

Açıklanabilir kuantum destekli hibrit öğrenme ile meme kanseri sınıflandırması

Breast cancer classification with explainable quantum-assisted hybrid learning

İlhan UYSAL* 

Burdur Mehmet Akif Ersoy Üniversitesi, Bucak Zeliha Tolunay Uygulamalı Teknoloji ve İşletmecilik Yüksekokulu, Bilişim Sistemleri ve Teknolojileri Bölümü, 15100, Burdur

• Geliş tarihi / Received: 07.06.2025

• Kabul tarihi / Accepted: 23.09.2025

Öz

Bu çalışma, meme kanseri tanısına yönelik olarak klasik makine öğrenmesi algoritmaları, derin öğrenme mimarileri ve kuantum destekli modellerin entegrasyonu ile oluşturulan açıklanabilir bir hibrit sınıflandırma yaklaşımı önermektedir. Breast Cancer Wisconsin (Diagnostic) veri seti üzerinde gerçekleştirilen analizde, Lojistik Regresyon, Rastgele Orman, Aşırı Gradyan Artırma (XGBoost), TabNet, Variational Quantum Classifier (VQC) ve Quantum Kernel Support Vector Classifier (QKSVC) gibi farklı sınıflandırıcılar kullanılmış, bu modellerin çıktıları yumuşak oylama (soft voting) yöntemiyle birleştirilerek nihai bir hibrit model oluşturulmuştur. Tabakalı on katlı çapraz doğrulama sonucunda topluluk modeli yaklaşık 0,995 ortalama AUC ve 0,98 doğruluk düzeyiyle yüksek bir başarı göstermiştir. Model kararlarının şeffaflığını artırmak amacıyla SHAP, LIME ve Q-MEDLEY gibi açıklanabilir yapay zekâ yöntemleri uygulanmıştır. Açıklanabilirlik analizlerinde ‘en kötü doku değeri’ (texture_worst), ‘tümör sınırındaki en belirgin içe çökük bölgelerin sayısı’ (concave points_worst) ve ‘tümör alan ölçümü standart hatası’ (area_se) gibi öznelitliklerin model kararları üzerinde belirleyici rol oynadığı tespit edilmiştir. Bu araştırma, kuantum bilişim destekli açıklanabilir sınıflandırma yaklaşımlarının tablo formatındaki biyomedikal veriler üzerindeki uygulanabilirliğini ortaya koyarak, literatüre özgün bir katkı sunmaktadır. Tek veri seti kullanılması ve kuantum modellerin gürültüsüz simülasyon ortamında değerlendirilmesi, sonuçların genellenebilirliğini sınırlayan başlıca etmenlerdir. Gelecek çalışmaların çok merkezli, dengesiz ve çok sınıflı veri kümelerinde dış doğrulama yapılması ve gerçek NISQ (gürültülü ara ölçekli kuantum) donanımlarında deneysel testler gerçekleştirilmesi önerilmektedir. Bulgular, kuantum çekirdek yöntemleriyle derin ve klasik öğrenme paradigmalarının açıklanabilir bir çerçevede bütünleştirilmesinin, klinik karar destek sistemleri için güvenilir ve yüksek performanslı çözümler sunma potansiyeli taşıdığını ortaya koymaktadır.

Anahtar kelimeler: Açıklanabilir yapay zekâ, Topluluk öğrenme yaklaşımı, Hibrit model, Kuantum makine öğrenmesi, Meme kanseri tanısı,

Abstract

This study proposes an explainable hybrid classification approach for breast cancer diagnosis by integrating classical machine learning algorithms, deep learning architectures, and quantum-assisted models. The analysis was conducted on the Breast Cancer Wisconsin (Diagnostic) dataset, employing classifiers such as Logistic Regression, Random Forest, Extreme Gradient Boosting (XGBoost), TabNet, Variational Quantum Classifier (VQC), and Quantum Kernel Support Vector Classifier (QKSVC). The outputs of these models were combined through a soft voting strategy to construct the final hybrid model. Stratified ten-fold cross-validation demonstrated that the ensemble achieved high performance, with an average AUC of approximately 0.995 and an accuracy level of 0.98. To enhance the transparency of model decisions, explainable artificial intelligence (XAI) techniques such as SHAP, LIME, and Q-MEDLEY were applied. The interpretability analysis revealed that features including texture_worst (worst texture value), concave points_worst (number of the most prominent concave regions along the tumor boundary), and area_se (standard error of tumor area) played a decisive role in the model's predictions. This research contributes uniquely to the literature by demonstrating the applicability of quantum computing-assisted explainable classification methods to tabular biomedical data. However, the reliance on a single dataset and the evaluation of quantum models within noiseless simulation environments represent key limitations that restrict the generalizability of the findings. Future studies are encouraged to conduct external validation on multi-center, imbalanced, and multi-class datasets, as well as experimental testing on real NISQ (Noisy Intermediate-Scale Quantum) devices. The findings highlight that integrating quantum kernel methods with deep and classical learning paradigms within an explainable framework holds strong potential for delivering reliable and high-performance solutions in clinical decision support systems.

Keywords: Explainable AI, Ensemble learning, Hybrid model, Quantum machine learning, Breast cancer diagnosis.

*İlhan UYSAL; iuysal@mehmetakif.edu.tr

1. Giriş

1. Introduction

Meme kanseri, kadınlarda en sık görülen kanser türü olup küresel kanser yükünün yaklaşık dörtte birini oluşturmaktadır. Uluslararası Kanser Araştırmaları Ajansının (IARC) GLOBOCAN 2022 tahminlerine göre, meme kanseri dünya çapında yaklaşık 2,3 milyon yeni olgu (tüm kanserlerin %11,6'sı) ve yaklaşık 670 000 ölüme (%6,9) neden olmuş; kadınlarda en sık tanı konulan kanser ve önde gelen ölüm nedenlerinden biri olmaya devam etmiştir (Bray vd., 2024). Erken teşhis, tedavi başarısı ve sağ kalım oranlarının artırılmasında kritik bir rol oynamaktadır. Günümüzde mamografi, ultrasonografi, manyetik rezonans görüntüleme (MRI) ve histopatolojik incelemeler gibi yöntemler yaygın olarak kullanılsa da bu tekniklerin önemli sınırlılıkları bulunmaktadır. Özellikle yoğun meme dokusuna sahip hastalarda mamografinin duyarlılığı düşmekte ve yanlış negatif sonuç oranları artmaktadır (Vamvakas vd., 2022). Ayrıca, uzmanlar arası yorum farklılıkları ve görüntüleme modalitelerindeki teknik kısıtlamalar, kesin tanıyı güçleştirmektedir. Bu sorunların üstesinden gelmek amacıyla, makine öğrenmesi (MÖ) ve derin öğrenme (DÖ) teknikleri biyomedikal veri analizinde giderek daha fazla kullanılmaktadır. MÖ algoritmaları, geleneksel istatistiksel yöntemlere kıyasla karmaşık veri örüntülerini daha iyi tanıyabilmektedir. Ancak, sınıf dengesizliği ve yüksek boyutluluk gibi zorluklar bu modellerin performansını etkileyebilmektedir (Nemade & Fegade, 2023; Ahmed, 2025). Literatürde, meme kanseri sınıflandırmasında Aşırı Gradyan Artırma ve Rastgele Orman gibi algoritmalar yüksek doğruluk oranları sağlamıştır (Sharma vd., 2018; Arravalli vd., 2025). Bununla birlikte, tekil modeller karmaşık veri yapılarını işlemede yetersiz kalabilmekte ve genelleme performansları sınırlı olabilmektedir.

Topluluk (ensemble) öğrenme yöntemleri, son yıllarda farklı modellerin güçlü yönlerini birleştirerek daha kararlı sonuçlar elde etmek için başarıyla uygulanmıştır. Örneğin, Vamvakas vd. (2022), çok parametrelili MRI verileri üzerinde geliştirdikleri bir arttırmalı topluluk öğrenme (boosting ensemble) modeli ile meme kanseri sınıflandırmasında 0,95 AUC değerine ulaşmıştır. Benzer şekilde, Qasrawi vd. (2024), YOLOv5 ve MedSAM segmentasyon tekniklerini birleştiren derin öğrenme tabanlı bir topluluk model kullanarak mamografi görüntülerinde %99,7 doğruluk elde etmiştir. Bu hibrit yaklaşımlar, farklı metodolojilerin avantajlarını birleştirerek tekil modellerden daha tutarlı bir performans sunmaktadır. Son dönemde, kuantum destekli makine öğrenmesi (Quantum Machine Learning, QML) meme kanseri teşhisinde yeni bir araştırma alanı olarak ortaya çıkmıştır. Variational Quantum Classifier (VQC) ve Quantum Kernel Support Vector Classifier (QKSVC) gibi yöntemler, verileri klasik yöntemlerden farklı olarak kuantum özellik uzaylarında temsil ederek sınıflandırma gücünü artırmayı hedeflemektedir (Shan vd., 2022; Prajapati vd., 2023). Ancak, kuantum modellerin optimizasyonundaki zorluklar ve mevcut kuantum donanımlarının gürültülü yapısı, bu tekniklerin klinik uygulamalara entegrasyonunu kısıtlamaktadır (Chereda vd., 2024).


Klinik uygulamada, model sonuçlarının güvenilirliği ve açıklanabilirliği büyük önem taşımaktadır. Açıklanabilir Yapay Zekâ (AYZ) yöntemleri, model kararlarının klinik olarak yorumlanabilmesini sağlamaktadır. Meme kanseri tanısında SHAP (Shapley Additive Explanations) ve LIME (Local Interpretable Model-agnostic Explanations) gibi teknikler, hangi özelliklerin tanıya en fazla katkı sağladığını belirlemede yaygın olarak kullanılmaktadır (Ghasemi vd., 2024). Ayrıca, Q-MEDLEY gibi kuantum tabanlı açıklanabilir yapay zekâ yöntemleri de geliştirilmekte ve model şeffaflığını artırmayı amaçlamaktadır (Chereda vd., 2024). Meme kanseri teşhisine yönelik literatür incelendiğinde, özellikle ulusal literatürde araştırmaların büyük ölçüde klasik makine öğrenmesi yöntemlerine odaklandığı, derin öğrenme ve kuantum modellerinin ise yeterince ele alınmadığı görülmektedir (Kör, 2019; Eyüpoğlu & Yavuz, 2020). Tablo 1'de özetlenen çalışmalar değerlendirildiğinde, mevcut yaklaşımların önemli sınırlılıklar taşıdığı göze çarpmaktadır. Özellikle tek modalite veriyile çalışan sistemler (Vidic vd., 2018) ve küçük örneklemli araştırmalar (Alelyani vd., 2024), klinik uygulamalarda karşılaşılan çeşitliliği karşılamakta yetersiz kalmaktadır. Son dönemde ortaya çıkan çoklu-omik veri analizi (Chereda vd., 2024) ve kuantum özellik haritalama (Xiang vd., 2024) gibi yenilikçi yöntemler umut vaat etmekle birlikte, bu çalışmaların önemli bir kısmı model kararlarının açıklanabilirliği konusunu göz ardı etmektedir. Bu çalışmada önerilen hibrit topluluk öğrenme modeli, literatürdeki bu eksiklikleri gidermeyi hedeflemektedir. Önerilen model, Qasrawi vd.'nin (2024) yüksek doğruluk oranları ve Vamvakas vd.'nin (2022) boosting performansı gibi başarılı yönleri bütünleştirmekte, aynı zamanda SHAP, LIME ve Q-MEDLEY yöntemleriyle tanı kararlarının klinik olarak yorumlanabilmesini sağlamaktadır.

Bu çalışma, literatürdeki bu boşluğu doldurmak amacıyla, klasik (Lojistik Regresyon, Rastgele Orman, XGBoost), derin öğrenme (TabNet) ve kuantum destekli (VQC, QKSVC) modelleri bir araya getiren açıklanabilir bir hibrit topluluk öğrenme modeli önermektedir. Çalışmada kullanılan model mimarisi Şekil

1’de verilmiştir. Önerilen yaklaşım, soft-voting (yumuşak oylama) tekniği ile farklı algoritmik paradigmaların avantajlarını birleştirerek tanı doğruluğunu ve genelleme yeteneğini artırmayı hedeflemektedir. Ayrıca, SHAP, LIME ve Q-MEDLEY gibi açıklanabilir yapay zekâ yöntemleri kullanılarak model kararlarının klinik olarak anlamlandırılabilmesi sağlanmıştır.

Tablo 1. Meme kanseri teşhisinde makine öğrenmesi ve derin öğrenme çalışmalarının karşılaştırmalı analizi
Table 1. Comparative analysis of machine learning and deep learning studies in breast cancer diagnosis

Çalışma (Yıl)	Veri Seti	Yöntem(ler)	En İyi Metrik	Avantajlar	Sınırlılıklar / Eksiklikler
Yıldız vd. (2012)	WDBC	GA-seçimli Random Forest	%95 doğruluk	Gürültülü özellikleri eleme	Açıklanabilirlik yok
Wang vd. (2016)	Histopatoloji görüntüleri	CAGA+SVM	%96 doğruluk	Doku analizi + ML entegrasyonu	Yoğun ön işleme gerektirir
Han & Yin (2022)	WDBC	Meta-öğrenme + ANN	%98 doğruluk	Otomatik hiperparametre ayarı	Tek veri seti ile sınırlı
Güler vd. (2025)	BreakHis, IDC	CNN mimarileri (DenseNet201)	%89 doğruluk AUC=0.95	Topluluk öğrenme F1 skorunu artırır	Özgüllük raporlanmamış, AYZ yöntemi eksik.
Nemade & Fegade (2023)	WDBC	DT, XGBoost	%97 doğruluk AUC = 0.999	Tablosal veride güçlü performans	AYZ yöntemleri kullanılmamış
Xiang vd. (2024)	BreakHis, SEER, GBSG	QCCNN	%99 doğruluk	Kuantum özellik haritalama	NISQ gürültüsü analiz edilmemiş
Prajapati vd. (2023)	WDBC	VQC	%96 doğruluk	Küçük veri setlerinde etkili	Barren plateau riski
Shan vd. (2022)	WDBC	QKSVC	AUC = 0.998	Kararlı çekirdek yapısı	SHAP/LIME ile açıklanabilirlik yok
Chereda vd. (2024)	Multi-omik veri	Quantum GNN	Klinik alt ağlar	GLRP ile açıklanabilirlik	Omik veri gereksinimi
Ghasemi vd. (2024)	30 çalışmanın derlemesi	-	-	SHAP/LIME kullanım haritalaması	Kuantum çalışmaları sınırlı
Alelyani vd. (2024)	Saudi Arabistan BC verisi	RF	%72 doğruluk	SHAP ile özellik önem analizi	Küçük hasta kohortu
Qasrawi vd. (2024)	VinDr-Mammo (20k mamografi)	YOLOv5+MedSAM → Topluluk öğrenme, derin öğrenme	%99 doğruluk	Gerçek zamanlı işlem (<1sn)	Tek merkezli; cihaz varyasyonu etkisi
Vamvakas vd. (2022)	mpMRI (140 hasta)	Boruta + Ada/GB/LGBM/XGBoost	AUC = 0.95	SVM’den anlamlı üstünlük	Küçük veri; harici validasyon yok
Vidic vd. (2018)	DWI-MRI (51 hasta)	Histogram özellikli SVM	%96 doğruluk	Tek histogram özelliğiyle yüksek doğruluk	Küçük örneklem; AYZ eksik
Kaddes vd. (2025)	Kaggle IDC + BreakHis	CNN-LSTM hibrit	%99 doğruluk	Uzaysal-zamansal özellik entegrasyonu	Yüksek donanım gereksinimi (2saat/devir)
Munshi vd., 2024	WDBC	CNN özelliklerini kullanan bir topluluk stratejisi (RF + SVM)	%99 F1-skoru, %99 duyarlılık, %99 kesinlik, %99 doğruluk	Yüksek doğruluk, açıklanabilirlik entegrasyonu	Sınırlı veri çeşitliliği, gerçek zamanlı test edilmemiş
Oztekin vd., 2024	752 farklı hasta ile oluşturulan Breast-XD veriseti	Destek Vektör Makinesi (SVM), K-en yakın komşu (K-NN), Rastgele Orman (RF), Karar Ağacı (DT), Lojistik Regresyon (LR) ve XGBoost + Radyolog değerlendirmeleri	%94 doğruluk, %92 kesinlik, %93 F1-skoru	SHAP ve LIME kullanılmış, radyolog değerlendirmesi ile karşılaştırma	Tek bir hastaeden sınırlı sayıda katılımcı
Islam vd., 2024	500 Bangladeşli hasta kaydı	Karar Ağaçları, Rastgele Orman, Lojistik Regresyon, Naive Bayes, XGBoost	%96 F1-skoru, %95 duyarlılık, %94 kesinlik, %97 doğruluk	Çok metrikli optimizasyon.	Demografik çeşitlilik ve gerçek klinik doğrulama eksik
Bu çalışma (2025) (Soft voting) + SHAP/LIME/Q-MEDLEY	WDBC	LR+RF+XGB+TabNet+VQC+QKSVC	AUC = 0.995; %98 doğruluk	Çok paradigmatlı hibrit yaklaşım. Tam açıklanabilirlik desteği	Harici validasyon gerekiyor



Şekil 1. Meme kanseri için açıklanabilir kuantum destekli hibrit sınıflandırma yaklaşımı.
Figure 1. Explainable quantum-assisted hybrid classification approach for breast cancer.

2. Materyal ve metot

2.1. Material and method

Bu çalışmada, meme kanserinin kötü huylu (malign, M) ve iyi huylu (benign, B) sınıflarının ayrımı için tablo formatındaki (tabular) biyomedikal veriler üzerinde hem klasik hem de kuantum temelli makine öğrenmesi algoritmaları uygulanmış ve bu modellerin çıktıları açıklanabilir yapay zekâ yöntemleriyle analiz edilmiştir. Tüm analizler Python 3.11.13 sürümü kullanılarak Google Colab platformunda gerçekleştirilmiştir. Çalışmada Scikit-learn, XGBoost, PyTorch TabNet, PennyLane, Optuna, SHAP ve LIME kütüphanelerinden yararlanılmıştır.

2.1. Veri kümesi ve ön işleme süreci

2.1. Dataset and preprocessing

Araştırma kapsamında, UCI Machine Learning Reporsitory'den alınan Wisconsin Meme Kanseri (Diagnostic) veri kümesi (Wolberg vd., 1993) kullanılmıştır. Bu veri kümesinin seçilmesinin üç temel nedeni şunlardır:

- *Yeniden üretilebilirlik:* Küresel araştırmalarda yaygın kullanımı ve etik bir kısıtlama içermemesi, sonuçların karşılaştırılabilirliğini sağlamaktadır.
- *Algoritmik adalet:* 30 sayısal özellikten (tümör çekirdek ölçümleri) oluşan homojen yapı, klasik, derin öğrenme ve kuantum modellerinin önyargı olmadan sınanmasına olanak tanır.
- *Metodolojik kontrol:* Çoklu veri kümelerinin karmaşıklığı yerine, standart bir küme üzerinde paradigmanın gerçek performansı değerlendirilmiştir.

Veri kümesi 569 hasta kaydından oluşmakta olup, hedef değişken ('diagnosis') malign (M: %37.3) ve benign (B: %62.7) şeklinde iki sınıflıdır. Eksik veri bulunmamakta; analiz dışı bırakılan 'Unnamed: 32' (boş sütun) ve 'id' (kimlik bilgisi) hariç tüm öznitelikler z-skör standardizasyonu ile ölçeklenmiştir. Sınıf dengesizliğini yönetmek için 10 katlı tabakalı çapraz doğrulama (stratified k-fold cross validation) uygulanmış, eğitim-test kümelerinde sınıf oranları korunmuştur. Sınıf etiketleri, iyi huylu için 0, kötü huylu için 1 olarak kodlanmıştır.

2.2 Klasik ve derin öğrenme modelleri

2.2. Classical and deep learning models

Öncelikle temel bir Lojistik Regresyon (Logistic Regression) modeli ile karşılaştırmalı bir başlangıç yapılmıştır. Ardından optimize edilmiş hiperparametrelerle çalışan XGBoost modeli kullanılmıştır. XGBoost, ağaç tabanlı gradyan artırma (gradient boosting) yöntemine dayalı olup, özellikle sınıflandırma problemlerinde yüksek başarı sağlamaktadır (Chen & Guestrin, 2016). Hiperparametreler Kılavuzlu Arama Çapraz Doğrulama (GridSearchCV) kullanılarak belirlenmiştir. Lojistik Regresyon modeli L2 düzenlileştirmesi (regularization) ve liblinear çözücü (solver) ile eğitilmiştir. Rastgele Orman (Random Forest) modeli için 100 ağaç ve

maksimum derinlik 5 olarak belirlenmiştir. Bununla birlikte, derin öğrenme tabanlı TabNet modeli de analizde yer almıştır. TabNet, dikkat mekanizması tabanlı (attention-based) bir yapı olup tablosal verilerde etkili özellik seçimi ve temsil öğrenme yeteneği sunmaktadır (Arik & Pfister, 2021). Model, PyTorch-TabNet kütüphanesi kullanılarak eğitilmiştir. Ana hiperparametrelerden adım sayısı (n_steps) = 5, gamma = 1.5, karar katmanı boyutu (n_d) = 8, dikkat katmanı boyutu (n_a) = 8 ve maskeleme türü ($mask_type$) = 'entmax' olarak belirlenmiştir. Bu değerler, eğitim ve doğrulama Eğri Altında Kalan Alan (AUC-Area Under Curve) skorları göz önünde bulundurularak deneysel olarak optimize edilmiştir. Bu modellerin performansı hem AUC hem de doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skorları üzerinden değerlendirilmiştir.

2.3. Kuantum destekli modeller

2.3. Quantum-assisted models

Kuantum makine öğrenmesi kapsamında iki farklı yaklaşım uygulanmıştır. İlk olarak, PennyLane ve PyTorch kütüphaneleri kullanılarak geliştirilen Değişimsel Kuantum Sınıflandırıcı (Variational Quantum Classifier-VQC) modelinden yararlanılmıştır. Klasik veriler, Pauli-Z tabanlı parametrik dönüşümler aracılığıyla dört kuantum bitlik (qubit) bir kuantum devresine gömülmüş; altı katmanlı ($depth = 6$) parametrik devre mimarisi, Optuna kütüphanesiyle gerçekleştirilen 25 denemelik hiperparametre optimizasyonu sonucunda belirlenmiştir. Eğitim süreci, varsayılan kuantum bit simülatörü (default.qubit) üzerinde Adam optimizasyon algoritmasıyla 100 devir boyunca yürütülmüş ve devre yapısında Güçlü Dolaşık Katmanlar (Strongly Entangling Layers) kullanılmıştır. Ölçüm operatörü olarak Pauli-Z seçilmiştir. Hiperparametre duyarlılığı nedeniyle farklı rastgele başlangıç koşulları denenmiş ve sonuçlarda yüksek varyans gözlemlenmiştir. İkinci modelde PennyLane'in sağladığı kuantum çekirdek (quantum kernel) yöntemi uygulanmıştır. Burada her örnek, Açık Gömme (Angle Embedding) tekniğiyle kuantum durumuna kodlanmış, ardından ZZ Özellik Haritası (ZZFeatureMap) kullanılarak çekirdek matrisi oluşturulmuştur. Elde edilen kuantum çekirdek matrisi, klasik Destek Vektör Makineleri (Support Vector Machines-SVM) algoritmasının girişinde kullanılmış ve böylece Radyal Taban Fonksiyonu (Radial Basis Function-RBF) çekirdeği yerine özelleştirilmiş kuantum çekirdeği tercih edilmiştir. Bu yaklaşım, özellikle küçük ölçekli ve doğrusal olarak ayrıştırılamayan (non-linearly separable) veri kümelerinde etkin sonuçlar vermektedir (Li et al., 2020; Blank et al., 2020; Krunić et al., 2022).

2.4. Hibrit model: Topluluk yaklaşımı

2.4. Hybrid model: Ensemble approach

Farklı modellerin güçlü yönlerini birleştirmek amacıyla XGBoost, TabNet, Optimized VQC ve Quantum Kernel SVC modellerinin çıktıları bir araya getirilerek yumuşak oylama (soft voting) prensibine dayalı hibrit bir sınıflandırıcı oluşturulmuştur. Başlangıçta performansa dayalı ağırlıklandırma stratejileri de test edilmiştir. Örneğin, test AUC skorlarına göre TabNet (%0.4), XGBoost (%0.3), QKSVC (%0.2) ve VQC (%0.1) şeklinde ağırlık dağılımı uygulanmıştır. Ancak bu yaklaşım, genel doğrulukta anlamlı bir artış sağlamadığı için nihai modelde tüm sınıflandırıcıların eşit ağırlıkla (%25) temsil edildiği bir yapı tercih edilmiştir. Böylece her modelin farklı temsil yeteneklerinden adil bir biçimde yararlanılmış ve aşırı uyum riski azaltılmıştır.

2.5. Topluluk model yapısı ve ağırlıklandırma yöntemi

2.5. Ensemble model structure and weighting strategy

Bu çalışmada geliştirilen topluluk modelinde, her bir modelin çıktı olasılıkları olasılık tahmin fonksiyonu ($predict_proba$) aracılığıyla elde edilmiş ve kötü huylu tümör sınıfı için hesaplanan olasılıklar eşit ağırlıkla birleştirilerek nihai tahmin oluşturulmuştur. Bu tercih, tüm modellerin farklı öğrenme paradigmasına dayalı olarak karar üretmesi ve her birinin modelleme sürecinde benzer düzeyde optimize edilmiş olmalarına dayandırılmıştır. Özellikle QKSVC modeli yüksek Eğri Altında Kalan Alan performansı gösterirken, TabNet ve XGBoost modelleri dengeli doğruluk ve açıklanabilirlik sunmuştur. VQC modeli, daha düşük performans sergilemiş olsa da kuantum mekaniği tabanlı bir öğrenme örüntüsüne sahip olması nedeniyle bilgi çeşitliliğine katkı sağladığı değerlendirilmiştir. Bu nedenle, eşit ağırlıklı yumuşak oylama stratejisi, model çeşitliliğinin korunmasını ve potansiyel önyargıların önlenmesini amaçlamıştır. Alternatif olarak performansa dayalı ağırlıklandırma yöntemleri (örneğin ROC AUC'a (ROC eğrisi altında kalan alan) göre normalize edilmiş ağırlıklar) test edilmiş, ancak bu stratejilerin genellikle baskın modelin (örn. QKSVC) kararını ağır basacak şekilde yönlendirdiği ve diğer modellerin katkısını sınırlandırdığı gözlemlenmiştir. Ayrıca, dinamik ağırlıklandırma stratejilerinin, model kararlarının açıklanabilirliğini azaltabileceği ve yorumlamayı zorlaştırabileceği düşünülerek eşit ağırlıklı strateji tercih edilmiştir. Bu yapının bir diğer avantajı da modellerin

birbirinden bağımsız olarak eğitilmesine ve yorumlanmasına olanak tanınmasıdır. Bu durum, açıklanabilirlik analizlerinde her modelin katkısını ayrı ayrı gözlemlemeyi ve karşılaştırmalı analiz yapmayı mümkün kılmıştır. Özellikle SHAP ve Q-MEDLEY analizleriyle yapılan değerlendirmelerde, tüm modellerin belirli özniteliklerde benzer öneme sahip olduğu gözlemlenmiş, bu da model kararlarında tutarlılık olduğunu göstermiştir. Sonuç olarak, eşit ağırlıklı yumuşak oylama stratejisi hem metodolojik şeffaflık hem de performans-denge uyumu açısından en uygun yaklaşım olarak değerlendirilmiş ve bu stratejiye dayalı topluluk modeli final sınıflandırıcı olarak seçilmiştir.

2.6. Eğitim süreleri, hesaplama kaynakları ve hiperparametreler

2.6. Training durations, computational resources and hyperparameters

Çalışmadaki tüm analizler, Google Colab platformunda, Python 3.10 ve ilgili kütüphanelerin (Scikit-learn 1.2+, XGBoost 1.7+, PyTorch TabNet, PennyLane 0.32+) yer aldığı bulut tabanlı bir ortamda gerçekleştirilmiştir. Donanım olarak NVIDIA Tesla T4 GPU (16 GB), Intel Xeon CPU (2.20 GHz) ve 12.7 GB RAM kapasiteli sistem kullanılmıştır. Lojistik Regresyon ve Rastgele Orman gibi klasik modellerin eğitimi saniyeler düzeyinde tamamlanırken, XGBoost modeli hiperparametre taraması dahil ortalama 45-60 saniye sürmüştür. 10 katlı çapraz doğrulama dahil toplam XGBoost eğitim süresi yaklaşık 7 dakika olarak hesaplanmıştır. TabNet modeli için eğitim süresi, Eğitim süreci sırasında fit() fonksiyonu GPU üzerinden çalıştırılmış ve ROC AUC değerine göre erken durdurma kriteri kullanılmıştır. VQC modeli, klasik optimizasyon algoritması olan Adam ile optimize edilmiş ve 100 devir süresince çalıştırılmıştır. VQC'nin eğitimi, her deneme için yaklaşık 80-90 saniye sürmüş, ancak hiperparametre optimizasyonu (Optuna ile 10 deneme) toplamda 18 dakikaya kadar uzamıştır. Eğitim, PennyLane'in varsayılan qubit simülatörü üzerinde gerçekleştirilmiştir. QKSVC modeli, tüm örnekler arasında kuantum çekirdek benzerlik matrisinin hesaplanmasını gerektirdiği için, özellikle test aşamasında yoğun hesaplama maliyeti oluşturmuştur. Eğitim süresi yaklaşık 4-5 dakika, test süresi ise çekirdek hesaplamalarına bağlı olarak 3 dakika civarındadır. Bu işlem sırasında `qml.matrix()` ve `qml.kernels.square_kernel_matrix()` fonksiyonları ile her bir örnek için 4 kuantum bitlik devre çalıştırılmıştır. Hibrit topluluk modeli için eğitim süresi bulunmamaktadır; çünkü bu model, dört temel modelin çıktılarının doğrusal kombinasyonu ile oluşturulmuştur. Ancak her bir alt modelin olasılık tahmin (`predict_proba`) çıktılarının alınması ve bunların yumuşak oylama ile birleştirilmesi işlemi toplamda 6-7 saniye sürmüştür. Toplamda, tüm deneylerin tekrarlanabilir bir şekilde tamamlanması yaklaşık 3 saatlik hesaplama süresi gerektirmiştir. Eğitimlerin tamamı simülasyon tabanlı olduğu için gerçek zamanlı kuantum donanımıyla yapılan deneylere kıyasla daha az donanımsal belirsizlik içermektedir. Ancak bu durum, hesaplama sürelerinin gerçek donanımlarda farklılaşabileceği gerçeğini de beraberinde getirmektedir. Bu bağlamda, geliştirilen modellerin hesaplama maliyetleri pratik düzeyde kalmakta ve klinik karar destek sistemlerine entegre edilebilecek nitelikte olduğu değerlendirilmektedir. Özellikle TabNet ve XGBoost gibi yüksek başarı gösteren modellerin hem doğruluk hem de işlem verimliliği açısından dengeli performans sunduğu gözlemlenmiştir. Tüm modellerin hiperparametre detayları Ek 1'deki tabloda verilmiştir.

2.7. Açıklanabilir yapay zekâ analizleri

2.7. Explainable artificial intelligence analytics

Model performansının ötesinde, karar süreçlerinin anlaşılabilirliğini güçlendirmek amacıyla açıklanabilir yapay zekâ teknikleri uygulanmıştır. Bu kapsamda SHAP, LIME ve Q-MEDLEY yöntemlerinden yararlanılmıştır. SHAP yöntemi hem genel veri kümesi düzeyinde hem de bireysel örnekler seviyesinde özelliklerin model kararlarına olan katkılarını nicel olarak ortaya koymaktadır. LIME yöntemi ise belirli bir örneğe ilişkin model tahminlerini, yerel doğrusal bir yaklaşımla yorumlanabilir şekilde açıklamaktadır. Q-MEDLEY ise kuantum ve klasik alt-modellerin ürettiği karar matrislerini birleştirerek, özellikle kuantum katkılı karar mekanizmalarının klinik açıdan yorumlanmasını kolaylaştıran hibrit bir açıklanabilirlik çerçevesi sunmaktadır. Bu yaklaşım, SHAP ve LIME'in öznitelik bazlı açıklamalarını tamamlayacak biçimde, model kararlarının yapısal çeşitliliğini istatistiksel karşılaştırmalarla ortaya koymaktadır. Çalışmada SHAP analizi XGBoost, TabNet, QKSVC ve hibrit topluluk öğrenme modellerine uygulanmış; öznitelik önemleri özet, çubuk ve karar diyagramlarıyla görselleştirilmiştir. Bu analizler, özniteliklerin sınıflandırma performansına pozitif ya da negatif etkilerini detaylı bir şekilde sağlamıştır. LIME ile rastgele seçilen test örneklerinin yerel açıklamaları incelenmiş ve hangi özniteliklerin bu örneklerde belirleyici olduğu belirlenmiştir. Özellikle yüksek doğrulukla sınıflandırılan vakalarda LIME görselleştirmeleri, model güvenilirliğini destekleyen bulgular sağlamıştır. Son olarak, test verisi üzerindeki öznitelik önemlerinin Q-MEDLEY ile doğrulanması sayesinde en kritik öznitelikler bütüncül olarak ele alınmış ve görsel olarak sunulmuştur.

3. Bulgular


3. Results

Bu çalışmada meme kanseri tanısı için geliştirilen farklı makine öğrenmesi modellerinin sınıflandırma performansları değerlendirilmiş ve açıklanabilir yapay zekâ teknikleriyle bu modellerin karar mekanizmaları analiz edilmiştir. Uygulanan modeller, klasik algoritmalar (Logistic Regression, Random Forest, XGBoost), derin öğrenme temelli TabNet, kuantum tabanlı modeller (Optimized VQC, QKSVC) ve bu modellerin birleşiminden oluşan hibrit bir topluluk öğrenme (hybrid ensemble) yapısını içermektedir.

3.1. Klasik modeller ve derin öğrenme modellerinin performansı

3.1. Performance of classical models and deep learning models


Şekil 2’de sunulan ROC eğrileri, klasik modeller arasındaki ayrım gücünü ayrıntılı biçimde ortaya koymaktadır. Optuna ile ayarlanan hiperparametrelerle eğitilen lojistik regresyon modeli, test kümesinde %97 doğruluk ve 0,9871 AUC değeri elde ederken, on katlı çapraz doğrulama boyunca hesaplanan ortalama 1,00 AUC değeriyle neredeyse mükemmele yakın bir ayrım performansı sergilemiştir (Şekil 2a). Buna karşılık, Random Forest modeli, test kümesinde AUC değeri 0,9928 düzeyine ulaşmakla birlikte, çapraz doğrulama katları arasında AUC değerlerinin 0,95 ile 1,00 aralığında dalgalanma gösterdiği gözlemlenmiştir; ortalama AUC değeri 0,99 olarak kaydedilmiş ve bazı katlardaki hafif düşüşler, modelin veri alt örneklerine karşı duyarlılığını işaret etmiştir (Şekil 2b). Her iki model de yüksek genel doğruluk sunmakla beraber, lojistik regresyonun katlar arası tutarlı performansı, sınıf dengesizliği ve örneklem varyasyonuna karşı daha kararlı bir karar yüzeyi oluşturduğunu göstermektedir. Rastgele Orman algoritmasının sınıf sınırlarını belirlerken kullandığı çok sayıda karar ağacı, veri alt kümelerine özgü özellikleri yakalamakta başarılı olsa da bu durum bazı katlarda hatalara daha yatkın bir yapı sergilemektedir. Bu nedenle, daha dengesiz ya da heterojen veri setlerinde ek parametre ayarlamaları veya öznitelik seçimi stratejileri gerekebileceği öngörülmektedir.



Şekil 2. Lojistik Regresyon ve Random Forest modellerinin ROC eğrileri


Figure 2. ROC curves of logistic regression and random forest models

Şekil 3, XGBoost modelinin çapraz doğrulama boyunca elde ettiği ROC eğrilerini ve ortalama eğitim-doğrulama logaritmik kayıp (log-loss) eğrilerini birlikte sunmaktadır. ROC panelinde, katlar arasında AUC değerlerinin 0,97 ile 1,00 aralığında seyretmesine karşın ortalama AUC’nin 0,99 düzeyinde kalması, modelin yüksek ayrım gücünü korurken belirli alt örneklem varyasyonlarına duyarlı davrandığını ortaya koymaktadır. Özellikle 4. ve 9. katlarda AUC’nin 0,98 düzeyine inmesi, bu katlardaki veri dağılımının modelin karar sınırlarını kısmen etkilediğini göstermektedir. Buna rağmen, diğer katlardaki tam puana yakın sonuçlar, genel performansın tutarlılığını belirtmektedir. Eğri alanlarının sol-üst köşeye yakın konumlanması, düşük yanlış-pozitif oranlarda bile yüksek gerçek-pozitif oran sağlandığını göstermekte ve XGBoost’un klinik tarama gibi hassas uygulamalar için uygun olduğunu vurgulamaktadır. Logaritmik kayıp grafiği ise modelin ilk 50 iterasyonda hızlı bir yakınsama sergilediğini, 100. iterasyondan sonra eğitim kaybının 0,05’in altına, doğrulama kaybının ise 0,10 civarına gerileyerek dengelendiğini göstermektedir. Eğitim ve doğrulama eğrileri arasındaki boşluğun makul düzeyde kalması, aşırı uyum (overfitting) riskinin olmadığını ve modelin genelleme yeteneğini koruduğunu işaret etmektedir. Bu bulgular, XGBoost’un karmaşık öznitelik etkileşimlerini öğrenmedeki başarısını ve erken durdurma (early stopping) gibi stratejilerle desteklendiğinde kararlı bir performans sergilediğini göstermektedir.



Şekil 3. XGBoost modelinin ROC eğrisi ve Eğitim-Doğrulama Kayıp Eğrisi
Figure 3. ROC curve and training-validation loss curve of the XGBoost model

Şekil 4, TabNet modelinin çapraz doğrulama sonuçlarını iki açıdan özetlemektedir. ROC panelinde, katlar arasındaki AUC değerlerinin 0,96 ile 1,00 aralığında dağıldığı gözlemlenmiş ve ortalama AUC 0,99 olarak kaydedilmiştir. Kat 1 ve Kat 5'te gözlenen 0,96 ve 0,97 AUC değerleri, TabNet'in maske tabanlı öznelilik seçim mekanizmasının bu özel alt kümelerdeki ince detayları yakalamada kısmen sınırlı kaldığını ortaya koymaktadır. Buna karşın, diğer katlardaki 0,99–1,00 aralığındaki tutarlı performans, modelin genel ayırım gücünün yüksek olduğunu göstermektedir. ROC eğrilerinin sol-üst bölgeye yığılması, modelin düşük yanlış-pozitif oranlarda yüksek gerçek-pozitif oran sağladığını ve klinik tarama gibi uygulamalarda dengeli bir performans sunduğunu vurgulamaktadır. Devir bazlı AUC eğrileri, modelin öğrenme dinamiklerini ayrıntılı olarak yansıtmaktadır. Eğitim ve doğrulama AUC değerlerinin ilk 3-4 devirde %70'lerden %95'in üzerine hızla yükselmesi, TabNet'in öznelilik maskelerini erken aşamada etkin biçimde öğrenebildiğini göstermektedir. 5. devirden itibaren doğrulama eğrisinin 0,98–1,00 aralığında plato çizmesi ve eğitim eğrisiyle arasındaki farkın azalması, aşırı uyum riskinin olmadığını ve erken durdurma stratejisinin başarıyla uygulandığını belirtmektedir. Son devir itibarıyla doğrulama AUC değerinin eğitim eğrisini çok küçük bir farkla takip etmesi, modelin genelleme yeteneğini koruduğunu göstermektedir. Bu bulgular, TabNet'in tablo formatındaki veri analizinde hem yüksek yorumlanabilirlik hem de güçlü tahmin performansı sunan bir mimari olduğunu ortaya koymaktadır. Özellikle karmaşık öznelilik etkileşimlerini öğrenme yeteneği ve hızlı yakınsama özellikleri, onu hibrit çerçeveler için ideal bir bileşen haline getirmektedir.




Şekil 4. TabNet modelinin ROC eğrisi ve eğitim-doğrulama AUC değişim grafiği
Figure 4. ROC curve and training-validation AUC change graph of the TabNet model

3.2. Kuantum tabanlı modellerin performansı

3.2. Performance of quantum-based models

Şekil 5, optimize edilen VQC modelinin çapraz doğrulama performansını ROC eğrileri ve kat bazlı eğitim kaybı eğrileri olmak üzere iki ana metrik üzerinden sunmaktadır. Grafikte görüldüğü üzere, dört kuantum bit (kübit) ve altı katmanlı devre mimarisi Optuna hiperparametre optimizasyonu ile belirlenmiş en uygun konfigürasyon olarak seçilmiştir. Ancak, katlar arasındaki AUC değerlerinin 0,672–0,738 aralığında değişiklik gösterdiği, ortalama AUC değerinin 0,731 olduğunu göstermektedir. ROC eğrilerinin bazı katlarda (AUC = 0,672) rastgele sınıflandırmayı temsil eden 45 derecelik köşegene (diyagonale) yaklaşması, modelin belirli alt örneklemelerde sınırlı ayırım gücüne sahip olduğunu ortaya koymaktadır. Eğitim kaybı eğrileri

incelendiğinde, tüm katlarda kaybın azalma eğiliminde olduğu gözlemlenmekle birlikte, Kat 8 ve Kat 9'da (508.8 ve 508.9) kayıp değerlerinin 150 devir sonunda bile yüksek kalması ($\sim 0,70$), barren plateau etkisiyle (kuantum devrelerinde optimizasyonun gradyan kaybı nedeniyle ilerleyememesi) ilişkili olabilecek yerel minimum problemlerine işaret etmektedir. Sonuç olarak, VQC'nin karmaşık karar sınırlarını tutarlı şekilde öğrenmedeki zorlukları, mimari tasarımın yanı sıra optimizasyon protokollerinin (parametre başlatma, hibrit klasik-kuantum algoritmalar) geliştirilmesinin gerekli olduğunu ortaya koymaktadır.



Şekil 5. VQC modelinin çapraz doğrulama ROC eğrileri ve devir başına eğitim kaybı dağılımı

Figure 5. Cross-validation ROC curves and per-epoch training loss distribution for the VQC model


Şekil 6'daki ROC eğrisi, QKSVC modelinin çapraz doğrulamadaki sınıflandırma performansını özetlemektedir. Tüm katlarda AUC değerlerinin 0,97 ile 1,00 arasında dağılım göstermesi ve ortalama AUC değerinin $0,99 \pm 0,01$ olarak hesaplanması, modelin istatistiksel olarak tutarlı bir ayırım gücüne sahip olduğunu belirtmektedir. ROC eğrilerinin sol-üst köşede (FPR (özgüllük) ≈ 0 , TPR(duyarlılık) (≈ 1)) yoğunlaşması, modelin düşük yanlış-pozitif oranlarında bile yüksek gerçek-pozitif oranlar sağlayabildiğini ortaya koymaktadır. Kat 5'te gözlemlenen 0,97'lik AUC değeri, veri dağılımındaki minimal varyasyonlardan kaynaklanmış olsa da, standart sapmanın $\pm 0,01$ bandında kalması kuantum çekirdek fonksiyonunun (quantum kernel) veriyi Hilbert uzayında kararlı şekilde ayrıştırabildiğini göstermektedir. Bu bulgular, özellikle düşük örneklemli biyomedikal veri kümelerinde ($n < 10^3$), kuantum çekirdek yöntemlerinin klasik SVM'lerin ulaşabildiği maksimum AUC değerlerini aşma potansiyeli taşıdığına işaret etmektedir. Kuantum donanımının ölçeklenebilirliği arttıkça, klinik tanı süreçlerinde bu tür modellerin yüksek doğruluklu sonuçlar üretebileceği öngörülmektedir.

3.3. Hibrit topluluk modeli


3.3. Hybrid ensemble model

XGBoost, TabNet, Optimized VQC ve Quantum Kernel SVC modellerinin çıktıları soft voting prensibine göre birleştirilmiştir. Şekil 7, bu hibrit topluluk modelin çapraz doğrulamadaki ROC eğrilerini göstermektedir. Kat-bazlı AUC değerleri 0,9762 ile 1,0000 arasında dar bir bantta dağılmış; ortalama AUC, dört ondalık hassasiyetle 1,0000 olarak hesaplanmıştır. Eğrilerin neredeyse tamamının sol-üst köşeye bitişik konumlanması, yanlış-pozitif oranının sıfıra yakın düzeylerde dahi gerçek-pozitif oranının korunduğunu göstermekte; modelin hem duyarlılık hem özgüllük bakımından pratik olarak kusursuz bir ayırım gücü sergilediğini ortaya koymaktadır.

Kat 4, 5 ve 9'da gözlenen 0,99'un altındaki küçük çaplı düşüşler, alt örneklemelerin içerdiği varyasyonun topluluk performansını yalnızca marjinal ölçüde etkilediğini göstermektedir. Dolayısıyla, modelin genelleme kabiliyetinin yüksek olduğunu ve katlar arası varyansın minimal düzeyde kaldığını ortaya koymaktadır. Bu sonuç, heterojen öğrenme paradigmalarının bir araya getirilmesinin öznitelik düzeyindeki tamamlayıcılığı maksimize ettiğini ve sınıf dengesizliği gibi olası veri sorunlarını etkili biçimde telafi ettiğini göstermektedir. Bununla birlikte, ROC eğrilerinin tavana yakın seyretmesi veri kümesinin görece sınırlı boyutuna ve kolay ayrılabilir özellik uzayına da bağlı olabilir. Bu nedenle, ileriki çalışmaların çok-merkezli ve daha karmaşık veri setleri üzerinde dış doğrulama yapılması modelin klinik geçerliliğini önemli ölçüde güçlendirecektir.



Şekil 6. QKSVC Modelinin Çapraz Doğrulama ROC Analizi
Figure 6. Cross-Validation ROC Analysis of the QKSVC Model



Şekil 7. Hibrit topluluk modelin çapraz doğrulama ROC analizi
Figure 7. Cross-validation ROC analysis of the hybrid ensemble model

3.4. Karşılaştırmalı model performans tablosu

3.4. Comparative model performance table

Klasik, derin öğrenme ve kuantum tabanlı yöntemlerin yanı sıra bu bileşenlerden oluşturulan hibrit topluluk modelin başlıca sınıflandırma metrikleri bakımından genel bir karşılaştırması Tablo 2’de verilmiştir. Ortalama AUC değerleri incelendiğinde, hibrit model ($AUC = 0,9952$) ve lojistik regresyon ($AUC = 0,9958$) modelleri, istatistiksel olarak neredeyse eşdeğer ayırma gücü sergileyerek en üst sırayı paylaşmıştır. Kappa ve MCC gibi sınıf dengesizliğine duyarlı ölçütlerde de bu iki modelin 0,93 üzeri skorlar elde etmesi, karar tutarlılığının ve genel güvenilirliğin yüksek olduğunu göstermektedir. TabNet ($AUC = 0,9907$) ve ağaç tabanlı modeller olan Random Forest ($AUC = 0,9894$) ile XGBoost ($AUC = 0,9918$) benzer doğruluk aralıklarında performans sunarken, TabNet’in kesinlik ve duyarlılık metriklerinde dengeyi koruması (0,98/0,98) dikkat çekicidir. Bu durum, tablo verisine özgü maske tabanlı öznetelik seçiminin hem yanlış pozitif hem de yanlış negatif hataları sınırlama açısından etkili olduğunu kanıtlamaktadır. XGBoost ve Rastgele Orman ise %100 kesinliğe karşılık duyarlılıkta kısmen azalma (0,93) yaşayarak, false-negative hataları görece artırma pahasına yanlış-pozitifleri minimumda tutma eğilimindedir. Kuantum modeller arasında QKSVC, 0,9902 ortalama AUC değeri, 0,97

kesinlik değeri ve 0,86 duyarlılık değeriyle güçlü bir ayırım gücü sunmasına karşın, duyarlılığın klasik topluluk bileşenlerine kıyasla düşmesi, bazı kötü huylu tümör örnekleri kaçırma olasılığını artırmaktadır. Buna karşılık Optimize VQC modelinin 0,7684 AUC, 0,38 duyarlılık ve 0,46 F1-skoru değerleri, parametrik kuantum devrenin mevcut konfigürasyonda veri örüntülerini tutarlı biçimde öğrenemediğini ortaya koymaktadır. Toplamda, hibrit topluluk modelinin neredeyse tavana yakın AUC, 0,98 doğruluk, 1,00 kesinlik ve 0,95 duyarlılık değerleri elde etmesi, farklı öğrenme paradigmalarının tamamlayıcı bilgi setlerini etkili biçimde bütünleyerek yüksek duyarlılığı kesinlikten ödün vermeden sağlayabildiğini doğrulamaktadır. Bu bulgular, heterojen sınıflandırıcıların yumuşak oylama ile entegrasyonunun, özellikle küçük ölçekli ve hafif dengesiz biyomedikal veri kümelerinde, tekil modellerin kısıtlılıklarını dengeleyerek klinik açıdan üstün ve güvenilir bir karar mekanizması sunduğunu ortaya koymaktadır.

Tablo 2. Modellerin performans karşılaştırması

Table 2. Performance comparison of models


Model	Ortalama AUC	Ortalama Kappa	Ortalama MCC	Doğruluk	Kesinlik	Duyarlılık	F1-Skoru
Lojistik Regresyon	0,9958	0,9581	0,9594	0,97	0,98	0,95	0,96
Rastgele Orman	0,9894	0,9053	0,9071	0,97	1,00	0,93	0,96
XGBoost	0,9918	0,9094	0,9117	0,97	1,00	0,93	0,96
TabNet	0,9907	0,9095	0,9128	0,98	0,98	0,98	0,98
Optimized VQC	0,7684	0,3579	0,3744	0,68	0,59	0,38	0,46
Quantum Kernel SVC	0,9902	0,8805	0,8862	0,94	0,97	0,86	0,91
Hibrit Topluluk Öğrenme	0,9952	0,9318	0,9333	0,98	1,00	0,95	0,98

3.5. Açıklanabilir yapay zekâ analizleri

3.5. Explainable artificial intelligence analytics


Bu çalışmada geliştirilen hibrit modelin karar mekanizmasını şeffaf hale getirmek amacıyla SHAP, LIME ve Q-MEDLEY açıklanabilirlik yöntemleri kullanılmıştır. Açıklanabilirlik analizleriyle, modelin karar alma sürecinde hangi özniteliklerin etkili olduğu hem bireysel hem de toplu düzeyde incelenmiştir. Şekil 8'deki grafik, SHAP değeri dağılımlarını göstermekte olup, her bir öznitelik için model kararlarını hem yön hem de büyüklük açısından nasıl etkilediğini bireysel örnekler düzeyinde sunmaktadır. Renk gradyanı öznitelik değerlerini (yüksek/düşük) temsil ederken, yatay eksen SHAP değeridir. En üstte yer alan 'en kötü doku değeri' (*texture_worst*), 'tümör sınırındaki en belirgin içe çökük bölgelerin sayısı' (*concave points_worst*) ve 'tümör çevresindeki içe çöküntülerin ortalama miktarı' (*concave points_mean*) gibi öznitelikler, sınıflandırma kararları üzerinde belirgin pozitif ve negatif etkiler göstermektedir. Bu durum, modelin karar alma sürecinde tek yönlü değil, çift yönlü etkiye sahip karmaşık öznitelik etkileşimlerini dikkate aldığını ortaya koymaktadır. Literatürde de sıklıkla vurgulanan bu özellikler, kötü huylu tümörler ile doğrudan ilişkili morfolojik belirteçlerdir.

Şekil 9, SHAP değerlerinin mutlak ortalamalarına göre sıralanmış öznitelik etkilerini göstermektedir. Bu grafik, modelin kararlarının hangi özniteliklere dayandığını bütüncül bir bakış açısıyla ortaya koymaktadır. 'En kötü doku değeri' (*texture_worst*), 'en kötü çukur nokta sayısı' (*concave points_worst*), 'tümör alan ölçümü standart hatası' (*area_se*) gibi değişkenler model çıktısındaki varyansın en büyük belirleyicileri olarak öne çıkmaktadır. Klinik açıdan da tümör dokusunun düzensizlikleriyle ilgili olan bu değişkenlerin önemi, modelin kararlarını biyomedikal temele dayandırıldığını göstermektedir. Ayrıca, modelin en yüksek AUC değerine sahip olmasının yanı sıra, açıklanabilirlik analizlerinin klinik bulgularla uyumlu olması, kararların istatistiksel ve klinik açıdan tutarlılığını pekiştirmektedir.



Şekil 8. SHAP dağılım şeması.

Figure 8. SHAP summary plot.



Şekil 9. SHAP özellik önemi çubuk grafiği.


Figure 9. SHAP feature importance bar plot.

Şekil 10, LIME algoritması kullanılarak oluşturulmuştur ve bir test örneğinin sınıflandırılmasındaki yerel karar mekanizmasını görselleştirmektedir. Örneğin, iyi huylu tümör (“Benign”, “B”) olarak sınıflandırılmış ve bu karar ‘en kötü doku değeri’ (*texture_worst*), ‘yoğunluk ölçümündeki standart hata’ (*compactness_se*), ‘ortalama doku’ (*texture_mean*) gibi öznelitliklerin negatif katkıları desteklemiştir. Diğer yandan, pozitif etkili ‘tümör yüzeyinin lokal varyasyonlarının ortalaması’ (*smoothness_mean*), ‘tümör sınırındaki en belirgin içe çökük bölgelerin sayısı’ (*concavity_worst*) gibi değişkenlerin de modele katkı sunduğu gözlemlenmektedir. LIME, bireysel hasta örneklerinin modelle nasıl etkileşime girdiğini analiz etmede etkili bir yaklaşımdır ve klinik ortamlarda karar destek sistemleri için kritik rol oynamaktadır. Modelin çeşitli özellikler arasında yaptığı bu karşıt yönlü değerlendirme, yalnızca bir eşik değere değil, daha karmaşık bir etkileşim ağına dayandığını göstermektedir.



Şekil 10. LIME karar açıklaması.
Figure 10. LIME decision explanation.

Şekil 11, Q-MEDLEY algoritmasıyla elde edilen özellik önem skorlarını sunmaktadır. Bu skorlar, her bir öznelitliğin modelden çıkarılmasının performans üzerindeki etkisini (permütasyon önemi) yansıtmaktadır. ‘Tümörün en anormal/geniş kesit alanı’ (*area_worst*), ‘en kötü çevre uzunluğu’ (*perimeter_worst*), ‘en kötü doku değeri’ (*texture_worst*), ‘en kötü yarıçap’ (*radius_worst*) gibi tümör boyutu ve morfolojisiyle ilişkili öznelitlikler, kararların biyolojik açıklanabilirliğini desteklemektedir. Bu analiz, klasik SHAP sonuçlarıyla yüksek derecede tutarlılık göstermiştir ve bu durum modelin farklı açıklanabilir yapay zekâ yaklaşımları altında benzer karar mantığı geliştirdiğini göstermektedir. Q-MEDLEY yöntemi, özellikle hibrit modellerde açıklanabilirlik düzeyini artırmakta ve biyomedikal yorumlamaları daha sağlam temellere dayandırmaktadır.



Şekil 11. Q-MEDLEY özellik skoru.
Figure 11. Q-MEDLEY feature score.

Yukarıda sunulan analizlerin tamamı, modelin yalnızca yüksek doğruluk değil, aynı zamanda güçlü açıklanabilirlik özelliklerine sahip olduğunu ortaya koymaktadır. Ancak, klinik validasyon sürecinin henüz gerçekleştirilmemiş olması bir sınırlılık olarak değerlendirilmiştir. Bu nedenle gelecekteki çalışmalarda açıklanabilirlik sonuçlarının klinik uzmanlar tarafından yorumlanması ve hasta temelli senaryolarla zenginleştirilmesi önerilmektedir.

4. Tartışma ve sonuçlar

4. Discussion and conclusions

Bu çalışma, Breast Cancer Wisconsin veri kümesi üzerinde klasik, derin öğrenme ve kuantum tabanlı yaklaşımları yumuşak oylama topluluk öğrenmesi ile bütünleştirerek meme kanseri tanısı için açıklanabilir bir sınıflandırma sistemi ortaya koymaktadır. Tablo 1'de sunulan ve literatürdeki benzer veri yapıları üzerine gerçekleştirilmiş araştırmalar karşılaştırıldığında, önerilen modelin hem ayırım gücü hem de açıklanabilirlik açısından mevcut yöntemlerin çoğundan üstün performans sergilediği görülmektedir. Örneğin, [Nemade ve Fegade \(2023\)](#) tarafından XGBoost ile rapor edilen 0,999'luk AUC tepe değer tek bir veri katmanında elde edilmişken, hibrit topluluk öğrenme modelimiz on kat çapraz doğrulama boyunca 0,995 AUC değeri ile istikrarlı bir performans ortaya koymuştur. Benzer biçimde, TabNet'in ortalama 0,991 AUC değeri ve dengeli duyarlılık–kesinlik profili, doku-temelli CNN modelleriyle ([Wang vd., 2016](#); [Güler vd., 2025](#)) bildirilen sonuçlara kıyasla tablo verisinde eşleşen bir başarı seviyesi sunmuştur. QKSVC modeli, [Shan vd. \(2022\)](#) çalışmasındaki 0,998 AUC değerini doğrular biçimde $0,990 \pm 0,010$ ortalama AUC ile en yüksek ayırım gücüne yaklaşmıştır. Buna karşılık, parametrik devre temelli VQC'nin AUC değerinin 0,768'de kalması, [Prajapati vd. \(2023\)](#) ve [Xiang vd. \(2024\)](#) tarafından rapor edilen barren-plateau ve optimizasyon hassasiyeti problemlerini yeniden doğrulamaktadır. Sonuçlarımız, küçük ve dengeli tablo formatındaki veri kümelerinde kuantum kernel yaklaşımlarının parametrik devrelere kıyasla daha güvenilir olduğunu ve klasik modellerle karşılaştırılabilir bir performans düzeyine ulaşabildiğini ortaya koymuştur. Yumuşak oylama topluluk öğrenmesi, bireysel modellerin zayıflıklarını telafi ederek %99,52 AUC ve %98 doğruluk düzeyine ulaşmış, [Yang vd. \(2010\)](#) ile [Homayouni ve Mansoori \(2017\)](#) tarafından savunulan “çoklu sınıflandırıcı sinerjisi”ni (birden çok sınıflandırıcının birlikte kullanıldığında tekil modellere göre daha yüksek performans sağladığını) deneysel olarak doğrulamıştır. Modeller eşit ağırlıklarla birleştirilmiş olup, dinamik ağırlıklandırma veya hata tersi ağırlıklandırma gibi stratejilerin ileride ek iyileştirme potansiyeli taşıyıp taşımadığı, gelecek çalışmalara yönelik açık bir araştırma sorusu olarak durmaktadır.

SHAP ile elde edilen genel öznitelik önem sıralaması, literatürde sıkça rapor edilen ‘en kötü doku değeri’ (*texture_worst*) ve ‘tümör sınırındaki en belirgin içe çökük bölgelerin sayısı’ (*concave points_worst*) ([Nemade & Fegade, 2023](#); [Ghasemi vd., 2024](#)) değişkenlerini en etkili öznitelikler arasında yer aldığını doğrulamıştır. LIME, bireysel hastalar bazında ‘tümör alan ölçümü standart hatası’ (*area_se*) ve ‘ortalama yarıçap’ (*radius_mean*) gibi klinisyenlerin aşına olduğu morfolojik özelliklerin sınıflandırma kararına baskın katkısını ortaya koyarak modelin güvenilirliğini pekiştirmiştir. Q-MEDLEY'nin öznitelik-katkı varyans analizi, klasik ile kuantum bileşenlerin karar yapılarının yüksek oranda örtüştüğünü göstermiş ve melez karar sürecinin klinik tutarlılığını nicel olarak desteklemiştir. Çalışmanın mevcut katkıları ve klinik potansiyeli, elde edilen yüksek performans ile SHAP ve LIME analizleriyle sağlanan açıklanabilirlikte yatmaktadır. Bu kombinasyon, modelin dijital patoloji sistemlerine entegrasyonunun önünü açmaktadır. Potansiyel bir klinik uygulamada, hekimlerin tanıya ek olarak karar gerekçesini de anında görmesi, otomatik bir 'ikinci görüş' mekanizması olarak işlev görebilir. Modelin %98-100 bandındaki kesinlik oranı ve şeffaf karar yapısı, yanlış negatif ve yanlış pozitif oranlarını azaltmayı vaat etmekte ve klinik onay süreçlerini kolaylaştırıcı bir katkı sunmaktadır.

Bu araştırma, literatürde standart kıyaslama ölçütü olarak kullanılan tek bir veri setiyle yürütülmüştür; bu tercih metodolojik değişkenleri kontrol altında tutsa da modelin genelleme yeteneğini sınırlandırmaktadır. [Vamvakas vd. \(2022\)](#) ve [Qasrawi vd. \(2024\)](#) tarafından önerilen mpMRI ve büyük ölçekli mamografi arşivleri üzerinde dış doğrulama, topluluk öğrenme modelinin klinik geçerliliğini güçlendirmek için planlanmaktadır. Ayrıca, çalışmadaki kuantum modeller gürültüsüz simülasyonlarda test edilmiştir; gerçek NISQ donanımlarında kuantum gürültüsü, kuantum bit kısıtları ve hata düzeltme gereksinimleri performansı yeniden şekillendirebilir ([Martino & Delmastro, 2022](#)). Heterojen çok sınıflı ve dengesiz veri senaryolarında model davranışı henüz incelenmemiştir; gelecek çalışmalarda sentetik örnekleme (SMOTE-BNN) ve maliyet duyarlı eğitim stratejilerinin entegrasyonu önerilmektedir.

Sonuç olarak, bu çalışma, klasik, derin ve kuantum öğrenme paradigmalarını açıklanabilirlik katmanı eşliğinde tek potada birleştirerek literatürde rapor edilmiş en yüksek performans bandına yakın, fakat açıklanabilirliği koruyan bir meme kanseri tanı modeli sunmuştur. Literatür karşılaştırması, önerilen modelin mevcut yöntemler arasındaki konumunu açıkça ortaya koymakta; gelecekte çok merkezli, dengesiz ve çok sınıflı veri kümeleri üzerinde yapılacak deneyler ile gerçek kuantum donanım testlerinin, bu hibrit yaklaşımın klinik geçerliliğini daha da pekiştireceği öngörülmektedir.

Yazar katkısı

Author contribution

Makalenin tüm süreci, ilgili yazar tarafından gerçekleştirilmiştir.

Etik beyanı

Declaration of ethical code

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

Çıkar çatışması beyanı

Conflicts of interest

Yazarlar herhangi bir çıkar çatışması olmadığını beyan eder.

Kaynaklar

References

- Ahmed, K. A., Humaira, I., Khan, A. R., Hasan, M. S., Islam, M., Roy, A., ... & Xames, M. D. (2025). Advancing breast cancer prediction: Comparative analysis of ML models and deep learning-based multi-model ensembles on original and synthetic datasets. *PLoS One*, 20(6), e0326221. <https://doi.org/10.1371/journal.pone.0326221>
- Alawad, D., Katebi, A., Kabir, M., & Hoque, M. (2023). Accurate gene regulatory network inference using ensemble machine learning methods. *Bioinformatics Advances*, 3 (1), vbad032. <https://doi.org/10.1093/bioadv/vbad032>
- Alelyani, T., Alshammari, M. M., Almuhan, A., & Asan, O. (2024, May). Explainable artificial intelligence in quantifying breast Cancer factors: Saudi Arabia context. In *Healthcare* (Vol. 12, No. 10, p. 1025). MDPI. <https://doi.org/10.3390/healthcare12101025>
- Arik, S. Ö., & Pfister, T. (2021). Tabnet: Attentive interpretable tabular learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 35 (8), 6679–6687.
- Arravalli, T., Chadaga, K., Muralikrishna, H., Swathi, K. S., Sampathila, N., Cenitta, D., & Chadaga, R. (2025). Detection of breast cancer using machine learning and explainable artificial intelligence. *Scientific Reports*, 15, 26931. <https://doi.org/10.1038/s41598-025-12644-w>
- Benedetti, M., Lloyd, E., Sack, S., & Fiorentini, M. (2019). Parameterized quantum circuits as machine learning models. *Quantum Science and Technology*, 4 (4), 043001. <https://doi.org/10.1088/2058-9565/ab4eb5>
- Blank, C., Park, D., Rhee, J., & Petruccione, F. (2020). Quantum classifier with tailored quantum kernel. *NPJ Quantum Information*, 6(1). <https://doi.org/10.1038/s41534-020-0272-6>
- Bray, F., Laversanne, M., Sung, H., Ferlay, J., Siegel, R. L., Soerjomataram, I., & Jemal, A. (2024). Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: a cancer journal for clinicians*, 74(3), 229-263. <https://doi.org/10.3322/caac.21834>
- Cerezo, M., Arrasmith, A., Babbush, R., Benjamin, S. C., Endo, S., Fujii, K., ... & Coles, P. J. (2021). Variational quantum algorithms. *Nature Reviews Physics*, 3 (9), 625–644. <https://doi.org/10.1038/s42254-021-00348-9>
- Chen, T., & Guestrin, C. (2016). Xgboost: A scalable tree boosting system. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785–794. <https://doi.org/10.1145/2939672.2939785>

- Chereda, H., Bleckmann, A., Menck, K., Perera-Bel, J., Stegmaier, P., Auer, F., ... & Beißbarth, T. (2021). Explaining decisions of graph convolutional neural networks: patient-specific molecular subnetworks responsible for metastasis prediction in breast cancer. *Genome medicine*, 13(1), 42. <https://doi.org/10.1186/s13073-021-00845-7>
- Eyüpoğlu, C., & Yavuz, E. (2020). Kanser teşhisi için makine öğrenmesi tekniklerine dayalı yeni bir sınıflandırma metodu. *Bilecik Şeyh Edebali Üniversitesi Fen Bilimleri Dergisi*, 7 (2), 1106–1123.
- Ghasemi, A., Hashtarkhani, S., Schwartz, D. L., & Shaban-Nejad, A. (2024). Explainable artificial intelligence in breast cancer detection and risk prediction: A systematic scoping review. *Cancer Innovation*, 3(5), e136. <https://doi.org/10.1002/cai2.136>
- Güler, M., Sart, G., Algorabi, Ö., Adıguzel Tuylu, A. N., & Türkan, Y. S. (2025). Breast Cancer Classification with Various Optimized Deep Learning Methods. *Diagnostics*, 15(14), 1751. <https://doi.org/10.3390/diagnostics15141751>
- Han, L., & Yin, Z. (2022). A hybrid breast cancer classification algorithm based on meta-learning and artificial neural networks. *Frontiers in oncology*, 12, 1042964. <https://doi.org/10.3389/fonc.2022.1042964>
- Homayouni, H., & Mansoori, E. (2017). A novel density-based ensemble learning algorithm with application to protein structural classification. *Intelligent Data Analysis*, 21 (1), 167–179. <https://doi.org/10.3233/IDA-150357>
- Islam, T., Sheakh, M. A., Tahosin, M. S., Hena, M. H., Akash, S., Bin Jordan, Y. A., ... & Bourhia, M. (2024). Predictive modeling for breast cancer classification in the context of Bangladeshi patients by use of machine learning approach with explainable AI. *Scientific Reports*, 14(1), 8487. <https://doi.org/10.1038/s41598-024-57740-5>
- Kaddes, M., Ayid, Y. M., Elshewey, A. M., & Fouad, Y. (2025). Breast cancer classification based on hybrid CNN with LSTM model. *Scientific Reports*, 15(1), 4409. <https://doi.org/10.1038/s41598-025-88459-6>
- Kronic, Z., Flöther, F., Seegan, G., Earnest-Noble, N., & Shehab, O. (2022). Quantum kernels for real-world predictions based on electronic health records. *Ieee Transactions on Quantum Engineering*, 3, 1-11. <https://doi.org/10.1109/tqe.2022.3176806>
- Kör, H. (2019). Classification of breast cancer by machine learning methods. *4th International Symposium on Innovative Approaches in Engineering and Natural Sciences*, 508–511.
- Li, Y., Zhou, R., Xu, R., Hu, W., & Fan, P. (2020). Quantum algorithm for the nonlinear dimensionality reduction with arbitrary kernel. *Quantum Science and Technology*, 6(1), 014001. <https://doi.org/10.1088/2058-9565/abbe66>
- Martino, F. D., & Delmastro, F. (2022). Explainable AI for clinical and remote health applications: A survey on tabular and time series data. *Artificial Intelligence Review*, 56 (6), 5261–5315. <https://doi.org/10.1007/s10462-022-10304-3>
- Munkhdalai, L., Munkhdalai, T., Pham, V., Hong, J., Ryu, K. H., & Theera-Umpon, N. (2022). Neural network-augmented locally adaptive linear regression model for tabular data. *Sustainability*, 14 (22), 15273. <https://doi.org/10.3390/su142215273>
- Munshi, R. M., Cascone, L., Alturki, N., Saidani, O., Alshardan, A., & Umer, M. (2024). A novel approach for breast cancer detection using optimized ensemble learning framework and XAI. *Image and Vision Computing*, 142, 104910. <https://doi.org/10.1016/j.imavis.2024.104910>
- Nemade, V., & Fegade, V. (2023). Machine learning techniques for breast cancer prediction. *Procedia Computer Science*, 218, 1314–1320. <https://doi.org/10.1016/j.procs.2023.01.110>
- Oztekin, P. S., Katar, O., Omma, T., Erel, S., Tokur, O., Avci, D., ... & Acharya, U. R. (2024). Comparison of explainable artificial intelligence model and radiologist review performances to detect breast cancer in 752 patients. *Journal of Ultrasound in Medicine*, 43(11), 2051-2068. <https://doi.org/10.1002/jum.16535>
- Panagiotou, E., Heurich, M., Landgraf, T., & Ntoutsis, E. (2024). Tabcf: Counterfactual explanations for tabular data using a transformer-based VAE. *Proceedings of the 5th ACM International Conference on AI in Finance*, 274–282. <https://doi.org/10.1145/3677052.3698673>
- Prajapati, J.B., Paliwal, H., Prajapati, B.G., Saikia, S., Pandey, R. (2023). Quantum Machine Learning in Prediction of Breast Cancer. In: Pandey, R., Srivastava, N., Singh, N.K., Tyagi, K. (eds) *Quantum Computing: A Shift from*

- Bits to Qubits. Studies in Computational Intelligence, vol 1085. Springer, Singapore. https://doi.org/10.1007/978-981-19-9530-9_19
- Qasrawi, R., Daraghme, O., Qdaih, I., Thwib, S., Polo, S. V., Owienah, H., ... & Atari, S. (2024). Hybrid ensemble deep learning model for advancing breast cancer detection and classification in clinical applications. *Heliyon*, 10(19). <https://doi.org/10.1016/j.heliyon.2024.e38374>
- Quinn, H., Sedky, M., Francis, J., & Streeton, M. (2024). A literature review of explainable tabular data. *Preprints*. <https://doi.org/10.20944/preprints202408.0556.v1>
- Rebentrost, P., Mohseni, M., & Lloyd, S. (2014). Quantum support vector machine for big data classification. *Physical Review Letters*, 113 (13), 130503. <https://doi.org/10.1103/PhysRevLett.113.130503>
- Sahakyan, M., Aung, Z., & Rahwan, T. (2021). Explainable artificial intelligence for tabular data: A survey. *IEEE Access*, 9, 135392–135422. <https://doi.org/10.1109/ACCESS.2021.3116481>
- Shan, Z., Guo, J., Ding, X., Zhou, X., Wang, J., Lian, H., ... & Xu, J. (2022). Demonstration of breast cancer detection using QSVM on IBM quantum processors. <https://doi.org/10.21203/rs.3.rs-1434074/v1>
- Sharma, S., Aggarwal, A. & Choudhury, T. (2018). Breast cancer detection using machine learning algorithms. International Conference on Computational Techniques, Electronics and Mechanical Systems (CTEMS) 2018 (pp. 114–118). IEEE.
- Vamvakas, A., Tsivaka, D., Logothetis, A., Vassiou, K., & Tsougos, I. (2022). Breast cancer classification on multiparametric MRI–increased performance of boosting ensemble methods. *Technology in cancer research & treatment*, 21, 15330338221087828. <https://doi.org/10.1177/15330338221087828>
- Vidić, I., Egnell, L., Jerome, N. P., Teruel, J. R., Sjøbakk, T. E., Østlie, A., ... & Goa, P. E. (2018). Support vector machine for breast cancer classification using diffusion-weighted MRI histogram features: Preliminary study. *Journal of Magnetic Resonance Imaging*, 47(5), 1205-1216. <https://doi.org/10.1002/jmri.25873>
- Wang, P., Hu, X., Li, Y., Liu, Q., & Zhu, X. (2016). Automatic Cell Nuclei Segmentation And Classification Of Breast Cancer Histopathology Images. *Signal Processing*, 122, 1-13.
- Wolberg, W., Mangasarian, O., Street, N., & Street, W. (1993). Breast Cancer Wisconsin (Diagnostic) [Dataset]. UCI *Machine Learning Repository*. <https://doi.org/10.24432/C5DW2B>
- Xiang, Q., Li, D., Hu, Z., Yuan, Y., Sun, Y., Zhu, Y., ... & Hua, X. (2024). Quantum classical hybrid convolutional neural networks for breast cancer diagnosis. *Scientific Reports*, 14(1), 24699. <https://doi.org/10.1038/s41598-024-74778-7>
- Yang, P., Yang, J., Zhou, B., & Zomaya, A. (2010). A review of ensemble methods in bioinformatics. *Current Bioinformatics*, 5 (4), 296–308. <https://doi.org/10.2174/157489310794072508>
- Yıldız, O., Tez, M., Bilge, H. Ş., Akcayol, M. A., & Güler, İ. (2012). Meme kanseri sınıflandırması için veri füzyonu ve genetik algoritma tabanlı gen seçimi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 27(3).

EK DOSYALAR
SUPPLEMENTARY MATERIALS

Ek 1. Tüm Modellerin Hiperparametre Detayları
Appendix 1. Hyperparameter Details of All Models

Model Kategorisi	Model Adı	Hiperparametreler	Optimizasyon	Önemli Notlar
Klasik ML	Lojistik Regresyon	C: [0.001-100] penalty: ['l1','l2'] solver: ['liblinear']	GridSearchCV (5-fold)	L1/L2 düzenlileştirme test edildi
	Rastgele Orman	n_estimators=100 max_depth=5 random_state=SEED	-	Scikit-learn implementasyonu
	XGBoost	n_estimators=100 max_depth=5 learning_rate=0.1 eval_metric='logloss' random_state=SEED	-	GPU çalıştırıldı desteğiyle
Derin Öğrenme	TabNet	n_d=32 n_a=32 n_steps=5 gamma=1.5 lambda_sparse=1e-3 lr=2e-2 mask_type='entmax'	Deneyisel	Dikkat mimari mekanizmalı
Kuantum ML	VQC	n_qubits=5 depth=4 n_epoch=149 lr=0.0081 dropout=0.136 optimizer=Adam	Optuna (25 trial)	Pauli-Z ölçümü
	Quantum Kernel SVC	n_qubits=4 kernel=Hadamard+RZ+CNOT embedding=AngleEmbedding	-	ZZFeatureMap kullanıldı
Hibrit Model	Topluluk öğrenmesi	weight=[0.25,0.25,0.25,0.25] voting='soft'	-	XGBoost+TabNet+VQC+QKSVC