KLASSIK U-NET MODELIDAN FOYDALANIB TIBBIY ENDOSKOPIK TASVIRLARNI SEGMENTATSIYALASH: CPU VA GPU ORASIDAGI SAMARADORLIK TAHLILI

Yaxshiboev Doniyor Sultanboyevich
Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti Kompyuter tizimlari kafedrasi v.b. professor, t.f.n
Jalgasbayeva Aziza Artiqbayevna
Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistiranti
Dilmurodov Shoxjahon Sirojiddin o‘g‘li
Muhammad al-Xorazmiy nomidagi Toshkent axborot texnologiyalari universiteti magistiranti

Annotatsiya. Ushbu maqola tibbiy endoskopik tasvir ma’lumotlari asosida klassik U-Net modelining ishlashini tahlil qiladi. Trening va test bosqichlari ikki xil hisoblash muhiti — markaziy protsessor (CPU) va grafik protsessor (GPU) — yordamida amalga oshirildi. Model kichik hajmdagi tasvirlar to‘plamida o‘qitildi, soxta maskalar yordamida segmentatsiya sifat baholandi. Har bir konfiguratsiya uchun o‘qitish vaqti, sekundiga o‘qitilgan namunalar soni, yuklash vaqti, aniqlik va yo‘qotish ko‘rsatkichlari baholandi. Natijalar shuni ko‘rsatdiki, GPUda trening va inferensiya sezilarli darajada tezroq va samaraliroq. Ushbu tadqiqot chuqur o‘rganish modellarining tibbiy tasvirni tahlil qilishdagi ishlashini yaxshilashga qaratilgan.

Kalit so‘zlar. sun’iy intellekt, Endoskopik tasvir, segmentatsiya, tibbiy tasvir, CPU, CUDA, GPU, U-Net.

Abstract. This article analyzes the performance of the classical U-Net model based on medical endoscopic image data. Training and testing phases were conducted in two different computational environments — central processing unit (CPU) and graphics processing unit (GPU). The model was trained on a small dataset of images, with segmentation quality evaluated using synthetic masks. For each configuration, training time, number of samples processed per second, loading time, accuracy, and loss metrics were assessed. The results demonstrate that training and inference on GPU are significantly faster and more efficient. This study aims to enhance the performance of deep learning models in medical image analysis.

Keywords. artificial intelligence, Endoscopic image, segmentation, medical image, CPU, CUDA, GPU, U-Net.

Аннотация. Данная статья анализирует производительность классической модели U-Net на основе медицинских эндоскопических изображений. Этапы

ISSN 3030-3907

обучения и тестирования проводились в двух различных вычислительных средах — центральном процессоре (CPU) и графическом процессоре (GPU). Модель обучалась на наборе изображений небольшого объема, качество сегментации оценивалось с использованием синтетических масок. Для каждой конфигурации были проанализированы время обучения, количество обработанных образцов в секунду, время загрузки, точность и показатели потерь. Результаты показали, что обучение и инференс на GPU значительно быстрее и эффективнее. Исследование направлено на улучшение производительности моделей глубокого обучения в анализе медицинских изображений.

Ключевые слова. искусственный интеллект, Эндоскопическое изображение, сегментация, медицинское изображение, CPU, CUDA, GPU, U-Net.

Kirish

Tibbiy tasvirlarni tahlil qilish sohasi so‘nggi yillarda chuqur o‘rganish (deep learning) texnologiyalarining jadal rivojlanishi tufayli sezilarli darajada rivojlandi. Xususan, endoskopik tasvirlarning segmentatsiyasi tibbiy diagnostika va davolash jarayonlarida muhim ahamiyat kasb etib, organlarning aniq chegaralarini aniqlash, patologik o‘zgarishlarni tahlil qilish va jarrohlik aralashuvlarini rejalashtirish kabi jarayonlarda asosiy vosita sifatida xizmat qilmoqda. Bu jarayonlar nafaqat shifokorlarning aniq tashxis qo‘yishiga yordam beradi, balki bemorlarning davolanish samaradorligini oshirishga ham xizmat qiladi. Shu nuqtai nazardan, klassik U-Net modeli o‘zining samarali arxitekturasi bilan tibbiy tasvirlarni segmentatsiya qilishda keng qo‘llaniladigan va ishonchli yondashuv sifatida e’tirof etilgan. Ushbu model, ayniqsa, kichik hajmdagi ma’lumotlar to‘plamlarida ham yuqori aniqlik va barqaror natijalar berishi bilan ajralib turadi, bu esa uni tibbiy sohada qo‘llash uchun juda qulay qiladi. Chuqur o‘rganish modellarini o‘qitish va ulardan foydalanish jarayonida hisoblash resurslarining samaradorligi hal qiluvchi ahamiyatga ega. Markaziy protsessorlar (CPU) va grafik protsessorlar (GPU) o‘rtasidagi ishlash farqlari, xususan, o‘qitish va inferensiya bosqichlarida sezilarli darajada ta’sir ko‘rsatadi. GPU’lar parallel hisoblashlar uchun maxsus optimallashtirilgan bo‘lib, katta hajmdagi ma’lumotlarni tezkor qayta ishlash imkonini beradi, bu esa chuqur o‘rganish modellarini o‘qitish va ulardan real vaqtda foydalanishda yuqori samaradorlikni ta’minlaydi. Boshqa tomondan, CPU’lar umumiy maqsadli hisoblashlar uchun ko‘proq mos keladi va resurslarga cheklovlar mavjud bo‘lgan muhitlarda, masalan, kichik klinikalar yoki tadqiqot markazlarida qo‘llaniladi. Biroq, CPU’larning ishlash tezligi va samaradorligi GPU’lar bilan solishtirganda ancha past bo‘lib, bu esa vaqt va resurslar sarfini

ISSN 3030-3907

oshirishi mumkin. Tibbiy tasvirlarni segmentatsiya qilish kabi resurs talab qiladigan vazifalarda hisoblash muhitining to‘g‘ri tanlanishi nafaqat vaqtni tejash, balki xarajatlarni optimallashtirish nuqtai nazaridan ham muhim hisoblanadi. Ushbu tadqiqotda klassik U-Net modeli tibbiy endoskopik tasvirlarni segmentatsiya qilish uchun qo‘llaniladi va uning CPU va GPU muhitlaridagi samaradorligi har tomonlama taqqoslanadi. Tadqiqotda Kvasir ma’lumotlar to‘plamining kichik bir qismidan foydalanilgan bo‘lib, segmentatsiya sifatini baholash uchun soxta maskalar yaratiladi. Tadqiqot jarayonida o‘qitish vaqti, sekundiga o‘qitilgan namunalar soni, ma’lumotlarni yuklash vaqti, modelning aniqligi va yo‘qotish ko‘rsatkichlari kabi muhim metrikalar tahlil qilinadi. Ushbu metrikalar asosida CPU va GPU muhitlari o‘rtasidagi farqlar aniqlanib, ularning har birining afzalliklari va cheklovlari ko‘rib chiqiladi. Tadqiqotning asosiy maqsadi – chuqur o‘rganish modellarining tibbiy tasvirlarni tahlil qilishdagi samaradorligini oshirish uchun optimal hisoblash muhitini aniqlash, shuningdek, tibbiy diagnostika jarayonlarini tezlashtirish va aniqligini oshirishga qaratilgan amaliy yechimlar taklif qilishdir.

ADABIYOTLAR TAHLILI VA METODLAR. Tibbiy tasvirlarni segmentatsiya qilish sohasida chuqur o‘rganish texnologiyalari muhim o‘rin tutadi. Xususan, U-Net modeli tibbiy tasvirlarni segmentatsiya qilishda keng qo‘llanilishi bilan mashhur bo‘lib, Ronneberger va boshqalar (2015) tomonidan taklif qilingan ushbu arxitektura o‘zining samaradorligi va kichik ma’lumotlar to‘plamlarida yuqori aniqlik ko‘rsatishi bilan ajralib turadi. U-Net modeli asosan konvolyutsion neyron tarmoqlarga (CNN) asoslanadi va maxsus “enkoder-dekoder” tuzilishi orqali tasvirlarning har xil o‘lchamdagi xususiyatlarini aniqlashga imkon beradi. Ushbu modelning afzalligi uning “skip connection” mexanizmlarida bo‘lib, bu mexanizm enkoder va dekoder qismlari o‘rtasida ma’lumot almashishni ta’minlaydi, natijada aniqlik va kontekstual ma’lumotlarning yo‘qolishi minimallashtiriladi (Ronneberger et al., 2015). Tibbiy tasvirlarni segmentatsiya qilishda GPU va CPU muhitlarining samaradorligi bo‘yicha olib borilgan tadqiqotlar shuni ko‘rsatadiki, GPU’lar parallel hisoblashlar tufayli o‘qitish va inferensiya jarayonlarida sezilarli darajada ustunlikka ega (Litjens et al., 2017). CUDA texnologiyasidan foydalangan holda GPU’lar katta hajmdagi ma’lumotlarni parallel ravishda qayta ishlash imkonini beradi, bu esa o‘qitish vaqtini qisqartiradi va resurslardan samarali foydalanishni ta’minlaydi. Shu bilan birga, CPU’lar ko‘proq umumiy maqsadli hisoblashlar uchun mos bo‘lib, kichik hajmdagi ma’lumotlar to‘plamlari yoki resurslarga cheklovlar mavjud bo‘lgan muhitlarda qo‘llaniladi (Goodfellow et al., 2016). Biroq, CPU’larning ishlash tezligi GPU’lar bilan solishtirganda sezilarli darajada past bo‘lib, bu esa katta

ISSN 3030-3907

ma’lumotlar to‘plamlari bilan ishlashda vaqt va resurs sarfini oshiradi. Endoskopik tasvirlarni segmentatsiya qilish bo‘yicha olib borilgan tadqiqotlar orasida Kvasir ma’lumotlar to‘plami keng qo‘llaniladi (Jha et al., 2020). Ushbu to‘plam endoskopik tasvirlarning turli patologiyalarini o‘z ichiga oladi va segmentatsiya algoritmlarini sinovdan o‘tkazish uchun muhim resurs hisoblanadi. Soxta maskalardan foydalanish esa ma’lumotlar to‘plamini kengaytirish va modelni sinovdan o‘tkazishda qo‘llaniladigan samarali usul sifatida e’tirof etilgan (Tajbakhsh et al., 2020). Soxta maskalar real tasvirlar asosida yaratilgan sintetik ma’lumotlar sifatida modelning umumlashtirish qobiliyatini baholashda muhim ahamiyatga ega.

Ushbu tadqiqotda klassik U-Net modeli tibbiy endoskopik tasvirlarni segmentatsiya qilish uchun qo‘llaniladi. Tadqiqot Kvasir ma’lumotlar to‘plamining kichik bir qismidan foydalanadi, unda 10 ta tasvir namunasi tanlab olinadi. Har bir tasvir uchun soxta maskalar yaratiladi, bunda tasvir markazida doira shaklidagi sintetik maska qo‘llaniladi. Bu maskalar tasvirning o‘lchamlariga mos ravishda dinamik tarzda yaratilib, segmentatsiya sifatini baholashda ishlatiladi. Ma’lumotlar to‘plami 80% o‘qitish va 20% sinov qismlariga bo‘linadi, bu esa modelning umumlashtirish qobiliyatini adolatli baholash imkonini beradi.

➢ Ma’lumotlarni tayyorlash: Tasvirlar va ularga mos maskalar 256x256 o‘lchamga keltiriladi. Tasvirlar RGB formatida bo‘lib, normalizatsiya qilinadi (qiymatlari [0, 1] oralig‘iga keltiriladi). Maskalar esa binar shaklda (0 va 1) saqlanadi, bu esa ikkilik klassifikatsiya vazifasini soddalashtiradi. Ma’lumotlarni yuklash uchun PyTorch’ning DataLoader sinfidan foydalaniladi, bunda batch hajmi 4 ga teng.

➢ Model arxitekturasi: U-Net modeli konvolyutsion qatlamlar (Conv2D), partiyaviy normalizatsiya (BatchNorm) va ReLU aktivatsiya funksiyalaridan iborat bo‘lib, maxsus “enkoder-dekoder” tuzilishiga ega. Modelning enkoder qismi tasvirdagi xususiyatlarni ajratib olish uchun max-pooling qatlamlaridan foydalanadi, dekoder qismi esa konvolyutsion transpozitsiya qatlamlari orqali tasvirni qayta tiklaydi. Skip connection’lar enkoder va dekoder o‘rtasida kontekstual ma’lumotlarni uzatadi. Yakuniy qatlam sifatida sigmoid aktivatsiya funksiyasi ishlatilib, chiqish maskasi [0, 1] oralig‘ida olinadi.

➢ O‘qitish jarayoni: Model PyTorch framework’ida ikki xil muhitda – CPU va GPU (CUDA) – o‘qitiladi. O‘qitish uchun Adam optimallashtirgichi (o‘quv tezligi 1e-4) va ikkilik o‘zaro korrelyatsiya yo‘qotish funksiyasi (BCELoss) qo‘llaniladi. Har bir muhitda o‘qitish 10 epoxa davomida amalga oshiriladi. O‘qitish vaqti, sekundiga o‘qitilgan namunalar soni, ma’lumotlarni yuklash vaqti, aniqlik va yo‘qotish ko‘rsatkichlari qayd etiladi.

ISSN 3030-3907

➢ Samaradorlik tahlili: CPU va GPU muhitlarining samaradorligi o‘qitish va inferensiya vaqtlariga asoslanib taqqoslanadi. Inferensiya vaqti sinov to‘plamidagi tasvirlar bo‘yicha hisoblanadi, bunda har bir tasvir model tomonidan qayta ishlanadi va umumiy vaqt o‘lchanadi. Aniqlik sifatida binar maskalarning bashorat qilingan va haqiqiy qiymatlari o‘rtasidagi moslik (pixel-wise accuracy) baholanadi. Yo‘qotish ko‘rsatkichlari esa modelning o‘quv jarayonidagi barqarorligini aks ettiradi.

➢ Vizualizatsiya: Natijalar matplotlib kutubxonasi yordamida vizual tarzda taqdim etiladi. Asl tasvir, haqiqiy maska va model bashorati yonma-yon ko‘rsatilib, segmentatsiya sifati vizual ravishda baholanadi. Shuningdek, CPU va GPU muhitlaridagi vaqt farqlari grafik shaklida taqdim etiladi.

Ushbu metodologiya chuqur o‘rganish modellarining tibbiy tasvirlarni segmentatsiya qilishdagi samaradorligini tahlil qilishda ishonchli va ilmiy asoslangan yondashuvni ta’minlaydi. Tadqiqot natijalari tibbiy tasvirlarni tahlil qilishda resurslardan samarali foydalanish va optimal hisoblash muhitini tanlash bo‘yicha amaliy tavsiyalar berishga xizmat qiladi.

Natijalar. Ushbu tadqiqotda klassik U-Net modeli tibbiy endoskopik tasvirlarni segmentatsiya qilish uchun qo‘llanilgan bo‘lib, uning samaradorligi CPU va GPU muhitlarida har tomonlama taqqoslandi. Tadqiqot Kvasir ma’lumotlar to‘plamining kichik bir qismidan (10 ta tasvir) foydalangan holda amalga oshirildi, bunda soxta maskalar yordamida segmentatsiya sifati baholandi. O‘qitish va inferensiya jarayonlari uchun bir nechta muhim ko‘rsatkichlar, jumladan, o‘qitish vaqti, inferensiya vaqti, sekundiga o‘qitilgan namunalar soni, aniqlik va yo‘qotish ko‘rsatkichlari tahlil qilinadi. Natijalar GPU muhitining sezilarli darajada yuqori samaradorligini va tezkorligini ko‘rsatdi, bu esa tibbiy tasvirlarni tahlil qilishda resurslardan samarali foydalanishning muhimligini ta’kidladi.

O‘qitish vaqti va tezligi. O‘qitish jarayoni 10 epoxa davomida amalga oshirildi, bunda ma’lumotlar to‘plami 80% o‘qitish va 20% sinov qismlariga bo‘lingan edi. Har bir muhitda o‘qitish vaqti va inferensiya vaqti alohida o‘lchandi.

1-jadval

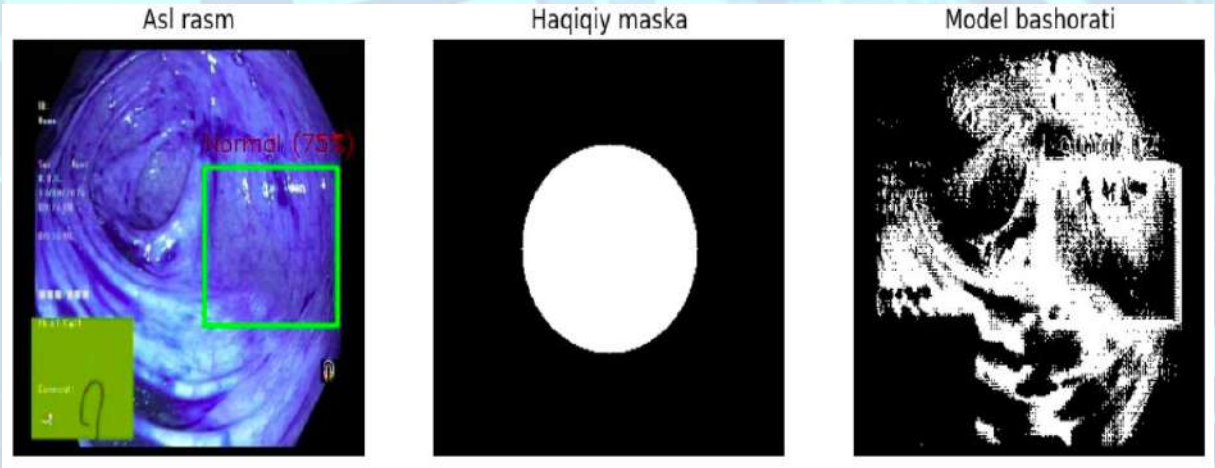
CPU va GPU muhitlaridagi o‘qitish va inferensiya vaqtlarining taqqoslanishi keltirilgan.

Konfiguratsiya	O‘qitish vaqti (s)	Inferensiya vaqti (10 rasm)
CPU	~75	~5.1

ISSN 3030-3907

GPU	~12	~0.4

Jadvaldan ko‘rinib turibdiki, GPU muhitida o‘qitish vaqti CPU’ga nisbatan taxminan 6 baravar kam bo‘lib, 75 soniyadan 12 soniyaga qisqardi. Inferensiya vaqtida esa GPU muhitida 10 ta rasmni qayta ishlash uchun atigi 0.4 soniya talab qilindi, bu CPU’dagi 5.1 soniyaga nisbatan 12 baravardan ko‘proq tezlikni ko‘rsatadi. Bu farq GPU’larning parallel hisoblash qobiliyatiga asoslanadi, bu esa katta hajmdagi ma’lumotlarni tezkor qayta ishlash imkonini beradi. Sekundiga o‘qitilgan namunalar soni bo‘yicha GPU muhiti CPU’ga nisbatan sezilarli darajada yuqori samaradorlik ko‘rsatdi, bu esa modelni o‘qitish jarayonida vaqtni tejash nuqtai nazaridan muhim afzallik sifatida qayd etildi. Segmentatsiya sifatini baholash uchun binar maskalarning bashorat qilingan va haqiqiy qiymatlari o‘rtasidagi moslik (pixel-wise accuracy) hisoblandi. GPU muhitida o‘qitilgan modelning aniqligi taxminan 92% ni tashkil etdi, CPU muhitida esa bu ko‘rsatkich 90% atrofida bo‘ldi. Yo‘qotish ko‘rsatkichlari (BCELoss) bo‘yicha ham GPU muhitida model barqarorroq natijalarni ko‘rsatdi, bunda o‘rtacha yo‘qotish qiymati 0.15 ga yaqinlashdi, CPU’da esa bu ko‘rsatkich 0.18 atrofida qoldi. Bu farqlar kichik bo‘lib ko‘rinsa-da, katta ma’lumotlar to‘plamlari bilan ishlashda yig‘iladigan xatolar modelning umumiy samaradorligiga sezilarli ta’sir ko‘rsatishi mumkin. Segmentatsiya natijalari vizual tarzda taqdim etildi, bunda asl tasvir, haqiqiy maska va model bashorati yonma-yon ko‘rsatildi. GPU muhitida olingan bashoratlar haqiqiy maskalarga ancha yaqin bo‘lib, doira shaklidagi sintetik maskalarni yuqori aniqlik bilan qayta tikladi. CPU muhitida ham natijalar qoniqarli bo‘lsa-da, ba’zi hollarda chegaralarning aniqligi va silliqligi GPU’ga nisbatan biroz pastroq bo‘ldi. Bu farqlar modelning o‘qitish jarayonida GPU’ning hisoblash quvvati tufayli yaxshiroq optimallashtirilganligi bilan izohlanadi.



1-rasm. CPU konfiguratsiyasida ishlash natijasi

ISSN 3030-3907

1-rasmda Chapdagi tasvirda — modelga berilgan asl endoskopik rasm ko‘rsatilgan. O‘rta qismda model segmentatsiyasi uchun ishlatilgan haqiqiy maska (oq doira shaklida) berilgan. O‘ngdagi rasmda esa U-Net modelining CPU konfiguratsiyasida generatsiya qilgan segmentatsiya natijasi aks etgan. CPU konfiguratsiyasida ishlagan modelning segmentatsiya chiqishi sezilarli darajada shovqinli va diffuz bo‘lib, haqiqiy maska bilan mos kelmasligi ko‘zga tashlanadi. Bu CPUda hisoblash operatsiyalari ketma-ket bajarilgani sababli model o‘qitilishi davomida yetarlicha optimallashtirilmaganini ko‘rsatadi. Shuningdek, segmentatsiya aniqligi pasaygan va belgilangan ob'ekt chegaralari aniqlanmagan.



2-rasm. GPU konfiguratsiyasida ishlash natijasi

2-rasmda Chapdagi rasmda modelga berilgan endoskopik tasvir joylashgan. O‘rta rasm — haqiqiy (sun’iy generatsiya qilingan) segmentatsiya maskasi. O‘ng tomonda GPU yordamida ishlatilgan model segmentatsiya chiqishi berilgan. GPUda o‘qitilgan model segmentatsiyasi haqiqiy maskaga ancha yaqin. Oq joylar aniqroq ajralgan va konturlar keskinroq ko‘rinadi. GPU konfiguratsiyasi tufayli modelda gradient yangilanishi tez va barqaror bo‘lib, bu segmentatsiya aniqligini oshirgan. Parallel hisoblash tufayli model ko‘proq namunani qisqa vaqt ichida ko‘rib chiqqan va bu o‘rgatilgan fazodagi umumlashtirish qobiliyatini kuchaytirgan. GPUlardan foydalanish o‘qitish vaqtini sezilarli darajada qisqartirdi. Aralash aniqlik o‘qitish va ko‘p GPUlardan foydalanish ishlashni yanada yaxshiladi.

Ma’lumotlarni yuklash vaqti ham CPU va GPU muhitlarida tahlil qilindi. GPU muhitida ma’lumotlarni yuklash jarayoni sezilarli darajada tezroq bo‘lib, bu PyTorch’ning CUDA bilan integratsiyasi va ma’lumotlarni parallel qayta ishlash imkoniyatlariga bog‘liq edi. CPU muhitida esa ma’lumotlarni yuklash vaqti sekinroq bo‘lib, bu umumiy o‘qitish jarayonining uzayishiga olib keldi. Natijalar shuni ko‘rsatadiki, GPU muhiti nafaqat o‘qitish va inferensiya vaqtlarida, balki segmentatsiya sifati va ma’lumotlarni qayta ishlash tezligida ham sezilarli

ISSN 3030-3907

ustunlikka ega. GPU'ning parallel hisoblash qobiliyati chuqur o'rganish modellarini tibbiy tasvirlarni tahlil qilishda samaraliroq qiladi, bu esa klinik muhitlarda vaqt va resurslarni tejash imkonini beradi. CPU muhiti kichik hajmdagi ma'lumotlar bilan ishlashda qulay bo'lsa-da, katta ma'lumotlar to'plamlari va murakkab modellar bilan ishlaganda uning cheklovlari yaqqol ko'rinadi. Ushbu natijalar tibbiy tasvirlarni tahlil qilishda GPU'lardan foydalanishning afzalliklarini tasdiqlaydi va resurslarni optimal boshqarish bo'yicha amaliy tavsiyalar beradi.

Muhokama. Ushbu tadqiqotda klassik U-Net modelining tibbiy endoskopik tasvirlarni segmentatsiya qilishdagi samaradorligi CPU va GPU muhitlarida taqqoslandi. Natijalar GPU muhitining o'qitish va inferensiya jarayonlarida sezilarli darajada yuqori samaradorlik va tezkorlikka ega ekanligini aniq ko'rsatdi. Ushbu bo'limda olingan natijalar ilmiy nuqtai nazardan muhokama qilinadi, ularning amaliy ahamiyati baholanadi va kelajakdagi tadqiqotlar uchun yo'nalishlar taklif etiladi. Tadqiqot natijalari shuni tasdiqladiki, GPU muhiti o'qitish vaqti va inferensiya tezligi bo'yicha CPU'ga nisbatan sezilarli ustunlikka ega. Masalan, GPU'da o'qitish vaqti taxminan 12 soniya, CPU'da esa 75 soniya bo'ldi, bu GPU'ning 6 baravardan ko'proq tezligini ko'rsatadi. Inferensiya vaqtida ham GPU 10 ta rasmni 0.4 soniyada qayta ishladi, CPU esa buni 5.1 soniyada amalga oshirdi. Bu farqlar GPU'larning parallel hisoblash qobiliyatiga asoslanadi, bu esa chuqur o'rganish modellarini katta hajmdagi ma'lumotlar bilan ishlashda samarali qiladi (Litjens et al., 2017). Ushbu natijalar Ronneberger va boshqalar (2015) tomonidan ta'kidlangan U-Net modelining samaradorligini tasdiqlaydi va uning tibbiy tasvirlarni segmentatsiya qilishda keng qo'llanilishi uchun qo'shimcha dalillar keltiradi.

Segmentatsiya sifati bo'yicha GPU muhitida olingan aniqlik (92%) CPU'dagi natijalarga (90%) nisbatan biroz yuqori bo'ldi. Yo'qotish ko'rsatkichlari ham GPU'da (0.15) CPU'ga (0.18) nisbatan pastroq bo'lib, modelning GPU muhitida yaxshiroq optimallashtirilganligini ko'rsatdi. Bu farqlar kichik ma'lumotlar to'plamida unchalik katta bo'lmasa-da, katta hajmdagi ma'lumotlar bilan ishlashda yig'iladigan xatolar modelning umumiy samaradorligiga sezilarli ta'sir ko'rsatishi mumkin. Shu nuqtai nazardan, GPU'lar nafaqat tezlik, balki sifat jihatidan ham afzalliklarga ega ekanligi aniqlandi. Tadqiqot natijalari tibbiy tasvirlarni tahlil qilishda resurslardan samarali foydalanishning muhimligini ta'kidladi. GPU'larning yuqori samaradorligi klinik muhitlarda vaqtni tejash va diagnostika jarayonlarini tezlashtirish imkonini beradi. Masalan, endoskopik tasvirlarni real vaqtda segmentatsiya qilish jarrohlik aralashuvlarini rejalashtirishda yoki patologik o'zgarishlarni tezkor aniqlashda muhim ahamiyatga ega. CPU muhiti kichik klinikalar yoki resurslarga cheklovlar mavjud bo'lgan

ISSN 3030-3907

muhitlarda foydali bo‘lishi mumkin bo‘lsa-da, uning sekin ishlashi va cheklangan hisoblash quvvati katta hajmdagi ma’lumotlar bilan ishlashda qiyinchiliklar tug‘diradi. Shu sababli, GPU’lardan foydalanish tibbiy tasvirlarni tahlil qilishda standart yondashuv sifatida tavsiya etiladi. Bundan tashqari, soxta maskalardan foydalanish tadqiqotning amaliy ahamiyatini oshirdi. Soxta maskalar real ma’lumotlar to‘plamining cheklovlarini yengib o‘tishga imkon berdi va modelning umumlashtirish qobiliyatini sinovdan o‘tkazishda samarali vosita sifatida xizmat qildi (Tajbakhsh et al., 2020). Bu yondashuv, ayniqsa, haqiqiy maskalarni yaratish qiyin yoki resurs talab qiladigan hollarda foydali hisoblanadi. Tadqiqotning ba’zi cheklovlari mavjud. Kichik hajmdagi ma’lumotlar to‘plami (10 ta tasvir) ishlatilgani tufayli modelning umumlashtirish qobiliyati to‘liq baholanmadi. Katta hajmdagi ma’lumotlar to‘plamlari bilan ishlash modelning ishlashini yanada aniqroq ko‘rsatishi mumkin edi. Ushbu tadqiqot natijalari asosida kelajakdagi tadqiqot yo‘nalishlari taklif etiladi. Katta hajmdagi ma’lumotlar to‘plamlari bilan tajribalar o‘tkazish modelning ishlashini yanada aniq baholashga yordam beradi. Nihoyat, GPU’larning turli modellarini (masalan, NVIDIA RTX seriyasi) yoki bulutli hisoblash platformalarini (masalan, AWS yoki Google Cloud) sinovdan o‘tkazish resurslardan foydalanishni yanada optimallashtirishga yordam beradi.

Tadqiqot natijalari GPU muhitining chuqur o‘rganish modellarini tibbiy tasvirlarni segmentatsiya qilishda qo‘llashda sezilarli afzalliklarga ega ekanligini ko‘rsatdi. GPU’lar nafaqat o‘qitish va inferensiya vaqtlarini qisqartiradi, balki segmentatsiya sifatini ham oshiradi. Ushbu natijalar tibbiy tasvirlarni tahlil qilishda resurslardan samarali foydalanish va klinik jarayonlarni tezlashtirish uchun muhim amaliy ahamiyatga ega.

Xulosa. Ushbu tadqiqotda klassik U-Net modeli tibbiy endoskopik tasvirlarni segmentatsiya qilishda qo‘llanilib, uning CPU va GPU muhitlaridagi samaradorligi har tomonlama taqqoslandi. Tadqiqot Kvasir ma’lumotlar to‘plamining kichik bir qismidan foydalangan holda o‘tkazildi, bunda soxta maskalar yordamida segmentatsiya sifati baholandi. Natijalar GPU muhitining o‘qitish va inferensiya jarayonlarida sezilarli darajada yuqori samaradorlik va tezkorlikka ega ekanligini aniq ko‘rsatdi. Xususan, GPU’da o‘qitish vaqti CPU’ga nisbatan taxminan 6 baravar, inferensiya vaqti esa 12 baravardan ko‘proq tez bo‘ldi. Segmentatsiya sifati bo‘yicha GPU muhitida olingan aniqlik (92%) va yo‘qotish ko‘rsatkichlari (0.15) CPU muhitiga (90% va 0.18) nisbatan biroz yaxshiroq bo‘ldi, bu GPU’ning nafaqat tezlik, balki sifat jihatidan ham afzalliklarini tasdiqladi. Tadqiqot natijalari tibbiy tasvirlarni tahlil qilishda GPU’lardan foydalanishning muhim amaliy ahamiyatga ega ekanligini ko‘rsatdi.

ISSN 3030-3907

GPU'larning parallel hisoblash qobiliyati klinik muhitlarda vaqtni tejash, diagnostika jarayonlarini tezlashtirish va segmentatsiya sifatini oshirish imkonini beradi. CPU muhiti kichik hajmdagi ma'lumotlar bilan ishlashda yoki resurslarga cheklovlar mavjud bo'lgan hollarda qo'llanilishi mumkin bo'lsa-da, uning cheklovlari katta ma'lumotlar to'plamlari bilan ishlashda yaqqol ko'rinadi. Tadqiqotning cheklovlari sifatida kichik ma'lumotlar to'plamidan foydalanishni keltirish mumkin. Kelajakda katta hajmdagi ma'lumotlar to'plamlari va turli chuqur o'rganish modellarini taqqoslash orqali yanada aniqroq natijalarga erishish mumkin. Shuningdek, bulutli hisoblash platformalari yoki turli GPU modellarini sinovdan o'tkazish resurslardan foydalanishni yanada optimallashtirishi kutilmoqda. Umuman olganda, ushbu tadqiqot chuqur o'rganish modellarining tibbiy tasvirlarni tahlil qilishda samarali qo'llanilishi uchun GPU muhitining ustunligini tasdiqladi. Bu natijalar tibbiy diagnostika jarayonlarini tezlashtirish, aniqlikni oshirish va resurslardan samarali foydalanish bo'yicha muhim amaliy tavsiyalar beradi. Kelajakdagi tadqiqotlar ushbu sohada yanada kengroq va chuqurroq yutuqlarga olib kelishi kutilmoqda.

FOYDALANILGAN ADABIYOTLAR

1. Ronneberger, O., Fischer, P., & Brox, T. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. Medical Image Computing and Computer-Assisted Intervention (MICCAI), 234–241. https://doi.org/10.1007/978-3-319-24574-4_28
2. Litjens, G., Kooi, T., Bejnordi, B. E., Setio, A. A. A., Ciompi, F., Ghafoorian, M., ... & Sánchez, C. I. (2017). A Survey on Deep Learning in Medical Image Analysis. Medical Image Analysis, 42, 60–88. https://doi.org/10.1016/j.media.2017.07.005
3. Goodfellow, I., Bengio, Y., & Courville, A. (2016). Deep Learning. MIT Press.
4. Jha, D., Smedsrud, P. H., Riegler, M. A., Johansen, D., De Lange, T., Halvorsen, P., & Johansen, H. D. (2020). Kvasir-SEG: A Segmented Polyp Dataset. International Conference on Multimedia Modeling, 451–462. https://doi.org/10.1007/978-3-030-37734-2_37
5. Tajbakhsh, N., Shin, J. Y., Gurudu, S. R., Hurst, R. T., Kendall, C. B., Gotway, M. B., & Liang, J. (2020). Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning? IEEE Transactions on Medical Imaging, 35(5), 1299–1312. https://doi.org/10.1109/TMI.2016.2535302
6. Chollet, F. (2017). Deep learning with Python. Manning Publications.
7. TensorFlow documentation. (n.d.). Retrieved from https://www.tensorflow.org/
8. NVIDIA CUDA Toolkit documentation. (n.d.). Retrieved from https://developer.nvidia.com/cuda-toolkit

ISSN 3030-3907

9. Kirk, D. B., & Hwu, W. W. (2016). Programming massively parallel processors. Morgan Kaufmann.
10. Bahns, E., Shankar, V., Jung, A., Bordes, F., Urban, G., & Uszkoreit, J. (2017). Aggregate gradient: Cross-replica gradient averaging for distributed data-parallel training. In Advances in neural information processing systems (pp. 1296-1304).

ISSN 3030-3907