

## Ա.Կ. ՄԱՅԻԼՅԱՆ

### ՆԵՅՐՈՆԱՅԻՆ ՑԱՆՑՈՎ ԱՅՐՎԱԾՔՆԵՐԻ ԴԱՍԱԿԱՐԳՄԱՆ ՀԱՄԱԿԱՐԳԻ ՄՇԱԿՈՒՄԸ

Ներկայացված է այրվածքների պատկերների ճանաչման և ըստ աստիճանների դասակարգման մեթոդը՝ նեյրոնային ցանցի միջոցով: Մեթոդի մշակման համար կիրառվել է կոնվոլյուցիոն նեյրոնային ցանցը, որտեղ օգտագործվել են Conv2D, Max Pooling, Flatten շերտերը: Մոդելի գնահատման համար կիրառվել են տվյալների վարժեցման և թեստավորման ենթաբազմությունների ճշգրտությունները, իսկ տվյալների գնահատման համար՝ շփոթության մատրիցի (Confusion Matrix) և հիմնական բաղադրիչների վերլուծության (Principal Component Analysis) մեթոդները:

**Առանցքային բառեր.** կոնվոլյուցիոն նեյրոնային ցանց, կոնվոլյուցիա, վերահսկվող վարժեցում:

**Ներածություն:** Ներկայումս արհեստական բանականության զարգացումը գերակա խնդիր է աշխարհի շատ երկրների համար: Եթե դիտարկենք խելացի համակարգերի ներդրումը բժշկության ոլորտում, ապա առաջին հերթին դա տարբեր հիվանդությունների ախտորոշումն է բարձր ճշգրտությամբ:

Բժշկի փորձը կարող է չբավարարել մարդու մարմնում որոշակի խնդիրներ ժամանակին հայտնաբերելու համար, մինչդեռ նեյրոնային ցանցը, որին հասանելի են հսկայական քանակությամբ տվյալներ, առաջադեմ գիտական գրականություն և միլիոնավոր բժշկական գրառումներ, կարող է արագ դասակարգել ցանկացած դեպք, այն կապել այլ հիվանդների նման խնդիրների հետ և առաջարկել բուժման ծրագիր:

**Վերահսկվող վարժեցմամբ մեթոդ.** Կիրառվել է վերահսկվող վարժեցմամբ մեթոդ՝ նախօրոք պիտակավորված թվով շուրջ 400 այրվածքների պատկերների բազայի վրա:

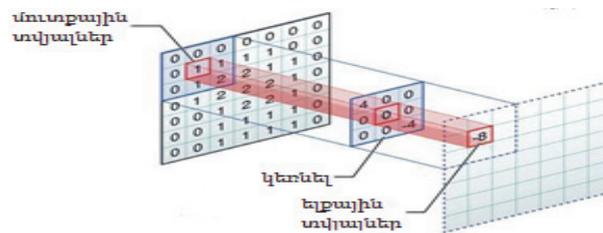
Նեյրոնային ցանցը բաղկացած է մուտքային, թաքնված (hidden layers) և ելքային շերտերից: Նպատակն է մուտքային տվյալների ձևափոխության արդյունքում ստանալ վեկտոր, ըստ որի նկարները կդասակարգվեն համապատասխան դասերով: Այդ ձևափոխությունը պարամետրական ֆունկցիա է, որն օգտագործում է մուտքային տվյալները՝ որոշակի կշիռներով, և կիրառում ակտիվացման ֆունկցիա՝ գծայնությունից խուսափելու համար:

Պատկերների վերլուծության համար ընդունված է կիրառել կոնվոլյուցիոն նեյրոնային ցանցը, որն օգտագործվում էր պատկերները աղոտ դարձնելու, պայծառացնելու և այլ գործողությունների համար [1]: Կեռնելը մատրից է, որը

պատկերից ֆիլտրում և գտում է անհրաժեշտ տեղեկությունը: Քանի որ պատկերը կարող ենք ներկայացնել որպես  $f(x, y)$  ֆունկցիա՝ կախված երկու պարամետրերից՝ փիքսելի կոորդինատներից, ուստի սույն վերլուծության դեպքում օգտագործվել է երկչափանի կոնվոլյուցիա՝

$$(f * g)(t, \tau) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y)g(t - x, \tau - y)dx dy$$

Ավելի պատկերավոր ներկայացնելու համար դիտարկենք նկ. 1-ը:



Նկ. 1. Կոնվոլյուցիայի կիրառումը մուտքային տվյալների վրա

Մասնավորապես՝ այս վերլուծության դեպքում որպես մուտքային փոփոխական ունենում ենք 150x150x3-չափանի մատրից, որտեղ 150x150 նկարի չափերն են, 3-ը՝ RGB (Red-Green-Blue) մակարդակները, իսկ որպես կեռնել՝ 3x3x3 – չափանի մատրիցը:

Կոնվոլյուցիայի կիրառման արդյունքում ստանում ենք 148x148 չափի մատրից: Տվյալ դեպքում կոնվոլյուցիան ոչ միայն անհրաժեշտ տեղեկությունը գտնելու, այլ նաև մուտքային տվյալների պարզեցման համար է: Տվյալների չափողականության նվազեցման համար, ինչն անհրաժեշտ է հաշվարկային բարդություններից խուսափելու համար, օգտագործվել է Max Pooling, որը 2x2 չափողականությամբ կեռնելի միջոցով ընտրում է այդ մատրիցի մեջ գտնվող թվային տվյալներից մեծագույնը: Այս մեթոդը հնարավորություն է տալիս փոխանցել պատկերի միայն ամենաակնառու հատկանիշները: Երրորդ շերտում մատրիցը հարթեցվում է flatten ֆունկցիայի միջոցով: Վերջինիս նպատակը վերջնական սյան ստացումն է CNN-ի հետագա մշակման համար:

Յուրաքանչյուր շերտում կիրառվել է ReLU գծային ֆունկցիան (the rectified - linear activation function), որը վերադարձնում է մուտքային արժեքը, եթե դրական է, և 0՝ հակառակ դեպքում: Այս ֆունկցիան շատ CNN մոդելների default պարամետրն է, և նպատակը գծայնությունից ազատվել է: Սա կարևոր քայլ է, քանի որ նկարները ինքնին ոչ գծային տվյալներ են, և հետևաբար՝ մոդելի գծայնությունը կենթադրեր ցածր ճշգրտությամբ արդյունք:

Քանի որ մեր տվյալները պատկանում են միայն մեկ դասին, այսինքն one-hot վեկտորներով ենք աշխատում, ապա նպատակահարմար է Softmax դասակարգչի կիրառումը որպես վերջին շերտ՝ դասակարգման համար: Softmax-ը բինար լոգիստիկ ռեգրեսիայի ընդհանրացված տարբերակն է, որի բանաձևային տեսքը հետևյալն է՝

$$S(x_1, x_2, \dots, x_n) = \left( \frac{e^{x_1}}{\sum_{i=1}^n e^{x_i}}, \frac{e^{x_2}}{\sum_{i=1}^n e^{x_i}}, \dots, \frac{e^{x_n}}{\sum_{i=1}^n e^{x_i}} \right):$$

Պատկերի նման մշակման արդյունքում ֆիլտրերը չեն սահմանվում, այլ ավտոմատ որոշվում են յուրաքանչյուր վարժեցման ընթացքում: CNN-ը կարող է պատկերներից ավելի շատ ինֆորմացիա քաղել, քան մարդիկ: Պատճառը յուրաքանչյուր մակարդակում սկզբնավորման չափանիշի տարբեր լինելն է, և հետևաբար՝ յուրաքանչյուր ֆիլտր այլ կերպ է վարժեցվում, հակառակ դեպքում՝ երկու ֆիլտրերի նման առանձնահատկությունների սովորելու հավանականությունը կտրուկ աճում է: Պատահական սկզբնավորման ապահովման արդյունքում դրանցից յուրաքանչյուրը հայտնաբերում է պատկերի տարբեր առանձնահատկություններ:

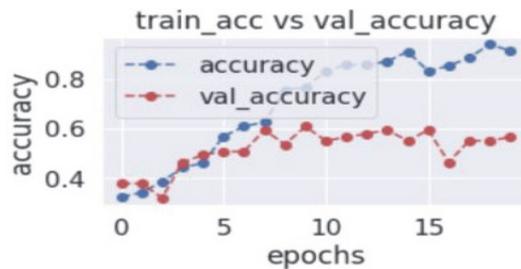
Շերտերից յուրաքանչյուրի սահմանումից զատ, անհրաժեշտ է կորստի ֆունկցիայի սահմանումը, որի մինիմալացման արդյունքում էլ գտնվում են բոլոր շերտերի օպտիմալ պարամետրերը: Կորուստի ֆունկցիան հետևյալն է՝

$$\frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i)^2,$$

որտեղ  $f(x_i)$ -ը կանխատեսված արժեքն է, իսկ  $y$ -ը՝ իրական արժեքը:

Տվյալ ֆունկցիայի հնարավորինս մինիմալ արժեքի ստացման համար օգտագործվել է ստոխաստիկ գրադիենտ դեսենտի մեթոդը, որը համատեղում է երկու այլ ընդլայնված տարբերակների առավելությունները, մասնավորապես՝ ադապտիվ գրադիենտի ալգորիթմը (AdaGrad) և միջին քառակուսի արմատի տարածումը (RMSProp) [2-4]:

Մոդելի կիրառման համար ընդհանուր տվյալների բազան բաժանվել է վարժեցման և թեստավորման ենթաբազմությունների, իսկ վարժեցման 20%-ը օգտագործվել է որպես վալիդացիոն բազմություն, այսինքն հիպերպարամետրերի վարժեցման համար: Որպեսզի խուսափենք վարժեցման բազմությունում միևնույն դասից նկարների անընդմեջ կրկնությունից, պատահական ձևով վերցվում են 128 նկարներ տարբեր դասերից, և մոդելները կիրառվում են այդ բազմության վրա: Նման բազմությունները կոչվում են ուսուցման շրջաններ (epoch), և մեր վերլուծության դեպքում դրանց քանակը 20-ն է: Վարժեցման ենթաբազմությունների ճշգրտությունը ներկայացված է նկ. 2-ում:



Նկ. 2. Ենթաբազմությունների ճշգրտությունների դինամիկան

Մոդելի ճշգրիտ աշխատանքն ապահովելու համար անհրաժեշտ է ստանալ հնարավորինս մոտ արժեքներ ունեցող վարժեցման, վալիդացիոն և վերջնական ճշգրտություններ: Մշակված մոդելի վերջնական ճշգրտությունը 63.37% է:

Պատկերների ստացված դասակարգման արդյունքը ներկայացնենք շփոթության մատրիցի միջոցով նկ. 3-ում:



Նկ. 3. Վալիդացիոն ենթաբազմության վրա կիրառված շփոթության մատրիցը

Նկ. 3 -ում օրդինատների առանցքը ցույց է տալիս իրական պիտակները, իսկ արքսիսներիինը՝ կանխատեսված: Մասնավորապես՝ երկրորդ տողի առաջին սյունը ցույց է տալիս, որ 13 նկար կանխատեսվել էին առաջին աստիճանի, սակայն իրականում պատկանում են երկրորդ դասին:

Հասկանալու համար, թե արդյոք նման սխալների պատճառը մոդելն է, թե նկարների տվյալների բազան, պատահականորեն ընտրենք սխալ կանխատեսված նկարներից որևէ մեկը (նկ. 4):

```

predictions = model.predict(test_images)
pred_labels = np.argmax(predictions, axis = 1)

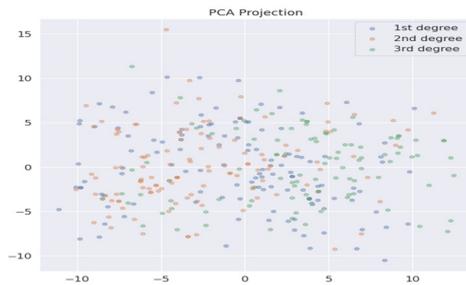
display_random_image(class_names, test_images, pred_labels)

```

Նկ. 4. Մոդելի կիրառման արդյունքում սխալ կանխատեսված նկարի օրինակ

Նկ. 4 -ից երևում է, որ կանխատեսված պիտակը մոտ է իրականությանը, սակայն տվյալների բազայի ոչ բավարար քանակի պատճառով մոդելը հնարավորություն չի ունեցել ավելի լավ վարժվելու:

Հասկանալու համար, թե արդյոք նկարները հնարավոր է ըստ պիտակների հստակ տարանջատել, թե ոչ, կիրառենք հիմնական բաղադրիչների վերլուծության (PCA) մեթոդը և պատկերենք երկչափ տարածությունում (նկ. 5) [5]:



Նկ. 5. Տվյալների բազայի պատկերումը երկչափ տարածությունում PCA մեթոդով

Ինչպես երևում է նկ. 5 -ից, առկա տվյալների բազայի նկարներն ըստ իրենց հատկանիշների չունեն հստակ տարանջատում, և հետևաբար՝ առկա մոդելներին ոչ մեկը չի կարող դասակարգել նկարները բարձր ճշգրտությամբ:

**Եզրակացություն.**

1. Դասակարգված այրվածքների վրա կիրառվել են նեյրոնային ցանցի մշակման մեթոդներ:
2. Մշակվել է նեյրոնային ցանցով այրվածքների դասակարգման մոդել, որի ճշգրտությունը կազմում է 63.37%:
3. Մեթոդի մշակման համար կիրառվել է կոնվոլյուցիոն նեյրոնային ցանցը:
4. Կատարվել է մոդելի և տվյալների գնահատում, որի արդյունքում պարզվել է, որ մշակված մոդելի ճշգրտությունը կարելի է բավականին բարձրացնել՝ օգտագործվող տվյալների բազայի ծավալի մեծացմամբ:

**ԳՐԱԿԱՆՈՒԹՅԱՆ ՑԱՆԿ**

1. **Simonyan K., Zisserman A.** Very Deep Convolutional Networks for Large-Scale Image Recognition // International Conference on Learning Representations (ICLR), May 7 - 9, 2015.- San Diego, CA, USA, 2015.-P. 1 – 14. <https://arxiv.org/abs/1409.1556> 01 Oct, 2014
2. **Kingma D.P., Lei Ba J., Adam.** A Method for Stochastic Optimization // International Conference on Learning Representations (ICLR), May 7 - 9, 2015.- San Diego, CA, USA, 2015.- P. 1 – 15. <https://arxiv.org/abs/1412.6980> 01 Oct, 2014.

3. **Loshchilov I., Hutter F.** Sgdr: Stochastic Gradient Descent with Warm Restarts // International Conference on Learning Representations (ICLR).- April 24-26, 2017, Palais des Congrès Neptune, Toulon, Fr.-P. 1 – 16. <https://openreview.net/forum?id=Skq89Scxx> 01 Oct, 2016
4. **Bishop C.M.** Pattern Recognition and Machine Learning.-Springer Science+Business Media, LLC. New York, 2006. – 758p.
5. **Murphy K.P.** Machine Learning: A Probabilistic Perspective // Massachusetts Institute of technology. – Cambridge, 2012. – 1098p.

**А.К. МАИЛЯН**

### **РАЗРАБОТКА СИСТЕМЫ КЛАССИФИКАЦИИ ОЖОГОВ С ИСПОЛЬЗОВАНИЕМ НЕЙРОННОЙ СЕТИ**

Представлен метод распознавания и классификации изображений ожогов с помощью нейронной сети. Для разработки метода применялась сверточная нейронная сеть с использованием Conv2D, Max Pooling, Flatten слоев. Для оценки модели использовалась точность обучающих данных и тестовых подмножеств, а для оценки данных - методы Confusion Matrix и Principal Component Analysis.

**Ключевые слова:** сверточная нейронная сеть, конволюция, контролируемое обучение.

**A.K. MAYILYAN**

### **DEVELOPING A SYSTEM FOR CLASSIFYING THE BURNS USING A NEURAL NETWORK**

The method of image recognition and classification of burns with neural network is presented. The method was developed with convolutional neural network, using Conv2D, Max Pooling, Flatten layers. The accuracy of the training and validation data is used for the model evaluation, and the Confusion Matrix and Principal Component Analysis methods are used for dataset evaluation.

**Keywords:** convolutional neural network, convolution, supervised learning.