

Beyin Şişlərinin Tibbi Təsvirlər Əsasında Vision Transformer Modelləri ilə Diaqnostikası

Məsumə Məmmədova¹, Fərqanə Abdullayeva²

ETN İnformasiya Texnologiyaları İnstitutu, Bakı, Azərbaycan

¹mmg51@mail.ru, ²a_farqana@mail.ru

Xülasə — Müasir dövrdə insanların ölümünə ən çox səbəb olan xəstəliklərdən biri beyin şışıdır. Bu xəstəliyin erkən mərhələdə və dəqiq aşkarlanması dünya əhalisinin böyük bir hissəsinin həyatını xilas edə bilər. Pasiyentlərdə beyin şişlərinin dəqiq diaqnostikası və klassifikasiyası effektiv müalicə üsulunun təyin olunmasında mühüm əhəmiyyət kəsb edir. Bu məqalədə maqnit rezonans tomoqrafiya təsvirlərindən istifadə etməklə pasiyentlərdə beyin şişlərinin yüksək dəqiqliklə aşkarlanmasını və kateqoriyalasdırılmasını təmin edən vision transformer və çoxbloklı konvalyusiya neyron şəbəkələrinə əsaslanan modellər işlənmişdir. Təklif olunan üsullar elmi tədqiqatlar üçün açıq olan tibbi təsvir bazalarında sınaqdan keçirilmiş və müxtəlif metrikalar əsasında qiymətləndirilmişdir. Bu modellərin tətbiqinin əsas üstünlüyü təsvirlərdə əlamətlərin çıxarılması proseslərinin ənənəvi seqmentləşdirmə üsulları ilə deyil, diqqət və filtrasiya mexanizmləri vasitəsilə həyata keçirilməsindən ibarətdir.

Açar sözlər— beyin şışı; vision transformer; maqnit rezonans tomoqrafiya; diqqət mexanizmi; konvalyusiya neyron şəbəkələri

I. GİRİŞ

Beyin insan orqanizminin ən vacib orqanıdır və əzələ hərəkətləri, nəfəsalma, həzm prosesi və hissiyyat orqanlarının fəaliyyətinə nəzarət edir. Beyin şişləri dünya üzrə ən geniş yayılmış xəstəliklər sırasındadır [1]. Beyin şışı — beyində sürətlə bölünən və nəzarətsiz yayılan hüceyrələrin yaratdığı anormal hüceyrə toplusudur. Şişin mövcudluğu aşağıdakı simptomlarla özünü göstərə bilər: tutmalar, baş ağrısı, qusma, danışq və hərəkət çətinliyi, görmə pozuntuları, psixi pozğunluqlar və digər nevroloji əlamətlər. Statistikaya görə, beyin şişləri mərkəzi sinir sisteminin zədələnmələrinin 85–90%-ni təşkil edir. Amerika Xərçəng Cəmiyyəti (American Cancer Society) 2025-ci ildə 24,820 nəfərdə bədxassəli beyin və ya onurğa beyni şışı qeydə alınacağını proqnozlaşdırmışdır. Bu göstəricilərdən 14,040 nəfəri kişi, 10,780 nəfəri isə qadın olacaqdır. Əgər xoşxassəli (xərçəng olmayan) şişlər də nəzərə alınsa, bu rəqəmlər daha yüksək olardı. Həmin təşkilatın məlumatına əsasən, 2025-ci ildə təxminən 18,330 nəfərin (10,170 kişi və 8,160 qadın) beyin və onurğa beyni şişləri səbəbilə həyatını itirəcəyi gözlənilir [2].

Beyin xərçəngi kəllədəki hüceyrələr nəzarətsiz şəkildə böyüyərək çoxaldıqda baş verir. Beyin toxumasında anormal böyüyən hüceyrələr kütlə və ya şiş əmələ gətirir və sərt quruluş olan kəllə sümüyünə təzyiq göstərməyə başlayır. Bu vəziyyət öz növbəsində kəllədaxili təzyiqin artmasına səbəb ola bilər ki, bu da müxtəlif nevroloji və epileptik pozuntular üçün şərait

yaradır [3]. Beyin şışı qeyri-adi bir xəstəlik olsa da, dünya əhalisi yaşlandıqca beyin şişlərinin sayının artacağı təxmin edilir. Erkən diaqnozla bu xəstəliyin qarşısını almaq mümkündür. Beyin şişlərinin sürətlə yayılması onların erkən mərhələdə aşkarlanması üçün yüksək effektivliyə malik diaqnostik üsulların inkişaf etdirilməsini zəruri edir.

Effektivlik göstəricisi təklif olunmuş maşın və dərin təlim model və alqoritmlərdən istifadə etməklə əldə edilən nəticənin keyfiyyətini ifadə edir. Bu göstərici qoyulmuş məsələnin xarakterindən, modelin arxitekturasından, verilənlər bazasının həcmi və mürəkkəbliyindən və digər amillərdən asılıdır. Effektivlik müxtəlif dəqiqlik və məhsuldarlıq metrikaları əsasında qiymətləndirilir. Praktika daha çox istifadə olunan səmərəlilik metrikalarına Accuracy, Precision, Recall və F1-score daxildir [4].

Beyin şışı xəstəliyi istənilən yaşda olan insanda aşkarlanma və hər pasiyentdə fərqli simptomlarla müşayiət oluna bilər. Hətta müalicə prosesinin gedişatı belə fərqli nəticələri göstərə bilər. Bu səbəbdən müalicə seansları geniş müxtəlifliklə müşahidə olunur.

Maqnit rezonans tomoqrafiyası (Magnetic Resonance Imaging, MRI) hüceyrə forması, maddələr mübadiləsi, fiziologiya və funksiyalarda qeyri-invaziv dəyişiklikləri izləməyə imkan verən ən effektiv və sürətli diaqnostik üsullardan biridir [5, 6]. MRI vasitəsilə əldə edilən məlumatlar xərçəngin diaqnostikası və müalicəsinin planlaşdırılması üçün həyati vacib əhəmiyyət daşıyır. Beyin şişlərinin MRI vasitəsilə aşkarlanması və təsnifatlandırılması mürəkkəb proses hesab olunur. Bu proses zamanı əldə edilən təsvirlər əsasında innovativ üsullar tətbiq edilməklə beyində aşkarlanmış müxtəlif şiş növlərinin dəqiq tanınması, identifikasiyası və klassifikasiyası mümkündür [7]. Qeyd etmək lazımdır ki, tibbi texnologiyaların inkişafına baxmayaraq, beyin şişlərinin effektiv aşkarlanması və təsnifatı hazırda çətin və açıq məsələ olaraq qalır.

Bu problemlərin həlli üçün tədqiqatçılar və mütəxəssislər adətən təsvirlərin analizi və maşın təliminə əsaslanan qabaqcıl texnologiyalardan istifadə edirlər. Mövcud yanaşmalarda beyin şişlərinin müəyyən edilməsi üçün təsvirlər öncə seqmentləşdirilir [8]. Seqmentləşdirmə əsasən lokal, xüsusilə də şiş olan sahələrə fokuslanır. Bu prosesin aparılması zamanı isə vacib informasiyanın gözdən qaçma ehtimalı mövcuddur. Bu problemi aradan qaldırmaq üçün təsvirin müxtəlif sahələri arasındakı əlaqələr də nəzərə alınmalıdır. Məqalədə tibbi təsvirlərdə şişlərin dəqiq diaqnostikasını həyata keçirmək üçün

diqqət (attention) və filtrasiya mexanizmlərinə əsaslanan görmə transformeri (vision transformer, ViT), Çoxbloklı konvolyusiya neyron şəbəkəsi (convolutional neural network, CNN) modelləri işlənmiş və K sayda ən yaxın qonşular alqoritmı (k -nearest-neighbors, KNN) tətbiq edilmişdir.

II. ƏLAQƏLİ İŞLƏR

Beyin şişinin effektiv diaqnostikası, şişin aşkarlanması, onun beyin daxilində yerinin müəyyənəşdirilməsi və növünə görə təsnifatlaşdırılması məsələlərini əhatə edir. Beyin şişlərinin diaqnostikası üçün MRI-dən istifadə olunur.

Şişlərin aşkarlanması üçün CNN əsaslı modellər işlənmişdir. Bundan əlavə beyinin segmentləşdirilməsi və şişin yerinin müəyyənəşdirilməsi istiqamətində bir sıra yanaşmalar təklif olunmuşdur. [8]-də beyin şişlərinin MRI təsvirləri əsasında aşkarlanması üçün DeepNeuroXpert adlı yanaşma təklif edilmişdir. Bu yanaşmanın əsasını beyin şişlərini tanıya və kateqoriyalara ayıra bilən effektiv, sabit və sürətli bir sistem yaratmaq təşkil edir. Burada iç-içə özünüdiqqət segmentasiya şəbəkəsi (Nested Self-Attentive Segmentation Network, NSAS-Net) üsulu tətbiq olunaraq MRI təsvirlərində şiş sahələrinin segmentləşdirilməsi aparılmışdır. Daha sonra diqqət əlavə edilmiş anlayış kapsulu (attention-integrated inception capsule, AI2CF) alqoritmı əsasında şişlərin klassifikasiyası həyata keçirilmişdir. Burada kapsul şəbəkəsinin (capsule networks) parametrlərinin optimal seçilməsi üçün Wombat-Pelikan Sinergiya Optimallaşdırması (Wombat-Pelican Synergy Optimization, WPSO) üsulundan istifadə edilmişdir. [9]-də Transfer learning alqoritmı əsasında beyin şişlərinin erkən aşkarlanması üçün yanaşma təklif olunmuşdur. [5]-də kompüter görməsi sahəsində məşhur olan AlexNet və ResNet-50 alqoritmlərinin beyin şişlərinin klassifikasiyası məsələsində müqayisəli analizi aparılmışdır.

Yuxarıdakı metodlarda beyin şişlərinin aşkarlanması üçün təsvirlər segmentləşdirilir. Beyin şişlərinin MRI təsvirlərində dəqiq segmentləşdirilməsi beyin anatomiyasının mürəkkəb təbiəti və şişlərin forma və ölçülərindəki dəyişənlik səbəbindən çətin məsələ hesab olunur. Yanlış segmentləşmə, şişin səhv təsnifatlaşdırılmasına və ya yerinin müəyyənəşdirilməsinə səbəb ola bilər.

Mövcud yanaşmaların problemlərini aradan qaldırmaq üçün təqdim olunan işdə beyin şişlərinin erkən mərhələdə aşkarlanması üçün effektiv üsullar işlənmişdir.

III. ÇOXBLOKLİ CNN MODELİ

CNN dərin təlim üsuludur, giriş təsvirlərini qəbul edir, müxtəlif obyektlərə çəkilər təyin edir, onları bir-birindən fərqləndirməyə imkan verir.

Çoxbloklı CNN modelinin filtrləri {64, 128, 256, 512, 4608} olan 21 konvolyusiya layı, 5 *MaxPooling* layı təşkil edir. Tədqiqatda ölçüsü (100, 100) olan tibbi təsvirlər təklif edilmiş modelin girişinə ötürülür. Modelin əvvəlki iki tam əlaqəli layını 4608 qovşaq (neyron) təşkil edir. Sonuncu tam əlaqəli layda neyronların sayı siniflərin sayına uyğun götürülmüşdür. Bütün laylarda qeyri-xəttiliyi əldə etmək üçün modelin aktivləşmə funksiyası *Relu* təyin edilmişdir. Klassifikasiyanın həyata

keçirilməsi üçün sonuncu tam əlaqəli layda softmax reqressiya funksiyası istifadə edilmişdir.

IV. KNN MODELİ

Beyin şişlərinin aşkarlanması üçün tətbiq olunan digər üsul KNN alqoritmidir. KNN həm klassifikasiya, həm də reqressiya məsələlərində istifadə olunan supervizorlu maşın təlimi alqoritmidir [10]. KNN hər bir etiketsiz nöqtə ilə verilənlər bazasındakı bütün nöqtələr arasındakı məsafəni hesablayaraq etiketsiz verilənləri klassifikasiya edir. Daha sonra verilənlər bazasında nümunələri tapmaqla hər bir etiketlenməmiş nöqtəni eyni şəkildə etiketlenmiş verilənlərin sinfinə təyin olunur. KNN alqoritmində nöqtələr arasındakı məsafənin tapılması üçün Evklid məsafəsindən istifadə edilir [11]. Hər bir test nümunəsi x ilə təlim nöqtələri X arasındakı məsafə aşağıdakı düstur vasitəsi ilə hesablanır.

$$d(x, X) = \sqrt{\sum_{i=1}^n (x_i - X_i)^2}$$

burada, $x_i = (x_1, x_2, x_3, \dots, x_n)$ və $X_i = (X_1, X_2, X_3, \dots, X_n)$.

Bu alqoritmə klassifikasiya k sayda ən yaxın qonşular (ən kiçik məsafə) əsasında aparılır. Burada k – səsvermə çoxluğu prosesinə cəlb edilmiş yaxın qonşuların sayıdır.

Test nümunəsinə təyin edilmiş sinif etiketi k ən yaxın qonşularının səs çoxluğu əsasında (k -də maksimum üzvləri olan sinif) aşağıdakı düstur vasitəsi ilə təsnif olunur.

$$C(x_i) = \arg \max_k \sum_{X_j \in KNN} C(X_j, Y_k).$$

burada x_i test nümunəsi, X_j - test nümunəsinin təlim verilənlər bazasındakı k sayda ən yaxın qonşularından biridir. $C(X_j, Y_k)$ X_j nümunəsinin Y_k sinfinə daxil olma dərəcəsini göstərir.

V. VISION TRANSFORMER ƏSASLI MODEL


ViT neyron şəbəkənin növlərindən biridir, təsvirlərin klassifikasiyası üçün istifadə edilir [12]. ViT təbii dilin emalı üçün layihələndirilmiş arxitekturdan (məsələn, BERT) istifadə edir. Bu arxitekturanın əsas komponentini özünüdiqqət (self-attention) təşkil edir.

Arxitektura bu funksiyanın olması giriş verilənlərinin mövqeyindən asılı olmayaraq onların təsvirdə bölünmüş ayrı-ayrı hissələri arasında əlaqələri müəyyən etməyə imkan verir.

Təsviri bütövlükdə emal etmək və ya CNN-də olduğu kimi konvolyusiya filtrlərindən istifadə etmək əvəzində ViT təsviri kiçik kvadrat hissələrə (16*16 piksel) bölür, hər bir hissəni vektora daxil edir, bu vektorlar ardıcılığını (təsvirin hissələrini) transformerə ötürür. Burada vektor sözlərdən ibarət cümləyə bənzəyir.

Ənənəvi CNN-dən fərqli olaraq ViT əlamətləri çıxarmaq üçün konvulyusiya layından istifadə etmir. Bu model yalnız diqqət mexanizminə (attention mechanism) əsaslanır. ViT modeli tətbiq edildikdə təsvirin seqmentləşdirilməsinə ehtiyac olmur. Model özünün self-attention mexanizmindən istifadə etməklə təsvirin vacib sahələrini öyrənir. ViT modeli çoxsaylı transformer bloklarından ibarətdir. Transformer blokları paketin ölçüsü, hissələrin sayı, proyeksiyanın ölçüsü adlı elementlərdən ibarət tenzor yaradır. Bu tenzor ViT modelinin sonuncu softmax classifier blokuna ötürülməklə çıxışda hər bir sinfin ehtimal qiymətlərinin hesablanmasını təmin edir.

Vision transformer tipli dərin təlim modelinin arxitekturası Şəkil 1-də verilmişdir [12].



Şəkil 1. ViT tipli dərin təlim modeli.


Şəkildən göründüyü kimi ilk öncə təsvir sabit ölçülü parçalara bölünür, hər bir təsvir parçası xətti şəkildə yerləşdirilir, yaranmış vektor ardıcılığı transformer kodlayıcısının girişinə ötürülür. Klassifikasiyanı həyata keçirmək üçün ənənəvi çoxlaylı perseptron tətbiq edilir. Qoyulmuş məsələdən asılı olaraq bu klassifikatorun əvəzində başqa üsul da istifadə edilər bilər. Baxılan halda beyin şişlərinin klassifikasiyası zamanı softmax klassifikatoru istifadə edilmişdir.

VI. EKSPERİMENTLƏR

Eksperimentlərin aparılması üçün beyin şişlərinin müəyyən edilməsində Brain Tumor MRI verilənlər bazası istifadə edilmişdir [13, 14].

Brain Tumor verilənlər bazası 7023 sayda təsvirdən ibarətdir və dörd sinif təşkil edir: glioma, meningioma, no tumor, pituitary. Bu siniflərdən olan nümunələr Şəkil 2-də göstərilmişdir.

Cədvəldən göründüyü kimi Çoxbloklı CNN modeli az itkiyə yol verərək verilənlər bazasının siniflər üzrə nümunələrini dəqiq tanıya bilmişdir. Belə ki, Glioma, Meningioma, Notumor, Pituitary sinifləri üzrə accuracy göstəricisi üzrə uyğun olaraq 0.8067, 0.7320, 0.9506, 0.8100 qiymətləri alınmışdır.



Şəkil 2. Brain Tumor bazasından nümunələr.


KNN, Çoxbloklı CNN və ViT modellərinin Brain Tumor Dataset üzərində aparılmış eksperimentlərin nəticələri Cədvəl 1-də verilmişdir.

CƏDVƏL 1. KNN, ÇOXBLOKLı CNN VƏ ViT MODELƏRİNİN BRAIN TUMOR VERİLƏNLƏR BAZASI ÜZƏRİNDƏ KLASSİFİKASIYA NƏTİCƏLƏRİ

Metod	Sınıf	Precision	Recall	F1-score	Accuracy
ViT	Glioma	0.9680	0.8542	0.9076	0.8542
	Meningioma	0.8260	0.8260	0.8152	0.8260
	Notumor	0.9442	0.9545	0.9493	0.9545
	Pituitary	0.8795	0.9498	0.9133	0.9498
Çoxbloklı CNN	Glioma	0.7883	0.8067	0.7974	0.8067
	Meningioma	0.7368	0.7320	0.7344	0.7320
	Notumor	0.8891	0.9506	0.9189	0.9506
	Pituitary	0.9101	0.8100	0.8571	0.8100
KNN	Glioma	0.7724	0.9181	0.8390	0.9181
	Meningioma	0.8684	0.6392	0.7364	0.6392
	Notumor	0.8930	0.9273	0.9098	0.9273
	Pituitary	0.9237	0.9528	0.9381	0.9528

CNN algoritmi verilənlərin klassifikasiyasını təsvirin pikselləri əsasında həyata keçirir. Hər bir şəkil piksellərdən ibarət 32x32 ölçülü matrisə transformasiya edilmişdir. Daha sonra 32x32 ölçülü RGB formatlı təsvir 3072 ölçülü vektora transformasiya edilmişdir ($32 \times 32 \times 3 = 3072$). Bu vektor verilənlərin klassifikasiyası prosesində əlamətlər kimi istifadə edilmişdir. Tibbi təsvirlərin sinifləri tam ədədlərlə göstərilmişdir. Verilənlər bazasında təsvirlərin 75 faizi təlim, 25 faizi test üçün istifadə edilmişdir. CNN klassifikatoru üçün qonşu qovşaqların sayı 7 götürülmüşdür. KNN təsvirdəki şişləri klassifikasiya etmək üçün piksel intensivliyi oxşarlığından istifadə edir. Çoxbloklı CNN modelində itki *categorical crossentropy* funksiyası, parametrlərinin optimallaşdırılması isə RMSprop vasitəsi ilə qiymətləndirilir.

Tədqiqatda ImageNet verilənlər bazası üzərində əvvəlcədən öyrədilmiş *google/vit-base-patch16-224-in21k* adlı ViT modeli beyin şişlərinin identifikasiyası məsələsinə tətbiq edilmişdir. Şişlərin aşkarlanmasını və klassifikasiyasını həyata keçirən metodlarının Brain Tumor verilənlər bazası üzərində 30 iterasiyada alınmış xətlər matrisi Şəkil 3-də verilmişdir.



Şəkil 3. Metodların Brain Tumor bazası üzərində xətlər matrisi

Şəkil 3-dən göründüyü kimi 30 iterasiyada ViT algoritmi Çoxbloklı CNN algoritmi ilə müqayisədə glioma sinfindən olan nümunələri 0.8542 dəqiqliyi ilə tanıya bilmişdir. Çoxbloklı CNN bu sinif nümunələrin tanınmasında 0,1933 xəyata yol verdiyi halda, ViT modelinin xəta qiyməti 0,1458 olmuşdur. KNN 2-ci sinifdən olan meningioma nümunələrini 0.6392, Çoxbloklı CNN isə 0.7320 dəqiqliyi ilə tanımışdır. ViT isə bu sinifdən olan nümunələri 0.8260 dəqiqliyi ilə tanımışdır.

Şəkildən göründüyü kimi ViT verilənlər bazasının bütün siniflərindən olan nümunələri yüksək dəqiqliklə tanıyaraq, xətlər matrisinin elementlərini diaqonal üzrə yığa bilmişdir. Bu nəticələr ViT modelinin daha üstün olduğunu sübut edir.

V. NƏTİCƏ

Beyin şişləri dünya üzrə ən geniş yayılmış xəstəliklər sırasında. Tibbi avadanlıqların və süni intellekt texnologiyalarının inkişafı müxtəlif xəstəliklərin, o cümlədən beyin şişlərinin erkən mərhələdə yüksək dəqiqliklə identifikasiyası üçün yeni imkanlar açmışdır. Məqalədə maqnit rezonans tomoqrafiya vasitəsilə əldə edilmiş histoloji təsvirlər bazasından beyin şişlərinin tibbi əlamətlərin çıxarılması üçün ViT və dərin təlim metodları sinfinə aid olan Çoxbloklı konvolyusiya neyron şəbəkələri əsasında yeni modellər işlənmişdir. Bu modellərin əsasını təşkil edən diqqət və filtrasiya mexanizmləri ənənəvi segmentləşdirmə üsullarının bəzi çatışmazlıqlarını aradan qaldırmaqla şişlərin daha dəqiq klassifikasiyanı təmin edir. Açıq tibbi təsvir bazası üzərində aparılmış eksperimentlərin nəticələrinin müxtəlif metrikalar əsasında qiymətləndirilməsi təklif olunmuş modellərin effektivliyini təsdiq edir.

MINNƏTDARLIQ

Bu iş Azərbaycan Elm Fondunun maliyyə dəstəyi ilə yerinə yetirilmişdir – Qrant № AEF-MCG-2023- 1(43)-13/04/1-M-04.

ƏDƏBİYYAT

- [1] C. Hardwidge, S. Hettige, “Tumours of the central nervous system,” Surgery, vol. 30, pp. 155–161, 2012.
- [2] Key statistics for brain and spinal cord tumors. American Cancer Society. <https://www.cancer.org/cancer/types/brain-spinal-cord-tumors-adults/about/key-statistics.html>
- [3] M. Babayomi, O.A. Olagbaju, A.A. Kadiri, “Convolutional XGBoost (C-XGBOOST) Model for Brain Tumor Detection,” 2023, pp. 1-14, arXiv:2301.02317v1
- [4] An Q, Rahman S, Zhou J, Kang JJ. A comprehensive review on machine learning in healthcare industry: classification, restrictions, opportunities and challenges. Sensors. 2023;23(9):4178. doi: 10.3390/s23094178
- [5] V.K. Dhakshnamurthy, M. Govindan, K. Sreerangan, M.D. Nagarajan, A. Thomas, “Brain tumor detection and classification using transfer learning models,” Engineering Proceedings, vol. 62, pp. 1–10, 2024.
- [6] I.S. Rajput, A. Gupta, V. Jain, S. Tyagi, “A transfer learning-based brain tumor classification using magnetic resonance images,” Multimedia Tools Applications, vol. 83, pp. 20487–20506, 2024.
- [7] S.E. Nassar, I. Yasser, H.M. Amer, M.A. Mohamed, “A robust MRI-based brain tumor classification via a hybrid deep learning technique,” The Journal of Supercomputing, vol. 80, pp. 2403–2427, 2024.
- [8] A.K. Dutta, Y. Bokhari, F. Alghayadh, et al., “A synaptic deep tumor sense predictor system for brain tumor detection and classification,” Alexandria Engineering Journal, vol. 123, pp. 29–45, 2025.
- [9] M. Agarwal, G. Rani, A. Kumar, et al. “Deep learning for enhanced brain Tumor Detection and classification,” Results Engineering, vol. 22, pp. 1-12, 2024.
- [10] G. Guo, H. Wang, D. Bell, Y. Bi, K. Greer, “KNN model-based approach in classification,” OTM Confederated International Conferences on the Move to Meaningful Internet Systems, Lecture Notes in Computer Science, vol 2888, pp. 986-996, Springer, Berlin, Heidelberg, 2003.
- [11] A. Almomany, W.R. Ayyad, A. Jarrah, “Optimized implementation of an improved KNN classification algorithm using Intel FPGA platform: Covid-19 case study,” Journal of King Saud University - Computer and Information Sciences, vol. 34, no. 6, pp. 3815-3827, 2022.
- [12] A. Dosovitskiy, L. Beyer et al., “An Image is Worth 16x16 Words: Transformers for Image Recognition at Scale,” arXiv:2010.11929v2 [cs.CV] 3 Jun 2021, pp. 1-22, 2021.
- [13] Brain Tumor MRI Dataset, <https://www.kaggle.com/datasets/masoudnickparvar/brain-tumor-mri-dataset>
- [14] A. Janowczyk, A. Madabhushi, “Deep learning for digital pathology image analysis: A comprehensive tutorial with selected use cases,” Journal of Pathology Informatics, vol. 7, no. 1, pp. 1-18, 2016. <https://www.kaggle.com/datasets/paultimothymooney/breast-histopathology-images>.