Böylece, fiziksel ve mekanistik temele dayalı bir modelle, tamamen veriye dayalı iki modeli karşılaştırma imkanı doğmuştur. Ayrıca, literatürde bulunan ve konu ile doğrudan ilgili deneysel sonuçlar derlenmiştir, ki bu verilerin bir kısmı yapay zeka modellerinin “eğitilmesi” (training) amacıyla kullanılmıştır. Deneysel sonuçlar, modellerin performanslarının karşılaştırılması açısından da kritik bir öneme sahiptir.

Yapay Sinir ağları ve Rastgele Orman modelleri, hem verilerin doğrudan kullanılması, hem de boyutsal analiz (dimensional analysis) tekniği ile elde edilen boyutsuz grupların kullanılması yöntemiyle eğitilmiştir, ve her iki yöntem de birbiriyle kıyaslanmıştır. Yapılan analizde, verilerin doğrudan kullanıldığı modeller, boyutsal analiz yöntemi kullanılarak eğitilen modellerden daha iyi performans göstermiştir.

Ayrıca, deneysel sonuçlarla kıyaslandığında, yapay zeka modelleri kullanılarak elde edilen sonuçların, mekanistik model kullanılarak elde edilen sonuçlara göre daha iyi performans gösterdiği saptanmıştır. Son yıllarda veriye dayalı modellerin kullanımının yaygınlaşması, teknolojik gelişmelerin veriye dayalı yöntemlerin daha hızlı ve başarılı şekilde uygulanabilirliğini sağlaması, birçok alanda mekanistik veya analitik modellere kıyasla daha başarılı performans göstermeleri de dikkate alındığında, bu çalışmadan elde edilen sonuçlar da benzer bir yönü işaret etmiştir.

## 1. GİRİŞ

Yapay zeka tabanlı modeller, birçok alanda olduğu gibi çok fazlı akışkanların analizi ve değişik operasyonel şartlarda davranış özelliklerinin tespiti konularında da son zamanlarda yaygın şekilde kullanılmaya başlanmıştır (Tombul ve ark., 2019; Özbayoğlu ve Yüksel, 2011; Özbayoğlu ve ark., 2012; Osgouei ve ark., 2010). Özellikle analitik olarak modellenmesi zor olan problemlerde yapay zeka yaklaşımlarının başarılı sonuçlar verdiği gözlenmiştir. Bu problemlerden biri de sondaj esnasında değişik çevresel şartlarda basınç kaybının tespiti.

Sondaj sırasında basınç kayıpları boruların çap oranı, iç borunun dönüş hızı, sıvı özellikleri ve diğer çeşitli parametrelerden etkilenir. Eksantriklik veya dönme hızı gibi bazı parametrelerin basınç kayıpları üzerindeki etkileri literatürde incelenmiştir (Ergo ve ark., 2015; Escudier ve ark. 2002, Hacıslamoğlu ve Langlinais, 1990; Kelessidis ve ark., 2011). Yine de, halkasal (anüler) basınç kayıplarını etkileyebilecek, daha karmaşık olabilen başka olaylar da vardır. Örneğin, matkap ucunun dönüşü mutlaka kendi eksenini etrafında gerçekleşmez. Matkap ucu döndürüldüğünde, karmaşıklığın artmasına neden olan yanıl bir hareket yapar. Bu, farklı bir basınç profili oluşturur. Başka bir örnek, büyük olasılıkla kuyu boyunca uzanan sondaj dizisinin aksenel pozisyonundan sapması olabilir. Bu durumda, sonuçta meydana gelen basınç kayıplarının, sabit bir sondaj dizisine kıyasla farklı olması beklenir. Bu çalışma ile, bu karmaşıklıkların bazılarında basınç kayıplarını tahmin edip edemeyeceğimizi anlamaya çalıştık. Çeşitli sıvılar, sondaj konfigürasyonları ve dönüş hızları ile yapılan farklı deneylerde fizik, veri güdümlü yaklaşım ve yapay zeka tabanlı modeller kullanılarak analizler yapılmıştır.

Kuyu hidroliğinin detaylı fizik modellemesi, sondaj operasyonundaki akışkan, kaya ve sondaj dizisinin etkileşimlerinden kaynaklı çeşitli dinamik etkiler nedeniyle karmaşıktır. Literatürde bu etkilerin bazılarını açıklayabilen modeller vardır, örnekler bu makalede daha ayrıntılı olarak sunulmaktadır. Ancak, henüz açıklanmayan üç boyutlu uzayda kesinti, kırıntı içeren rotasyonlar gibi bazı dinamik etkiler de olacaktır.

Bu çalışmada, çeşitli modeller (fizik güdümlü modelleme, veri güdümlü, vb.), farklı sondaj dizisinin konfigürasyonları ve hareketlerini içeren kapsamlı deneylerle karşılaştırılmıştır. Bu karşılaştırma, her yaklaşımda basınç kayıplarının ne kadar doğru tahmin edilebileceğini anlamak için yapılır. Fizik güdümlü modelleme ve veri güdümlü yaklaşımların doğruluğu karşılaştırılmış ve bazı avantaj ve dezavantajlar tartışılmıştır. Ayrıca bu makalede, bu fizik ve veri güdümlü modeller veriden öğrenen bir yapay zeka paradigması olan makine öğrenimi (yapay sinir ağları ve rastgele orman) yaklaşımları ile karşılaştırılmıştır. Makine öğrenimi esasen veri güdümlü modelleme olmakla birlikte, bu makalede, makine öğrenimi ve veri güdümlü yöntemler arasında herhangi bir karışıklığı önlemek için her tartışıldığında makine öğrenme yöntemlerinden (yani yapay sinir ağları ve rastgele orman) açıkça bahsedilmektedir.

Yapay zeka modellemesi ve deneylerle karşılaştırma için literatürden üç model seçilmiştir:

(1) Düzeltilmiş dar oluk yaklaşımı (narrow slot approach) (Ahmed ve Miska, 2009; Hacıslamoğlu ve Langlinais, 1990)

(2) Dar oluk yaklaşımı ve Ahmed ve ark. (2010) model birleşimi (Ahmed ve Miska, 2009; Ahmed ve ark., 2010)

(3) Ergo ve ark. model (Ergo ve ark., 2015)

Birinci model (1) dar bir oluk yaklaşımı olarak değerlendirilir ve Hacıslamoğlu ve Langlinais (1990) modeli kullanılarak eksantrik halka için düzeltilir. Ancak, rotasyon veya burkulmanın

etkilerini dikkate almaz. İkinci model (2), yani dar oluk yaklaşımı ile Ahmed ve ark. (2010) geliştirdiği yarı deneysel model, rotasyonun etkisini dahil etmek için birleştirilmiştir, ancak bu model burkulmanın etkisini dikkate almaz. Son model (3), eksantriklik, dönme ve burkulmanın etkisini dikkate alan basitleştirilmiş ve pratik bir modeldir. Modellerin daha fazla detayı referanslarda bulunabilir. Bu çalışmada, bu üç model yapay sinir ağları ve rastgele orman ile karşılaştırılmış ve tüm modelleme yaklaşımları deneysel sonuçlarla karşılaştırılmıştır.

Bu çalışmanın odağı, Yield Power Law (YPL) sıvılarının laminer akışı üzerinedir. YPL, Herschel ve Bulkley (1926) sıvı modeli olarak da bilinir. Gerçek sondaj akışkanının davranışının temsili bir modelidir (Hemphill ve ark. 1993). Bu model aşağıdaki ilişkiye dayanır:

$$\tau = \tau_y + K\dot{\gamma}^m \quad (1)$$

Çalkantılı (turbulent) ve özellikle geçişli akış, basınç kayıplarını tahmin ederken karmaşıklığı artırır. Bu, karmaşık sondaj dizisi konfigürasyonları ve hareketleri dikkate alınarak basınç kayıplarını tahmin etmek için makine öğrenimini kullanmaya çalışan önceki çalışmalardan biri olduğundan, sadece laminer bölge test noktaları dikkate alınmıştır. Laminer bölge, önceki bir çalışmada verilen adımlar kullanılarak belirlenir (Erge ve ark., 2015).

Literatürde, basınç kayıplarını daha iyi tahmin etmek için fizik ve veri güdümlü yaklaşımlar araştırılmış ve son yıllarda makine öğrenimi, yapay zeka yaklaşımları daha yaygın hale gelmiştir. Bazı araştırmacılar kuyu hidroliği kapsamında makine öğrenme tekniklerini uygulamışlardır (Fruhworth ve ark., 2006; Sorgun ve ark., 2014; Özbayoğlu ve Özbayoğlu, 2007; Wang ve Salehi, 2015; Özbayoğlu ve ark., 2018; Osgouei ve ark., 2015; Osgouei ve ark., 2015a, Sorgun ve ark., 2012; Özbayoğlu ve ark., 2010; Özbayoğlu ve Özbayoğlu, 2009). Örneğin, Sorgun ve arkadaşları (2014), iç boru dönüşü olan ve olmayan Newton ve Newton olmayan sıvıların basınç kayıplarını tahmin etmek için destek vektör regresyonunu (SVR) kullanmıştır. SVR tahmini sonuçlarını deneylerle ve hesaplamalı akışkanlar dinamiği yaklaşımının sonuçlarıyla karşılaştırdıklarında elde edilen sonuçlar SVR'nin, özellikle Newton olmayan sıvılarla basınç kayıplarını iyi bir doğrulukla tahmin ettiğini göstermiştir. Pompa basıncının gerçek zamanlı tahmininde Fruhwirth ve ark. (2006) ve Wang ve Salehi (2015) sinir ağı modellemesini kullanmışlardır. Saha verilerini kullanarak modellerini doğrulamışlar ve sonuçların iyi doğruluk verdiğini gözlemlemişler ve kuyu hidroliği üzerindeki makine öğrenimi uygulamasının potansiyelini göstermişlerdir. Özbayoğlu ve Özbayoğlu (2007), bir yapay sinir ağları modeli kullanarak gazlı sondaj sıvıları için akış örüntülerini ve sürtünme basıncı kaybını tahmin etmeye çalışmışlardır. Çeşitli modelleri deney sonuçlarıyla karşılaştırmışlar ve makul doğruluk elde etmişlerdir.

Yukarıda bahsedilen çeşitli araştırmalar göz önüne alındığında, yapay zeka yöntemlerinin sonuçları, deneysel veya saha verileriyle yapılan ölçümlerle iyi bir uyum göstermektedir. Yapay zeka yöntemlerinin uygulanması, endüstride daha yaygın olarak kullanılması için iyi bir potansiyel göstermektedir. Bu çalışmada, iç borunun yapay zeka modelleri ile çeşitli konfigürasyonlarını ve hareketlerini dikkate alarak basınç kayıplarını tahmin ederek bu zor problemi modellemeye çalıştık. Ardından yapay zeka modellerinin sonuçlarını bazı fizik ve veri güdümlü yöntemlerle karşılaştırdık. Bu çalışmanın sonuçlarının endüstrinin kuyulardaki hidroliği daha iyi değerlendirme çabalarına katkıda bulunması beklenmektedir.

## 2 YAPAY ZEKA YÖNTEMLERİ

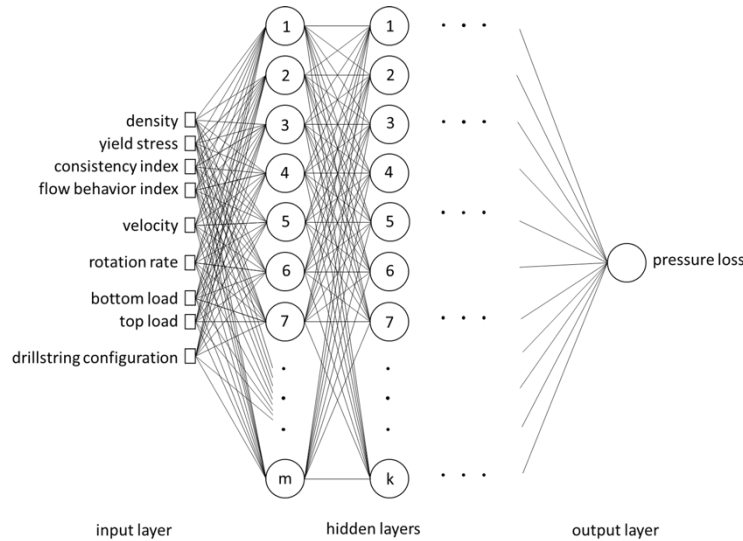
### 2.1 Yapay Sinir Ağları

Yapay sinir ağları petrol mühendisliğinde birçok farklı uygulamada kullanılmıştır. Yapay sinir ağları, verilerin altında yatan işlevsel bir sunumun mevcut olmadığı veya oluşturulması çok zor olan belirli uygulamalar için karmaşık girdi-çıkı ilişkileri oluşturmada çok iyidir. Bu arada, çok katmanlı yapay sinir ağlarının hiyerarşik doğası, her bir katmanda oluşan farklı boyutlar arasında örtük özellik dönüşümleri sağlar. Bu örtük dönüşüm, gradyan inişine dayanan backpropagation adı verilen iyi kurulmuş bir öğrenme algoritmasıyla optimize edilir. İlgilenen kullanıcılar konu ile ilgili daha detaylı bilgiye ilgili referanstan ulaşabilir (Haykin, 2002).

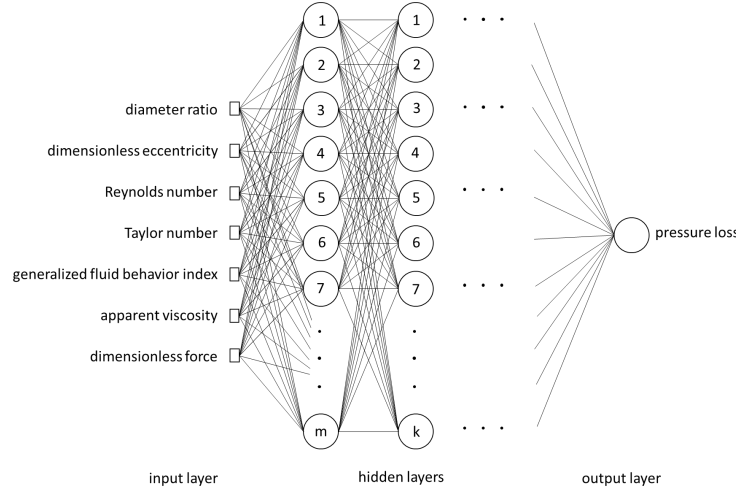
Çeşitli yapay sinir ağları olmasına rağmen, çok katmanlı algılayıcı (MLP) açık arayla, iyi kurulmuş öğrenme algoritması, uygulama kolaylığı ve başarılı genelleme yetenekleri nedeniyle araştırmacılar tarafından en çok tercih edilen yapay sinir ağıdır.

Mevcut çalışmada Yapay Sinir Ağı (YSA) modelimiz için MultiLayer Perceptron (MLP) seçilmiştir. Biri doğrudan girdiler olarak ölçülen parametreleri kullanan diğeri boyutsuz girdiler (ölçülen girdilerden dönüştürülmüş) kullanan iki ayrı model geliştirilmiştir. İlk modelde 9 girdi, ikincisinde 7 girdi bulunmaktadır. Her iki modelde de 20 nöron ve bir çıktı (basınç kaybı) bulunan tek bir gizli katman vardır. Modellerin geliştirilmesi için kullanılan veri setinde ölçülen 1286 veri noktası bulunmaktadır. Veri kümesi rastgele seçilen 5 bölüme ayrılmıştır. 5 kat çapraz validasyon ve test çalışmamızda uyarlanmıştır. Verilerin %60'ı eğitim için, %20'si Çapraz Doğrulama (CV) için ve geri kalan %20'si test için kullanılmaktadır. Eğitim, CV ve test veri dağılımlarının farklı rasgele seçimleri üzerinde çeşitli istatistiksel anlamlılık testleri uygulanmıştır ve karşılık gelen performanslar karşılaştırılmıştır, ancak rastgele veri seti bölümleri arasında anlamlılık testlerindeki istatistiksel farklılıklar gözlenmemiştir.

Bu çalışmada, YSA kullanarak basınç kayıplarını değerlendirmek için iki farklı girdi kullanılmıştır: Ölçüm girdileri ve boyutsuz girdiler. Analiz detayları ve girdi seçiminin sonuçları sonuç ve tartışma bölümünde verilmiştir (bölüm 4.1.1. Yapay Sinir ağları için girdi analizinin sonuçları). Şekil 1 ve Şekil 2'de, yapay sinir ağları sırasıyla ölçüm ve boyutsuz girdilerle gösterilmiştir.



**Şekil 1.** Ölçüm girdilerine sahip yapay sinir ağı: yoğunluk, akma gerilimi, tutarlılık indeksi, akış davranışı indeksi, dönme hızı, alt yük, üstten yük, sondaj dizisi konfigürasyonu: tamamen eksantrik, sinüzoidal burulmuş, geçiş burulmuş, helezonik burulmuş.



**Şekil 2.** Boyutsuz girişlere sahip yapay sinir ağı: boru çapı oranı, boyutsuz eksantriklik, Reynolds sayısı, Taylor sayısı, genelleştirilmiş akış davranış indeksi, görünür viskozite ve boyutsuz kuvvet.

## 2.2 Rastgele Orman

Yaygın olarak tercih edilen bir başka yapay zeka modeli olan Rastgele Orman, bünyesinde birçok Karar Ağacını barındıran bir çoklu veri tahmin modelidir (Breiman, 2001). Rastgele Ormanın nasıl çalıştığının anlaşılabilmesi için öncelikle bir Karar Ağacının çalışma mekanizmasının incelenmesi uygun olacaktır. Karar Ağacı veri kümesinde yer alan verilerin en uygun şekilde sınıflandırılmasını sağlayacak şekilde hiyerarşik olarak özniteliklerin seçilmesi ilkesine dayanır (Özbayoğlu ve Yüksel, 2012). Ağacın girişinde (kök) en önemli ayırıcı özelliğe sahip öznitelik seçilir. En iyi ayırıcılığa ise entropi kullanarak karar verilir. Her öznitelik için belirli bir değerin altı veya üstü seçilecek şekilde sadece tek bir öznitelik kullanılarak sınıflandırma yapılır. Her özneliğin aldığı değerlere bağlı olarak gerçekleştirdiği ayırıcılık (sınıflandırma) ölçülür. En düşük entropi değerine sahip seçim en uygun seçimdir. Yüksek entropi düzensizlik, yani kararsızlık bildirdiği için en düşük entropi en kararlı (en iyi sınıf ayırımını yapan) çözümü işaret eder. Bu ilk ayırimdan sonra alt dallarda veriler aynı yapıyı kullanarak özyineli olarak bölünmeye (sınıflandırılmaya) devam ederler. Ağaç belirli bir yüksekliğe geldiğinde ya da bölünen veriler arasındaki farklılık kabul edilebilir bir seviyenin altına gerilediğinde ağaç dallandırma işlemi sona erer. Rastgele orman bütün verinin rastgele seçilmiş alt kümelerini kullanarak oluşturulan birbirinden farklı ağaçlardan oluşur. Rastgele orman oluşturulduktan sonra karar mekanizması çoğunluk oylaması ile çalışır. Herhangi bir durumda ağaçların çoğunluğunun verdiği karar sistemin kararı olarak değerlendirilir.

### 3. DENEYLER

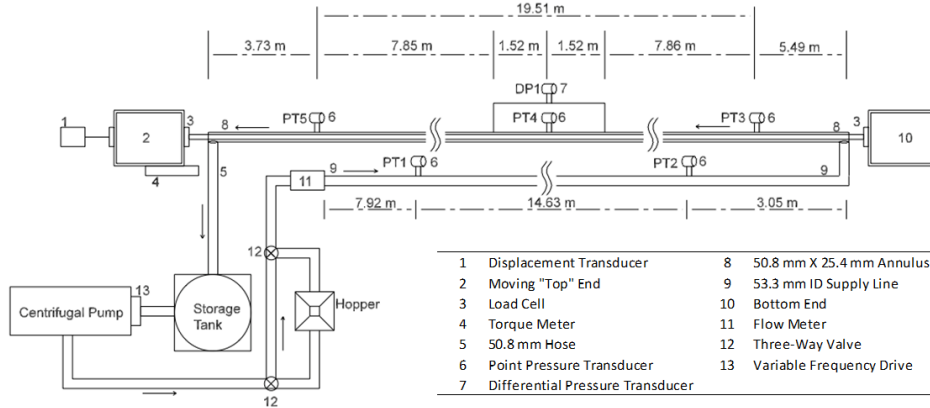
Deneyle daha önce gerçekleştirilen bir çalışmada (Erge ve ark. (2015)) yapılmıştır, bu çalışmadaki analiz için kullanılmıştır. Bu bölüm deneysel yaklaşımı, test sınırlarını ve deneysel tesis özelliklerini özetlemektedir. Ayrıntılı bilgi için lütfen önceki yayına bakınız (Erge ve ark., 2015).

Deney ortamının özellikleri aşağıda verilmiştir:

**Tablo 1. Deney ortamının özellikleri**

Deney Düzenineğinin Özellikleri		İç Borunun Özellikleri	
Toplam tesis uzunluğu	31.70 m	uzunluk	27.74 m
Test bölümünün uzunluğu	27.98 m	Malzeme Türü	304L paslanmaz çelik
Besleme hattının uzunluğu	25.60 m	Dış çap	25.4 mm
Test borusunun malzeme tipi	Acrylic	Kalınlık	0.889 mm
Test borusunun dış çapı	57.15 mm	Havadaki ağırlık	0.423 kg/m
Test borusunun kalınlığı	3.175 mm	Esneklik modülü	$2 \times 10^5$ MPa
Rezervuar tankının hacmi	227 l	Eylemsizlik momenti	$5.15 \times 10^{-8}$ m <sup>4</sup>
Akış hızı aralığı	0-454 lpm		
Devir aralığı	0-120 c/min		

Deney ortamının ayrıntılı bir şeması Şekil 3'te sunulmaktadır.



**Şekil 3. Deney ortamının şematik diyagramı**

Sekiz farklı YPL sıvısı test edilmiştir; test sıvılarının bileşimleri ve sıvı parametreleri Tablo 2'de sunulmaktadır. Test sıvıları için laponit (Laponit RD), ksantan zıncı (XCD) ve polianyonik selüloz (PAC R) katkı maddeleri kullanılmıştır.

Laponit RD, reoloji değiştirici olarak kullanılan renksiz kildir (sodyum magnezyum silikat). Renksiz olma özelliği, iç borunun görüntülenmesine izin vermektedir. XCD uzun zincirli, su bazlı bir polimerdir. PAC R, tatlı su, deniz suyu ve tuzlu su sondaj sıvısı sistemlerinde sıvı kaybını kontrol eden polianyonik selülozdur. Viskozleştirici olarak PAC R de kullanılmaktadır. Bu kil ve

polimer karışımı, YPL sıvıları olarak karakterizasyon için gerekli olan yüksek akma gerilmelerine ve kesme inceltme yeteneklerine sahiptir.

**Table 2. Test sıvılarının bileşimi ve reolojik özellikleri**

Test Sıvısı	Bileşim			Akışkan (sıvı) parametreleri			
	XCD (% by wt.)	PAC R (% by wt.)	Laponite RD (% by wt.)	$\tau_y - Pa$	$K - Pa.s^m$	$m$	$R^2$
YPL1	0.03%	-	0.28%	0.29	0.07	0.55	0.999
YPL2	-	0.03%	1.96%	3.15	1.44	0.37	0.997
YPL3	-	0.03%	2.51%	4.09	2.44	0.33	0.997
YPL4	-	-	2.51%	5.93	1.69	0.35	0.997
YPL5	-	0.06%	1.50%	1.59	0.39	0.51	0.996
YPL6	-	0.03%	1.82%	4.04	0.89	0.39	0.997
YPL7	-	0.03%	2.11%	7.10	1.09	0.40	0.960
YPL8	-	0.08%	2.23%	9.65	3.33	0.31	0.983

#### 4. SONUÇLAR VE TARTIŞMA

Sonuçlar ve tartışmalar üç bölüm halinde sunulmaktadır. İlk kısımda (bölüm 4.1.1.), yapay zeka modellerine (yapay sinir ağları ve rastgele orman) girdi seçiminin bir analizi sunulmaktadır. Halkalardaki akış için girdi olarak doğrudan ölçümlerin veya bazı boyutsuz sayıların kullanılmasının daha iyi olup olmadığını anlamak için yapılmıştır. İkinci kısımda (bölüm 4.1.2.), yedi farklı modelle bir tahmin analizi sunulmaktadır. Sonuçları deneylerin rotasyon ve rotasyon olmayan vakaları (0-120 rpm) içerdiği deneysel verilerle karşılaştırılmıştır. Son kısımda (bölüm 4.1.3.), beş farklı model ile bir tahmin analizi gösterilmiş ve sonuçları deneysel verilerle karşılaştırılmıştır. Bu durumda, deneyler rotasyon, rotasyon olmayan ve farklı iç boru konfigürasyonları ile birlikte düşünülmüştür. Boru konfigürasyonları arasında serbest, sinüsoidal, geçiş ve helezonik burulmuş iç borular bulunmaktadır. Bu konfigürasyonlara, yapılan yükleme deneylerine dayanarak karar verilmiştir. Boru konfigürasyonları ile ilgili daha fazla ayrıntı önceki yayında bulunabilir (Erge ve ark., 2015).

##### 4.1 Yapay Zeka Modelleri için Girdi Analizi Sonuçları

Çeşitli sıvılar, sondaj dizisi konfigürasyonları ve dönme hızları ile basınç kaybı ölçümlerinin (Erge ve ark. 2015) deneysel verileri analiz edilmiştir. Deneysel veriler ve yapay zeka modelleri tahmini dikkate alınarak iki farklı analiz yapılmıştır. İlk analizde, yapay zeka modellerinin eğitim verileri için doğrudan ölçümler kullanılmıştır. İkinci analizde, yapay zeka modelleri için eğitim verisi olarak boyutsuz parametreler kullanılmıştır. Bu karşılaştırma, doğrudan ölçümlerin veya boyutsuz parametrelerin, bu çalışma için yapay zeka modelleri tahmini girdileri için daha uygun olup olmadığını anlamayı mümkün kılabilir.

Yapay zeka modelleri için ölçüm girdileri şunlardır: hız, yoğunluk, dönme hızı, akma gerilimi, tutarlılık indeksi, akış davranışı indeksi, alt yük, üst yük, sondaj dizisi konfigürasyonu: serbest,

sinüzoidal burulmuş, geçiş burulmuş, helezonik burulmuş. Yapay zeka modellerine girdi olarak kullanılan boyutsuz sayılar şunlardır: çap oranı, boyutsuz eksantriklik, Reynolds sayısı, Taylor sayısı, genelleştirilmiş akış davranış indeksi, görünür viskozite ve boyutsuz kuvvet. Yukarıdaki boyutsuz sayıların açıklamasının çoğu literatürde bulunabilir (Ergе ve ark., 2015). Bazı açıklamalar verilen listenin sırasına göre Ek A'da sunulmaktadır.

Ek A'da açıklanan boyutsuz sayılar, kuyu içi hidroliğin fiziği dikkate alınarak seçilmiştir. Bu boyutsuz sayılar, literatürde annuli'deki basınç kayıplarını öngörmeye yaygın olarak kullanılan boyutsuz sayılardır (Ahmed ve Miska, 2009; Ahmed ve ark., 2010; Ergе ve ark., 2015; Ergе ve Vagarjah ve ark., 2015; Hacıslamoğlu ve Langlinaıs, 1990). Daha iyi sonuçların elde edilip edilemeyeceğini görmek için başka bir boyutsuz sayı kümesinin kullanılabilmesine dikkat edilmelidir. Bu deneysel veri kümesi veya bu çalışma alanı için hangi kümenin en iyi sonuçları vereceğini anlamak için boyutsuz sayıların duyarlılık analizi yapılabilir. Ancak bu, bu çalışma kapsamında değildir. Bu çalışmada, yapay sinir ağına ve rastgele orman modeline girdi olarak ölçümler ve yaygın olarak kullanılan boyutsuz sayı arasında temel bir karşılaştırma yapılmıştır.

Sonuçlar, yapay zeka modellerine girdi olarak ölçümlerin doğrudan kullanılmasının boyutsuz sayıların kullanılmasına kıyasla daha doğru sonuçlar verdiğini göstermiştir. Sonuçlar aşağıdaki bölümlerde sunulmaktadır: Şekil 7, 8, 9, 10 ve 14, 15, 16, 17 ölçümler ve boyutsuzlar yapay zeka modellerine girdi olarak kullanıldığında sonuçlar arasındaki doğruluk farkını açıkça göstermektedir.

Boyutsuz gruplar, yukarı / aşağı ölçeklendirme, mevcut koşullardan bağımsız fiziksel davranışı analiz etme ve hesaplamalar için basitleştirme amaçları dahil olmak üzere birçok nedenden dolayı akışkan akış problemlerini açıklamak için kullanılır. Ancak, boyutsuz grupların uygulanması sırasında bir genelleme ve kategorizasyon süreci de gerçekleşir. Boyutsuz gruplar, belirli bir sonucu, yani basınç düşüşünü tahmin etmek için ampirik veya yarı ampirik korelasyonlarda kullanılırsa, tahmini değerler gerçek (yani ölçülen) değerlerden biraz farklı olma potansiyeline sahiptir, çünkü boyutsuz gruplar zorunlu olarak fiziksel davranışın ayrıntılarını, özellikle laminer akış bölgesinin sonu gibi bir davranış tipinden başka bir tipe geçiş bölgelerinde yansıtmalıdır. Bununla birlikte, ampirik korelasyonlar, hız, kanal boyutları, sıvı özellikleri, vb. Gibi gerçek giriş verileri kullanılarak doğrudan geliştirilirse, tahmini sonuçlar daha doğru olabilir. Ne yazık ki, bu tür ampirik korelasyonlar sadece benzer boyutlara ve akış koşullarına sahip problemler için başarılı bir şekilde kullanılabilir. Bu nedenle, boyutsuz gruplara dönüştürülmeden gerçek verilerden geliştirilen girdi, şekil 7, 9, 14, 16 ile şekil 8, 10, 15, 17'yi karşılaştırırken daha iyi sonuçlar vermiştir.

#### **4.2 Tamamen Eksantrik Matkapla Farklı Dönüş Oranlarındaki Basınç Kayıplarını Tahmin Etme**

Bu ve bir sonraki bölümde, deneysel verilerle yedi farklı modelin performansı değerlendirilmektedir. Değerlendirmede kullanılan yöntemler aşağıdaki gibidir:

- (1) Düzeltilmiş dar oluk yaklaşımı (Ahmed ve Miska, 2009; Hacıslamoğlu ve Langlinaıs, 1990)
- (2) Dar oluk yaklaşımı ve Ahmed ve ark. (2010) model birleşimi (Ahmed ve Miska, 2009; Ahmed ve ark., 2010)
- (3) Ergе ve ve ark. model (Ergе ve ark., 2015)
- (4) Ölçümleri doğrudan girdi olarak kullanan yapay sinir ağları




(5) Girdi olarak ölçümlerden elde edilen boyutsuz sayıları kullanan yapay sinir ağları

(6) Ölçümleri doğrudan girdi olarak kullanan rastgele orman


(7) Girdi olarak ölçümlerden elde edilen boyutsuz sayıları kullanan rastgele orman

Bu bölümde, delme işlemi tamamen eksantrik bir geometriye yaklaşırken tabana yerleştirilirken farklı dönme hızlarında basınç kaybı değerleri için toplanan veriler dikkate alınarak analiz yapılmıştır. Matkap ucu döndükçe, tamamen eksantrik olmayabilir ve sadece kendi eksenini etrafında dönebilir. Bu oluşum nedeniyle, bu yapılandırma serbest sondaj dizisi konfigürasyonu olarak adlandırılır (Erge ve ark., 2015). İçerideki boru, dönme hızına bağlı olarak, kendi eksenini etrafında veya eksensiz bir şekilde, düzenli veya düzensiz dönebilir (Erge ve ark., 2014). Bu hareket değişimi modelleme karmaşıklığına katkıda bulunur. (1) ve (2) 'de yapılan modelleme çalışmasının serbest sondaj dizisi davranışını hesaba katmadığına dikkat edilmelidir. Bu, diğerlerine göre daha yüksek mutlak hata yüzdesini açıklar.


Bu analizde, çeşitli akışkanlardan ve farklı dönme hızlarından deneylerden 250 veri noktası analiz edilmiştir. Aşağıdaki 7 şekilde ölçülen basınç kayıpları, daha önce özetlenen 7 farklı yöntem dikkate alınarak öngörülen basınç kayıpları ile karşılaştırılmıştır. Grafiklerdeki doğrusal siyah çizgiler % + - 10 hata çizgisini temsil etmektedir.




**Şekil 4.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin (1) Düzeltilmiş dar oluk yaklaşımı ile yapılır (Ahmed ve Miska, 2009; Hacisismoğlu ve Langlinais, 1990)




**Şekil 5.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin (2) Dar oluk yaklaşımı ve Ahmed ve ark. (2010) model birleşimi (Ahmed ve Miska, 2009; Ahmed ve ark., 2010)




**Şekil 6.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin (3) Erge ve ark. model (Ergo ve ark., 2015)




**Şekil 7.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin (4) Sinir ağı ile ölçümleri doğrudan girdi olarak kullanarak yapılır.



**Şekil 8.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin, (5) Ölçümlerden elde edilen boyutsuz sayıları kullanan sinir ağı ile yapılır.



**Şekil 9.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin, (6) Ölçümleri doğrudan girdi olarak kullanan rastgele orman ile yapılır.



**Şekil 10.** Farklı dönüş hızları (0 ila 120 rpm) dikkate alınarak, öngörülen ve ölçülen basınç kaybının karşılaştırılması. Tahmin, (7) Girdi olarak ölçümlerden elde edilen boyutsuz sayıları kullanan rastgele orman ile yapılır.

Aşağıdaki tablo, bu çalışmada açıklanan beş modelle basınç kayıplarının tahmininin doğruluğunu anlamaya yardımcı olabilecek çeşitli tanımlardaki hatayı göstermektedir.

**Tablo 3.** Borunun dönüşünü dikkate alarak basınç kayıplarını tahmin etmek için çeşitli modellerde hata tablosu

Model No.	Hata (H)	Mutlak Hata (MH)	Yüzde Hata (YH)	Mutlak Yüzde Hata (MYH)	RMSE	R <sup>2</sup> (Korelasyon)	İstatistiksel Önem için p değeri (işaret testi)
(1)	-214.29	243.27	-17.19	18.12	327.56	0.86	0.00
(2)	-898.83	901.13	-56.96	57.04	1040.28	0.00	0.00
(3)	52.04	214.77	-1.81	12.98	280.96	0.89	0.01
(4)	-4.08	59.15	-0.83	3.93	96.63	0.99	0.75
(5)	-31.24	280.11	-5.37	17.83	385.55	0.80	0.57
(6)	-5.34	155.97	-0.39	8.92	235.29	0.93	0.09
(7)	87.37	251.64	1.52	15.76	438.22	0.76	0.05

Sonuçlar, yapay sinir ağı modelinin (4) ve rastgele orman modelinin (6) basınç kayıplarını doğru olarak tahmin ettiğini göstermektedir. Bu modelleri takiben Erge ve ark. model (3) mutlak hata yüzdesi yaklaşık %13 ile iyi bir tahmin göstermektedir. Model (1) rotasyonun etkisini dikkate almaz ve yine de yaklaşık %18 mutlak hata yüzdesine sahip tahmin adil görünür. Bununla birlikte, bu hatanın YPL7, YPL8 gibi daha viskoz akışkanlar için önemli ölçüde daha büyük olduğunun altı çizilmelidir.

Önceki bölümde 4.1.1. de belirtildiği gibi, girdi olarak kullanılan ölçümle yapay zeka modelleri, boyutsuz girişlerle olan yapay zeka modellerinden daha iyi performans göstermiştir.

Modelin (2) nispeten düşük performansının nedeni, saha verileri ve deneysel veri farklılıkları olabilir. Modelin (2) katsayıları alan ölçümlerinin veri kümeleri kullanılarak oluşturulur.

#### 4.3. Basınç Kayıplarını Çeşitli Dönüş Hızları ve Sondaj Dizi Konfigürasyonları ile Tahmin Etme


Bu analizde, çeşitli akışkanlardan ve farklı dönme hızlarından elde edilen deneylerden 1036 veri noktası analiz edilmiştir. Aşağıdaki 7 şekilde (şekil 11-17), ölçülen basınç kayıpları, daha önce özetlenen 5 farklı yöntem dikkate alınarak öngörülen basınç kayıpları ile karşılaştırılmıştır.

Şekil 11-17, önceki bölümdeki şekillere (4.1.2.) benzer desenleri göstermektedir. (1) ve (2) 'deki modeller, burkulma konfigürasyonlarını ve burkulmuş ve dönen matkap uçlarını hesaba katmaz. Bu, daha yüksek hata yüzdesini açıklamaktadır. Model (3) ve sinir ağı tahminleri karşılaştırıldığında, sinir ağları basınç kayıplarını tahmin ederken nispeten daha iyi bir doğruluk göstermiştir. Özellikle modelden (4) elde edilen sonuçların sunulduğu şekil 14'de, bazı verilerin farklı burkulma konfigürasyonlarında ve farklı dönme hızlarında toplandığı göz önüne alındığında, sonuçlar önemli ölçüde daha iyi görünür. Bu, belirgin ve karmaşık basınç profilleri oluşturur. Bunu göz önünde bulundursa bile, tahmin, basınç kayıplarını tahmin etmede önemli bir doğruluk göstermektedir (yaklaşık yüzde 6'lık mutlak bir hata ile).


Model (3) 'ün tahmin doğruluğu (1) ve (2) 'nin sonuçlarına kıyasla daha iyi görünmekte ve genel modeli daha iyi yakalamaktadır. Ancak, nispeten büyük olan yaklaşık %62 mutlak yüzde hatası göstermektedir. Bunun nedeni, çok değişkenli regresyon yoluyla, saha uygulamaları için pratik ve ayarlanabilir olması amaçlanan çok basit bir denklemler kümesine inşa edilmesidir. Daha karmaşık

bir modelleme ve daha iyi bir uyum sunulabilir, ancak kullanılabilirliği azaltacak denklemlerin karmaşıklığına katkıda bulunacaktır.


Tam bir fizik modellemesinin, makaslama bağımlı bir akışkanda sıkıştırma boru ile üç boyutlu uzayda boru dönüşü gibi birçok dinamik oluşum göz önüne alındığında karmaşık olabileceğine dikkat edilmelidir. Bu koşullar altında MLP, aşağıdakiler için çok uygundur: dinamik ve karmaşık fiziksel oluşumları dikkate alan bu uygulama, boru sıkıştırma altında döndürüldükten sonra gerçekleşir.




**Şekil 11.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin (1) Düzeltilmiş dar oluk yaklaşımı ile yapılır (Ahmed ve Miska, 2009; Hacıslamoğlu ve Langlinais, 1990)




**Şekil 12.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin (2) Dar oluk yaklaşımı ve Ahmed ve ark. (2010) model birleşimi (Ahmed ve Miska, 2009; Ahmed ve ark., 2010)




**Şekil 13.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin (3) Erge ve ark. model (Ergo ve ark., 2015)



**Şekil 14.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin (4) Sinir ağları ile ölçümleri doğrudan girdi olarak kullanarak yapılır.

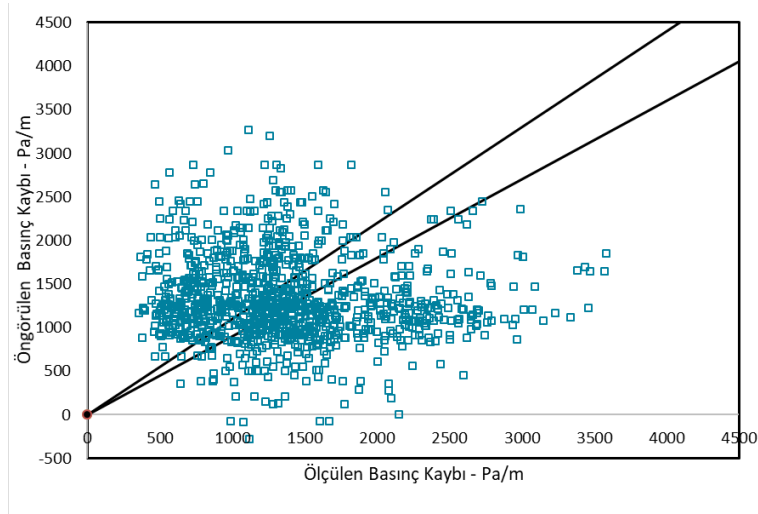


**Şekil 15.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin, (5) Ölçümlerden elde edilen boyutsuz sayıları kullanan sinir ađları ile yapılır.



**Şekil 16.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin, (6) Ölçümleri doğrudan girdi olarak kullanan rastgele orman ile yapılır.





**Şekil 17.** Farklı dönüş hızları ve boru konfigürasyonları göz önünde bulundurularak öngörülen ile ölçülen basınç kaybının karşılaştırılması. Tahmin, (7) Girdi olarak ölçümlerden elde edilen boyutsuz sayıları kullanan rastgele orman ile yapılır.

Aşağıda, bu çalışmada açıklanan beş modelle basınç kayıplarının tahmininin doğruluğunu değerlendirmeye yardımcı olabilecek çeşitli tanımlardaki hatayı özetleyen bir tablo sunulmaktadır.

**Tablo 4.** Borunun dönüşünü ve çeşitli boru konfigürasyonlarını dikkate alarak basınç kayıplarını tahmin etmek için çeşitli modellerde hata tablosu

Model No.	Hata (H)	Mutlak Hata (MH)	Yüzde Hata (YH)	Mutlak Yüzde Hata (MYH)	RMSE	R <sup>2</sup> (Korelasyon)	İstatistiksel Önem için p değeri (işaret testi)
(1)	-385.69	801.76	-56.52	77.33	959.07	0.00	0.00
(2)	-892.02	1135.33	-102.02	114.64	1440.55	0.00	0.00
(3)	-136.75	673.16	-34.46	61.65	818.52	0.00	0.00
(4)	-7.72	68.50	-0.88	5.59	97.39	0.97	0.64
(5)	33.58	509.58	-18.70	45.24	645.52	0.00	0.01
(6)	-8.19	109.07	-0.87	7.86	179.45	0.91	0.20
(7)	40.98	648.19	-20.23	56.67	805.43	0.00	0.93

Yapay sinir ağları ve rastgele orman sonuçları üzerinde yapılan testler sonuçların istatistiksel olarak anlamlı olduğunu göstermiştir. Bu analizde yapay sinir ağları (4), (5) ve rastgele orman (6), (7) modelleri, (1), (2) ve (3) 'te fizik ve ampirik model yaklaşımından daha iyi performans göstermiştir. Yapay zeka modelleri, çeşitli dönüş hızları ve yaklaşık 6 civarında mutlak yüzde olan çeşitli boru konfigürasyonları göz önüne alındığında basınç kayıplarını doğru bir şekilde tahmin etmiştir. Diğer modellerin alt yüzdesi, iç borunun kaotik hareketinin halkada çok farklı basınç profillerine neden olabileceğini göstermektedir.

## 5 ÇIKARIMLAR

Analizin sonuçları, özellikle geometri ve sıvı nispeten daha karmaşık olduğunda, halkadaki basınç kayıplarının daha iyi tahmin edilmesi için sinir ağlarının kullanılma potansiyelini göstermektedir. Sonuçlar yapay zeka yöntemlerinin umut verici bir doğrulukla eşdeğer sirkülasyon yoğunluğu (ECD) yönetimi için kullanılabileceğini göstermektedir.

Literatürdeki modellerin karşılaştırılması ve yapay zeka modellerinin uygulanması bize bir veya daha fazla kullanmanın avantajlarını ve dezavantajlarını göstermiştir. Yapay zeka modellerini kullanmanın bir dezavantajı, verilerden eğitim gerektirmesi ve tahminleri makul bir doğrulukla çıkarmak için yeterli veri biriktirmesi gerekmesidir. Yapay zeka modellerini kullanmanın avantajı, özellikle karmaşık ortamlarda iyi bir doğruluk oranı yakalayabilme potansiyelidir. Nicel bir karşılaştırma örneği olarak: yapay zeka modelleri %6-8 mutlak ortalama yüzde hatası kadar düşük bir sonuç elde ederken mevcut modelleri kullanmak %115 mutlak ortalama yüzde hatası kadar yüksek bir değer ortaya çıkarmıştır.

ECD üzerinde çeşitli etkileyen parametrelere sahip kompleks kuyular için yapay zeka modelleri, ölçümlerden öğrenerek tahmin edebilmek için yararlı olabilir. Bu şekilde, matkap dizisini çeşitli konfigürasyonlarla döndürürken basınç profili, yapay zeka modelleri tarafından yakalanabilir ve modellenebilir.

Ek olarak, girişlerin yapay zeka modellerine optimize edilmesi amacıyla, girdi olarak doğrudan ölçümlerden ve girdi olarak boyutsuz parametrelerden elde edilen sonuçlar arasında bir analiz yapılmıştır. Analiz, yapay zeka modellerinin ölçümlerle bu konunun boyutsuz parametrelerinden ve bu özel deneysel veri kümesinden daha iyi performans gösterdiğini göstermiştir.

Bu çalışma, geleneksel modellerin sondaj işleminde yaygın olarak ortaya çıkan bazı fiziksel şartları (kesimler varlığı, çeşitli sıvı özellikleri, termal etkiler, boru rotasyonu ve yapılandırma efektleri, vb.) tam yansıtamadığı bir ortamda yapay sinir ağları ver rastgele orman gibi yapay zeka modellerinin iyi bir sonuç verebileceğini göstermektedir. Gerçek bir uygulamada, bu yaklaşım yapay zeka modellerinin eğitilebilmesi için yeterli veri toplandıktan sonra uygulanabilir. Eğitim verisi olarak gerçek çalışma ortamını en iyi şekilde yansıtacak temsili veri kullanmak gerekmektedir. Bu da, kuyunun aynı bölümünde delme işlemi sırasında toplanan veriyi kullanılarak veya öğrenmek için belirli bir derinlik aralığındaki hareketli bir pencere kullanılarak yapılabilir. Bu nedenle, sondaj devam ederken eski verilerin süresinin dolması ve mümkün olduğunda yapay zeka modellerinin yeniden eğitilmesi mantıklı olacaktır. Yapay zeka modellerinin yeterince temsili verilerle eğitilmediği zamanlarda geleneksel yöntemleri kullanmak mümkündür ve yapay zeka tahminleri ne zaman yapabilirse, sonuçlar güncellenebilir. Bu çalışma, bu tür sistemlerin potansiyellerini göstermektedir ve bu alanda yapılabilecek gelecekteki bazı çalışmalara işaret etmektedir.

## 6 TEŞEKKÜR

Bu makalenin yazarları, destekleri için Tulsa Üniversitesi Sondaj Araştırma Projeleri, Det norske oljeselskap ASA ve Baker Hughes'a teşekkür ederler. Ayrıca yazarlar Dr. Stefan Miska, Dr. Mengjiao Yu, Dr. Nicholas Takach, Dr. Arild Saasen ve Roland May'a destek ve rehberliklerinden dolayı da teşekkür etmektedirler.

**REFERANSLAR**

- Ahmed, R., Enfis, M., Miftah-El-Kheir, H., Laget, M, and Saasen, A. 2010. The Effect of Drillstring Rotation on Equivalent Circulation Density: Modeling and Analysis of Field Measurements. Paper SPE 135587 presented at the SPE Annual Technical Conference and Exhibition, Florence, Italy, 19–22 September.
- Ahmed, R., Miska, S., 2009. Advanced Wellbore Hydraulics. In: Aadnoy, B., Cooper, I., Miska, S., Mitchell, F., Payne, M.L., 2009. Advanced Drilling and Well Technology. Richardson, TX: Society of Petroleum Engineers. p. 191-220.
- Breiman Leo, 2001, Random Forests, Machine Learning, 45 (5-32)
- Drazin, P.G. and Reid, W.H. 1981. Hydrodynamic Stability. Cambridge University Press, Cambridge.
- Erge, O., Ozbayoglu, E. M., Miska, S. Z., Yu, M., Takach, N., Saasen, A., May, R., 2014. Effect of drillstring deflection and rotary speed on annular frictional pressure losses. Journal of Energy Resources Technology 136 (4), 042909-042909-10, (2014); doi: 10.1115/1.4027565.
- Erge, O., Ozbayoglu, E. M., Miska, S. Z., Yu, M., Takach, N., Saasen, A., May, R., 2015. The effects of drillstring eccentricity, rotation and buckling configurations on annular frictional pressure losses while circulating Yield Power Law Fluids. SPE Drilling & Completion 30 (3), 257-271, SPE-167950-PA; doi: 10.2118/167950-PA.
- Erge, O., Vagarjah, A. K., Ozbayoglu, E. M., van Oort, E., 2015. Frictional pressure loss of drilling fluids in a fully eccentric annulus", Journal of Natural Gas Science and Engineering, 26, 11191129; doi:10.1016/j.jngse.2015.07.030
- Escudier, M. P., Oliveira, P. J., Pinho, F. T., 2002. Fully developed laminar flow of purely viscous non-Newtonian liquids through annuli, including the effects of eccentricity and inner-cylinder rotation. International Journal of Heat and Fluid Flow 23, 52-73.
- Fruhworth, R. K., Thonhauser, G., Mathis, W. 2006. Hybrid Simulation using neural networks to predict drilling hydraulics in real time. Paper SPE 103217 presented at the SPE Annual Technical Conference and Exhibition, 24-27 September, San Antonio, Texas, USA. doi:10.2118/103217-MS.
- Haciislamoglu, M. and Langlinais, J. 1990. Non-Newtonian Flow in Eccentric Annuli. J. Energ. Resour. 112: 163-169. doi:10.1115/1.2905753.
- Haykin, S. 2002. Neural Networks, A Comprehensive Foundation, 2nd ed. Upper Saddle River, NJ: Prentice Hall
- Hemphill, T., Campos W. and Pilehvari A. 1993. Yield-Power Law Model More Accurately Predicts Mud Rheology. Oil & Gas Journal 45.
- Herschel, W. H., Bulkley, R., 1926. Konsistenzmessungen von Gummi-Benzollosungen. Kolloid Z. 39, 291–300.
- Kelessidis, V. C., Dalamarinis, P., Maglione, R., 2011. Experimental study and predictions of pressure losses of fluids modeled as Herschel–Bulkley in concentric and eccentric annuli in laminar, transitional and turbulent flows. Journal of Petroleum Science and Engineering,

- Osgouei, R.E., Özbayoglu, E., Özbayoglu, M. and Yüksel. E., 2015, A new model to determine the two phase drilling Fluid Behaviors through Horizontal Eccentric Annular Geometry, Part B: Frictional Pressure Losses Estimation., Energy Sources, Part A: Recovery, Utilization, and Environmental Effects, Volume 37, Issue 16, pp. 1756-1765
- Osgouei, Reza Ettehad, Ozbayoglu, A. Murat, Ozbayoglu Evren M., Yuksel Ertan, Eresen, Aydin., 2015, Pressure drop estimation in horizontal annuli for liquid–gas 2 phase flow: Comparison of mechanistic models and computational intelligence techniques., Computers & Fluids 112, pp. 108-115
- Osgouei, Reza Ettehad, ME Ozbayoglu, Ozbayoglu, MA, and E Yuksel., 2010, Flow pattern identification of gas-liquid flow through horizontal annular geometries. Paper SPE 129123, SPE oil and gas conference and exhibition, 20-22 January 2010, Mumbai, India.
- Ozbayoglu, M.E., Erge, O. and Ozbayoglu, A.M., 2018, Predicting the pressure losses while the drillstring is buckled and rotating using artificial intelligence methods, Journal of Natural Gas Science & Engineering, volume 56, August 2018, pp. 72-80
- Ozbayoglu, Mehmet, Osgouei, Reza, Ozbayoglu, Murat, and Yuksel, Ertan., 2012, Hole Cleaning Performance of Gasified Drilling Fluids in Horizontal Well Sections., SPE Journal 17.3, pp. 912-923.
- Ozbayoglu, Mehmet Evren, Reza Ettehad Osgouei, Ozbayoglu, Ahmet, Ertan Yuksel., 2010, Estimation of very-difficult-to-identify data for hole cleaning, cuttings transport and pressure drop estimation in directional and horizontal drilling, IADC/SPE Asia Pacific Drilling Technology Conference and Exhibition, 1-3 November, Ho Chi Minh City, Vietnam.
- Ozbayoglu, A Murat and Yuksel, H Ertan., 2012, Analysis of gas–liquid behavior in eccentric horizontal annuli with image processing and artificial intelligence techniques., Journal of Petroleum Science and Engineering 81.1, pp. 31-40.
- Ozbayoglu, A Murat and H Ertan Yuksel., 2011, Estimation of Multiphase Flow Properties using Computational Intelligence Models., Procedia Computer Science, Complex Adaptive Systems, CAS 2011. Vol. 6, pp. 493–498.
- Ozbayoglu, E.M. and Ozbayoglu, M.A., 2009, Estimating flow patterns and frictional pressure losses of two-phase fluids in horizontal wellbores using artificial neural networks., Petroleum Science and Technology 27.2, pp. 135-149.
- Ozbayoglu, M. E., Ozbayoglu, M. A. 2007. Flow pattern and frictional-pressure-loss estimation using neural networks for uhd operations. Paper SPE 108340 presented at IADC/SPE Managed Pressure Drilling and Underbalanced Operations Conference and Exhibition Society of Petroleum Engineers. doi:10.2118/108340-MS.
- Sorgun, Mehmet, Ozbayoglu, Murat, and Evren Ozbayoglu., Estimation of Frictional Pressure Losses in Annulus with Pipe Rotation Using Neural Networks and Computational Fluid Dynamics., 10th International Conference on Advances in Civil Engineering, ACE 2012, Ankara, Turkey.

Sorgun M., Ozbayoglu M.A, Ozbayoglu M. E. 2014. Support vector regression and computational fluid dynamics modeling of newtonian and non-newtonian fluids in annulus with pipe rotation. ASME. J. Energy Resour. Technol. 137 (3) 032901-032901-5. doi:10.1115/1.4028694.

Tombul, H., Ozbayoglu, A.M. and Ozbayoglu, M.E., Computational Intelligence Models for PIV based Particle (Cuttings) Direction and Velocity Estimation in Multi-Phase Flows, Journal of Petroleum Science & Engineering, vol 172, Jan 2019, pp. 547-558.

Wang Y, Salehi S. 2015. Application of real-time field data to optimize drilling hydraulics using neural network approach. ASME. J. Energy Resour. Technol. 137 (6) 062903-062903-9. doi:10.1115/1.4030847.

## 7 TERMINOLOJİ

a, b	geometrik parametreler, m	N:	genelleştirilmiş akış davranış indeksi
D:	çap, m	Q:	akış hızı, m <sup>3</sup> /s
dP/dl:	sürtünme basınç kaybı gradyanı, Pa/m	r, R:	yarıçap, m
dP	sürtünme basınç kaybı, Pa	Re:	Reynolds sayısı
E:	ofset farkı, m	rpm:	dakikada dönme sayısı
f:	sürtünme faktörü	Ta:	Taylor sayısı
h:	oluğun yüksekliği, m	V:	averaj akışkan hızı, m /s
K:	tutarlılık indeksi, Pa · s <sup>m</sup>	w:	oluğun genişliği, m
m:	akış davranış indeksi	x, T <sub>0</sub> :	boyutsuz akma gerilimi

### 7.1 Kullanılan diğer parametreler

τ:	kesme gerilimi, Pa	ρ:	yoğunluk, kg/m <sup>3</sup>
γ:	kesme hızı, 1/s	μ:	viskozite, Pa · s
ε:	boyutsuz eksantriklik	κ:	çap oranı
λ:	geometrik sabit, m	υ:	hız, m /s

### 7.2 Diğer kısaltmalar

app:	apparent (görünür)	i:	inner (içeri)
b:	bulk (kütle)	w:	wall (duvar)
y:	yield (akma gerilimi)	h, H:	hydraulic (hidrolik)
o:	outer (dışarı)	YPL:	Akma gerilimli üslü bağıntı (Yield Power Law)