

ANKARA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

DOĞRU AKIM ÖZDİRENÇ VERİLERİNİN İKİ BOYUTLU TERS
ÇÖZÜMÜNÜN DERİN ÖĞRENME ALGORİTMASI İLE İYİLEŞTİRİLMESİ

Demet ÖVER

JEOFİZİK MÜHENDİSLİĞİ ANABİLİM DALI

ANKARA
2024

Her hakkı saklıdır

ÖZET

Doktora Tezi

DOĞRU AKIM ÖZDİRENÇ VERİLERİNİN İKİ BOYUTLU TERS ÇÖZÜMÜNÜN DERİN ÖĞRENME ALGORİTMASI İLE İYİLEŞTİRİLMESİ

Demet ÖVER

Ankara Üniversitesi
Fen Bilimleri Enstitüsü
Jeofizik Mühendisliği Anabilim Dalı

Danışman: Prof. Dr. M. Emin CANDANSAYAR

Bu tez çalışması, Doğru Akım Özdirenç (DAÖ) verilerinin ters çözüm sonuçlarının iyileştirilmesine odaklanmaktadır. Bu amaçla tez kapsamında iki yeni yaklaşım önerilmiştir. İlk olarak DAÖ verilerinin kademeli iki boyutlu (2B) ters çözümü, ikinci olarak ise DAÖ verilerinin 2B ters çözüm sonuçlarının, evrişimli sinir ağları (CNN) kullanarak iyileştirilmesi önerilmiştir.

Kademeli ters çözümde, önce dipol aralığı, $d=a$ olarak alınmış ve 8 seviye için veri setleri, yüzeye yakın blokların özdirençlerinin belirlenmesi amacıyla kullanılmıştır. Bu veri setinin ters çözümünden elde edilen model, ön kesitim modeli olarak kullanılarak ikinci aşamada $d=2a$ dipol aralığı ve 8 seviye için ölçülen ikinci veri setinin ters çözümü yapılmıştır.

Diğer taraftan, CNN kullanılarak yeni bir ağ oluşturulmuştur. Arkeolojik alanları simüle eden 2B özdirenç modellerinden 1080 veri seti oluşturulmuştur. Hazırlanan modellere %2 rastgele gürültü eklenmiş ve 2B ters çözüm yapılmıştır. 2B ters çözüm sonuçları girdi, karşılık gelen gerçek modeller ise çıktı olarak kullanılmıştır. Bu 1080 girdi ve çıktı veri setleriyle, DCR2D_Net_Archaeo adını verdiğimiz CNN tabanlı ağ arkeolojik alanlarda kullanılmak üzere geliştirilmiştir. Bu ağ öncelikle sentetik veriler kullanılarak test edilmiştir. Daha sonra geliştirilen bu ağ, iki farklı arkeolojik alandan toplanan gerçek verilerle test edilmiştir. Arkeolojik alanlarda toplanan DAÖ verilerinin 2B ters çözüm sonuçlarını iyileştirmek için CNN'in nasıl kullanılabileceği araştırılmıştır. Sentetik veriler ve Türkiye'deki iki arkeolojik alanda ölçülen arazi verileriyle yapılan deneme sonuçları, algoritmanın başarısını göstermiştir.

Temmuz 2024, 38 sayfa

Anahtar Kelimeler: Doğru Akım Özdirenç, Ters Çözüm, Derin Öğrenme, İki-Boyutlu, Arkeojeofizik

ABSTRACT

PhD Thesis

ENHANCEMENT OF DIRECT CURRENT RESISTIVITY DATA TWO DIMENSIONAL INVERSION RESULT USING DEEP LEARNING BASED ALGORITHM

Demet ÖVER

Ankara University
Graduate School of Natural and Applied Sciences
Department of Geophysical Engineering

Supervisor: Prof. Dr. M. Emin CANDANSAYAR

This thesis focuses on improving the inversion results of Direct Current Resistivity (DCR) data. For this purpose, two new approaches within scope of this thesis have been suggested; first, gradual two-dimensional (2D) inversion of DCR data is suggested. Second, improving the 2D inversion results of DCR data using Convolutional Neural Networks (CNN).

In the gradual inversion, the dipole spacing, $d=a$, is initially considered, and datasets for 8 levels are used to resolve the resistivities of near-surface blocks. In the second step, the inversion of the second dataset, measured for $d=2a$ dipole spacing and 8 levels, is performed by using initial resistivity model obtained in the first step inversion. This suggestion is applied in 2D inversion; however, I showed that the result does not improve the accuracy of the model.

The U-net based CNN algorithm, named DCR2D_Net_Archaeo, is developed for archaeological sites using these 1080 datasets. A dataset of 1080 2D resistivity models simulating archaeological sites is generated. Random noise of 2% is added to the prepared models, and 2D inversion is performed. The inverted models are used as input, and the corresponding real models are used as output. The DCR2D_Net_Archaeo algorithm was initially tested with synthetic data. The algorithm was also tested with two field data collected to investigate buried archaeological remains in Türkiye. We showed that the DCR2D_Net_Archaeo algorithm is useful for archeogeophysical surveys.

July 2024, 38 pages

Key Words: Direct Current Resistivity, Inversion, Two-Dimensional, Archaeogeophysics

TEŐEKKÜR

Tezimin her aŐamasında bana bilgi birikimi, tecrübesi ve deęerli zamanıyla rehberlik eden tez danıŐmanım Prof. Dr. Mehmet Emin Candansayar' a iŐtenlikle teŐekkür ederim. Akademik rehberlięi ile tez sürecimde saęladığı destek bu ŐalıŐmanın baŐarıya ulaşmasındaki en önemli etkenlerden biri olmuŐtur.

Bu süreçte, desteklerini esirgemeyen ve her zaman yanımda olan ve biricik aileme teŐekkürlerimi sunarım. Verdikleri moral ve sabır, bu sürecin en zor anlarında bile bana güç olmuŐtur. Sadece bu tez sürecinde deęil, hayatımın her döneminde bana verdikleri destek için onlara minnettarım.

Tez süresince, kademeli 2B ters Őözüm için “Detectsol DCRMT2D” algoritmasını düzenleyen Dr. İsmail Demirci, arazi verilerinin format deęiŐiklięinde yardımcı olan Jeofizik Yüksek Mühendisi Cansu Arıcan' a, tezim konusunda tartıŐma olanağı bulduğum Dr. Yıldırım Gündoędu' ya ve Mustafa Nejafi' ye destek ve katkılarından dolayı teŐekkür ederim. Ayrıca, tez izleme komitesi üyeleri ile tez jürisine de tezim kapsamındaki deęerli katkılarından dolayı teŐekkür ederim.

Bu ŐalıŐma aynı zamanda Ankara Üniversitesi Teknokent Ar-Ge projeleri (STBP kod: 084286) kapsamında yapılmıŐtır.

Demet ÖVER
Ankara, Temmuz 2024

İÇİNDEKİLER

TEZ	ONAYI
ETİK	i
ÖZET	ii
ABSTRACT	iii
TEŞEKKÜR	iv
SİMGELER VE KISALTMALAR DİZİNİ	vi
ŞEKİLLER DİZİNİ	viii
ÇİZELGELER DİZİNİ	ix
1. GİRİŞ	1
2. YÖNTEM	5
2.1 Doğru Akım Özdirenç Yönteminde 2B Modelleme ve Ters Çözüm	5
2.2 DAÖ Verilerinin Kademeli Ters Çözümü	8
2.3 Evrişimli Sinir Ağı ve U-net Mimarisi	9
2.3.1 U-Net mimari tasarımı	9
2.3.2 U-Net temelli CNN algoritma tasarımı	12
2.3.3 Model eğitimi ve optimizasyonu	14
2.4 DCR2D_Net_Archaeo Ağının Geliştirilmesi	15
3. UYGULAMA VE SONUÇLAR	20
3.1 Sentetik Verinin Kademeli Ters Çözümü	20
3.2 Evrişimli Sinir Ağı (CNN)' nda U-net Mimarisi ile Özdirenç Modelinin İyileştirilmesi	24
3.2.1 Yapay veri uygulamaları	24
3.2.2 Arazi verisi uygulaması: Ankara Roma Hamamı	28
3.2.3 Arazi verisi uygulaması 2: Kayseri, Kültepe	30
4. SONUÇLAR	32
KAYNAKLAR	34
ÖZGEÇMİŞ	38

SİMGELER DİZİNİ

d	Dipol aralığı
a	Elektrotlar arası mesafe
∇	İraksama fonksiyonu
σ	İletkenlik
φ	Gerilim
I	Akım
δ	Birim “impuls” fonksiyonu
Δm	Model düzeltme vektörü
N_d	Veri sayısı
N_p	Parametre sayısı
A	Jacobian dizeyi
Δd	Ölçülen ve kurumsal veri farkından oluşan yöney
C	Yuvarlatıcı dizey
W_d	Veri ağırlık dizeyi
α	Düzgünleştirici parametresi
m	Model vektörü
Ω_m	Ohm.m

Kısaltmalar

DAÖ	Doğru Akım Özdirenç
CNN	Evrişimli Sinir Ağı, Convolutional Neural Network
1B	Bir boyutlu
2B	İki Boyutlu
3B	Üç Boyutlu
DCR	Direct Current Resistivity
2D	Two-dimensional
ANN	Yapay Sinir Ağı, Artificial Neural Network

RMS	Root Mean Squares
ReLU	Rectified Linear Unit
MAE	Ortalama Mutlak Hata, Mean Absolute Error
RMSm	Model karekk hata
DD	Dipol-Dipol
PDL	Sol ynl Pol-Dipol
PDR	Saę ynl Pol-Dipol



ŞEKİLLER DİZİNİ

Şekil 2.1 (a) 1B (b) 2B (c) 3B iletkenlik modelleri (Candansayar 1997)	6
Şekil 2.2 128 elektrotlu bir ölçü sisteminde DD dizilimi için dipol aralığı, $d=a$ ve $d=2a$ için veri setleri.	8
Şekil 2.3 U-net mimarisinin genel gösterimi	10
Şekil 2.4 Sigmoid ve ReLU aktivasyon fonksiyonları.....	11
Şekil 2.5 DCR2D_Net_Archaeo ağının tasarımı	14
Şekil 2.6 Arkeolojik alanları temsil eden 2D özdirenç modeli	16
Şekil 2.7 DCR2D_Net_Archaeo algoritmasının geliştirilmesi sırasında her epoktaki eğitim ve doğrulama kaybının ortalama mutlak hatası.....	18
Şekil 2.8 1080 modelden test için ayrılan 84 veri seti içinden rasgele seçilmiş dört model için gerçek model, ters çözüm sonucu ve DCR2D_Net_Archaeo ile elde edilmiş sonuçlar	19
Şekil 3.1 (a) 2B özdirenç modeli, (b) Veri seti-1, $d=1$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (c) Veri seti-2, $d=2$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (d) Veri seti-1 ve Veri seti-2'nin birlikte 2B ters çözüm sonucundan elde edilen model. (e) Veri seti-1'in ters çözüm sonucu ön kestirim kullanılarak elde edilen 2B ters çözüm modeli.....	21
Şekil 3.2 (a) 2B özdirenç modeli, (b) Veri seti-1, $d=1$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (c) Veri seti-2, $d=2$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (d) Veri seti-1 ve Veri seti-2'nin birlikte 2B ters çözüm sonucundan elde edilen model. (e) Veri seti-1'in ters çözüm sonucu ön kestirim kullanılarak elde edilen 2B ters çözüm modeli.....	22
Şekil 3.3 2B özdirenç modellerinin karşılaştırması: Gerçek model (ilk sütun), gerçek modelden elde edilen ters çözüm sonucu (ikinci sütun), DCR2D_Net_Archaeo'dan elde edilen sonuç (üçüncü sütun). Üçüncü sütundaki beyaz dikdörtgen yapıların gerçek sınırlarını göstermektedir	26
Şekil 3.4 Roma dönemine ait hamam ve kazılan duvarın fotoğrafı (Candansayar 2008'den alınmıştır)	29
Şekil 3.5 (a) 2D ters çözüm sonucu ve (b) DCR2D_Net_Archaeo kullanılarak özdirenç modelinin geliştirilmesi. Beyaz dikdörtgen, kazı sonucunda sur duvarının yerini göstermektedir	29
Şekil 3.6 2008'de kazılan duvarın hava fotoğrafı (Kulakoğlu vd. tarafından 2021'de çekilmiştir).....	30
Şekil 3.7 (a) 2D ters çözüm sonucu ve (b) DCR2D_Net_Archaeo kullanılarak elde edilen sonuç. Beyaz dikdörtgen, kazı sonucunda bulunan antik duvarın yerini göstermektedir	30

ÇİZELGELER DİZİNİ

Çizelge 2.1 Tez kapsamında kullanılan CNN algoritmasının parametreleri	13
Çizelge 2.2 Yüksek özdirençli yapının (x- ve z-yönünde) ve I. tabakanın (z-yönünde) özdirenç değişimi ve yapının boyutu	16
Çizelge 3.1 Kademeli ters çözüm sonucu ile geleneksel ters çözüm sonucundan hesaplanan RMSm değerleri	23
Çizelge 3.2 DCR2D_Net_Arhaeo algoritmasını test etmek için kullanılan model parametreleri.....	25
Çizelge 3.3 Çizelge 3.1’de verilen modellerin % misfit değerleri	27



1. GİRİŞ

Jeofizik arařtırmalar, kapsamlı bir süreç içermekte olup veri toplama, veri işlem ve yorumlama aşamalarını içerir. Genelde, uygulamalı jeofizik yöntemlerin veri işlem aşaması tamamlandıktan sonra, verilerin ters çözümü yapılarak elde edilen fiziksel modeller yorumlanır.

Doğru Akım Özdirenç (DAÖ) yöntemi, uygulamalı jeofizikte en yaygın kullanılan yöntemlerden biridir. Yöntem, özellikle çevresel gürültülerden az etkilenmesi, veri toplama ve veri işleme aşamalarının kolay ve ekonomik olması gibi üstünlükleri nedeniyle çeşitli amaçlar için tercih edilmektedir. Son yıllarda, DAÖ yöntemindeki veri toplama ve veri işleme teknikleri büyük gelişme göstermiştir. Bu yöntem, hidrojeofizik arařtırmalarında (Binley ve Kemna, 2005; Soupios vd., 2007; Demirci vd., 2020), maden jeofiziği alanında (Parasnis, 2013; Özyıldırım vd., 2020), alan incelemelerinde (Chambers vd., 2006; Wisén vd., 2008; Gündoğdu vd., 2020) ve arkeojeofizik çalışmalarında (Papadopoulos vd., 2006; Candansayar, 2008; Gündoğdu vd., 2017) çeşitli uygulamalı jeofizik çalışmalarında yaygın bir şekilde kullanılmıştır. Bu çeşitli alanlardaki uygulamalarıyla DAÖ yöntemi, jeofizik arařtırmalarındaki çok yönlü etkinliğini göstermektedir.

1990'lardan itibaren geliştirilen çok elektrotlu ve çok kanallı ölçü sistemleri, kısa bir süre içinde, örneğin bir saat gibi bir sürede, binlerce veriyi ölçme kapasitesine sahiptir (Candansayar 2008). Bu teknolojik ilerlemeler, veri toplama sürecini hızlandırarak jeofizik arařtırmalarda daha etkili ve verimli çalışmaları mümkün kılmıştır. DAÖ verileri günümüzde genellikle bir doğrultu üzerinde sondaj-profil ölçüsü şeklinde toplanarak 2B ters çözüm (Sasaki 1989; Candansayar 2008; Demirci vd. 2012) veya paralel doğrultularda sondaj-profil ölçüleri şeklinde toplanarak 3B ters çözüm algoritmaları (Sasaki 1994; Loke and Barker 1996; Günther et al. 2006; Gündoğdu ve Candansayar 2018) kullanılarak da yorumlanmaktadır.

DAÖ yönteminde, 2B algoritmalar ile sadece ölçü ve derinlik yönünde (x ve z eksenleri) özdirençlerin değiştiği kabul edilir. 3B algoritmalar, gerçeğe en yakın yer altı temsilini

sağlar; burada öz direnç dağılımı her yönde (x, y ve z eksenleri) farklılık gösterir ve genellikle homojen ve izotrop küpler veya tetrahedronlar ile ifade edilir. DAÖ verilerinin 2B ters çözümünde genelde düzenli ağ yapıları tercih edilir (Loke ve Barker 1996a, 1996b). Bu yaklaşımlar, ölçüm verilerini etkili bir şekilde işleyerek yer altı yapısının ayrıntılı ve doğru bir modelini oluşturmak için kullanılır.

DAÖ verilerinin 2B ters çözümünde elektrot diziliminin seçimi ters çözüm sonucunu etkileyen bir faktördür. Candansayar (2008), klasik elektrot dizilimlerinin ayrık ve birleşik 2B ters çözümünü inceleyerek, çok elektrotlu ölçü sistemine uygun dipol-dipol (DD), sol-yönlü (PDL) ve sağ-yönlü pol-dipol (PDR) dizilimleri için ölçülen verilerin birlikte ters çözümünün, klasik elektrot dizilimlerinin ayrı ters çözümünden daha iyi sonuç verdiğini göstermiştir. Çok elektrotlu bir ölçü sistemi kullanılarak N adet elektrot ile " $N_d = Nx(N - 1)x(N - 2)x(N - 3)/8$ " adet farklı akım ve gerilim elektrot çifti için veri toplanabilir (Noel and Xu, 1991). Örneğin, N=100 elektrot için 11.763.675 adet veri ölçülür. Bu, uygulama olarak yeni nesil çok kanallı ölçü sistemleri için bile uzun süre gerektirir.

DAÖ verilerinin 2B ters çözümünde veri seti seçimi için birçok çalışma vardır. Friedel (2003) optimum veri seti ile durağan ve etkili bir ters çözüm seçiminde nelere dikkat edilmesi gerektiğini incelemiştir. Stummer vd. (2004) optimum veri setinin 2B ters çözüme etkisini incelemişler. Wilkinson vd. (2006, 2012) optimum veri setinin otomatik seçimi için öneride bulunmuştur. Nyquist vd. (2007) ise optimum veri seti ile DD veri setinin 2B ters çözümünü karşılaştırmış ve çok az farklılıkla sonuçların neredeyse aynı olduğunu ancak optimum dizilimin daha uzun veri toplama süresi gerektirdiğini göstermişlerdir. Papadopoulos vd (2006, 2011), paralel hatlar boyunca ölçülmüş verilerin 3B ters çözümünü yapan bir algoritma geliştirmişlerdir. Bu algoritmada, Jacobian (duyarlılık) matrisinin güncellenmesi için quasi-Newton yöntemini kullanmışlardır. Ayrıca, geliştirdikleri algoritmayı arkeolojik alanlarda gömülü yapıların tespiti için test etmişlerdir. Bu algoritma ile, veri setlerini farklı yönlerde ölçü olarak ve duyarlılık matrisini güncelleyerek daha hassas ve ayrıntılı sonuçlar elde etmeyi amaçlamışlardır. Alaia ve diğ. (2008b), olasılık tomografisi (probability tomography) algoritmasını 2B

özdirenç modelleri için geliştirmişler ve arkeolojik yapıların sınırlarını, geleneksel ters çözüme göre daha ayrıntılı elde etmişlerdir.

DAÖ verilerinin, diğer jeofizik verilerle birleşik ters çözüm kullanılarak, radiomanyetotellürik ve sismik gibi yöntemlerle birleştirildiğinde DAÖ verilerinin ters çözüm modelinin iyileştirilebildiği ve yapı sınırlarının daha ayrıntılı bir şekilde çözümlenebildiği gözlemlenmiştir. Ancak, arkeolojik yapılar gibi keskin sınırlı yapıları incelediğimizde, yukarıda bahsedilen yaklaşımlar hala yapı sınırlarını net bir şekilde çözememektedir.

DAÖ yönteminde olduğu gibi, diğer tüm jeofizik yöntemlerde de çözünürlük, derinlik arttıkça azalmaktadır. Yanal çözünürlük, elektrot aralığına ve anomalinin büyüklüğüne bağlı olarak değişmektedir. Bu nedenle, DAÖ verilerinin ters çözümü, birçok uygulama için kabul edilebilir olabilir. Ancak, gömülü arkeolojik yapıların keskin sınırları, 2B ters çözüm ile tam anlamıyla çözümlenememektedir.

Son yirmi yılda, Yapay Sinir Ağı (Artificial Neural Network, ANN) algoritmaları da 2B DAÖ veri görüntüleme kullanılmıştır (Neyamadpour vd. 2009; Aleardi vd. 2021). Son birkaç yılda, Evrişimli Sinir Ağı (CNN) tabanlı U-Net mimarisi (Zhang vd. 2021; Liu vd. 2020, 2023; Guo vd. 2023; Hiskiawan vd., 2023) ve SegNet mimarisi (Wilson vd. 2022; Vu ve Jardani 2021; Jia vd. 2022), ANN algoritmasına alternatif olarak 2B/3B görüntüleme kullanılmıştır. Bu algoritmaların çoğunda, gözlemlenen veriler (görünür özdirenç) giriş verisi olarak kullanılırken, 2B özdirenç modelleri ise çıkış verisi olarak kullanılmıştır. (Liu vd. 2020; Aleardi vd. 2021; Jia vd. 2022; Wilson vd. 2022). Bu teknolojik gelişmeler, jeofizik araştırmalarda veri işlemenin ve yorumunun daha etkili ve doğru olmasına katkı sağlayacaktır.

Bu tez çalışması, Doğru Akım Özdirenç (DAÖ) verilerinin 2B ters çözüm sonuçlarını iyileştirmek ve daha etkin sonuçlar elde etmek amacıyla, literatürden farklı olarak iki yeni yaklaşım önerilmiştir. İlk olarak DAÖ verilerinin kademeli ters çözümü; ikinci olarak ise DAÖ verilerinin ters çözüm sonuçlarının U-net mimarisi tabanlı evrişimli sinir ağı (CNN) kullanarak iyileştirilmesi önerilmiştir. Bunun için yeni bir algoritma geliştirmek

hedeflenmiştir. Bu yaklaşım, geleneksel yöntemler ile CNN algoritmalarını birleştiren önemli bir adımdır.

Tezin ikinci bölümünde, kullanılan yöntemler ayrıntılı bir şekilde anlatılmıştır. Burada, DAÖ yönteminde 2B modelleme ve ters çözüm, U-net mimarisi ve tez kapsamında geliştirilen yeni mimarinin tasarımı, model eğitimi ve optimizasyonu ile model iyileştirmesi ele alınmıştır.

Tezin özgün bölümlerinden biri olan kademeli ters çözüm üçüncü bölümde yer almaktadır. Kademeli ters çözümde, belirli bir derinliğe kadar bulunan blok öz dirençleri sabit tutularak daha derindeki blok öz dirençlerinin ters çözümü için ölçülmüş veri setinin ters çözümünün sonuçları karşılaştırmalı olarak incelenmiştir. Tez kapsamında CNN tabanlı algoritmalar ile yeni bir algoritma geliştirilmiştir. Bu geliştirilen algoritma, DAÖ ters çözüm sonuçlarını iyileştirmektedir. Bu uygulama ile, arkeolojik alanlarda modellemede doğruluk ve derinlik açısından iyileştirmeler elde etmeyi amaçlamaktadır.

Üçüncü bölümde, arkeolojik alanlarda sıklıkla rastlanan nesnelere temsil eden öz direnç modelleri kullanılarak hem kademeli ters çözüm hem de CNN algoritması için denemeler yapılmıştır. Yapay veri setleri üzerinde gerçekleştirilen kademeli ters çözümün sonuçları ve CNN algoritmasının arkeolojik alan verileri üzerindeki deneme sonuçları irdelenmiştir. Yine aynı bölümde tez kapsamında geliştirilen DC2D_Archaeo_Net algoritmasının başarısı incelenmiştir.

Tezin dördüncü ve son bölümünde ise, elde edilen sonuçlar kapsamlı bir şekilde tartışılmıştır.

Sonuç olarak, DAÖ verilerinin kademeli ters çözümünün ve 2B DAÖ verilerinin ters çözümü sonrasında derin öğrenme tekniklerinin kullanımının potansiyel üstünlüklerini, eksikliklerini ve özellikle arkeolojik alanlarda nasıl uygulanabileceği gösterilmiştir.

2. YÖNTEM


Bu bölümde DAÖ yönteminin 2B modelleme ve ters çözümü, DAÖ verilerinin kademeli ters çözümü ve derin öğrenme teknikleri, özellikle de Evrişimli Sinir Ağı ve U-net mimarisi üzerinde durulmaktadır.

2.1 Doğru Akım Özdirenç Yönteminde 2B Modelleme ve Ters Çözüm

Modelleme, jeofizikte iki önemli durumda karşımıza çıkmaktadır. İlk olarak, "düz çözüm" olarak da bilinen bu süreç, ters çözüm algoritmalarının bir parçasıdır ve belirli bir model için kuramsal verilerin hesaplanmasını ifade eder. Bu, modelin matematiksel bağıntılarını kullanarak, belirli parametreler altında nasıl davranacağını tahmin etmeyi içerir. İkinci olarak, modelleme jeofizikte veri toplama aşamasından önce karşımıza çıkar. Burada amaç, görüntülemek istenen alan için en uygun elektrot dizilimini, aralığını vb. belirleyerek olası bir model yanıtını tahmin etmektir. Bu, arazide yapılacak çalışmaların daha verimli ve hedefe yönelik olmasını sağlar.

Model yanıtı, belirli bir model parametre kümesi için hesaplanan kuramsal verilerdir. Bu, modelin nasıl tepki vereceğini anlamamızı sağlar. Ters çözüm algoritmalarının ilk adımı olan modelleme, kuramsal verilerin ve kısmi türevlerin hesaplanmasında kullanılır.

DAÖ verilerinin bir boyutlu (1B) modellemesinde, araştırılan alanın yatay homojen ve sabit özdirenç tabakalarından oluştuğu ve sadece düşey yönde özdirençlerin değiştiği kabul edilir. 2B modellemede ise, bu özdirenç değerlerinin ölçü doğrultusu (x) ve derinlik (z) yönlerinde değiştiği, ölçü doğrultusuna (y-yönü) dik yönde ise değişmediği kabul edilir. 3B modellemede, her biri içerisinde homojen ve sabit özdirenç değerlerine sahip olan küplerin bir araya gelerek oluşturduğu bir model kullanılır (Şekil 2.1)



Şekil 2.1 (a) 1B (b) 2B (c) 3B iletkenlik modelleri (Candansayar 1997)

DAÖ yönteminde, 1B modelleme oldukça basit bir yapıya sahip olduğundan, belirtiler analitik olarak hesaplanabilir. Bu, matematiksel denklemler kullanılarak doğrudan bir çözüme ulaşılabileceği anlamına gelir. Ancak, 2B ve 3B modellemelerde durum daha karmaşıktır. Bu karmaşıklık nedeniyle, 2B ve 3B modellerin belirtileri analitik olarak hesaplamak genellikle zordur veya mümkün değildir. Bu durumda, sayısal hesaplama yöntemleri kullanılır. DAÖ yönteminde 2B ve 3B düz çözümde sonlu elemanlar veya sonlu farklar sayısal çözüm yöntemleri kullanılır (Candansayar 1997).

DAÖ yönteminde, 2B modellemede eliptik tip kısmi türevli denklem sınıfına giren Poisson denklemi kullanılır. Poisson denkleminin elde edilmesi ayrıntılı olarak Candansayar'ın (1997) çalışmasında anlatılmıştır. 2B Poisson denklemi aşağıdaki bağıntıda verildiği şekildedir.

$$-\nabla \cdot [\sigma(x, z)\nabla\varphi(x, y, z)] = I \cdot \delta(x - x_s) \cdot \delta(y - y_s) \cdot \delta(z - z_s) \quad (2.1)$$

Burada, “ ∇ .” İraksama (divergence) fonksiyonu, σ , iletkenlik (2B veya 3B ortama ait), φ , gerilim, I akım ve δ ise nokta akım kaynağının yerini tanımlamak için kullanılan birim “impuls” fonksiyonudur.

DAÖ yönteminde ters çözüm problemi, kötü koşullu (ill-posed) bir problemdir. Bu, problemi zorlu ve karmaşık kılan üç ana özelliği ifade eder: Durağan olmaması (unstable), doğrusal olmaması (nonlinear) ve çözümünün tek olmaması (non-unique). Bu özellikler, problemi doğrudan ve basit bir şekilde çözmenin mümkün olmadığını gösterir.

Bu nedenlerle, DAÖ verilerinin ters çözümü genellikle yinelemeli bir süreçle gerçekleştirilir. Her yineleme adımında, bir başlangıç modeli alınır ve bu modelin ürettiği teorik veriler ile gerçekte ölçülen veriler arasındaki fark minimize edilmeye çalışılır. Yineleme sırasında elde edilen parametre düzeltme vektörü, önceki yinelemedeki parametre vektörüne eklenerek yeni model parametreleri elde edilir. Bu işlem, belirlenen bir durdurma kriteri sağlanana kadar devam eder.

Ters çözüm algoritması olarak genelde türev tabanlı Tikhonov düzgünleştiricisi (Regularization) yöntemi kullanılmaktadır. Bu yöntem, ters çözümün durağanlığını artırarak ve aşırı uyumu önleyerek problemi daha iyi durumlu hale getirir. Bu yöntemde, her yinelemede aşağıdaki dizey denkleminde model düzeltme vektörü, $\Delta \mathbf{m}$, çözülür.

$$(\mathbf{A}^T \mathbf{W}_d^T \mathbf{W}_d \mathbf{A} + \alpha \mathbf{C}^T \mathbf{C}) \Delta \mathbf{m} = \mathbf{A}^T \mathbf{W}_d^T \mathbf{W}_d \Delta \mathbf{d} \quad (2.2)$$

Veri sayısı, N_d , ve parametre sayısı N_p için bağıntı (2.' de; \mathbf{A} (N_d, N_p) boyutunda Jacobian dizeyi, $\Delta \mathbf{d}$, ($N_d, 1$) boyutunda ölçülen ve kurumsal veri farkından oluşan yöney, \mathbf{C} , (N_p, N_p) boyutunda yuvarlatıcı dizey (Laplacian matrix), \mathbf{W}_d , köşegen elemanları veri standart sapma değerlerinden oluşan (N_d, N_d) boyutunda veri ağırlık dizeyi ve α düzgünleştirici parametresidir.


Ters çözüm algoritmasında, ölçülen ve kuramsal veri uyumunun bir ölçütü olarak, her yinelemede karekök hata (Root Mean Squares -RMS) izleyen eşitlik ile elde edilir

$$RMS = \sqrt{\frac{(\mathbf{W}_d \Delta \mathbf{d})(\mathbf{W}_d \Delta \mathbf{d})^T}{N_d}} \quad (2.3)$$

Ters çözüm adımı, RMS' in 1 değerinin altına düşmesi veya bir önceki adıma göre küçülmemesi durumunda durdurulur.

22 DAÖ Verilerinin Kademeli Ters Çözümü

Bu tez çalışması kapsamında, DAÖ verilerinin ters çözüm sonuçlarının iyileştirilmesi için yeni bir yaklaşım olarak kademeli ters çözüm önerilmiştir. Çok elektrotlu çok kanallı ölçü sistemlerinde Ne-adet elektrot bir doğrultu boyunca dizilir. Burada elektrod aralığı, a için farklı seviyelerde ($n=1,2,\dots,N$) ölçü alınır. Genelde, sinyal genliğinin gürültü seviyesi altına düşmemesi için en büyük seviye sayısı $N \leq 8$ alınır. Daha derinden bilgi almak için aynı elektrot dizilimi için dipol aralığı, $d=2a$ seçilerek tekrar farklı seviyeler ile ölçüler alınır. Aşağıda, Şekil 2.2’ de, $d=a$ ve $2a$ için ve her dipol aralığında $n=1,2,\dots,8$ seviye için gösterilmiştir. Burada $d=2a$ için olan ölçüler daha derinden bilgi vermektedir. Bu veri seti $d=3a, 4a$ vb. içinde çoğaltılabilir.



Şekil 2.2 128 elektrotlu bir ölçü sisteminde DD dizilimi için dipol aralığı, $d=a$ ve $d=2a$ için veri setleri

Kademeli ters çözüm için iki uygulama örneği aşağıda bölüm “3.Sentetik verilerin Kademeli Ters Çözümü” alt başlığında sunulmaktadır.

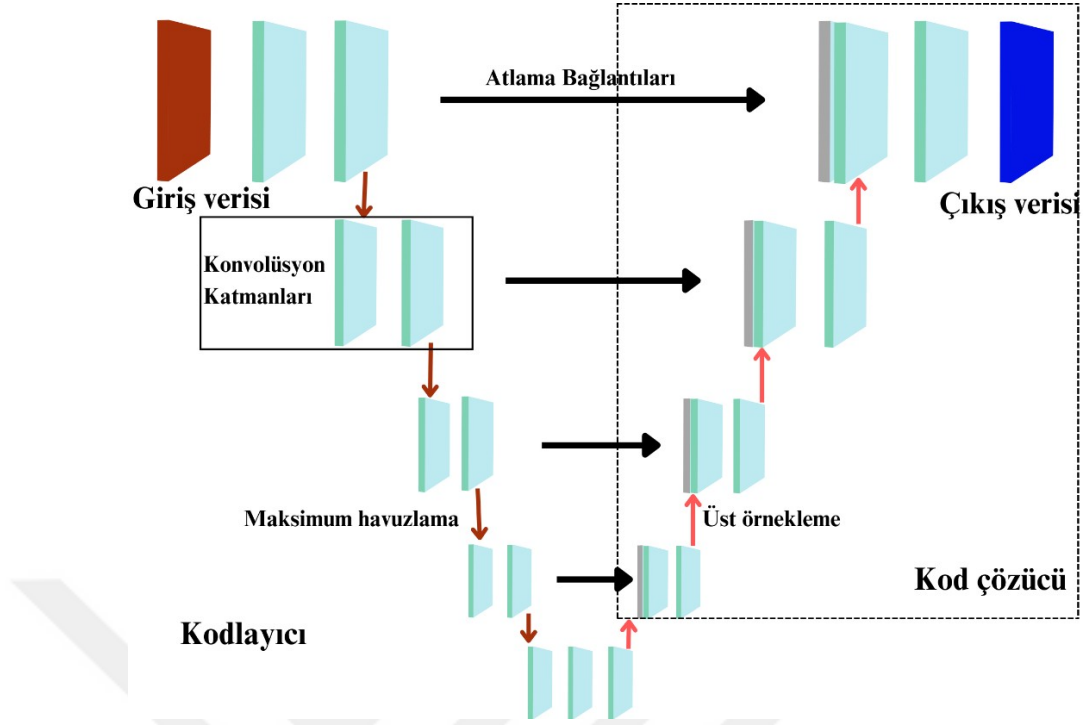
Bu tez kapsamında, keskin sınırlı öz direnç modeli elde edebilmek için, alternatif olarak derin öğrenme tabanlı “Evrişimli Sinir Ağı” kullanarak yeni bir yaklaşım izleyen bölümlerde önerilmiştir.

23 Evriřimli Sinir Ađı ve U-net Mimarisi

Derin öğrenme (deep learning) tabanlı yapay sinir ađları (Artificial Neural Network), görüntü işlemede yaygın olarak kullanılmaktadır. Yapay Sinir Ađları' nın geliştirilmiş formu "Evriřimli Sinir Ađı (Convolutional Neural Network CNN)", son yıllarda jeofizik verilerin ters çözümüne alternatif olarak kullanılmaktadır (örn. Liu vd. 2020; Aleardi vd. 2021; Vu vd 2021; Jia vd. 2022; Wilson vd. 2022). CNN' de son yıllarda U-net temelli mimarinin tasarımı görüntü işlemede çok daha hızlı ve doğru görüntüleme için kullanılmaktadır (Ronneberger vd. 2015). U-net tabanlı CNN algoritmaları DAÖ verilerinin ters çözümüne alternatif olarak son yıllarda kullanılmaya başlamıştır (Zhang vd. 2021; Liu vd. 2023; Hiskiawan vd., 2023; Guo vd. 2023;). İzleyen bölümde U-net mimarisi tanıtılacaktır.

2.3.1 U-Net mimari tasarımı

U-Net mimarisi, ilk olarak Ronneberger vd. (2015) tarafından önerilmiştir. Diğer CNN'lere göre daha az giriş verisi isteyen bu nedenle daha hızlı olan bu mimari pek çok alanda kullanılmaya başlanmıştır. U-net mimarisi Şekil 2.3' de sunulmuştur. Bu mimarinin her bir bölümü aşağıda sırasıyla açıklanmaktadır.



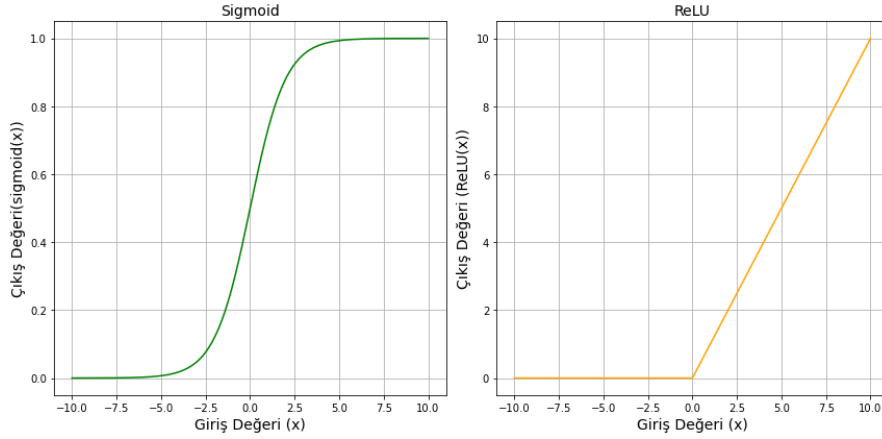
Şekil 2.3 U-net mimarisinin genel gösterimi

U-net mimarisi kodlayıcı (encoder) ve kod çözücü (decoder) olmak üzere iki ana bölümden oluşur (Ronneberger vd., 2015). U-Net modelinin temelinde yer alan kodlayıcı kısmı, giriş görüntüsünün özellik boyutunu giderek küçülterek işler. Giriş katmanı, modelin girdi olarak alacağı veri şeklini tanımlar ve genellikle derin öğrenme modellerinde kullanılan evrişimli sinir ağlarının (CNN) ilk adımıdır.

Evrişim Katmanları, görüntüdeki özellikleri yakalamak üzere tasarlanmış birden fazla evrişimi içerir. Evrişim katmanlarında, ağ ilk olarak girişten düşük seviyeli özellikleri yakalar. Ağın daha derinlerine ilerledikçe, sonraki katmanlar daha karmaşık, yüksek seviyeli özellikleri çıkarmaya odaklanır.

Evrişim işlemi doğrusal bir işlemdir. Aktivasyon fonksiyonlarının amacı modelin doğrusallığını bozmaktır. Ayrıca aktivasyon fonksiyonları tahminlerin doğruluğunu artırır ve normalizasyon işlemini de gerçekleştirir.

Şekil 2.4'deki Sigmoid ve Rectified Linear Unit (Doğrultulmuş lineer birim, (ReLU)) aktivasyon fonksiyonlarını göstermektedir. İki aktivasyon fonksiyonu da CNN'lerde farklı amaçlar için kullanılır ve kendine özgü özelliklere sahiptir.



Şekil 2.4 Sigmoid ve ReLU aktivasyon fonksiyonları

Sigmoid Aktivasyon Fonksiyonu, gerçek sayıları 0 ile 1 arasında bir değere sıkıştırır. Böylece çıktıyı bir olasılık gibi yorumlamak mümkün hale gelir. Bu özelliği sayesinde, özellikle son katmanda kullanılmak için uygundur. Ancak, derin ağlarda gradyanların kaybolmasına (vanishing gradient) neden olabilir. Çünkü fonksiyonun türevi, giriş değerleri çok büyük veya çok küçük olduğunda sıfıra yaklaşır. Aşağıda verilen formül ile hesaplanır.

$$f(x_i) = \frac{1}{1 + e^{-x_i}} \quad (2.2)$$

ReLU Aktivasyon Fonksiyonu, negatif değerler için sıfır çıktı verirken, pozitif değerler için giriş değerini doğrudan verir. Bu özellik, ReLU'nun daha hızlı hesaplanmasını sağlar. Ayrıca, derin ağlarda gradyanların kaybolmasını önleyerek eğitimi hızlandırabilir ve böylece modelin daha hızlı öğrenmesine yardımcı olabilir. ReLU Aktivasyon Fonksiyonu, aşağıdaki matematik ifade ile gösterilebilir.

$$f(x) = \max(0, x) = \begin{cases} x_i, & x_i > 0 \\ 0, & x_i < 0 \end{cases} \quad (2.3)$$

Her iki fonksiyonda CNN'lerde yaygın olarak kullanılmakla birlikte ağ mimarileri için en uygun olanın seçimi önemlidir. Sigmoid genellikle çıkış katmanlarında kullanılırken, ReLU genellikle gizli katmanlarda kullanılır. Bu çalışmada da bu şekilde kullanılmıştır.

Evrişim katmanlarını takip eden, her bir maksimum havuzlama (**max pooling**) katmanı öznelik (feature) haritalarının boyutunu azaltır. Bu, modelin daha genel özellikleri öğrenmesine ve hesaplama yükünü azaltmasına yardımcı olurken, aynı zamanda aşırı uyumu (overfitting) önlemeye yardımcı olur. **Atlama Bağlantıları (Skip Connections, Concat)**, U-Net mimarisinin tanımlayıcı bir özelliğidir. Kodlayıcıdan elde edilen özellik haritaları, kod çözücü sırasında ilgili katmanlarla birleştirilir. Bu bağlantılar, farklı katmanlardan hem düşük seviyeli hem de yüksek seviyeli özellikleri birleştirirler. Böylece ayrıntı kaybını önlemiş olur ve ağı doğru segmentasyon yapmasını sağlar. Kod çözücü, kodlayıcının aksine, görüntünün çözünürlüğünü artırarak, ayrıntılı bir harita oluşturur.

Üst örnekleme (**Upsampling**) ile maksimum havuzlama işlemi ile küçültülmüş öznelik haritaları, özgün boyutlarına geri getirilir. Kod çözücü kısmındaki evrişim katmanları, kodlayıcıda küçültülen ve üst örnekleme ile büyütülen öznelik haritaları, daha küçük ayrıntıları öğrenmek üzere kullanılır. Çıkış katmanı, son evrişim katmanından elde edilen öznelik haritalarını alır ve çıkış haritasını oluşturmak için her bir piksel için bir sınıflandırma gerçekleştirir. Bu sınıflandırma genellikle 1x1 evrişim kullanılarak yapılır.


2.3.2 U-Net temelli CNN algoritma tasarımı

Bu çalışmada, arkeolojik alanlarda kullanılmak üzere U-Net temelli CNN algoritması kullanarak DCR2D_Net_Archaeo isimli yeni bir ağ tasarlanmıştır. Ağ tasarımı Şekil 2.5'te verilmiştir. DCR2D_Net_Archaeo, arkeolojik alanlarda çevresine göre keskin özdirenç sınırlı gömülü duvar oda vb. arkeolojik nesnelerin yerlerinin tespitine yönelik geliştirilmiştir. Bu derin öğrenme ağı geliştirilirken CNN algoritmasında kullanılan temel parametreler Çizelge 2.1'de sunulmuştur.

Çizelge 2.1 Tez kapsamında kullanılan CNN algoritmasının parametreleri

Parametre	Değer
Öğrenme oranı	0.001
Aktivasyon fonksiyonu	ReLU
Küme boyutu	32
Son katmanda kullanılan aktivasyon fonksiyonu	Sigmoid
Optimizasyon algoritması	Adam
Epok sayısı	200
Eğitim veri seti sayısı	900
Doğrulama veri seti sayısı	96
Deneme veri seti sayısı	84

Modelin geliştirilmesi sırasında kullanılan temel parametreler ve bu parametrelerin modelin performansı üzerindeki etkileri ayrıntılı bir şekilde incelenmiştir. Öğrenme oranı (0.001), hata fonksiyonu (loss function), üzerinde optimum noktaya yani kayıp değerinin minimum olduğu noktaya ulaşmaya çalışır. Model öğrenme süreci sırasında, hedef genellikle tahmin hatalarını en aza indirmektir. Bu süreç, çeşitli optimizasyon algoritmaları kullanılarak gerçekleştirilir. Bu algoritmalar arasında “Stochastic Gradient Descent” (Bottou 2010), “Adagrad” (Duchi vd. 2011), “Adam” (Kingma ve Ba 2014) gibi optimizasyon algoritmaları bulunmaktadır. Bu çalışmada hem hızlı hem de etkili bir eğitim süreci için optimizasyon algoritması olarak Adam optimizasyon algoritması seçilmiştir (Kingma ve Ba 2014). Modelin doğrusal olmayan problemleri çözmesi için aktivasyon fonksiyonu olarak ReLU kullanılmıştır. Küme boyutu (Batch size) boyutunun 32 olması, her seferinde veri setinden alınacak örnek sayısını ifade eder. Çıkış katmanında kullanılan Sigmoid aktivasyon fonksiyonu, sonuçların 0 ile 1 arasında sınırlı olmasını sağlar. Son olarak, model 200 epok (epoch) boyunca eğitilmiştir. Ters çözüm sonuçları giriş verisi olarak modeller ise çıkış verisi olarak verilmiştir. Giriş ve çıkıştaki piksel sayıları eşittir.



Şekil 2.5 DCR2D_Net_Archaeo ağının tasarımı

2.3.3 Model eğitimi ve optimizasyonu

Bu tez çalışmasında U-net algoritması için giriş olarak DAÖ verilerinin 2B ters çözümü ve çıkış verisi olarak 2B ters çözümde kullanılan görünür özdirenç veri setinin hesaplandığı 2B özdirenç modeli kullanılmıştır. **Burada veri seti denince U-net mimarisinde giriş ve çıkış olarak kullanılan veri anlaşılmalıdır. Bu iki veri grubu DAÖ yönteminde ters çözümden elde edilen özdirenç modeli ile gerçek modeldir. Düz çözümlerle elde edilen veya arazide ölçülen verilerden elde edilen görünür özdirenç veri seti ile karıştırılmamalıdır.**

Modelin eğitimi ve optimizasyonu için, eğitim (training), doğrulama (validation) ve deneme (test) olmak üzere üç veri setine ihtiyaç vardır. Bu veri setleri, aşağıda açıklanmaktadır.

- Eğitim Veri Seti:** Eğitim (Training) veri seti, modelin öğrenme sürecinde kullanıldığı veri kümesidir. Bu veri seti, modelin temel özelliklerini ve ilişkilerini öğrenmesi için gerekli olan örnekleri içerir. Bu veri seti üzerinde eğitilen modeller belirli görevleri gerçekleştirmek için gerekli ilişkileri tanımaya çalışır. Eğitim veri setinin çeşitliliği ve kalitesi, modelin genel performansı üzerinde önemli bir etkiye sahiptir.

- b. Doğrulama Veri Seti:** Doğrulama (Validation) veri seti, modelin eğitim sürecindeki performansını değerlendirmek için kullanılır. Bu set, modelin eğitim veri setinde öğrendiklerini ne kadar iyi genelleştirebildiğini test etmek amacıyla kullanılır. Doğrulama veri seti, modelin aşırı uyum (overfitting) gibi problemlerini tespit etmekte ve parametre ayarlamalarını yaptığı için önemlidir.
- c. Deneme Veri Seti:** Deneme (Test) veri seti, modelin eğitim ve doğrulama süreçlerinden sonra gerçek performansını değerlendirmek için kullanılır. Bu veri seti, modelin daha önce hiç görmediği verileri içerir ve modelin genelleme yeteneğini ölçmek için önemlidir. Modelin test veri seti üzerindeki başarısı, gerçek arazi koşullarında nasıl performans göstereceğine dair ipuçları verir. Modelin bu set üzerindeki başarısı, genellikle nihai performans ölçütü olarak kabul edilir.

24 DCR2D_Net_Archaeo Ağının Geliştirilmesi

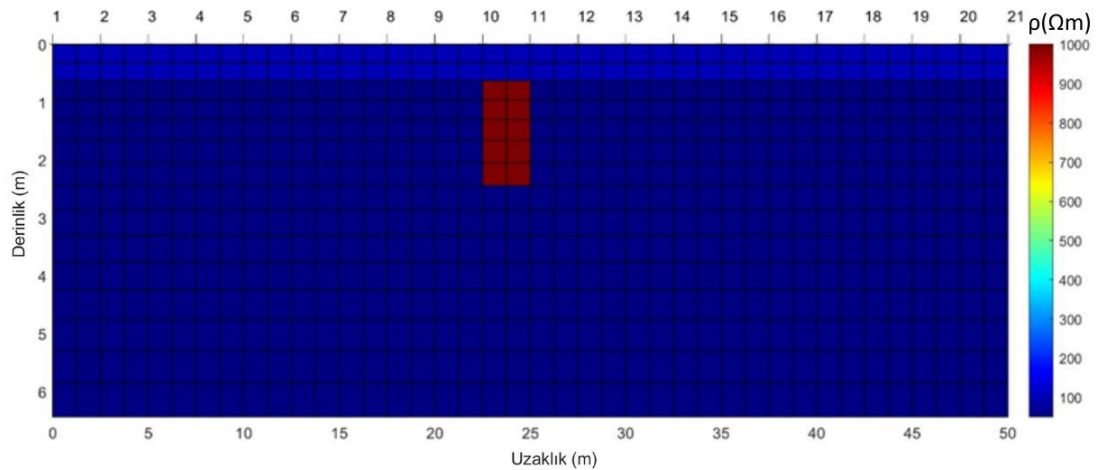
Şekil 2.6'daki model 1080 tane özdirenç modelini oluşturmak için kullanılmıştır. Bu model, Türkiye'deki arkeolojik sahaları genel olarak temsil eden bir modelin 2B kesitidir. Höyük gibi arkeolojik alanlarda, yüzeyde 0.3-1 metre derinliğe kadar olan örtü birimi sıkıştırılmış topraktan oluşmakta ve altındaki temel birime göre özdirenç % 10-50 aralığında daha yüksek olmaktadır. Gömülü duvar veya odanın kesitini gösteren yapıya ise çevresine göre 3-10 kat daha yüksek özdirenç değerleri atanmıştır. Bu genelleme kapsamında Şekil 2.6'daki model oluşturulmuştur. Bu modeldeki yapının konumu, x- ve z-yönünde kalınlığı ve konumu değiştirilmiştir. Ayrıca yapının özdirenç değeri de değiştirilmiştir. Benzer şekilde birinci tabaka özdirenç ve kalınlıkları da değiştirilmiştir. Bu yapıların özdirenç/ derinlik aralıkları Çizelge 2.2'de belirtildiği gibi değiştirilmiştir.

Böylece, rasgele 1080 farklı özdirenç modeli oluşturulmuştur. Bu özdirenç modellerinden, arkeolojik alanlarda yanal ayrımlılığı diğer klasik dizilimlere göre yüksek olan pol-dipol dizilimleri (A-MN, MN-B) ve dipol-dipol dizilimi (AB-NM) (Candansayar 2008) için, 2B düz çözüm ile görünür özdirenç veri setleri hesaplanmıştır. Daha sonra bu verilere %2 rasgele gürültü eklenmiş tüm veriler birlikte kullanılarak 2B ters çözümü yapılmıştır. Tüm ters çözümler 1.3'den küçük karekök hata ($RMS < 1.3$) ile elde edilmiştir. Düz çözüm ve ters çözümde, Candansayar (2008) tarafından geliştirilen programlar

DCR2D_Net_Archaeo ağı için kullanılmıştır. Toplam 1080 model için yapay veri hesaplanması ve bunların ters çözümü 174 dakika (2.9 Saat) CPU süresinde tamamlanmıştır. Böylece 1080 adet 2B ters çözüm sonucu U-net algoritmasında giriş veri seti ve ilgili 1080 adet gerçek 2B özdirenç modeli ise çıkış veri seti olarak elde edilmiştir. Toplam veri setinin bölünmesi, verilerin sayısına ve U-net mimarisine bağlı olarak değişmektedir. Bu çalışmada 1080 veri setinin (giriş ve çıkış çifti) 900' ü eğitim, 96' sı doğrulama ve 84' ü ise test veri seti olarak kullanılmıştır.

Çizelge 2.2 Yüksek özdirençli yapının (x- ve z-yönünde) ve I. tabakanın (z-yönünde) özdirenç değişimi ve yapının boyutu

	Özdirenç Değişim Aralığı (Ωm)	Boyutu (dx, dz) (metre)	1. tabaka için Derinlik değişim, blok için x- ve z-yönünde değişimi aralığı (metre)
I.Tabaka	50-150	-	z- yönünde 0-0.5
II. Tabaka (Temel)	25-75	-	-
Yüksek Özdirençli blok	500-1500	dx=0.5-2 dz=0.5-2	x-yönünde 5-45 z-yönünde 0.5-4



Şekil 2.6 Arkeolojik alanları temsil eden 2D özdirenç modeli

Toplam 900 eğitim veri seti ile Çizelge 2.1'deki değişkenler kullanılarak, DCR2D_Net_Archaeo isimli U-net algoritması elde edilmiştir. Bu algoritma Python

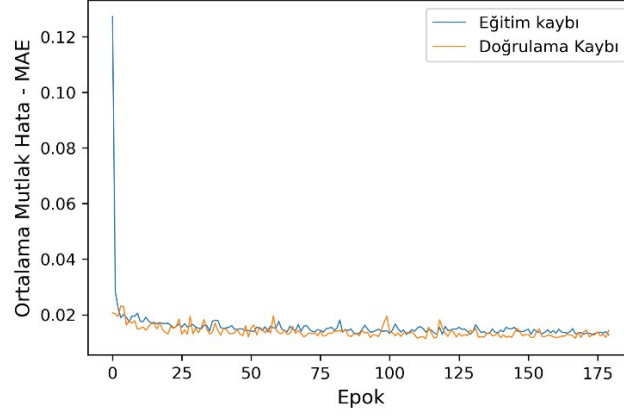
programlama dilinde bulunan ‘‘PyTorch kütüphanesi’’ kullanarak 78 dakikada oluşturulmuştur (<https://pytorch.org/>). Bu çalışmada 1080 veri seti oluşturulmasında ve DCR2D_Net_Archaeo algoritmasının da geliştirilmesinde 48GB RAM ve Intel(R) Core(TM) i7-5930K CPU'ya sahip masaüstü bilgisayar kullanılmıştır. Modelin eğitim aşaması, modele sağlanan giriş-çıkış veri setlerinin öğrenmesi, verileri yorumlama ve analiz etme becerisini sürekli olarak iyileştirmek için tekrarlayan bir optimizasyon işlemidir.

Bu tezde geliştirdiğimiz DCR2D_Net_Archaeo algoritmasının doğrulama aşamasında 96 veri seti kullanılmıştır. Doğrulama adımı, eğitim aşaması sırasında gerçekleşen öğrenmenin etkinliğini ölçmek için bir kontrol görevi görür. Aşırı uyum veya yetersiz uyum gibi potansiyel sorunları tespit etmede önemlidir. Son adımda, 84 veri seti testi için kullanılmıştır. Test aşaması, modelin tarafsız bir değerlendirmesini sağlar. Bu örnekler, eğitim ve doğrulama aşamalarında kullanılanlardan farklıdır. Böylece testin daha önce görülmemiş veriler üzerinde gerçekleştirilmesini sağlar.

Şekil 2.7, eğitim aşaması sırasında, ortalama mutlak hata (Mean Absolute Error- MAE) göz önünde bulundurularak, eğitim ve doğrulama kaybının epoklar boyunca nasıl ilerlediğini göstermektedir. ‘‘Ortalama Mutlak Hata (Mean Absolute Error- MAE)’’ aşağıdaki gibi tanımlanır

$$MAE = \frac{1}{N} \sum_{i=1}^N |M_g(i) - M_y(i)|. \quad (2.6)$$

Burada, $M_g(i)$, i-ninci örneğin gerçek değeri (çıkış verisi), $M_y(i)$ ise i-ninci örneğin (yani tahmini çıkış verisi) model tarafından tahmin edilen değeridir. N veri setindeki örnek sayısı (özdirenç modelleri sayısı/ eğitim veri setindeki örnek sayısını) göstermektedir. Bizim uygulamamızda N=900’ dür. Doğruluk veri setindeki örnek sayısı 96 dır. Epok sayısı arttıkça, her iki kayıp da azalır ve yakınsar. Buda modelin eğitim verilerinden doğrulama verilerine genelleme yeteneğinin geliştiğini gösterir.

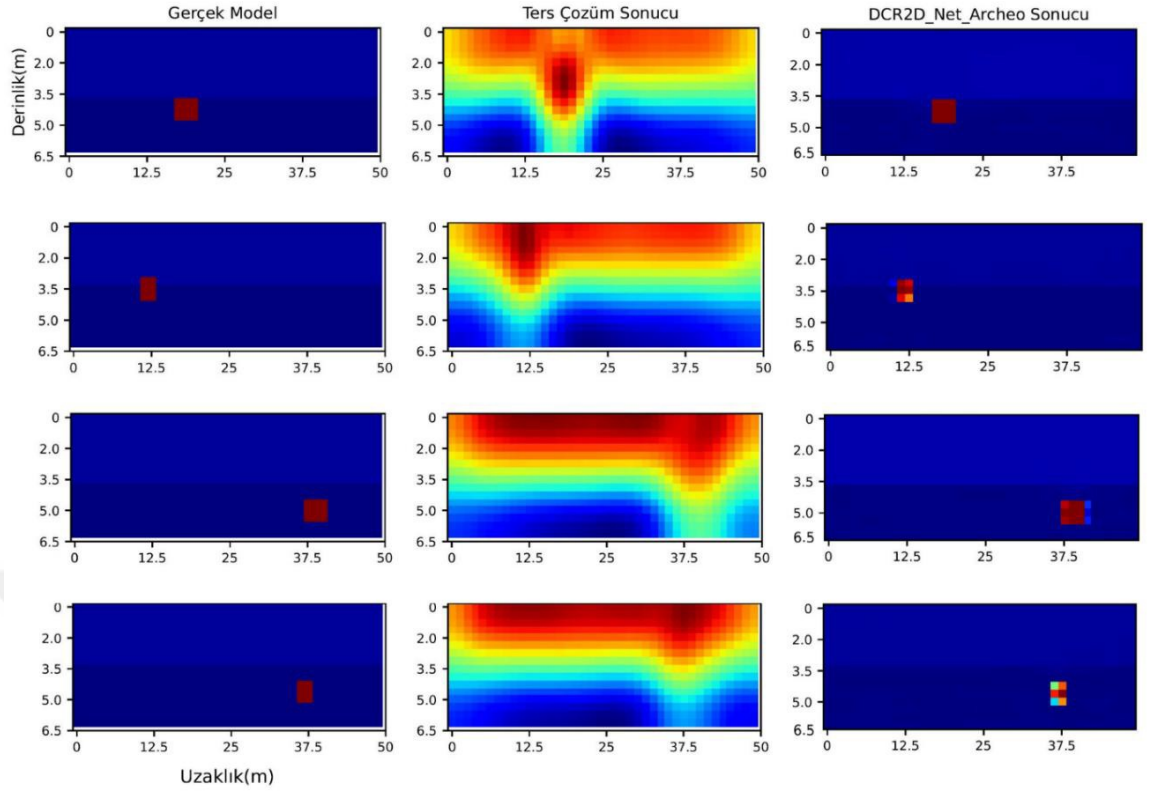


Şekil 2.7 DCR2D_Net_Archaeo algoritmasının geliştirilmesi sırasında her epoktaki eğitim ve doğrulama kaybının ortalama mutlak hatası

DCR2D_Net_Archaeo algoritmasının gelişim sürecinin son aşaması, test aşamasıdır. Bu aşamada, algoritma daha önce karşılaşmadığı veri setleriyle test edilir. Çalışmamızda, bu amaçla 84 veri seti kullanılmıştır. Bu test süreci, algoritmanın tanıdık olmayan verilere nasıl tepki verdiğini değerlendirmektedir. Bu yaklaşım, algoritmanın gerçek dünya verileri üzerindeki performansını ölçmemizi sağlar. Şekil 2.8, bu verilerin dört örneğini sunmaktadır. Burada, genel olarak DCR2D_Net_Archaeo sonuçlarının, 2B ters çözüm sonuçlarına göre gerçek modeli daha iyi yansıttığı görsel olarak görülmektedir. Gerçek model ile 2D ters çözüm sonucu ve gerçek model ile DCR2D_Net_Archaeo algoritması kullanılarak elde edilen öz direnç modeli arasındaki RMSe hesaplanmıştır. Bu işlem, ters çözüm ve DCR2D_Net_Archaeo sonuçlarının niceliksel olarak değerlendirilmesi amacıyla gerçekleştirilmiştir. Gerçek model ve ters çözümden bulunan modeller arasındaki karekök hata (Model karekök hata, RMSm), aşağıdaki formül kullanılarak hesaplanmıştır (Li ve diğerleri, 2024):

$$\text{RMSm} = \sqrt{\frac{1}{N_p} \sum_{i=1}^{N_p} \frac{\|\mathbf{mr}(i) - \mathbf{m}(i)\|^2}{\|\mathbf{mr}(i)\|^2}} \quad (2.7)$$

Burada \mathbf{mr} gerçek model parametrelerini içeren vektör ve \mathbf{m} ise ters çözüm sonucu veya DCR2D_Net_Archaeo algoritmasından elde edilen model vektörüdür.




Şekil 2.8 1080 modelden test için ayrılan 84 veri seti içinden rasgele seçilmiş dört model için gerçek model, ters çözüm sonucu ve DCR2D_Net_Archeo ile elde edilmiş sonuçlar

3. UYGULAMA VE SONUÇLAR


3.1 Sentetik Verinin Kademeli Ters Çözümü

Kademeli ters çözümde, ilk aşamada $a=1$ metre için dipol aralığı, $d=a$ olarak alınmış ve $n=1, 2, \dots, 8$ 'e kadar olan seviyeler için veri setleri, yüzeye yakın blokların öz dirençlerinin belirlenmesi amacıyla kullanılmıştır. Bu veri setinin ters çözümünden elde edilen model, ön kesitim modeli olarak kullanılarak ikinci aşamada $d=2a$ dipol aralığı için $n=1, 2, \dots, 8$ seviye için ölçülen ikinci veri grubunun ters çözümü yapılmaktadır. Örnek olarak Şekil 3.1 a' daki 2B öz direnç modeli için kuramsal veriler hesaplanmıştır. Bu modelde yüzey yakın $10 \Omega\text{m}$ öz dirençli $4\text{m} \times 3\text{m}$ boyutlarında bir iletken ve 2m derinde $2\text{m} \times 2\text{m}$ boyutlarında $1000 \Omega\text{m}$ öz dirençli yalıtkan bir yapı $50 \Omega\text{m}$ öz dirençli homojen ortama gömülüdür. Bu model için hesaplanan veri birinci veri seti ($d=a=1\text{m}$ ve $n=1, 2, \dots, 8$) için 2B ters çözüm sonucu Şekil 3.1b' de sunulmuştur. İkinci veri seti ($d=2a=2\text{m}$ ve $n=1, 2, \dots, 8$) için ters çözüm sonucu ise Şekil 3.1c' de sunulmuştur. Her iki veri seti kullanılarak elde edilen ters çözüm sonucu Şekil 3.1d' de sunulmuştur. Veri seti-1' in ters çözüm sonucunu (Şekil 3.1b) ön kestirim modeli kullanarak 2. veri setinin ters çözümü ise Şekil 3.1e' de sunulmuştur. Tüm modeller 1.2' den küçük RMS hata ile hesaplanmıştır (Şekil 3.1).

Şekil 3.2a' daki 2B öz direnç modeli için kuramsal veriler hesaplanmıştır. Bu modelde yüzey yakın $1000 \Omega\text{m}$ öz dirençli $3\text{m} \times 2\text{m}$ boyutlarında ve 2m derinde $2\text{m} \times 1\text{m}$ boyutlarında $10 \Omega\text{m}$ öz dirençli bir yapı $50 \Omega\text{m}$ öz dirençli homojen ortama gömülüdür. Bu model için hesaplanan veri birinci veri seti ($d=a=1\text{m}$ ve $n=1, 2, \dots, 8$) için 2B ters çözüm sonucu Şekil 3.2b' da sunulmuştur. İkinci veri seti ($d=2a=2\text{m}$ ve $n=1, 2, \dots, 8$) için ters çözüm sonucu ise Şekil 3.2c' de sunulmuştur. Her iki veri seti kullanılarak elde edilen ters çözüm sonucu Şekil 3.2d' de sunulmuştur. Veri seti-1' in ters çözüm sonucunu (Şekil 3.2b) ön kestirim modeli kullanarak 2. veri setinin ters çözümü ise Şekil 3.2e' de sunulmuştur. Tüm modeller 1.5' den küçük RMS hata ile hesaplanmıştır (Şekil 3.2).



Şekil 3.1 (a) 2B öz direnç modeli, (b) Veri seti-1, $d=1$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (c) Veri seti-2, $d=2$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (d) Veri seti-1 ve Veri seti-2'nin birlikte 2B ters çözüm sonucundan elde edilen model. (e) Veri seti-1'in ters çözüm sonucu ön kestirim kullanılarak elde edilen 2B ters çözüm modeli



Şekil 3.2 (a) 2B öz direnç modeli, (b) Veri seti-1, $d=1$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (c) Veri seti-2, $d=2$ ve $n=8$ için elde edilen 2B ters çözüm modeli. (d) Veri seti-1 ve Veri seti-2'nin birlikte 2B ters çözüm sonucundan elde edilen model. (e) Veri seti-1'in ters çözüm sonucu ön kestirim kullanılarak elde edilen 2B ters çözüm modeli

Tez kapsamında önerilen kademeli ters çözümün, geleneksel ters çözüme göre daha iyi sonuç verse de yapı sınırlarını net olarak veremediği görülmüştür. Bunun birçok nedeni vardır.

Bunlar;

- i- DAÖ yönteminde derinlik arttıkça yanal ve düşey ayrımlılığın azalması
- ii- DAÖ verilerinin ters çözümünün kötü tanımlı (ill-conditioned) olması. Yani çözüm tek değil (non-unique) ve/veya durağan değil (unstable) ve/veya çözüm bazen bulunamamaktadır (non-exist)
- iii- DAÖ yönteminde düz çözüm için kullanılan sayısal çözümdeki kabuller ve yaklaşımlar

Çizelge 3.1'deki RMSm değerleri karşılaştırıldığında, kademeli ters çözüm yönteminin geleneksel ters çözüme göre daha yüksek doğrulukta sonuçlar verdiğini ortaya koymaktadır. Ancak bu yaklaşımın beklenen çıktıyı vermemiştir. Elde edilen model yine yumuşak geçişli olmuştur. DAÖ yönteminin arkeolojik alanlarda uygulanmasında, aranan öz direnç yapıları keskin sınırlıdır ve yumuşak öz direnç geçişli modeller, bu yapıların görülmesini maskeleymektedir. Çizelge 3.1'de verilen gerçek model ve ters çözümden bulunan modeller arasındaki karekök hata (Model karekök hata, RMSm) Denklem (2.'ya göre hesaplanmıştır.

Çizelge 3.1 Kademeli ters çözüm sonucu ile geleneksel ters çözüm sonucundan hesaplanan RMSm değerleri

	Şekil 3.1	Şekil 3.2
Geleneksel ters çözüm sonucundan RMSm	0.37	0.34
Kademeli ters çözüm sonucundan RMSm	0.35	0.31

Tezin temel amacı, arkeolojik alanlarda ölçülen DAÖ verileri ile keskin sınırlı modeller elde etmektir. Dolayısıyla, yukarıda iki örnekte görüldüğü gibi bu tez kapsamında önerilen “kademeli ters çözüm” ün model ayrımlılığını artıramamıştır.

3.2 Evrişimli Sinir Ağı (CNN)' nda U-net Mimarisi ile Özdirenç Modelinin İyileştirilmesi

Bu bölümde, DCR2D_Net_Archaeo'nun arkeolojik alanlardaki etkinliğini doğrulamak için yapılmış yapay veri ve arazi verisi uygulamaları anlatılmıştır. Arazi verisi olarak, Ankara'daki Roma hamamı ve Kayseri'deki Kültepe olarak bilinen iki farklı arkeolojik alandan toplanan veriler kullanılmıştır.

Bu iki arkeolojik alan incelemesi, DCR2D_Net_Archaeo'nun arkeolojik alanlardaki ters çözüm sonuçlarını iyileştirme potansiyelini ortaya koymuştur.

3.2.1 Yapay veri uygulamaları

Arkeolojik alanların, DCR2D_Net_Archaeo algoritması ile 2 boyutlu özdirenç modellemesi üzerinden yapılan çalışmalar incelenmiştir. Araştırmanın odak noktası, arkeolojik alanlarda sık rastlanan özdirenç farklılıklarının doğru bir şekilde saptanabilmesi ve modellenmesi olmuştur. Bu amaçla, beş farklı model parametresi tanımlanmış ve bu parametreler, örtü tabakası, ortam ve gömülü yapılar gibi temel jeofizik özellikleri temsil edecek şekilde düzenlenmiştir.

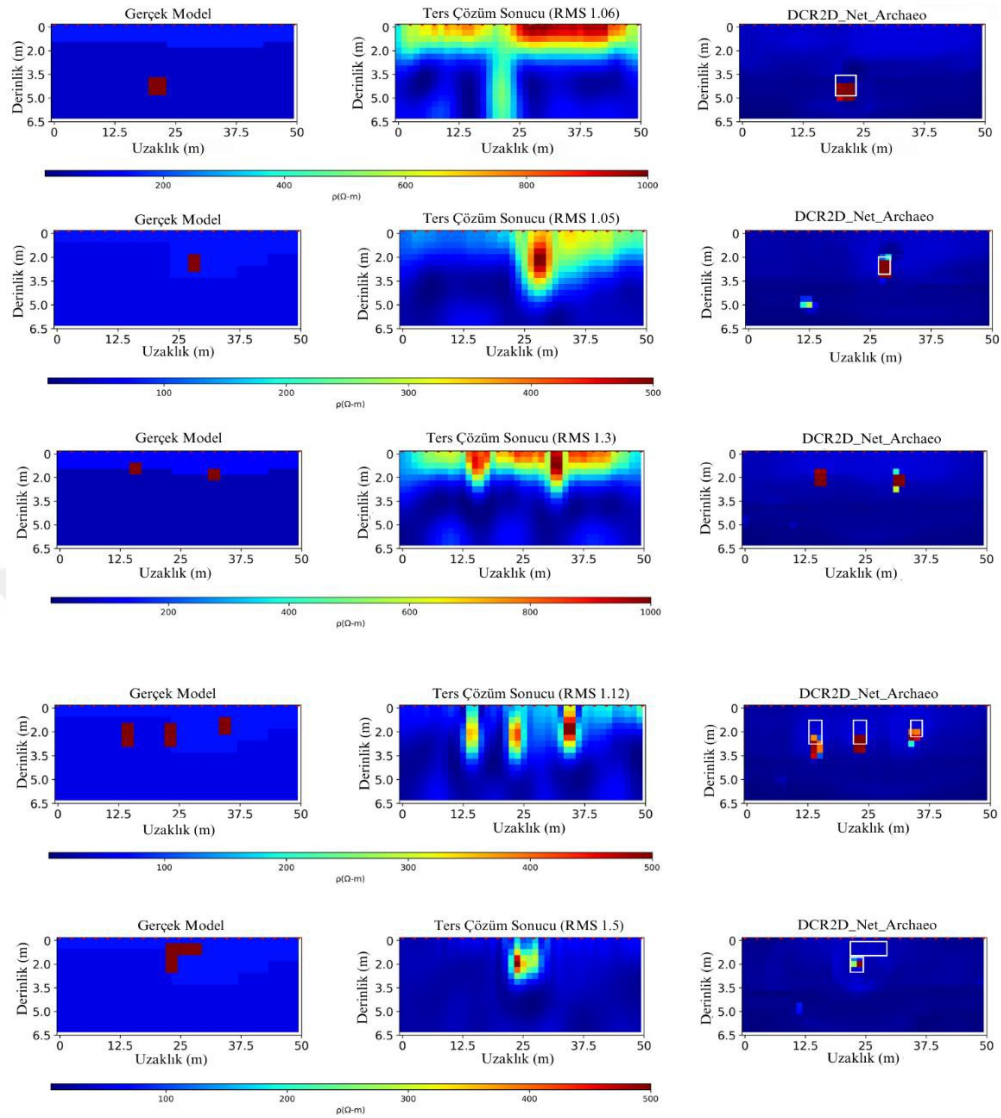
Arkeolojik alanlar genellikle, ilk 0.25-0.5 metre derinliğe kadar örtü tabaka olarak 60 ile 100 Ωm özdirenç sahip sıkıştırılmış topraktan oluşur ve bu tabakanın altında, örtü tabakadan %10-%30 daha düşük özdirenç sahip toprak bulunur. Gömülü yapılar, ortama göre 5- 10 kat daha yüksek özdirenç sahiptir. Bu genel özellikler kullanarak, arkeolojik alanlar için 2B özdirenç modelleri oluşturulmuştur.

Geliştirilen DCR2D_Net_Archaeo'nun görüntü iyileştirme performansını test etmek için, gömülü arkeolojik yapıları simüle eden beş farklı özdirenç modeli oluşturulmuştur. Verilere %2 rastgele gürültü eklenmiştir. Yapı sayısı, örtü tabakanın özdirenci, ortamın özdirenci, yapının özdirenci, yapının boyutu, yapının derinliği gibi model parametreleri beş model için Çizelge 3.2 verilmiştir. Her modelde, birinci tabaka, ortamın özdirenci ve gömülü yapıların özdirenci ve derinliği farklıdır. Test modelleri oluşturulurken DAÖ yönteminin nüfuz derinliği de dikkate alınmıştır.

Çizelge 3.2 DCR2D_Net_Arhaeo algoritmasını test etmek için kullanılan model parametreleri

Yapı	Model 1	Model 2	Model 3	Model 4	Model 5
İlk tabakanın öz direnci	75 Ω m	75 Ω m	125 Ω m	75 Ω m	75 Ω m
Yapının öz direnci	250 Ω m	500 Ω m	1000 Ω m	500 Ω m	500 Ω m
Ortamın öz direnci	30 Ω m	40 Ω m	60 Ω m	50 Ω m	50 Ω m
Özdirenç Yapıları (ÖY), Derinlik (D) m, Boyut (B) m	D: 3.5 B: 3.75x1.5	D: 1.5 B: 2.5x1	ÖY1 D: 1 B: 2.5x0.5 ÖY2 D: 2.4 B: 2.5x0.5	ÖY1 D: 1 B: 2.5x1 ÖY2 D: 1 B: 2.5x1 ÖY3 D: 0.5 B: 2.5x1	ÖY1 D: 0.25 B: 6.5x0.5 ÖY2 D: 0.25 B: 2.5x1.5

Şekil 3.3'de, sol sütunda yer alan gerçek öz direnç modelleri, orta sütunda bulunan ters çözüm sonuçları ve sağ sütunda gösterilen DCR2D_Net_Arhaeo algoritması ile iyileştirilmiş sonuçlar karşılaştırılmıştır. İyileştirme sürecinde, ters çözüm sonuçlarının gömülü yapıların konumu ve formu açısından belirgin bir iyileştirme gösterdiği gözlenmiştir. DCR2D_Net_Arhaeo algoritması, örtü tabakayı belirgin bir şekilde iyileştirememiş olsa da gömülü yapıyı temsil eden yüksek öz dirençli yapıyı düzgün bir şekilde çözmüştür.



Şekil 3.3 2B öz direnç modellerinin karşılaştırması: Gerçek model (ilk sütun), gerçek modelden elde edilen ters çözüm sonucu (ikinci sütun), DCR2D_Net_Archaeo'dan elde edilen sonuç (üçüncü sütun). Üçüncü sütundaki beyaz dikdörtgen yapıların gerçek sınırlarını göstermektedir (Över ve Candansayar, 2024)

Şekil 3.3'de ters çözüm sonucu için RMS hataları da verilmiştir. Buradaki 2D ters çözüm sonuçlarını, geliştirdiğimiz DCR2D_Net_Archaeo algoritmamızda kullandık. Ayrıca, Ters çözüm sonucunu ve DCR2D_Net_Archaeo sonucunu niceliksel olarak değerlendirmek için gerçek model ile 2D ters çözüm sonucu ve gerçek model ile DCR2D_Net_Archaeo algoritmasından elde edilen iyileştirilmiş öz direnç modeli arasındaki RMS hesapladık. Her bir ters çözüm için hesaplanan RMS hataları, algoritmanın yüksek hassasiyetini ortaya koymuştur; DCR2D_Net_Archaeo

algoritmasından elde edilen iyileştirilmiş model ve gerçek model arasındaki RMS değerleri 0,1'den küçük olması, modelin gerçek verilere oldukça yakın olduğunu işaret etmektedir.

DCR2D_Net_Archaeo algoritması ile 2D öz direnç modeli iyileştirildikten sonra, modellerde bazı yan etkiler görülebilir. Bunun nedeni, sentetik verilere rastgele gürültü eklememiz ve ayrıca DCR2D_Net_Archaeo algoritmasını geliştirirken rastgele gürültü eklenmiş veri ters çözüm sonuçlarını kullanmamızdır.

DCR2D_Net_Archaeo algoritmasını oluştururken sadece tek yapılı modeller kullandığımız halde, iki ve üç yapılı modeller içinde, Model 3 ve Model 4'te olduğu gibi, test ettik. DCR2D_Net_Archaeo algoritması, bu dikdörtgen yapıların konumunu bulabiliyor. Ancak, derinliklerini kesin olarak çözemiyor. Algoritmanın sınırlamalarını görmek için L-şekilli yapı için de test ettik. Ancak algoritma, bu L-şekilli anomaliyi çözmedi. Bu, algoritmamızın sınırlamaları arasındadır. Ancak, algoritmanın eğitim aşamasında iki ve üç yapılı modeller ve L-şekilli yapılar kullanılırsa, bu yapıları da daha kesin bir şekilde çözebileceğini düşünmekteyiz.

Çizelge 3.3 Çizelge 3.2'de verilen modellerin % misfit değerleri

	Model 1	Model 2	Model 3	Model 4	Model 5
Gerçek model ile ters çözüm modeli arasındaki RMSe	0.011	0.014	0.028	0.030	0.026
Gerçek model ile DCR_Net_Archaeo modeli arasındaki RMSe	0.014	0.016	0.029	0.023	0.030
Yalnızca gömülü yapı için gerçek model ile ters çözüm modeli arasındaki RMSe	0.29	0.33	0.43	0.35	0.22
Yalnızca gömülü yapı için gerçek model ile DCR_Net_Archaeo modeli arasındaki RMSe	0.20	0.31	0.17	0.22	0.16

Çizelge 2.1’de modellerin % misfit değerleri de verilmiştir. Her bir modelin gerçek değerlerle ne derece uyum sağladığını gösteren % misfit değerlerini içermektedir.

Bu bulguların ışığında, DCR2D_Net_Archaeo algoritması, arkeolojik alanlarda veri iyileştirmesi ve görsel çözünürlüğün artırılması konusunda önemli katkılar sağlamaktadır. İyileştirilmiş sonuçlar, gerçek modellerle kıyaslandığında daha kesin ve ayrıntılı bilgiler sunarak, arkeolojik yapıların tespitinde kullanılabilir bir araç olduğunu kanıtlamıştır. Bu çalışma, DCR2D_Net_Archaeo algoritmasının, öz direnç verilerinin daha doğru bir şekilde yorumlanması, arkeolojik alanlarda yapılan çalışmaların doğru lokasyonların belirlenmesinde kullanılabilir olduğunu göstermektedir.

DAÖ verilerinin 2B ters çözüm sonucunu iyileştirmek için kullanılan DCR2D_Net_Archaeo algoritmasının sonuçları, gerçek modellerle karşılaştırıldığında daha yakın ve net sonuçlar sunmuştur.


Bir sonraki bölümde, geliştirilen derin öğrenme algoritmasının arazi verilerinde test edildiği uygulamalar anlatılmıştır.

3.2.2 Arazi verisi uygulaması: Ankara Roma Hamamı

Ankara’da bulunan Roma hamamında, Roma İmparatorluğu'nun son dönemlerinde ve Osmanlı İmparatorluğu'nun ilk yıllarında inşa edilen sur duvarını bulmak amacıyla DCR verileri toplanmıştır (Candansayar, 2008). Bu alanda, Wenner, Wenner-Schlumberger, Dipol-Dipol (DD), sol ve sağ yönlü pol-dipol (PDL ve PDR) dizilimleri kullanılarak DCR verileri toplanmıştır. Candansayar (2008), üç ve dört elektrotlu dizilimlerin tek ve birlikte kullanımının çözünürlüğü nasıl etkilediğini karşılaştırmıştır ve DD, PDL ve PDR dizilimlerinin birleşik kullanımının, daha iyi çözünürlük sağladığını belirtmiştir. Yapılan çalışmanın sonuçlarına göre, önerilen kazı yerinde, kazı sonrasında sur duvarı 3.5 metre derinlikte bulunmuştur (Şekil 3.4).



Şekil 3.4 Roma dönemine ait hamam ve kazılan duvarın fotoğrafı (Candansayar 2008'den alınmıştır)



Şekil 3.5 (a) 2D ters çözüm sonucu ve (b) DCR2D_Net_Archeo kullanılarak öz direnç modelinin geliştirilmesi. Beyaz dikdörtgen, kazı sonucunda sur duvarının yerini göstermektedir (Över ve Candansayar, 2024)


Bu çalışmada, DCR2D_Net_Archeo algoritmasına girdi olarak DD, PDL ve PDR ters çözüm sonucunu verilmiştir (Şekil 3.4a) ve iyileştirilmiş öz direnç modeli elde edilmiştir (Şekil 3.4b). Geliştirilen derin öğrenme algoritması tarafından tespit edilen net duvar anomalisi, kazı sonuçlarıyla uyumlu bir yapı sergilemiştir (Şekil 3.5). Bu bulgu, geleneksel ters çözüm sonuçlarının aksine, DCR2D_Net_Archeo algoritmasının daha net mekansal ve yapısal bilgi sağlama kapasitesinin altını çizmektedir. Geleneksel yöntemlerin sınırlılıklarını aşarak, DCR2D_Net_Archeo'nun sağladığı yüksek çözünürlüklü sonuçlar, arkeolojik yapıların daha kesin bir biçimde tespit edilmesine imkan tanımıştır.

3.2.3 Arazi verisi uygulaması 2: Kayseri, Kültepe

Kültepe-Kaneş arkeolojik alanı, Anadolu'nun tarih öncesi dönemlerine ışık tutan ve antik dönem ticaretinin önemli bir merkezi olarak kabul edilen bir bölgedir. 1893 yılında başlayan ilk kazı faaliyetleri, bölgenin zengin tarihini ve kültürel mirasını gün yüzüne çıkarmaya başlamıştır. (Kulakoğlu, 2014). 2006 yılında ise, Kültepe-Kaneş'de modern, bilimsel ve disiplinler arası yaklaşımlarla kazı çalışmaları başlamıştır (Atıcı vd.2014).



Şekil 3.6 2008'de kazılan duvarın hava fotoğrafı (Kulakoğlu vd. tarafından 2021'de çekilmiştir)



Şekil 3.7 (a) 2D ters çözüm sonucu ve (b) DCR2D_Net_Archeo kullanılarak elde edilen sonuç. Beyaz dikdörtgen, kazı sonucunda bulunan antik duvarın yerini göstermektedir (Över ve Candansayar, 2024)

Kültepe-Kaneş arkeolojik alanındaki jeofizik çalışmalar, bölgenin Asur uygarlığına ait tarihi yapılarını araştırmak için yapılmıştır. Bu çalışmalar sırasında, 2018 yılında, AGI SuperSting R8/IP kullanarak 7 paralel hat boyunca DCR verileri toplanmıştır. Elde edilen veriler, yer altındaki olası arkeolojik yapıların tespit edilmesinde kullanılmış ve bu süreç sonucunda 1x4 metrelik bir alan kazı için önerilmiştir.

Bu öneri üzerine, 2008 yılında gerçekleştirilen kazılarda, yaklaşık 0.6 metre derinlikte bir taş duvarın varlığı doğrulanmıştır (Şekil 3.6) (Kulakoğlu vd., 2021). 2D ters çözüm sonucu ve DCR2D_Net_Archaeo algoritmasıyla elde edilen sonuç Şekil 3.7’te verilmiştir. Yapılan karşılaştırmada, geliştirilen DCR2D_Net_Archaeo ile elde edilen sonuçların, kazı sonucuyla daha iyi uyum sağladığı görülmektedir.

Bu karşılaştırma, geleneksel 2B ters çözüm sonuçlarının DCR2D_Net_Archaeo ile iyileştirilmesi ile elde edilen sonuçların, kazı sonuçlarıyla daha iyi uyum gösterdiğini ortaya koymuştur. Algoritma ile elde edilen sonuçlar, kazıda bulunan taş duvarın konumunu, boyutlarını ve derinliğini daha net bir şekilde yansıtmıştır.

Kulakoğlu ve diğer yazarların 2021 yılında yayınladıkları çalışma, Kültepe-Kaneş arkeolojik alanında uygulanan jeofizik yöntemin başarısını ve bu yöntemin kazı sonuçlarıyla ne derece uyum sağladığını ortaya koymaktadır.

Sonuç olarak, bu çalışma, Kültepe-Kaneş arkeolojik alanında yapılan kazılarda derin öğrenme tekniklerinin ve algoritmalarının başarılı bir şekilde entegre edilerek kullanılabileceğini göstermiştir.

4. SONUÇLAR

Bu tez çalışmasında, DAÖ verilerinin 2B ters çözüm sonuçlarının iyileştirilmesi amacıyla iki yeni yaklaşım önerilmiştir. Önerilen her iki yaklaşımda da türev tabanlı yöntemlerle elde edilen sonuçların kalitesini arttırmak hedeflenmiştir. İlk yaklaşım, DAÖ verilerinin kademeli 2B ters çözümü önerilmiştir. İkinci yaklaşım olarak ise CNN kullanılarak 2B ters çözüm sonuçlarının iyileştirilmesi önerilmiştir.

Kademeli ters çözüm yöntemi, DAÖ verilerinin farklı dipol aralıkları ile aşamalı olarak çözümlenmesini içermektedir. İlk aşamada, yüzeye yakın blokların öz dirençlerini belirlemek amacıyla küçük dipol aralıkları kullanılmıştır. Bu aşamada elde edilen model, sonraki aşamalarda daha büyük dipol aralığı kullanılarak yapılan çözümlerde ön kesitim modeli olarak kullanılmıştır. Yapılan uygulamalarda, kademeli ters çözümün, geleneksel ters çözüme göre bazı durumlarda daha iyi sonuçlar verdiği gözlemlenmiş olsa da, yapı sınırlarını net bir şekilde belirlemede başarısız olduğunu göstermiştir (Şekil 3.1 ve Şekil 3.2). Bu başarısızlığın nedenleri arasında, DAÖ yönteminde derinlik arttıkça yanal ve düşey ayrımlılığın azalması, ters çözüm probleminin kötü tanımlı (ill-conditioned) olması yer almaktadır.

CNN tabanlı yaklaşımda, U-Net mimarisi kullanılarak geliştirilen DCR2D_Net_Archaeo algoritması, DAÖ verilerinin 2B ters çözüm sonuçlarını iyileştirmede başarılı olmuştur. Bu algoritma, sentetik ve gerçek arazi verileri ile test edilmiş ve her iki durumda da olumlu sonuçlar elde edilmiştir. Özellikle arkeolojik alanlarda yapılan uygulamalarda, DCR2D_Net_Archaeo algoritması, geleneksel ters çözüm yöntemlerine kıyasla daha yüksek doğruluk ve ayrıntı sağlamıştır. Sentetik verilerle yapılan çalışmalarda, CNN algoritmasının çeşitli model parametreleri ile başarılı sonuçlar verdiği görülmüştür. Gömülü yapıların konum ve boyutlarının doğru bir şekilde belirlenmesi, bu yöntemin etkinliğini göstermektedir. Ancak, L-şekilli anomaliler gibi karmaşık yapıların belirlenmesinde bazı sınırlamalar olduğu tespit edilmiştir.

Bu tez çalışmasında, DCR2D_Net_Archaeo'nun sentetik veriler üzerindeki başarısı ve farklı arkeolojik alanlardan toplanan gerçek veriler üzerindeki uygulamaları incelenmiştir. Arazi verisi uygulamalarında, Ankara Roma Hamamı ve Kayseri Kültepe arkeolojik alanlarından elde edilen veriler kullanılmıştır. Ankara Roma Hamamı ve Kayseri Kültepe gibi iki farklı arkeolojik alan için yapılan uygulamalarda, DCR2D_Net_Archaeo algoritması, geleneksel yöntemlerle elde edemediğimiz ayrıntılı ve net sonuçlar sunmuştur. Roma Hamamı'nda yapılan çalışmalarda, DCR2D_Net_Archaeo algoritması, geleneksel yöntemlerle elde edilen sonuçlara kıyasla daha net ve doğru sonuçlar vermiştir. Özellikle, Ankara Roma Hamamı'nda bulunan sur duvarının net olarak tespit edilmesi, algoritmanın yüksek çözünürlük sağlama kapasitesini göstermektedir (Şekil 3.5). Bu iki arkeolojik alanın incelenmesi, DCR2D_Net_Archaeo'nun arkeolojik alanlardaki ters çözüm sonuçlarını iyileştirme potansiyelini göstermiş. Bu sonuçlar, algoritmanın arkeolojik yapıların tespitinde kullanılabileceğini göstermektedir. Kayseri Kültepe'deki uygulamalarda da benzer sonuçlar elde edilmiştir (Şekil 3.7). Algoritma, gömülü yapıların yerlerini ve sınırlarını başarılı bir şekilde belirlemiştir. Bu uygulamalar, DCR2D_Net_Archaeo algoritmasının gerçek veriler üzerinde de etkin bir şekilde çalıştığını göstermektedir.

Bu tez çalışması ile, DAÖ verilerinin 2B ters çözüm sonuçlarını iyileştirmek için yeni yaklaşımlar sunulmuştur. Kademeli ters çözüm yöntemi, geleneksel ters çözüm yöntemlerine göre daha iyi sonuçlar verse de yapıların sınırlarını ve derinliklerini tespit etmede yetersiz kalmıştır. Buna karşın, bu tez kapsamında geliştirilen CNN tabanlı DCR2D_Net_Archaeo algoritması, hem sentetik hem de gerçek arazi verilerinde, geleneksel ters çözüm yöntemlerinin sınırlamalarını aşarak, daha yüksek çözünürlüklü ve doğru sonuçlar elde edilmesini sağlamıştır. Buda, derin öğrenme tekniklerinin, jeofizik verilerin yorumlanmasında ve özellikle arkeolojik alanlarda uygulanabilirliğini göstermiştir. Algoritma, yeraltı yapılarının konumlarını ve sınırlarını belirgin bir şekilde iyileştirerek, arkeolojik yapıların daha doğru şekilde tespit edilmesine imkan tanımıştır.

Daha sonra yapılacak çalışmalar, algoritmanın karmaşık yapılar üzerindeki performansını artırmayı hedeflemelidir. Ayrıca, daha geniş veri setleri kullanılarak, algoritmanın etkinliği artırılabilir.

KAYNAKLAR

- Alaia, R., Patella, D. and Mauriello P. 2008b. Application of geoelectrical 3D probability tomography in a test-site of the archaeological park of Pompei (Naples, Italy). *J. Geophys. Eng.*, 5, 67-76.
- Aleardi, M., Vinciguerra, A., & Hojat, A. 2021. A convolutional neural network approach to electrical resistivity tomography. *Journal of Applied Geophysics*, 193, 104434.
- Atıcı, L., Kulakoglu, F., Fairbairn, A., & Barjamovic, G. 2014. Current Research at Kultepe-Kanesh: An Interdisciplinary and Integrative Approach to Trade Networks, Internationalism, and Identity. *Current Research at Kultepe-Kanesh*, 1-232.
- Binley, A., & Kemna, A. 2005. DC resistivity and induced polarization methods. In *Hydrogeophysics* (pp. 129-156). Dordrecht: Springer Netherlands.
- Bottou, L. 2010. Large-scale machine learning with stochastic gradient descent. In *Proceedings of COMPSTAT'2010: 19th International Conference on Computational Statistics Paris France, August 22-27, 2010 Keynote, Invited and Contributed Papers* (pp. 177-186). Physica-Verlag HD.
- Chambers, J. E., Kuras, O., Meldrum, P. I., Ogilvy, R. D., & Hollands, J. 2006. Electrical resistivity tomography applied to geologic, hydrogeologic, and engineering investigations at a former waste-disposal site. *Geophysics*, 71(6), B231-B239.
- Candansayar, M. E. 1997. Doğru akım öz direnç yönteminde modelleme ve iki boyutlu sığ yapıların aranmasında elektrot dizimlerinin ayrımlıklarının karşılaştırılması, Yüksek Lisans Tezi. Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Candansayar, M. E. 2008. Two-dimensional individual and joint inversion of three-and four-electrode array dc resistivity data. *Journal of Geophysics and Engineering*, 5(3), 290-300.
- Demirci, I., Erdoğan, E., and Candansayar, M. E. 2012. Two-dimensional inversion of direct current resistivity data incorporating topography by using finite difference techniques with triangle cells: Investigation of Kera fault zone in western Crete. *Geophysics*, 77(1), E67-E75.
- Demirci, I., Gündoğdu, N. Y., Candansayar, M. E., Soupios, P., Vafidis, A., & Arslan, H. 2020. Determination and evaluation of saltwater intrusion on bafra plain: joint interpretation of geophysical, hydrogeological and hydrochemical data. *Pure and Applied Geophysics*, 177, 5621-5640.
- Duchi, J., Hazan, E., & Singer, Y. 2011. Adaptive subgradient methods for online learning and stochastic optimization. *Journal of machine learning research*, 12(7).

- Friedel, S. (2003). Resolution, stability and efficiency of resistivity tomography estimated from a generalized inverse approach. *Geophysical Journal International*, 153(2), 305-316.
- Guo, Y., Peng, S., Du, W., & Li, D. 2023. Denoising and wavefield separation method for DAS VSP via deep learning. *Journal of Applied Geophysics*, 210, 104946.
- Gündoğdu, N. Y., Candansayar, M. E. & Genç, E. 2017. Rescue archaeology application: Investigation of Kuriki mound archaeological area (Batman, SE Türkiye) by using direct current resistivity and magnetic methods. *Journal of Environmental and Engineering Geophysics*, 22(2), 177-189
- Gündoğdu, N. Y. & Candansayar, M. E. 2018. Three-dimensional regularized inversion of DC resistivity data with different stabilizing functionals. *Geophysics*, 83(6), E399-E407.
- Gündoğdu, N. Y., Demirci, İ., Demirel, C., & Candansayar, M. E. 2020. Characterization of the bridge pillar foundations using 3d focusing inversion of DC resistivity data. *Journal of Applied Geophysics*, 172, 103875.
- Günther, T., Rücker, C. & Spitzer, K. (2006). Three-dimensional modelling and inversion of DC resistivity data incorporating topography—II. Inversion. *Geophysical Journal International*, 166(2), 506-517.
- Hiskiawan, P., Chen, C. C., & Ye, Z. K. (2023). Processing of electrical resistivity tomography data using convolutional neural network in ERT-NET architectures. *Arabian Journal of Geosciences*, 16(10), 581.
- Jia, Z., Li, Y., Lu, W., Zhang, L., & Monkam, P. (2022). EMRNet: End-to-end electrical model restoration network. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-12.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*.
- Kulakoğlu, F. (2014). Kanesh after the Assyrian Colony period: current research at Kültepe and the question of the end of the Bronze Age settlement. *Current Research at Kültepe-Kanesh: An Interdisciplinary and Integrative Approach to Trade Networks, Internationalism, and Identity*, 85-94.
- Kulakoğlu, F., Kryszat, G., & Michel, C. 2021. Cultural exchanges and current research at Kültepe and its surroundings: Kültepe, 1-4 August, 2019. In *KIM-Kültepe international meetings (Vol. 4)*. Brepols.
- Neyamadpour, A., Taib, S., & Abdullah, W. W. 2009. Using artificial neural networks to invert 2D DC resistivity imaging data for high resistivity contrast regions: A MATLAB application. *Computers & Geosciences*, 35(11), 2268-2274.

- Nyquist, J. E., Peake, J. S., & Roth, M. J. 2007. Comparison of an optimized resistivity array with dipole-dipole soundings in karst terrain. *Geophysics*, 72(4), F139-F144.
- Li, J., Mikada, H., & Takekawa, J. (2024). Improved full-waveform inversion for seismic data in the presence of noise based on the k-support norm. *Pure and Applied Geophysics*, 1-28.
- Liu, B., Guo, Q., Li, S., Liu, B., Ren, Y., Pang, Y., ... & Jiang, P. 2020. Deep learning inversion of electrical resistivity data. *IEEE Transactions on Geoscience and Remote Sensing*, 58(8), 5715-5728.
- Liu, B., Guo, Q., Tang, Y., & Jang, P. 2023. Deep learning inversion method of tunnel resistivity synthetic data based on modelling data. *Near Surface Geophysics*.
- Loke, M. H., and Barker, R. D. 1996. Practical techniques for 3D resistivity surveys and data inversion. *Geophysical prospecting*, 44(3), 499-523.
- Özyıldırım, Ö., Demirci, İ., Gündoğdu, N. Y., & Candansayar, M. E. 2020. Two dimensional joint inversion of direct current resistivity and radiomagnetotelluric data based on unstructured mesh. *Journal of Applied Geophysics*, 172, 103885.
- Över, D., & Candansayar, M. E. (2024). Enhancing DC resistivity data two-dimensional inversion result by using U-net based Deep learning-algorithm: Examples from archaeogeophysical surveys. *Journal of Applied Geophysics*, 105430.
- Papadopoulos, N.G., Tsourlos, P., Tsokas, G.N., Sarris, A., 2006. Two-dimensional and three-dimensional resistivity imaging in archaeological site investigation. *Archaeological Prospection* 13, 163–181.
- Papadopoulos, N.G., Tsourlos, P., Papazachos, C., Tsokas, G.N., Sarris, A. and Kim, J.H. 2011. An algorithm for fast 3D inversion of surface electrical resistivity tomography data: application on imaging buried antiquities. *Geophysical Prospecting*, 59, 557-575.
- Parasnis, D. 2013. *Mining geophysics* (Vol. 3). Elsevier.
- Ronneberger, O., Fischer, P., & Brox, T. 2015. U-net: Convolutional networks for biomedical image segmentation. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III* 18 (pp. 234-241). Springer International Publishing.
- Sasaki, Y. 1989. Two-dimensional joint inversion of magnetotelluric and dipole-dipole resistivity data. *Geophysics*, 54, 254–262.
- Sasaki, Y. 1994. 3-D resistivity inversion using the finite-element method. *Geophysics* 59.12, 1839-1848.

- Soupios, P. M., Kouli, M., Vallianatos, F., Vafidis, A., & Stavroulakis, G. 2007. Estimation of aquifer hydraulic parameters from surficial geophysical methods: A case study of Keritis Basin in Chania (Crete–Greece). *Journal of Hydrology*, 338(1-2), 122-131.
- Stummer, P., Maurer, H., & Green, A. G. 2004. Experimental design: Electrical resistivity data sets that provide optimum subsurface information. *Geophysics*, 69(1), 120-139.
- Wisén, R., Christiansen, A. V., Dahlin, T., & Auken, E. 2008. Experience from two resistivity inversion techniques applied in three cases of geotechnical site investigation. *Journal of geotechnical and geoenvironmental engineering*, 134(12), 1730-1742.
- Wilkinson, P. B., Meldrum, P. I., Chambers, J. E., Kuras, O., & Ogilvy, R. D. 2006. Improved strategies for the automatic selection of optimized sets of electrical resistivity tomography measurement configurations. *Geophysical Journal International*, 167(3), 1119-1126.
- Wilkinson, P. B., Loke, M. H., Meldrum, P. I., Chambers, J. E., Kuras, O., Gunn, D. A., & Ogilvy, R. D. 2012. Practical aspects of applied optimized survey design for electrical resistivity tomography. *Geophysical Journal International*, 189(1), 428-440.
- Wilson, B., Singh, A., & Sethi, A. 2022. Appraisal of Resistivity Inversion Models With Convolutional Variational Encoder–Decoder Network. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-10.
- Vu, M. T., Jardani, A., Massei, N., & Fournier, M. 2021. Reconstruction of missing groundwater level data by using Long Short-Term Memory (LSTM) deep neural network. *Journal of Hydrology*, 597, 125776.
- Zhang, L., Zhang, G., Liu, Y., & Fan, Z. 2021. Deep learning for 3-D inversion of gravity data. *IEEE Transactions on Geoscience and Remote Sensing*, 60, 1-18.