

## KERAS PLATFORMASIDA CHUQUR O'RGANISH ASOSIDA TASVIR KLASSIFIKATSIYASI ALGORITMLARI

**Tojimamatov Israil Nurmamatovich**

*Farg'ona davlat universiteti amaliy matematika  
va informatika kafedrası katta o'qituvchisi  
israiltojimatov@gmail.com*

**Ma'murova Mashhuraxon Rahmatjon qizi**

*Farg'ona davlat universiteti talabasi  
mamurovmansurbek05@gmail.com*

**Annotatsiya:** Ushbu maqola tasvirlarni chuqur o'rganish asosida klassifikatsiya qilishning nazariy va amaliy jihatlarini keng qamrovda o'rganadi. Maqolada shuningdek, data augmentation, transfer learning va learning rate scheduling kabi samaradorlikni oshirish texnikalari tahlil qilinadi. Amaliy qismda MNIST ma'lumotlar to'plamidagi raqamlarni CNN orqali tasniflash algoritmi ishlab chiqilib, natijalar baholanadi.

**Kalit so'zlar:** Keras, Konvolyutsion Neyron Tarmoqlari, Deep Learning, tasvir klassifikatsiyasi, pooling qatlamlari, aktivatsiya funksiyalari, MNIST ma'lumotlar to'plami.

**Abstract:** This article comprehensively examines the theoretical and practical aspects of image classification based on deep learning. The article also analyzes techniques for improving model performance, such as data augmentation, transfer learning, and learning rate scheduling. In the practical section, a CNN-based algorithm for classifying digits from the MNIST dataset is developed, and the results are evaluated.

**Keywords:** Keras, Convolutional Neural Networks, Deep Learning, image classification, pooling layers, activation functions, MNIST dataset.

**Аннотация:** Данная статья всесторонне рассматривает теоретические и практические аспекты классификации изображений на основе глубокого обучения. Также в статье анализируются методы повышения эффективности модели, такие как увеличение данных, перенос обучения и планирование скорости обучения. В практической части разработан алгоритм классификации цифр из набора данных MNIST с использованием CNN, и результаты его работы оцениваются.

**Ключевые слова:** Keras, сверточные нейронные сети, глубокое обучение, классификация изображений, слои пуллинга, функции активации, набор данных MNIST.

Raqamli texnologiyalarning tezkor rivojlanishi va sun'iy intellektning keng qo'llanilishi tasvirlarni avtomatik qayta ishlash tizimlariga bo'lgan talabni sezilarli darajada oshirdi. Hozirgi kunda turli sohalarda - tibbiyotda rentgen va MRT tasvirlarini tahlil qilish, avtonom transportda obyektlarni aniqlash, xavfsizlik tizimlarida yuz va harakatni kuzatish, qishloq xo'jaligida o'simlik kasalliklarini aniqlash va sanoatda mahsulot sifatini baholash kabi jarayonlarda avtomatlashtirilgan tasvir tahlili keng qo'llanilmoqda. Chuqur o'rganish texnologiyalari, ayniqsa Konvolyutsion Neyron Tarmoqlari, murakkab tasvirlarni aniqlash va tasniflashda yuqori aniqlikni ta'minlaydi. CNN arxitekturasida tasvirlardagi lokal xususiyatlarni - chiziqlar, burchaklar, teksturalar va rang o'zgarishlarini - avtomatik aniqlash orqali sinflarga ajratadi. Shu tariqa, model inson aralashuvisiz murakkab vizual naqshlarni o'rganadi va yanada barqaror va umumlashtirilgan natijalar beradi. Keras platformasi yuqori darajadagi API sifatida chuqur o'rganish modellarini tez va qulay yaratish, ularni o'qitish va baholash imkonini beradi. U TensorFlow bilan to'liq integratsiyalashgan bo'lib, GPU qo'llab-quvvatlashi orqali hisoblash samaradorligini oshiradi.

Tasvir klassifikatsiyasi - kompyuter ko'rish sohasidagi eng muhim vazifalardan biri bo'lib, kiruvchi tasvirlarni oldindan belgilangan kategoriyalarga ajratish jarayonini anglatadi. Ushbu jarayonning maqsadi - tasvirlardagi murakkab vizual naqshlarni avtomatik aniqlash va tegishli sinflarga taqsimlash orqali inson mehnatini kamaytirish va aniqlikni oshirishdir. Tasvir klassifikatsiyasi amaliyotda quyidagi sohalarda keng qo'llaniladi:

1. Tibbiyot - rentgen, MRT, KT va boshqa tibbiy tasvirlarni tahlil qilish, xastalikni aniqlash va diagnostik qarorlarni qo'llab-quvvatlash.
2. Avtonom transport - yo'l belgilarini, piyodalarni va boshqa obyektlarni aniqlash orqali xavfsiz avtonom harakatni ta'minlash.
3. Biometrik tizimlar - yuzni, barmoq izlarini va boshqa biometrik ma'lumotlarni avtomatik aniqlash, autentifikatsiya va xavfsizlik tizimlarida qo'llash.
4. Qishloq xo'jaligi - o'simliklarning kasallik yoki zararkunanda ta'sirini aniqlash, hosil sifatini baholash.
5. Sanoat - ishlab chiqarish jarayonida mahsulot sifatini nazorat qilish, nuqsonlarni aniqlash va ishlab chiqarish samaradorligini oshirish.
6. Geologiya va atrof-muhit - xaritalarni avtomatik tahlil qilish, yer tuzilishini aniqlash va tabiiy resurslarni baholash.

Chuqur o'rganish algoritmlari tasvir klassifikatsiyasida an'anaviy metodlarga nisbatan sezilarli ustunlikka ega. Xususan, Konvolyutsion Neyron Tarmoqlari tasvirlardagi murakkab naqsh va xususiyatlarni avtomatik aniqlash hamda sinflarga ajratish imkonini beradi. CNNning eng muhim xususiyati shundaki, u tasvirdagi xususiyatlarni inson aralashuvisiz ekstrakt qiladi. Konvolyutsion qatlamlar filtrlar yordamida tasvir bo'ylab harakatlanib, chiziqlar, burchaklar, teksturalar va rang

o'zgarishlarini aniqlaydi. Shu orqali model murakkab vizual naqshlarni o'rganadi va tasvirlarni aniq sinflarga ajratadi, bu esa qo'lda xususiyat ajratishga bo'lgan ehtiyojni bartaraf etadi. An'anaviy to'liq ulanadigan neyron tarmoqlarda katta o'lchamli tasvirlar uchun parametrlar soni yuzlab minglarga yetadi, bu esa modelni o'qitish jarayonini sekinlashtiradi va ko'p hisoblash resurslarini talab qiladi. CNN arxitekturasida esa parametrlarni kamaytirish orqali shu muammoni bartaraf etadi. Kichik yadrolar va ulanishlarning lokal xususiyati tufayli parametrlar soni necha yuzlabga kamayadi. Bu nafaqat o'qitish tezligini oshiradi, balki modelning umumlashtirish qobiliyatini ham yaxshilaydi. CNN konvolyutsion qatlamlari kichik yadrolar yordamida tasvirni bo'laklarga ajratib tahlil qiladi. Bu yondashuv tasvirning mahalliy xususiyatlarini aniqlashga imkon beradi va real dunyodagi vizual naqshlarga mos keladi. Lokal aloqadorlik nafaqat xususiyatlarni samarali o'rganishga yordam beradi, balki modelning kattaroq tasvirlarda ham barqaror ishlashini ta'minlaydi.

Keras - yuqori darajadagi neyron tarmoqlarini yaratish va o'qitish uchun mo'ljallangan ochiq manbali platforma bo'lib, u ilmiy tadqiqotlar va amaliy loyihalarda keng qo'llaniladi. Keras quyidagi asosiy afzalliklarni taqdim etadi:

1. **Oddiy va tushunarli sintaksis:** Keras sintaksisi intuitiv va foydalanuvchiga qulay bo'lib, murakkab model arxitekturalarini ham tez va oson yaratish imkonini beradi.
2. **GPU qo'llab-quvvatlashi:** Hisoblash jarayonini tezlashtirish uchun GPU bilan integratsiyalashgan ishlashni qo'llab-quvvatlaydi.
3. **Keng qatlamlar va optimizatorlar to'plami:** Keras turli turdagi konvolyutsion, pooling, dense, recurrent qatlamlar va optimizatorlarni o'z ichiga oladi.
4. **Tayyor datasetlar:** MNIST, CIFAR-10, ImageNet kabi mashhur datasetlar bilan ishlash imkoniyati mavjud, bu esa modelni tez prototiplash va test qilishga yordam beradi.
5. **Modelni saqlash:** Modelni JSON yoki H5 formatda saqlash imkoniyati mavjud bo'lib, uni keyinchalik qayta ishlatish yoki boshqa loyihalarda integratsiya qilish osonlashadi.
6. **TensorFlow bilan to'liq integratsiyalashgan:** Keras TensorFlow ustida ishlaydi, shu bilan birga model yaratish, o'qitish va eksport qilish jarayonlarini soddalashtiradi.

Mazkur bo'limda Keras platformasi va Konvolyutsion Neyron Tarmoqlari yordamida MNIST ma'lumotlar to'plamidagi qo'l bilan yozilgan raqamlarni avtomatik tasniflash jarayoni bosqichma-bosqich ko'rib chiqiladi. Ushbu amaliy misol tasvir klassifikatsiyasining nazariy bilimlarini real loyiha orqali mustahkamlash imkonini beradi. MNIST datasetida jami 70 000 ta  $28 \times 28$  piksel o'lchamli qora-oq tasvirlar mavjud bo'lib, ular quyidagicha bo'lingan:

1. Train set (o'qitish to'plami): 60 000 tasvir
2. Test set (sinov to'plami): 10 000 tasvir

Keras kutubxonasi yordamida MNIST datasetini yuklash va tayyorlash jarayoni quyidagicha amalga oshiriladi:

```
from tensorflow.keras.datasets import mnist
(X_train, y_train), (X_test, y_test) = mnist.load_data()
X_train = X_train.reshape(-1, 28, 28, 1) / 255.0
X_test = X_test.reshape(-1, 28, 28, 1) / 255.0
```

Izoh: 4D formatda tasvirlarni o'zgartirish - CNN qatlamlari bilan ishlash uchun talab qilinadi. Normallashtirish esa modelning tezroq va barqaror o'qitilishiga yordam beradi.

CNN modeli bir nechta turli qatlamlardan tashkil topadi, ularning har biri tasvirni qayta ishlash va sinflarga ajratishda muhim rol o'ynaydi. Birinchi qatlam - Conv2D qatlamlari, ular tasvirdagi xususiyatlarni ekstrakt qilish vazifasini bajaradi. Ushbu qatlam filtrlar (kernellar) yordamida tasvir bo'ylab harakatlanib, chiziqlar, burchaklar, tekstura va rang o'zgarishlari kabi vizual naqshlarni aniqlaydi. Keyingi qatlam - MaxPooling qatlamlari, ular xususiyat xaritalarining o'lchamini kamaytiradi va faqat eng muhim elementlarni saqlaydi. Bu jarayon hisoblash yukini kamaytiradi va modelni ortiqcha moslashuvdan himoya qiladi. So'ng Flatten qatlam ishlatiladi, u 2D xususiyat xaritalarini 1D vektorga aylantiradi, bu esa Dense qatlamlar orqali yakuniy klassifikatsiya qilishga imkon beradi. Dense qatlamlar modelning yakuniy qaror qabul qilish bosqichi bo'lib, ular tasvirdagi xususiyatlarni tahlil qilib, chiqish sinfini aniqlaydi. Ushbu qatlamlar modelning chiqish qatlamiga ulanadi. Dropout qatlam esa o'qitish jarayonida qatlamdagi neyronlarning ma'lum foizini vaqtincha o'chirib turadi, bu overfittingni kamaytiradi va modelning umumlashtirish qobiliyatini oshiradi. Oxirgi qatlamda Softmax aktivatsiyasi ishlatiladi, u chiqish qatlamidagi har bir sinf uchun ehtimollarni taqsimlaydi. Shu tariqa, model tasvirdagi obyektning qaysi sinfga tegishli ekanligini aniqlaydi va yuqori aniqlik bilan tasniflaydi.

Modelni Keras yordamida yaratish kodi:

```
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Conv2D, MaxPooling2D, Flatten, Dense, Dropout
model = Sequential([
    Conv2D(32, (3,3), activation='relu', input_shape=(28,28,1)),
    MaxPooling2D(2,2),
    Conv2D(64, (3,3), activation='relu'),
    MaxPooling2D(2,2),
    Flatten(),
    Dense(128, activation='relu'),
    Dropout(0.5),
```

Dense(10, activation='softmax')

)

Birinchi Conv2D qatlam 32 filtr va ReLU aktivatsiyasiga ega bo'lib, tasvirdagi asosiy xususiyatlarni aniqlashga mo'ljallangan. Ushbu qatlam chiziqlar, burchaklar va tekstura kabi dastlabki vizual naqshlarni o'rganadi. Ikkinchi Conv2D qatlam esa tasvirdagi chuqurroq xususiyatlarni o'rganadi. U birinchi qatlamda aniqlangan oddiy naqshlarni birlashtirib, murakkabroq tasvir strukturalarini ajratadi va yuqori darajadagi xususiyat xaritalarini hosil qiladi. MaxPooling qatlamlari xususiyat xaritalarining o'lchamini kamaytiradi va eng muhim elementlarni saqlaydi. Shu orqali hisoblash yukini sezilarli darajada kamaytiradi va modelning ishlash samaradorligini oshiradi. Dropout qatlam esa modelni overfittingdan himoya qiladi.

Modelni o'qitishdan oldin optimizer, loss function va metrics tanlanadi. Bu parametrlar modelning o'qitish jarayoni va sifatini belgilaydi.

```
model.compile(
    optimizer='adam',
    loss='sparse_categorical_crossentropy',
    metrics=['accuracy']
)
model.fit(
    X_train, y_train,
    epochs=5,
    batch_size=32,
    validation_split=0.1
)
```

Adam optimizer modeli tez va barqaror konvergensiyani ta'minlaydi, shuning uchun ko'pgina chuqur o'rganish vazifalarida eng samarali optimizer hisoblanadi. Sparse categorical crossentropy esa ko'p sinfli tasniflash vazifalari uchun mos yo'qotish funksiyasidir. U modelning chiqishi va haqiqiy qiymatlar orasidagi farqni o'lchaydi va neyron tarmog'ining o'qitilish jarayonida vaznlarni to'g'ri yangilashga yordam beradi. Validation split o'qitish jarayonida modelning overfitting darajasini kuzatish imkonini beradi. Bu parametr yordamida ma'lumotlarning bir qismi modelni baholash uchun ajratiladi va o'qitish davomida uning umumlashtirish qobiliyati tahlil qilinadi. Model CNN yordamida raqamli tasvirlarni avtomatik tanib, ularni 0–9 raqamlar sinflariga ajratadi va modelning aniqligini baholaydi. Epoch va batch size esa o'qitish jarayoni va hisoblash resurslarini samarali boshqarishga xizmat qiladi.

O'qitish jarayonidan so'ng quyidagi natijalar kuzatildi:

- O'qitish aniqligi: ~99%
- Test aniqligi: 97–98%

Tahlil:

1. Model MNIST datasetidagi raqamlarni aniqlashda yuqori samaradorlik ko'rsatdi.
2. Dropout va pooling qatlamlari overfittingni kamaytirib, modelning umumlashtirish qobiliyatini oshirdi.
3. Konvolyutsion qatlamlar tasvirdagi lokal xususiyatlarni aniqlash orqali murakkab naqshlarni to'g'ri klassifikatsiya qilish imkonini berdi.

Shu bilan, Keras va CNN yordamida MNIST raqamlarini avtomatik tasniflash jarayoni muvaffaqiyatli amalga oshirildi. Ushbu amaliy misol tasvir klassifikatsiyasida chuqur o'rganish yondashuvining samaradorligini aniq namoyish etdi.

Mazkur maqolada Keras platformasida tasvir klassifikatsiyasi algoritmlarining nazariy va amaliy jihatlari keng qamrovda tahlil qilindi. Asosiy e'tibor Konvolyutsion Neyron Tarmoqlari arxitekturasini, uning qatlamlari, optimizatsiya usullari va model samaradorligini oshirish texnikalariga qaratildi. Shuningdek, data augmentation, batch normalization, transfer learning va learning rate scheduling kabi zamonaviy metodlar chuqur o'rganildi, ularning amaliy ishlashdagi ahamiyati misollar bilan ko'rsatildi. Xulosa qilib aytganda, CNN arxitekturasini va Keras platformasi birgalikda tasvir klassifikatsiyasi sohasida zamonaviy va yuqori samarali yechimlarni taqdim etadi. Ushbu yondashuv ilmiy tadqiqotlarda va amaliy loyihalarda, ayniqsa murakkab va katta hajmli ma'lumotlar bilan ishlashda, aniq va barqaror natijalarni ta'minlaydi. Kelajakda bu texnologiyalarni yanada rivojlantirib, ularni tibbiyot, sanoat, transport, xavfsizlik va boshqa sohalarda keng qo'llash imkoniyatlari yanada oshadi.

#### **Foydalanilgan adabiyotlar ro'yxati:**

1. Bekmurotov Q.A. , Sun'iy intellekt va neyron tarmoqlar. O'quv qo'llanma, Samarqand – 2021.
2. Sadullayeva SH.A, Yusupov D.F., Yusupov F., Sun'iy intellekt va neyron to'g'ri texnologiyalar. O'quv qo'llanma, Urganch – 2021.
3. H.N.Zayniddinov, T.A.Xo'jaqulov, M.P.Atadjanov, "Sun'iy intellekt" fanidan o'quv qo'llanma, Toshkent – 2018.
4. Q.A.Bekmurotov, Sun'iy intellekt. O'quv qo'llanma, Toshkent – 2019.
5. Игнатьев Н.А., Усманов Р.Н., Мадрахимов Ш.Ф., Берилганларнинг интеллектуал тахлили // Ўқув қўлланма. Тошкент-2018. 144 б.
6. Yusupbekov N.R. Aliyev R.A. Boshqarishning intellektual tizimlari. "O'zbekiston milliy ensiklopediyasi", Toshkent – 2015
7. Дейтел Пол, Дейтел Харви, Python: Искусственный интеллект, большие данные и облачные вычисления. СПб.: Питер, 2020. — 864 с.

#### **Elektron manbalar:**

1. [www.my.gov.uz](http://www.my.gov.uz) – O'zbekiston Respublikasi hukumat portal
2. [www.lex.uz](http://www.lex.uz) - O'zbekiston Respublikasi Qonun hujjatlari milliy bazasi
3. [www.edu.uz](http://www.edu.uz) – Oliy va o'rta maxsus ta'lim vazirligi portali



4. [www.tdpu.uz](http://www.tdpu.uz) – Nizomiy nomidagi TDPU rasmiy sayti
5. [www.fdu.uz](http://www.fdu.uz) – Farg‘ona davlat universiteti rasmiy sayti
6. <https://ru.wikipedia.org>
7. <http://lib.nuu.uz/> - Ўзбекистон Миллий университети электрон кутубхонаси
8. <http://www.raii.org/library> - Российская ассоциация искусственного интеллекта
9. <https://www.javatpoint.com/artificial-intelligence-ai>
10. <https://www.geeksforgeeks.org/machine-learning>