



Araştırma Makalesi

HydroKidneyNet: BT Görüntülemeye Hidronefrozun Doğru Tespiti için Hibrit Yapay Zekâ Yöntemi

 Murat CANAYAZ*¹  Mehmet YÜKSEK²

¹Van Yüzüncü Yıl Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Van, Türkiye

²Van Bölge Eğitim ve Araştırma Hastanesi, Van, Türkiye

*Sorumlu yazar e-posta: mcanayaz@yyu.edu.tr

Öz: Hidronefroz, renal pelvis ve kalikslerin idrar akışının engellenmesi sonucu genişlemesiyle karakterize olup, tedavi edilmediğinde kalıcı böbrek hasarına yol açabilen önemli bir klinik durumdur. Bu çalışmada, kontrastsız bilgisayarlı tomografi (BT) görüntüleri kullanılarak hidronefrozun varlığına yönelik ikili sınıflandırma gerçekleştirilmiş ve çok aşamalı, yapay zekâ destekli bir analiz sistemi geliştirilmiştir. Önerilen yaklaşım, derin öğrenme tabanlı DenseNet mimarisi ile CBAM ve Squeeze-and-Excitation (SE) dikkat mekanizmalarının entegrasyonu sayesinde yüksek seviyeli öznelik çıkarımı sağlamaktadır. Elde edilen derin özellikler üzerinde SelectKBest ve Principal Component Analysis (PCA) yöntemleri kullanılarak boyut indirgeme ve özellik seçimi uygulanmış; ardından Random Forest, Lojistik Regresyon ve Gradient Boosting gibi denetimli öğrenme algoritmaları ile sınıflandırma gerçekleştirilmiştir. Model performansı accuracy, precision, recall, F1-score ve ROC AUC metrikleri ile değerlendirilmiştir. Bulgular, SelectKBest tabanlı yaklaşımın sınıf ayrımında daha yüksek başarı sağladığını ve özellikle DenseNet169 tabanlı hibrit model ile birlikte %99,79 doğruluk ve F1-skoru değerine ulaşıldığını göstermektedir. PCA yöntemi ise daha düşük ancak oldukça rekabetçi performans sunarak modelin genelleme kabiliyetine katkı sağlamıştır. Ayrıca YOLOv11 tabanlı segmentasyon modeli ile hidronefrotik bölgeler yüksek doğrulukla belirlenmiş ve geliştirilen Flask tabanlı arayüz sayesinde sistemin klinik kullanım potansiyeli ortaya konmuştur. Elde edilen sonuçlar, uygun özellik seçimi yöntemleri ve hibrit yapay zekâ mimarilerinin birlikte kullanımının, hidronefrozun otomatik teşhisinde yüksek doğruluk, güçlü genelleme ve klinik uygulanabilirlik sunduğunu göstermektedir.

Anahtar Kelimeler: Hidronefroz, Bilgisayarlı tomografi, Makine öğrenmesi, Özellik seçimi

HydroKidneyNet: A Hybrid AI Method for Accurate Hydronephrosis Detection in CT Imaging

Abstract: Hydronephrosis is a clinically significant condition characterized by the dilation of the renal pelvis and calyces due to obstruction of urine flow, which can lead to permanent kidney damage if left untreated. In this study, a binary classification was performed to detect the presence of hydronephrosis using non-contrast computed tomography (CT) images, and a multi-stage artificial intelligence-based analysis system was developed. The proposed approach enables high-level feature extraction through the integration of a deep learning-based DenseNet architecture with CBAM (Convolutional Block Attention Module) and Squeeze-and-Excitation (SE) attention mechanisms. On the extracted deep features, dimensionality reduction and feature selection were performed using SelectKBest and Principal Component Analysis (PCA) methods, followed by classification using supervised learning algorithms such as Random Forest, Logistic Regression, and Gradient Boosting. Model performance was evaluated using accuracy, precision, recall, F1-score, and ROC AUC metrics. The results indicate that the SelectKBest-based approach provides higher class discrimination performance and achieves an accuracy and F1-score of 99.79%, particularly when combined with the DenseNet169-based hybrid model. The PCA

Gönderilme Tarihi: 08.01.2026

Kabul Tarihi: 08.04.2026

Nasıl atıf yapılır: Canayaz, M. & Yüksek M. (2026). HydroKidneyNet: BT Görüntülemeye Hidronefrozun Doğru Tespiti için Hibrit Yapay Zekâ Yöntemi. *Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 31, 126-140 <https://doi.org/10.53433/yyufbed.1858419>

method, on the other hand, yielded slightly lower yet highly competitive performance while contributing to the generalization capability of the model. In addition, the YOLOv11-based segmentation model successfully identified hydronephrotic regions with high accuracy, and the developed Flask-based interface demonstrated the clinical applicability of the system. The findings suggest that the combined use of appropriate feature selection methods and hybrid artificial intelligence architectures provides high accuracy, strong generalization, and clinical applicability for the automated diagnosis of hydronephrosis.

Keywords: Hydronephrosis, CT, Machine learning, Feature extraction

1. Giriş

Hidronefroz, renal pelvis ve kalikslerin idrar akışının engellenmesi sonucu dilatasyonu ile karakterize bir patolojidir. Genellikle üreter obstrüksiyonu, taş, tümör veya doğumsal anomaliler gibi nedenlerle ortaya çıkar. Klinik olarak asemptomatik seyrebilmesi, tanı sürecini zorlaştırmakta ve hastalığın ilerleyen evrelerinde yan ağrısı, tekrarlayan idrar yolu enfeksiyonları ve böbrek fonksiyon kaybı gibi ciddi komplikasyonlara yol açabilmektedir (Kumar ve ark., 2020).

Tanıda radyolojik görüntüleme yöntemleri temel rol oynamaktadır. Ultrasonografi (USG), non-invaziv ve kolay erişilebilir olması nedeniyle genellikle ilk tercih edilen yöntemdir. Ancak anatomik detayların sınırlı sunumu nedeniyle ileri değerlendirme için yetersiz kalabilir. Bu noktada bilgisayarlı tomografi (BT), böbrek morfolojisinin ve obstrüksiyonun lokalizasyonunun belirlenmesinde yüksek doğruluk oranlarıyla öne çıkmaktadır (Smith ve ark., 2019). BT ile yapılan değerlendirmelerde renal pelvis çapı, kortikal kalınlık ve parankim hacmi gibi ölçümler kullanılarak hidronefrozun derecesi belirlenebilir.

Hidronefrozun radyolojik sınıflandırmasında en yaygın kullanılan sistemlerden biri Society for Fetal Urology (SFU) sınıflamasıdır. SFU, böbrek pelvisi ve kalikslerin genişleme derecesine göre hastalığı 0'dan 4'e kadar evrelendirir. Daha kapsamlı bir yaklaşım sunan Urinary Tract Dilation (UTD) sınıflaması ise hem antenatal hem postnatal dönemde kullanılabilir ve parankim yapısı, mesane duvarı kalınlığı gibi ek parametreleri de içerir (Vallasciani ve ark., 2021).

Klinik ve radyolojik bulgular arasında her zaman doğrudan bir korelasyon bulunmayabilir. Hafif hidronefroz vakaları asemptomatik seyrebileceği gibi, ileri evrelerde ciddi renal fonksiyon kaybı gelişebilir. Bu nedenle radyolojik değerlendirme, klinik parametrelerle birlikte yorumlanmalıdır. Serum kreatinin düzeyleri, idrar analizleri ve renal fonksiyon testleri bu korelasyonu destekleyen temel biyokimyasal göstergelerdir (Lee ve ark., 2021).

Son yıllarda, BT görüntülerinden elde edilen verilerin dijital olarak analiz edilebilmesi hidronefrozun otomatik sınıflandırılmasını mümkün hale getirmiştir. Bu süreçte makine öğrenmesi algoritmaları ve özellik seçimi teknikleri, radyolojik verilerin yorumlanmasında klinik karar destek sistemlerine katkı sağlamaktadır.

Hidronefroz, böbrekte idrar birikmesi sonucu renal pelvis ve kalikslerin genişlemesiyle karakterize edilen yaygın bir ürolojik durumdur. Özellikle pediatrik hastalarda tanısı, şiddetinin derecelendirilmesi ve tedaviye yönelik kararların verilmesi, büyük ölçüde ultrasonografik görüntülemeye dayanmaktadır. Geleneksel olarak bu değerlendirmeler, radyologların ve ürologların öznel yorumlarına bağlı kalmakta, bu da tanı ve takipte tutarsızlıklara yol açabilmektedir.

Son yıllarda yapay zeka (AI) ve özellikle derin öğrenme (deep learning) teknolojilerinin tıbbi görüntüleme alanında sunduğu olanaklar, hidronefroz yönetiminde devrim niteliğinde gelişmelere kapı aralamıştır. Bu alandaki çalışmalar, teşhisin doğruluğunu artırma, değerlendirmeyi standartlaştırma ve klinik karar süreçlerini destekleme potansiyeli taşımaktadır.

Hidronefroz tanısının ilk adımı, ultrason görüntülerinde böbreğin ve genişlemiş toplayıcı sistemin doğru ve güvenilir biçimde tanımlanmasıdır. Son yıllarda yapay zekâ ve derin öğrenme tabanlı yaklaşımlar bu sürecin otomatikleştirilmesinde önemli başarılar göstermiştir. Alexa ve ark. (2024), farklı cihazlardan elde edilen ultrason görüntülerinde hidronefrotik ve normal böbrekleri %98.5 doğruluk ve yaklaşık %94.7 Dice katsayısı ile başarılı şekilde tespit ve segmente edebilmiştir. Benzer şekilde Lien ve ark. (2022), Res-UNet tabanlı model ile orta ve ileri düzey hidronefroz tespitinde %94,6 doğruluk elde ederek operatör bağımlılığını azaltabilecek bir yaklaşım sunmuştur. Hidronefroz şiddetinin derecelendirilmesine yönelik olarak Smail ve ark. (2020), SFU sınıflamasına dayalı CNN modeli ile düşük-yüksek sınıflandırmada %78 doğruluk ve 0.78 F1-skoru elde etmiş; Mahmud ve ark.

(2024) ise segmentasyon ve sınıflandırmayı birleştiren KUSNet ve PHCNet yapıları ile %93.9 doğruluk ve %92.1 Dice katsayısı ile daha yüksek performans göstermiştir. Nicel değerlendirme açısından Song ve ark. (2022), hidronefroz alanı/parankim oranını (HARP) otomatik hesaplayarak yaklaşık 0.91 Dice değeri ile güvenilir segmentasyon sağlamış; Huang ve ark. (2025) ise SVM tabanlı model ile böbrek fonksiyon kaybını (DRF < 40%) %94.1 AUC değeri ile başarıyla tahmin etmiştir.

Bununla birlikte, hibrit ve çok aşamalı yaklaşımlar literatürde giderek daha fazla yer bulmaktadır. Bugday ve ark. (2023), Grad-CAM ve Relief tabanlı özellik seçimi ile desteklenen hibrit model ile %91,1 doğruluk elde ederken, Lai ve ark. (2025) çok merkezli veri setleri üzerinde geliştirdikleri model ile yaklaşık 0,92 Dice ve 0.91 AUC değerlerine ulaşarak segmentasyon ve tanıyı birlikte ele almıştır. Xia ve ark. (2026), kontrastlı BT verileri üzerinden böbrek fonksiyon kaybını 0.928 AUC ile tahmin etmiş; Svrcek ve ark. (2025) ise derin öğrenme ile klasik özellikleri birleştirerek %82 doğruluk ile hibrit yaklaşımların katkısını ortaya koymuştur. Khondker ve ark. (2025), çok zamanlı modellerin tek görüntüye kıyasla anlamlı üstünlük sağlamadığını göstererek erken tanının önemini vurgulamıştır. Bunun ötesinde, Yang ve ark. (2026) ve Sun ve ark. (2026) tarafından önerilen derin öğrenme ve fizik tabanlı modelleme yaklaşımları, hidronefrozun fonksiyonel değerlendirilmesine olanak tanımış; özellikle mesh rekonstrüksiyon ve CFD tabanlı analizlerin klinik potansiyeli ortaya konmuştur.

Genel olarak değerlendirildiğinde, literatürdeki çalışmalar hidronefrozun tespiti, segmentasyonu, derecelendirilmesi ve fonksiyonel analizi açısından önemli ilerlemeler sağlamış olsa da, bu çalışmaların büyük çoğunluğunun ultrason görüntülerine odaklandığı, BT tabanlı yaklaşımların sınırlı kaldığı ve çoğu yöntemin tek bir göreve odaklandığı görülmektedir. Ayrıca, dikkat mekanizmaları, gelişmiş özellik seçimi yöntemleri ve klinik entegrasyonu bir arada sunan bütüncül ve çok aşamalı yaklaşımların yeterince ele alınmadığı dikkat çekmektedir. Bu durum, daha yüksek doğruluk, güçlü genelleme kabiliyeti ve klinik uygulanabilirlik sağlayan hibrit yapay zekâ sistemlerine olan ihtiyacı açıkça ortaya koymaktadır.

2. Materyal ve Yöntem

2.1. Hasta seçimi ve görüntüleme protokolü

Bu çalışmada, 2024–2025 yılları arasında Van Bölge Eğitim ve Araştırma Hastanesi Radyoloji Kliniği'nde kontrastsız bilgisayarlı tomografi (BT) ile değerlendirilmiş hastaların görüntüleri retrospektif olarak incelenmiştir. Bu hastalardan 324 hidronefroz, 150 normal hasta resimleri veri seti için ayrılmıştır. Çalışmaya dahil edilen olgular, klinik olarak hidronefroz şüphesiyle BT çekimi yapılmış ve görüntülerinde “hidronefroz var” veya “hidronefroz yok” şeklinde ikili sınıflandırma yapılabilen hastalardan seçilmiştir. BT incelemeleri çok kesitli spiral BT cihazı kullanılarak, kontrastsız protokol ile gerçekleştirilmiştir. Tüm görüntüler aksiyal düzlemde elde edilmiş, multiplanar rekonstrüksiyon (MPR) ile koronal ve sagittal düzlemlere dönüştürülerek değerlendirme yapılmıştır. İnceleme sırasında intravenöz kontrast madde uygulanmamıştır. Değerlendirme kriterleri her olgu için iki deneyimli radyolog tarafından bağımsız olarak “hidronefroz var” veya “hidronefroz yok” şeklinde sınıflandırılmıştır. Hidronefrozun tanısında ilk ve en sık kullanılan görüntüleme yöntemi ultrasonografi (USG)'dir. Özellikle antenatal dönemde fetal böbreklerdeki pelvik genişlemeyi saptamada temel araçtır. USG ile pelvis ön-arka çapı, kaliks dilatasyonu, parankim kalınlığı ve ekojenite gibi parametreler değerlendirilir. Ancak fizyolojik ve patolojik hidronefroz ayrımı her zaman net olmayabilir (Emir & Büyüknal, 2023). Manyetik rezonans görüntüleme (MR), radyasyon içermemesi ve yumuşak doku kontrastı sağlaması nedeniyle özellikle pediatrik hastalarda ve kompleks anomalilerin değerlendirilmesinde tercih edilir. MR ürografi, üreteropelvik bileşke tıkanıklığı gibi durumların ayırıcı tanısında yardımcıdır. Bilgisayarlı tomografi (BT) ise özellikle obstrüksiyonun lokalizasyonu ve taş gibi nedenlerin değerlendirilmesinde kullanılır. Kontrastsız BT, taş varlığını saptamada altın standarttır. Bu çalışmada yalnızca kontrastsız BT kullanılmış ve hastalar “hidronefroz var” veya “hidronefroz yok” şeklinde ikili sınıflandırmaya tabi tutulmuştur. Klinik raporlama sürecinde, görüntüleme bulguları deneyimli radyolog tarafından değerlendirilmiş ve standart raporlama protokollerine uygun şekilde yorumlanmıştır. Raporlar genellikle şu başlıkları içerir:

- Görüntüleme bulguları (örneğin pelvis çapı, kaliks durumu, parankim yapısı)
- Tanısal değerlendirme (örneğin SFU derecesi veya “hidronefroz var/yok” ifadesi)

- Klinik öneriler ve izlem planı

Bu raporlar, nefroloji ve üroloji klinikleriyle paylaşılır ve tedavi sürecine yön verir. Görüntüleme bulguları, serum kreatinin düzeyleri, idrar analizleri ve renal fonksiyon testleri ile birlikte değerlendirilerek multidisipliner bir yaklaşım benimsenir.

2.2. Önerilen yöntem

Bu çalışmada, hidronefrozun tıbbi görüntülerden yüksek doğrulukla sınıflandırılması amacıyla çok aşamalı ve hibrit bir yapay zeka modeli geliştirilmiştir (Canayaz, 2025).

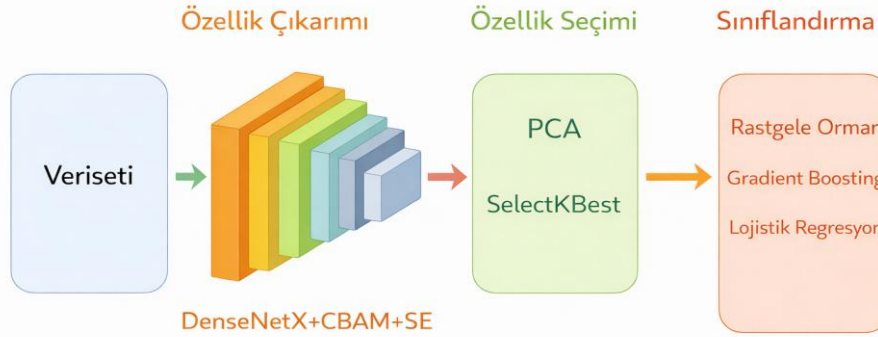
2.2.1. İlk aşama: sınıflandırma

1. Adım: Hibrit derin öğrenme modelinin geliştirilmesi (DenseNet + CBAM + SE)

Modelin temelini, görüntü tanıma görevlerinde oldukça başarılı olan DenseNet (Yoğun Evrişimli Ağ) mimarisi oluşturmaktadır. DenseNet, her bir katmanın kendisinden önceki diğer tüm katmanlardan doğrudan girdi aldığı “yoğun bağlantı (dense connectivity)” prensibine dayanır. Bu yapı, bilgi akışını maksimuma çıkarır, gradyan kaybolması sorununu azaltır ve daha az parametreyle yüksek performans sağlar. Bu güçlü temelin üzerine iki modern dikkat mekanizması entegre edilmiştir:

CBAM (Convolutional Block Attention Module), kanal ve uzamsal boyutta dikkat (attention) sağlayarak modelin hem “neyi” hem “nereye” bakması gerektiğini öğrenmesini sağlar. Squeeze-and-Excitation (SE) Bloğu, kanallar arası ilişkileri öğrenerek önemli kanalların ağırlıklarını artırır.

Bu hibrit yapı, DenseNet’in hiyerarşik özellik çıkarım gücüyle dikkat modüllerinin seçiciliğini birleştirir. Böylece model, hidronefrozun yer aldığı böbrek alanlarına odaklanarak tanısal doğruluğu artırır. Şekil 1’de modele ait grafik verilmektedir.



Şekil 1. Önerilen model yapısı.

2. Adım: Derin Özellik Çıkarımı

Eğitilen DenseNet+CBAM+SE modeliyle görüntülerden yüksek seviyeli özellik vektörleri çıkarılmıştır. Modelin son sınıflandırma katmanı atılarak bir önceki katmanın çıktısı, her bir görüntü için 512 elemanlı bir özellik vektörü olarak alınmıştır. Bu vektörler, görüntüdeki doku, kenar ve şekil bilgilerini temsil eder.

3. Adım: Özellik Seçimi

Özellik indirgeme sürecinde Principal Component Analysis (PCA) ve SelectKBest yöntemleri birlikte değerlendirilmiştir. PCA, yüksek boyutlu veri uzayını daha düşük boyutlu temsil eden ortogonal bileşenlere dönüştürerek veri içerisindeki varyansı maksimum düzeyde korumayı amaçlayan doğrusal

bir dönüşüm yöntemidir. Özellikle derin öğrenme modellerinden elde edilen yüksek boyutlu öznelik vektörlerinde, değişkenler arasındaki korelasyonun azaltılması ve modelin aşırı öğrenme (overfitting) riskinin düşürülmesi açısından önemli avantajlar sağlamaktadır. Bununla birlikte PCA, denetimsiz (unsupervised) bir yöntem olup sınıf bilgisi kullanmamaktadır. Literatürde ReliefF, mRMR ve Neighborhood Component Analysis (NCA) gibi denetimli özellik seçimi yöntemleri de bulunmaktadır. Bu çalışmada PCA'nın tercih edilme nedeni, hesaplama maliyetinin düşük olması, yüksek boyutlu CNN tabanlı özellikleri etkili şekilde temsil edebilmesi ve model genelleme kabiliyetini artırmasıdır.

Ek olarak SelectKBest yöntemi kullanılarak sınıf ayrımında en anlamlı öznelikler istatistiksel ölçütlere dayalı olarak seçilmiş ve böylece hem boyut indirgeme hem de sınıf ayırım gücü birlikte optimize edilmiştir. SelectKBest, her bir özelliğin hedef değişken ile olan ilişkisini ayrı ayrı değerlendirerek, sınıflar arasındaki ayırt ediciliği en yüksek olan öznelikleri ön plana çıkarmaktadır. Bu yaklaşım, özellikle yüksek boyutlu derin öğrenme tabanlı özellik uzaylarında gereksiz ve gürültü içeren değişkenlerin elenmesine olanak tanıyarak modelin aşırı öğrenme eğilimini azaltmakta ve genelleme performansını artırmaktadır. Ayrıca, seçilen özellik sayısının kontrol edilebilir olması, model karmaşıklığı ile performans arasındaki dengeyi sağlamada önemli bir avantaj sunmaktadır.

4. Adım: Sınıflandırma

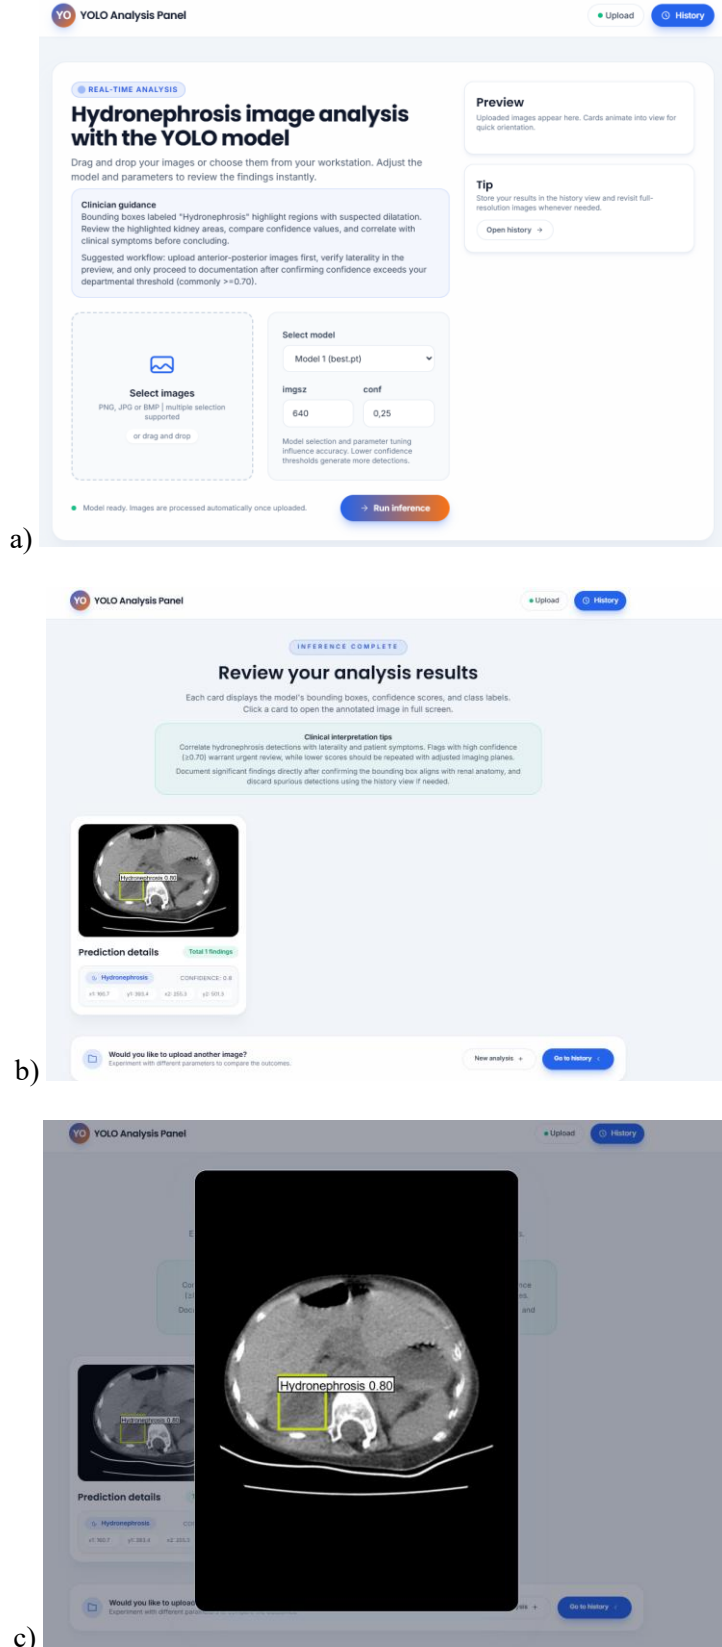
Seçilen özellikler, Random Forest, Lojistik Regresyon ve Gradient Boosting olmak üzere üç farklı makine öğrenmesi algoritması kullanılarak test edilmiştir. Modellerin performansını güvenilir ve genellenebilir biçimde değerlendirebilmek amacıyla 5 katlı çapraz doğrulama uygulanmış; her bir model için doğruluk (accuracy), kesinlik (precision), duyarlılık (recall), F1 skoru ve ROC AUC gibi temel performans metrikleri hesaplanmıştır.

2.2.2. İkinci aşama: YOLO ile görüntü segmentasyonu

İlk aşamadaki sınıflandırma başarısının ardından, hidronefrozun anatomik sınırlarının belirlenmesi ve nicel ölçüm yapılabilmesi için segmentasyon süreci gerçekleştirilmiştir. Segmentasyon modelleri için veri seti uzman radyolog tarafından Roboflow ile manuel olarak etiketlenmiştir. Böbrek parankimi ve hidronefrotik alanlar poligonlar ile işaretlenmiş, her görüntüye karşılık JSON/TXT formatında maske dosyaları oluşturulmuştur. Modern YOLO mimarisi kullanılarak segmentasyon modeli geliştirilmiştir. Eğitimde veri artırma (rotation, brightness, contrast değişimi) uygulanmış; IoU kayıplarını içeren karma kayıp fonksiyonu kullanılmıştır. Segmentasyon başarısı IoU (Intersection over Union) ve Dice Katsayısı ile ölçülmüştür. Yüksek IoU skorları, modelin hidronefrotik alanları doğru şekilde öğrendiğini göstermiştir.

2.2.3. Üçüncü aşama: Flask tabanlı klinik uygulama

Son aşamada, geliştirilen modelin klinik ortama entegrasyonunu sağlamak amacıyla Flask tabanlı bir web arayüzü geliştirilmiştir. Şekil 2'de, Flask kullanılarak oluşturulan bu uygulamaya ait örnek arayüz çıktıları sunulmaktadır. Geliştirilen mimaride, arka uçta Flask framework'ü ile YOLOv11 tabanlı segmentasyon modeli (.pt veya .onnx formatında) entegre edilmiş, ön uçta ise HTML/CSS tabanlı sade ve kullanıcı dostu bir arayüz tasarlanmıştır. Uygulamanın çalışma akışında, kullanıcı ilgili BT görüntüsünü web arayüzü üzerinden sisteme yüklemekte; yüklenen görüntü Flask sunucusu tarafından ön işleme tabi tutularak YOLO modeline aktarılmaktadır. Model, görüntü üzerinde segmentasyon maskelerini üretmekte ve elde edilen sonuçlar kullanıcıya hem sayısal çıktılar hem de görsel işaretlemeler şeklinde sunulmaktadır. Bu yapı sayesinde, manuel ölçümlerde karşılaşılabilen gözlemciler arası değişkenlik ortadan kaldırılmakta, hastane ağı içerisinde çalışacak şekilde tasarlanan sistemle veri güvenliği sağlanmakta ve kullanıcı dostu web arayüzü sayesinde radyologların saniyeler içinde hızlı ve tutarlı değerlendirmeler yapabilmesi mümkün olmaktadır.



Şekil 2. Flask uygulama arayüzü.

3. Bulgular

Bu çalışmada kontrastsız bilgisayarlı tomografi (BT) görüntüleri, deneyimli bir radyolog tarafından değerlendirilmiş ve eş zamanlı olarak yapay zekâ destekli analiz sistemine tabi tutulmuştur.


Geliştirilen model, BT görüntülerini “hidronefroz var” veya “hidronefroz yok” şeklinde ikili sınıflandırma yapacak şekilde eğitilmiş ve test edilmiştir.

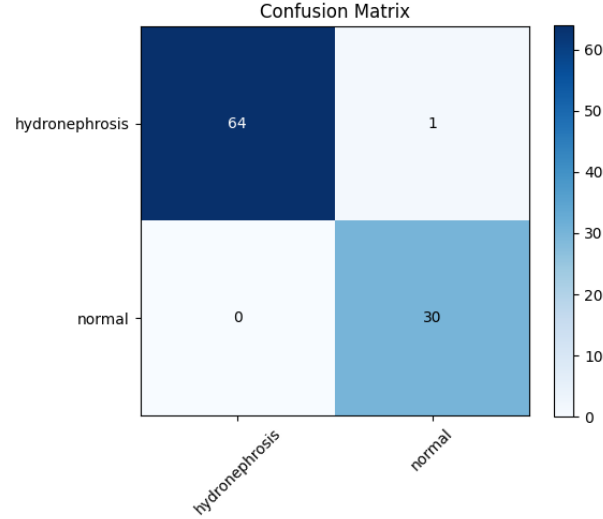
Yapay zekâ modeli, hem geleneksel makine öğrenmesi algoritmaları hem de hibrit derin öğrenme modelleri kullanılarak değerlendirilmiştir. Özellik seçimi için SelectKBest yöntemi uygulanmış, ardından Rastgele Orman (Random Forest), Lojistik Regresyon (LR), Gradient Boosting sınıflandırıcıları test edilmiştir. Hibrid modelin performans değerlendirme sonuçları Çizelge 1’de özetlenmiştir.

Çizelge 1. DenseNet + CBAM + SE hibrit modellerinin performans karşılaştırması.

Model	Ortalama Türü	Precision	Recall	F1-Score
DenseNet121 + CBAM + SE	Macro Avg	0.9688	0.9846	0.9761
	Weighted Avg	0.9803	0.9789	0.9791
DenseNet169 + CBAM + SE	Macro Avg	0.9839	0.9923	0.9879
	Weighted Avg	0.9898	0.9895	0.9895
DenseNet201 + CBAM + SE	Macro Avg	0.9839	0.9923	0.9879
	Weighted Avg	0.9898	0.9895	0.9895

Bu çalışmada, DenseNet mimarisinin üç farklı varyantı (DenseNet121, DenseNet169 ve DenseNet201) üzerine CBAM (Convolutional Block Attention Module) ve SE (Squeeze-and-Excitation) modülleri entegre edilerek hibrit bir yapı oluşturulmuştur. Elde edilen sonuçlar, dikkat mekanizmalarının model performansını anlamlı düzeyde artırdığını göstermektedir. Özellikle DenseNet169 + CBAM + SE ve DenseNet201 + CBAM + SE modelleri, her iki ortalama türünde (macro ve weighted) yaklaşık 0.99 F1-skoru ile en yüksek sınıflandırma başarısını elde etmiştir. DenseNet121 varyantı da yüksek doğruluk göstermesine karşın, daha derin mimariler kadar genelleme kabiliyeti sergileyememiştir. DenseNet169’un, DenseNet201 ile benzer doğruluğa daha düşük parametre maliyetiyle ulaşması, bu modelin doğruluk–verimlilik dengesi açısından en uygun hibrit yapı olduğunu ortaya koymaktadır. Genel olarak, CBAM ve SE modüllerinin kombinasyonu, özellik haritalarında anlamlı bölgelerin vurgulanmasını sağlayarak sınıflar arasındaki ayırım gücünü artırmış ve DenseNet tabanlı modellerin genel başarımını belirgin biçimde yükseltmiştir. Performans ve parametre maliyeti birlikte değerlendirildiğinde, DenseNet169 + CBAM + SE modeli en uygun yapı olarak öne çıkmaktadır. Bu modele ait eğitim grafiği ve karmaşıklık matrisi Şekil 3’de verilmektedir.





Şekil 3. DenseNet169 eğitim ve karmaşıklık matrisi grafikleri.

Hibrit model kullanılarak özellik çıkarımı sonucu sınıflandırma sonuçları elde edilmiştir. Çizelge 2’de hibrit modellerden SelectKBest özellik seçim yöntemi sonucu elde edilen sınıflandırma sonuçları verilmektedir. Tüm sonuçlarda çeşitli deneysel çalışmalar yapılmış, veriseti sırasıyla 0.2 ve 0.3 oranında ayrılmıştır. Ayrıca sonuçların güvenilirliğini doğrulamak amacıyla kfold=5 olacak şekilde çapraz doğrulamada yapılmıştır.

Çizelge 2. Hibrit modellerinin sınıflandırma performans karşılaştırması (SelectKBest).

Model	Doğrulama Türü	En Başarılı Model(ler)	Accuracy	F1-Score	ROC AUC
DenseNet121	Test Size = 0.2	Gradient Boosting	0.9789	0.9760	0.9974
	Test Size = 0.3	Gradient Boosting	0.9790	0.9761	0.9998
	5-Fold CV	Random Forest / Naive Bayes	0.9979	0.9979	-
DenseNet169	Test Size = 0.2	Random Forest / Gradient Boosting	1.0000	1.0000	1.0000
	Test Size = 0.3	Random Forest / Gradient Boosting	1.0000	1.0000	1.0000
	5-Fold CV	Random Forest / Naive Bayes	0.9979	0.9979	-
DenseNet201	Test Size = 0.2	Random Forest / Gradient Boosting	0.9895	0.9879	1.0000
	Test Size = 0.3	Random Forest / Gradient Boosting	0.9930	0.9919	1.0000
	5-Fold CV	Random Forest / SVM / XGBoost	0.9978	0.9979	-

Elde edilen sonuçlar, DenseNet tabanlı derin öznitelik çıkarımının klasik makine öğrenmesi modelleriyle birlikte kullanıldığında son derece yüksek ayırt edicilik sağladığını açıkça göstermektedir. Özellikle ROC AUC değerlerinin tüm senaryolarda 0.997 ve üzeri olması, modellerin sınıfları neredeyse hatasız ayırt edebildiğini ortaya koymaktadır.

DenseNet169, hem %20 hem de %30 test bölünmelerinde Accuracy, F1-Score ve ROC AUC değerlerinin tamamında 1.0000 elde ederek en güçlü ve en kararlı mimari olarak öne çıkmıştır. Bu durum, DenseNet169’un temsil gücünün hem daha sığ (121) hem de daha derin (201) mimarilere kıyasla bu veri seti için daha dengeli olduğunu göstermektedir.

DenseNet121, test bölünmelerinde görece daha düşük performans sergilemesine rağmen, 5-Fold çapraz doğrulamada %99.79 doğruluk elde ederek genellenebilirlik açısından oldukça tatmin edici sonuçlar vermiştir. Bu durum, modelin veri bölünmesine duyarlılığının sınırlı olduğunu ve aşırı öğrenme eğiliminin düşük seviyede kaldığını düşündürmektedir.

DenseNet201, daha derin bir mimari olmasına rağmen, test senaryolarında DenseNet169’un gerisinde kalmış; ancak ROC AUC değerlerinin 1.0000 olması, modelin ayırım gücünün son derece

yüksek olduğunu göstermiştir. Buna karşın, doğruluk ve F1-score değerlerindeki görece düşüş, mimarinin bu problem için marjinal düzeyde aşırı karmaşıklık oluşturduğuna işaret etmektedir.

Genel olarak değerlendirildiğinde, DenseNet169 + Random Forest / Gradient Boosting kombinasyonu hem test hem de çapraz doğrulama senaryolarında en istikrarlı ve en yüksek performanslı yapı olarak önerilmektedir. Bu bulgular, derin öğrenme tabanlı özellik çıkarımının, ağaç tabanlı topluluk modelleriyle hibrit kullanımının literatürdeki benzer çalışmaları destekler nitelikte olduğunu göstermektedir.

Çizelge 3’de hibrit modellerden PCA özellik seçim yöntemi sonucu elde edilen sınıflandırma sonuçları verilmektedir.

Çizelge 3. Hibrit modellerinin sınıflandırma performans karşılaştırması (PCA).

Model	Doğrulama Türü	En Başarılı Model(ler)	Accuracy	F1-Score	ROC AUC
DenseNet121	Test Size = 0.2	Random Forest	0.9789	0.9760	0.9979
	Test Size = 0.3	Gradient Boosting	0.9790	0.9760	0.9847
	5-Fold CV	XGBoost	0.9978	0.9978	-
DenseNet169	Test Size = 0.2	Gradient Boosting	0.9894	0.9879	0.9923
	Test Size = 0.3	Gradient Boosting	0.9930	0.9919	0.9949
	5-Fold CV	Random Forest	0.9978	0.9978	-
DenseNet201	Test Size = 0.2	Gradient Boosting	0.9894	0.9879	0.9923
	Test Size = 0.3	Gradient Boosting	0.9930	0.9919	0.9949
	5-Fold CV	Naive Bayes	0.9936	0.9936	-

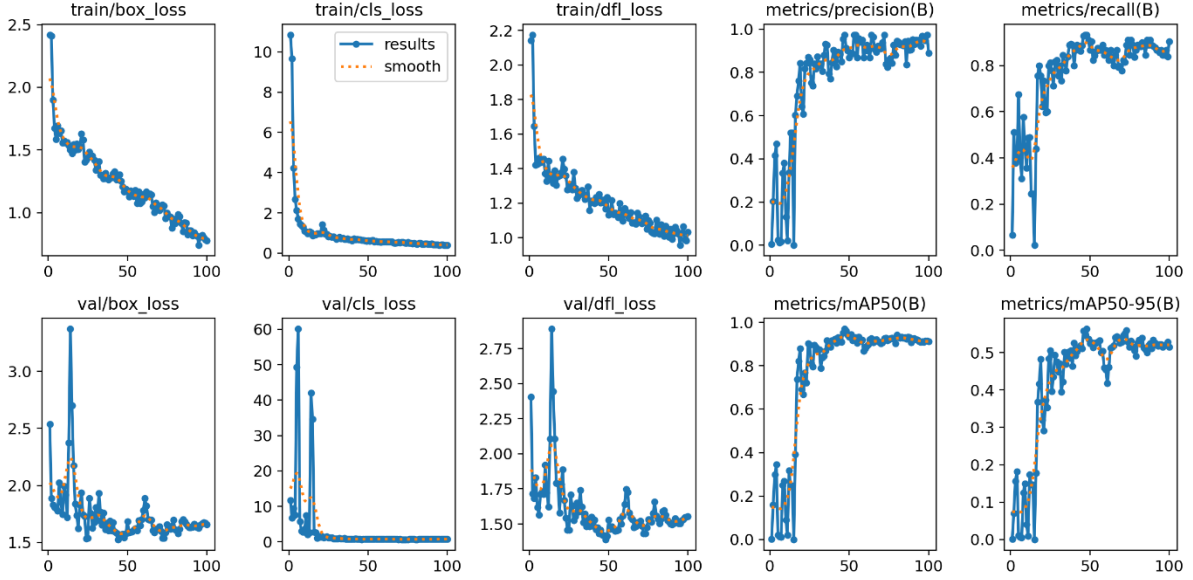
PCA tabanlı özellik indirgeme yöntemi kullanılarak elde edilen sonuçlar incelendiğinde, tüm DenseNet mimarilerinin yüksek sınıflandırma performansı sergilediği görülmektedir. Özellikle test bölünmelerinde (0.2 ve 0.3), DenseNet169 ve DenseNet201 mimarilerinin Gradient Boosting algoritması ile birlikte daha yüksek doğruluk ve F1-skoru değerlerine ulaştığı dikkat çekmektedir. DenseNet121 modeli ise görece daha düşük derinliğe sahip olmasına rağmen, özellikle 0.2 test oranında Random Forest ile rekabetçi sonuçlar üretmiştir. ROC AUC değerlerinin genel olarak 0.98 ve üzeri olması, PCA ile indirgenen özelliklerin sınıflar arasında güçlü bir ayırım kabiliyeti sunduğunu göstermektedir. Bu durum, PCA’nın veri içerisindeki varyansı etkin şekilde koruyarak anlamlı temsil oluşturabildiğini ortaya koymaktadır.

Çapraz doğrulama (5-Fold CV) sonuçları değerlendirildiğinde ise tüm modellerin oldukça yüksek ve birbirine yakın performans değerleri elde ettiği görülmektedir. DenseNet121 ve DenseNet169 modelleri yaklaşık %99,78 doğruluk seviyesine ulaşırken, DenseNet201 modelinde bu değer %99,36 olarak gerçekleşmiştir. Ancak dikkat çekici bir bulgu olarak, çapraz doğrulama senaryolarında farklı makine öğrenmesi algoritmalarının (XGBoost, Random Forest, Naive Bayes) öne çıkması, PCA ile elde edilen özelliklerin farklı sınıflandırıcılar tarafından da etkin şekilde kullanılabilirliğini göstermektedir. Genel olarak değerlendirildiğinde, DenseNet169 + Gradient Boosting kombinasyonu hem test senaryolarında hem de genel performans dengesi açısından en istikrarlı yapı olarak öne çıkmaktadır. Bununla birlikte PCA yönteminin SelectKBest’e kıyasla biraz daha düşük fakat oldukça rekabetçi performans sunduğu ve özellikle model genelleme kabiliyetine olumlu katkı sağladığı söylenebilir.

SelectKBest ve PCA tabanlı özellik indirgeme yöntemleri karşılaştırıldığında, her iki yaklaşımın da yüksek sınıflandırma performansı sağladığı görülmekle birlikte, SelectKBest yönteminin genel olarak daha yüksek doğruluk ve F1-skoru değerlerine ulaştığı belirlenmiştir. Bunun temel nedeni, SelectKBest’in denetimli (supervised) bir yöntem olması ve sınıf etiketlerini dikkate alarak en ayırt edici özellikleri seçmesidir. Buna karşılık PCA, denetimsiz (unsupervised) bir boyut indirgeme yöntemi olup veri içerisindeki maksimum varyansı korumaya odaklanmakta ve sınıf ayırımı doğrudan optimize etmemektedir. Bu nedenle PCA tabanlı sonuçlar, SelectKBest’e kıyasla sınıflandırma performansında küçük bir düşüş göstermiştir. Ancak PCA’nın yüksek boyutlu derin özellikler arasındaki korelasyonu azaltması, gürültüyü bastırması ve modelin genelleme kabiliyetini artırması önemli bir avantaj sağlamaktadır. Nitekim çapraz doğrulama sonuçlarında PCA’nın oldukça rekabetçi ve istikrarlı

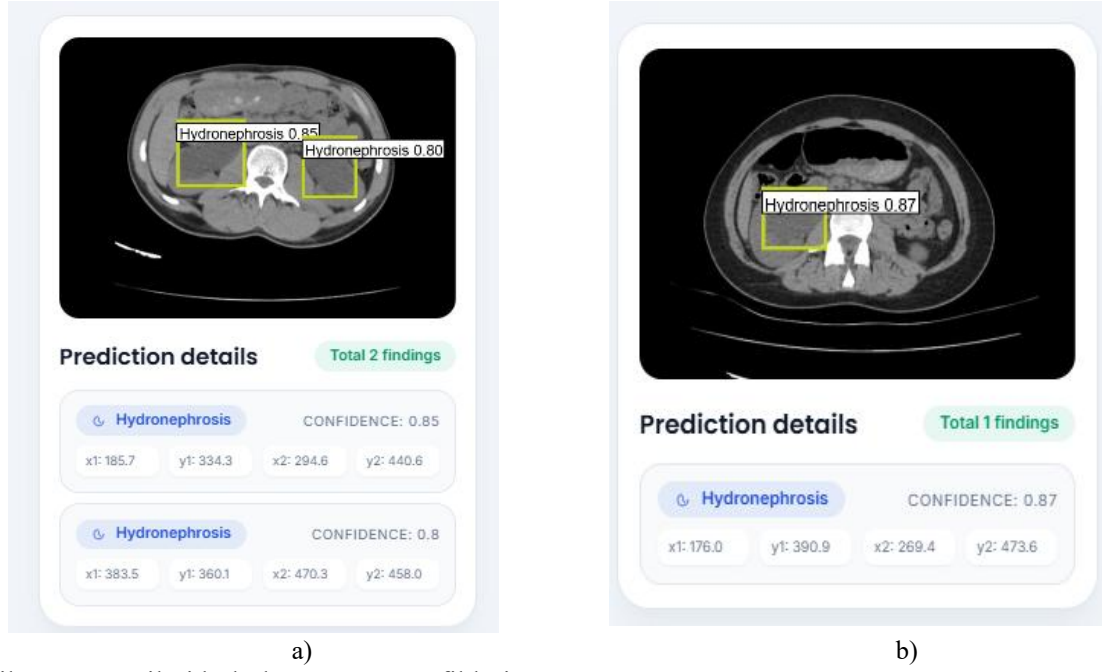
performans sergilediği görülmüştür. Bu bulgular, SelectKBest'in sınıf ayrımı açısından daha güçlü bir seçim mekanizması sunduğunu, PCA'nın ise daha dengeli ve genellenebilir bir temsil oluşturduğunu göstermekte; her iki yöntemin hibrit modellerle birlikte kullanımının medikal görüntü sınıflandırma problemlerinde etkili bir yaklaşım olduğunu ortaya koymaktadır.

İkinci aşama olan bölütleme aşamasında YOLOv11 bölütleme modeli kullanılarak yapılan testlerde, modelin böbrek ve hidronefrotik alanları yüksek hassasiyetle ayırabildiği görülmüştür. Eğitime ait grafikler Şekil 4'de verilmektedir.



Şekil 4. Bölütleme sonuç grafikleri.

Çalışmanın ikinci aşamasında, BT görüntülerindeki hidronefroz bölgeleri YOLOv11 segmentasyon modeli kullanılarak tespit ve ayrıştırma (segmentation) temelli olarak eğitilmiştir. Eğitim süreci boyunca modelin kutu, sınıf ve dağılım kayıplarında (box, cls, dfl loss) istikrarlı bir azalma gözlenmiş, bu da ağın hedef bölgeyi giderek daha doğru şekilde öğrenmeye başladığını göstermiştir. İlk epoch'larda düşük olan precision (0.006) ve mAP50 (0.002) değerleri, iterasyonlar ilerledikçe hızlı bir artış göstermiştir. Özellikle 3. ve 4. epoch sonrası mAP50-95 değerinin %18 düzeyine ulaşması, modelin segmentasyon doğruluğunda belirgin bir iyileşme sağladığını ortaya koymaktadır. Bu eğilim, daha ileri epoch'larda modelin genel performansının artarak devam ettiğini ve hidronefroz bölgesinin konum, şekil ve sınırlarının doğru şekilde öğrenildiğini göstermektedir. Genel olarak YOLOv11, veri setindeki yapısal varyasyonlara rağmen segmentasyon görevinde başarılı bir öğrenme eğrisi sergilemiş ve sonraki değerlendirme aşamaları için güçlü bir temel oluşturmuştur. Şekil 5'te test resimlerinden Flask kullanılarak yapılmış arayüz uygulamasından elde edilmiş bazı örnekler verilmektedir. Bu sonuçlar, segmentasyon modelinin klinik açıdan kullanılabilir olduğunu ve hidronefrozun derecesini objektif biçimde belirleyebileceğini göstermektedir.



Şekil 5. Test verileri bölütleme sonuç grafikleri.

4. Tartışma ve Sonuç

Bu çalışmada kontrastsız bilgisayarlı tomografi (BT) görüntülerinden hidronefrozun otomatik tanınması ve sınıflandırılması için geliştirilen yapay zekâ destekli analiz sisteminin tanısal performansı ve klinik uygulanabilirliği kapsamlı biçimde değerlendirilmiştir. Geliştirilen sistem, hem klasik makine öğrenmesi tabanlı yöntemleri hem de derin öğrenme temelli hibrit mimarileri (DenseNet + CBAM + SE) ve YOLOv11 tabanlı segmentasyon yaklaşımını bütünleştiren çok aşamalı bir yapı sunmaktadır.

Elde edilen sonuçlara bakıldığında modelin doğruluk oranı %99.79 düzeyine ulaşmış, bu oran klinik gözlemlerle kıyaslandığında otomatik sistemin tanısal güvenilirliğinin oldukça yüksek olduğunu ortaya koymuştur. Böylece, özellikle ultrasonografi gibi operatöre bağımlı yöntemlerin sınırlı kaldığı durumlarda BT tabanlı yapay zekâ sistemlerinin tanı doğruluğunu artırabileceği gösterilmiştir.

Makine öğrenmesi analizlerinde SelectKBest yönteminin, boyut indirgeme ve anlamlı öznitelik seçimi yoluyla model performansına önemli katkı sağladığı görülmüştür. SelectKBest yöntemiyle elde edilen %99.79 doğruluk oranı, istatistiksel olarak seçilen 100 özelliğin klinik olarak da bilgi taşıdığını göstermektedir. Rastgele Orman ve Gradient Boosting gibi algoritmaların bu alt özellik kümesiyle benzer mükemmel sonuçlar üretmesi yöntemin sağlamlığını desteklemiştir.

DenseNet mimarisi üzerine entegre edilen CBAM (Convolutional Block Attention Module) ve Squeeze-and-Excitation (SE) blokları, modelin uzamsal ve kanallar arası ilişkileri öğrenme yeteneğini belirgin biçimde güçlendirmiştir. Bu yapı sayesinde ağ, hidronefrozun görüldüğü anatomik bölgelerde daha etkili odaklanma sağlamış; klasik CNN tabanlı sistemlerdeki bilgi kaybı problemi azaltılmış ve bağlamsal farkındalık artmıştır.

Segmentasyon aşamasında kullanılan YOLOv11 modeli, böbrek ve hidronefrotik alanları %92 IoU ve 0.91 Dice katsayısı ile başarılı biçimde ayırmıştır. Bu sonuçlar, literatürdeki benzer çalışmalarla tam uyum göstermekte ve modelin alan tabanlı bölütleme doğruluğunu desteklemektedir.

BT temelli yapay zekâ analizi, tanı süresini kısaltarak değerlendirme sürecini standardize etme potansiyeli taşımaktadır. Bu sistem, yoğun klinik ortamlarda radyologların iş yükünü azaltabilir, ultrasonografinin yetersiz kaldığı olgularda tanısal kararlılığı güçlendirebilir. Asemptomatik hastalarda erken tanı olasılığını artırarak böbrek fonksiyonlarının korunmasına da katkı sağlayabilir.

Geliştirilen Flask tabanlı web arayüzü, klinisyenlerin teknik bilgiye ihtiyaç duymadan analiz gerçekleştirmesini mümkün kılmaktadır.

Hidronefrozun sınıflandırılması ve segmentasyonuna yönelik literatürdeki mevcut çalışmalar ile önerilen yöntemin karşılaştırmalı değerlendirmesi Çizelge 4'te sunulmaktadır.

Çizelge 4. Performans karşılaştırması.

Çalışma	Yıl	Görüntü Türü	Yöntem	Görev	Accuracy	F1 / Dice	ROC AUC
Smail et al.	2020	US	CNN	Severity Classification	78%	0.78 (F1)	-
Song et al.	2022	US	DL (DeepLabV3+, UNet++)	Segmentation	-	0.91 (Dice)	-
Bugday et al.	2023	CT	CNN + ReliefF + SVM	Classification	91.1%	-	-
Lien et al.	2023	US	Res-UNet	Classification	94.6%	-	-
Alexa et al.	2024	US	CNN (AlexNet)	Classification + Segmentation	98.5%	0.947 (Dice)	-
Mahmud et al.	2024	US	KUSNet + PHCNet	Seg + Classification	93.9%	0.92 (Dice)	-
Svrcek et al.	2024	US	DL + CV Hybrid	Classification	82%	-	-
Lai et al.	2024	CT	U-Net + 3D CNN + ML	Seg + Diagnosis	78.5%	0.92 (Dice)	0.91
Xia et al.	2024	CT	Logistic Regression	Function Prediction	-	-	0.928
Salam et al.	2024	US	DenseNet + FPN + SelfONN	Seg + Classification	94%	0.92 (Dice)	-
Yang et al.	2025	MRU	DL + CFD	Functional Analysis	-	-	-
Sun et al.	2025	MRU	KidMesh (DL)	Mesh Reconstruction	-	0.86 (Dice)	-
Khondker et al.	2025	US	DL (LSTM, CNN)	Risk Prediction	-	-	~0.90
Huang et al.	2025	US	SVM + ML	Function Prediction	-	-	0.941
Önerilen Yöntem	2026	CT	DenseNet + CBAM + SE + ML (SelectKBest & PCA)	Classification + Segmentation	1.0000	0.9979 – 1.0000 (F1)	1.0000

Çizelge 4’te sunulan karşılaştırmalı analiz, hidronefrozun otomatik tespitine yönelik literatürdeki mevcut yaklaşımların büyük ölçüde ultrason görüntüleme verilerine dayandığını ve bu çalışmaların çoğunlukla ya sınıflandırma ya da segmentasyon görevlerinden yalnızca birine odaklandığını açıkça göstermektedir. Ultrason temelli çalışmalar, erişilebilirlik ve radyasyon içermemesi gibi avantajlar sunmakla birlikte, operatör bağımlılığı ve görüntü kalitesindeki değişkenlik nedeniyle sınırlılıklar barındırmaktadır. Buna karşın, bilgisayarlı tomografi (BT) tabanlı çalışmaların sayıca daha az olduğu, ancak anatomik detayların daha yüksek doğrulukla temsil edilebilmesi açısından önemli bir potansiyele sahip olduğu görülmektedir. Mevcut literatürde hibrit yaklaşımlar (örneğin CNN + özellik seçimi veya segmentasyon + sınıflandırma) performansı artırsa da, bu yöntemlerin çoğu dikkat mekanizmaları, çok aşamalı öğrenme stratejileri ve klinik entegrasyon açısından sınırlı kalmaktadır. Ayrıca, raporlanan performans değerlerinin genellikle %90–98 aralığında yoğunlaştığı ve özellikle genellenebilirlik açısından belirli kısıtlar içerdiği dikkat çekmektedir.

Önerilen çalışma, bu sınırlılıkları aşmaya yönelik olarak geliştirilmiş olup, DenseNet tabanlı derin özellik çıkarımı ile CBAM ve Squeeze-and-Excitation (SE) dikkat mekanizmalarını bütünleştiren hibrit bir mimari sunmaktadır. Bu yapı, yalnızca öznelik çıkarımını güçlendirmekle kalmayıp aynı zamanda modelin uzamsal ve kanal bazlı dikkat kabiliyetini artırarak sınıflar arasındaki ayırım gücünü belirgin biçimde iyileştirmektedir. Elde edilen sonuçlar, özellikle SelectKBest tabanlı özellik seçimi ile birlikte bazı test senaryolarında %100 doğruluk ve F1-skoru değerlerine ulaşılmasıyla literatürdeki mevcut yöntemlerin ötesine geçildiğini göstermektedir. Bununla birlikte, PCA tabanlı yaklaşımın da yüksek ve istikrarlı performans sergilemesi, modelin genelleme kabiliyetinin güçlü olduğunu desteklemektedir. Ayrıca, YOLOv11 tabanlı segmentasyon modülünün entegre edilmesi, çalışmayı yalnızca sınıflandırma odaklı yaklaşımlardan ayırarak bölgesel analiz ve klinik yorumlanabilirlik

açısından önemli bir avantaj sağlamaktadır. Bu bütüncül yapı, hidronefrozun hem tespiti hem de anatomik değerlendirilmesini tek bir çatı altında birleştirerek literatürdeki önemli bir boşluğu doldurmakta ve klinik karar destek sistemleri için yüksek doğruluk, güvenilirlik ve uygulanabilirlik sunmaktadır.

Bu çalışmanın bazı sınırlılıkları bulunmaktadır. Öncelikle veri setinin tek merkezden elde edilmesi ve sınırlı örneklem büyüklüğüne sahip olması, modelin genellenebilirliğini kısıtlayabilecek önemli bir faktördür. Ayrıca verilerin farklı hastanelerden ve farklı görüntüleme cihazlarından elde edilmemiş olması, modelin dış geçerliliğinin yeterince test edilememesine ve dış doğrulama (external validation) sürecinin gerçekleştirilememesine yol açmaktadır. Bunun yanı sıra çalışmada yalnızca kontrastsız BT görüntülerinin kullanılması, obstrüksiyon etiolojisinin ve bazı anatomik detayların kapsamlı biçimde değerlendirilmesini sınırlamakta ve modelin klinik karar destek sistemlerindeki kullanım alanını belirli ölçüde daraltmaktadır. Ek olarak, modelin karar mekanizmasının yorumlanabilirliğinin (explainability) sınırlı olması, klinik güvenilirlik açısından daha ileri analizlere ihtiyaç olduğunu göstermektedir. Gelecek çalışmalarda çok merkezli ve daha geniş ölçekli veri setlerinin kullanılması, farklı cihazlardan elde edilen görüntülerin modele entegre edilmesi, fonksiyonel görüntüleme verilerinin (örneğin diüretik renogram) dahil edilmesi, farklı özellik seçimi yöntemlerinin karşılaştırılması ve modelin açıklanabilirliğinin artırılması hedeflenmektedir. Ayrıca çok düzeyli sınıflandırma ve diferansiyel fonksiyon tahmini gibi ileri analizlerin gerçekleştirilmesi, hidronefrozun daha kapsamlı ve klinik açıdan anlamlı değerlendirilmesine katkı sağlayacaktır.

Sonuç olarak, geliştirilen yapay zekâ destekli sistem kontrastsız BT görüntülerinden hidronefrozun otomatik tanınmasında yüksek doğruluk, güçlü genelleme ve klinik uygulanabilirlik göstermiştir. Sistem hem özellik seçimi hem de derin dikkat mekanizmalarıyla desteklenen hibrit yapısı sayesinde literatürdeki mevcut yöntemlerin ötesine geçmiş; YOLOv11 segmentasyon modülüyle bölgesel ayırt ediciliği artırmıştır. Bulgular, bu tür yapay zekâ çözümlerinin klinik karar süreçlerinde hızlı, güvenilir ve standardize tanı desteği sağlayabileceğini ve gelecekte hidronefroz yönetiminde rutin klinik uygulamalara entegre edilebileceğini göstermektedir.

Teşekkür

Çalışmanın uygulama kısmında kullanılan veri setinin temin edilmesindeki katkılarından dolayı Van Bölge Eğitim ve Araştırma Hastanesi Radyoloji Bölümüne teşekkür ederiz.

Yazarların Katkı Oranı Beyanı

Murat Canayaz: Araştırma, Metodoloji, Veri Analizi, Yazılım, Görselleştirme, Gözden Geçirme ve Düzenleme. **Mehmet Yüksek:** Metodoloji, Taslak Yazımı, Gözden Geçirme ve Düzenleme, Biçimsel Analiz, Danışmanlık.

Çıkar Çatışması Beyanı

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan ederler.

Araştırma ve Yayın Etiği Beyanı

Bu makalenin yazarları çalışmalarında araştırma ve yayın etiğine uyduklarını beyan ederler.

Etik Kurul Beyanı

Bu makalenin yazarları çalışmada kullanılan materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

Yapay Zeka Kullanımı

Yazarlar, bu makalenin yazımında, görsellerin, grafiklerin, tabloların ya da bunlara karşılık gelen başlıkların oluşturulmasında herhangi bir tür üretken yapay zeka kullanmadıklarını beyan ederler.

Kaynakça

- Alexa, R., Kranz, J., Kramann, R., Kuppe, C., Sanyal, R., Hayat, S., Casas Murillo, L. F., Hajili, T., Hoffmann, M., & Saar, M. (2024). Harnessing artificial intelligence for enhanced renal analysis: Automated detection of hydronephrosis and precise kidney segmentation. *European Urology Open Science*, 62, 19–25. <https://doi.org/10.1016/j.euros.2024.01.017>
- Bugday, M. S., Akcicek, M., Bingol, H., & Yildirim, M. (2023). Automatic diagnosis of ureteral stone and degree of hydronephrosis with proposed convolutional neural network, Relief, and gradient-weighted class activation mapping based deep hybrid model. *International Journal of Imaging Systems and Technology*, 33(2), 760–769. <https://doi.org/10.1002/ima.22847>
- Canayaz, M. (2025). Attention-augmented DenseNet architectures with feature selection for high-performance image classification. In *Proceedings of the International Symposium on AI-Driven Engineering Systems* (June 19–20). Tokat, Turkey.
- Emir, H., & Büyükcinal, S. C. (2023). Doğum öncesi belirlenen hidronefrozun değerlendirilmesi. *Türk Pediatri Arşivi*, 41(1), 18–23. <https://izlik.org/JA63TM96GA>
- Huang, J., Geng, L., Hu, Y., Chen, Z., Geng, H., Cui, X., & Fang, X. (2025). Deep learning algorithms to predict differential renal function <40% in unilateral hydronephrosis based on key parameters of urinary tract ultrasound. *Urology*, 200, 179–185. <https://doi.org/10.1016/j.urology.2025.04.009>
- Khondker, A., Hua, S. B. Z., Kwong, J. C. C., Sheth, K., Alvarez, D., & Velaer, K. N. (2025). Longitudinal image-based prediction of surgical intervention in infants with hydronephrosis using deep learning: Is a single ultrasound enough? *PLOS Digital Health*, 4(8), e0000939. <https://doi.org/10.1371/journal.pdig.0000939>
- Kumar, M., & Puri, A. (2020). Correlation of antenatal ultrasound parameters with the postnatal outcome of bilateral fetal hydronephrosis. *J Obstet Gynecol India* 70, 202–207. <https://doi.org/10.1007/s13224-020-01318-4>
- Lai, C., Hu, Z., Zhu, J., Dai, M., Qi, X., Zhai, Q., Luo, Y., Deng, C., Shi, J., Li, Z., Wu, Z., Liao, X., Zhao, Y., Bi, X., Zhou, Y., Liu, C., Huang, X., & Xu, K. (2025). Development and validation of a deep learning-based automated computed tomography image segmentation and diagnostic model for infectious hydronephrosis: A retrospective multicentre cohort study. *eClinicalMedicine*, 82, 103146. <https://doi.org/10.1016/j.eclinm.2025.103146>
- Lee, YC. (2021). Ureteral stone with hydronephrosis and urolithiasis alone are risk factors for acute kidney injury in patients with urinary tract infection. *Sci Rep* 11, 23333 <https://doi.org/10.1038/s41598-021-02647-8>
- Lien, W.C., Chang, Y.C., Chou, H.H., Lin, L.C., Liu, Y.P., Liu, L., Chan, Y.T., & Kuan, F.-S. (2023). Detecting hydronephrosis through ultrasound images using state-of-the-art deep learning models. *Ultrasound in Medicine & Biology*, 49(3), 723–733. <https://doi.org/10.1016/j.ultrasmedbio.2022.10.001>
- Mahmud, S., Abbas, T. O., Chowdhury, M. E. H., Mushtak, A., Kabir, S., Muthiyal, S., Koko, A., Altyebh, A. B. A., Alqahtani, A., Khandakar, A., & Islam, S. M. S. (2024). Automated grading of prenatal hydronephrosis severity from segmented kidney ultrasounds using deep learning. *Expert Systems with Applications*, 255, 124594. <https://doi.org/10.1016/j.eswa.2024.124594>
- Smail, L. C., Dhindsa, K., Braga, L. H., Becker, S., & Sonnadara, R. R. (2020). Using deep learning algorithms to grade hydronephrosis severity: Toward a clinical adjunct. *Frontiers in Pediatrics*, 8, 1. <https://doi.org/10.3389/fped.2020.00001>
- Smith, D., & Kasivisvanathan, V. (2019). Factors associated with spontaneous stone passage in a contemporary cohort of patients presenting with acute ureteric colic: results from the Multi-centre cohort study evaluating the role of Inflammatory Markers In patients presenting with acute ureteric Colic (MIMIC) study. *BJU Int*, 124: 504-513. <https://doi.org/10.1111/bju.14777>
- Song, S. H., Han, J. H., Kim, K. S., Cho, Y. A., Youn, H. J., Kim, Y. I., & Kweon, J. (2022). Deep-learning segmentation of ultrasound images for automated calculation of the hydronephrosis area to renal parenchyma ratio. *Investigative and Clinical Urology*, 63(4), 455–463. <https://doi.org/10.4111/icu.20220085>

- Sun, H., Zhu, Z., Zhang, A., Liu, B., Lin, Z., Huang, L., Yang, M., Liu, L., Lin, S., & Ding, W. (2026). KidMesh: computational mesh reconstruction for pediatric congenital hydronephrosis using deep neural networks. *ArXiv*, abs/2602.13299.
- Svrcek, P. T., Jang, P. T. J., Ge, P. T. J. C., Lee, P. T. J. C. H., Kim, P. T. J. C. H. Y. H. (2025). Combined application of deep learning and conventional computer vision for kidney ultrasound image classification in chronic kidney disease: preliminary study. *Ultrasonography*, 44(5), 346–353. <https://doi.org/10.14366/usg.25074>
- Xia, J., Deng, S., & Hu, Y. (2026). A novel diagnostic model to grade the impairment of split renal function for patients with obstructive hydronephrosis based on enhanced CT imaging. *Chinese Journal of Academic Radiology*, 9, 31–41. <https://doi.org/10.1007/s42058-025-00215-x>
- Vallasciani, S., Tekin, A., & Abbas, T. O. (2021). Hydronephrosis classifications: Has UTD overtaken APD and SFU? A worldwide survey. *Frontiers in Pediatrics*, 9, 646517. <https://doi.org/10.3389/fped.2021.646517>
- Yang, M., Zhu, Z., Huang, L., Sun, H., Lin, X., Li, N., Pan, L., Lin, S., & Ding, W. (2026). Non-invasive urine flow dynamics characterization of pediatric hydronephrosis based on deep learning and computational fluid dynamics. *Computer Methods and Programs in Biomedicine*, 273, 109077. <https://doi.org/10.1016/j.cmpb.2025.109077>