

**ՏԵՂԵԿԱՏՎԱԿԱՆ ՏԵԽՆՈԼՈԳԻԱՆԵՐ, ԷԼԵԿՏՐՈՆԻԿԱ,  
ՌԱԴԻՈՏԵԽՆԻԿԱ**

**ԻՆՖՈՐՄԱՏԻԿԱ ԵՎ ՀԱՇՎՈՂԱԿԱՆ ՏԵԽՆԻԿԱ**

ՀՏԴ 004.658

**Գ.Տ. ԿԻՐԱՎՈՍՅԱՆ, Ա.Կ. ՄԱՅԻԼՅԱՆ**

**ՆԵՅՐՈՆԱՅԻՆ ՑԱՆՑՈՎ ԱՅՐՎԱԾՔՆԵՐԻ ԴԱՍԱԿԱՐԳՄԱՆ  
ՀԱՄԱԿԱՐԳԻ ԲԱՐԵԼԱՎՈՒՄԸ ՏՎՅԱԼՆԵՐԻ ԲԱԶԱՅԻ ԸՆԴԱՐՁԱԿՄԱՆ  
ԱՐԴՅՈՒՆՔՈՒՄ**

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՝ Confusion Matrix և Principal Component Analysis մեթոդները:


**Առանցքային բառեր.** կոնվոլյուցիոն նեյրոնային ցանց, նեյրոնային շերտեր, փիքսելներ, վերահսկվող վարժեցում:

**Ներածություն:** Ներկայումս արհեստական բանականության զարգացումը գերակա խնդիր է աշխարհի շատ երկրների համար: Օրինակ՝ խելացի համակարգերի ներդրումը բժշկության ոլորտում, առաջին հերթին, դրանց օգտակարությունն է տարբեր հիվանդությունների ախտորոշումը բարձր ճշգրտությամբ կատարելու համար:

Արհեստական բանականությունը հիանալի է կատարում պարզ առաջադրանքներ և լուծում պարզ խնդիրներ: Օրինակ, այն ունակ է հայտնաբերելու օտար մարմնի կամ պաթոլոգիայի առկայությունը ռենտգենյան նկարների վրա, ինչպես նաև՝ որոշելու քաղցկեղի բջիջների առկայությունը ցիտոլոգիական նյութում: Տարբեր բժշկական տվյալների վերլուծության ժամանակ արհեստական բանականությունը արդեն իսկ հիանալի արդյունքներ է ցույց տալիս: Մասնավորապես՝ ուլտրաձայնային և ՄՌՏ-ի միջոցով պաթոլոգիաների հայտնաբերման ճշգրտությունը գերազանցում է 90% -ը:

**Վերահսկվող վարժեցմամբ մեթոդ:** Կիրառվել է վերահսկվող վարժեցմամբ մեթոդ նախօրոք պիտակավորված թվով շուրջ 400 այրվածքների պատկերների բազայի վրա (նկ. 1):

```
[ ] plt.pie(train_counts,
            explode=(0, 0, 0) ,
            labels=class_names,
            autopct='%1.1f%%')
plt.axis('equal')
plt.title('Proportion of each observed category')
plt.show()
```



Նկ. 1. Օգտագործված տվյալների բազայի բաշխման դիագրամ՝ ըստ այրվածքների տեսակի

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

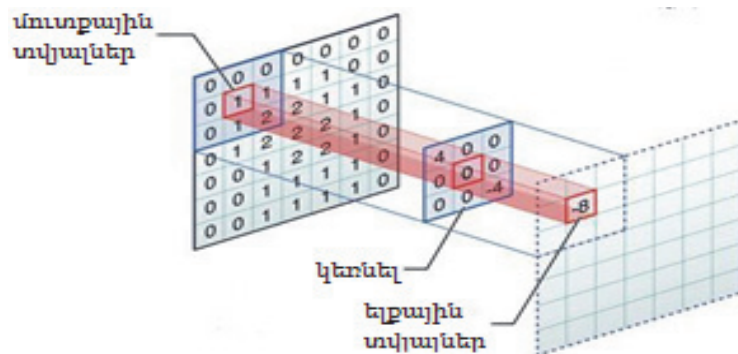
Պատկերների վերլուծության համար ընդունված է օգտագործել կոնվոլյուցիոն նեյրոնային ցանցը, որի հիմքում, որպես ֆունկցիա, ընկած է կոնվոլյուցիան: Նախկինում կոնվոլյուցիաներն օգտագործվում էին պատկերները աղոտ դարձնելու, կոնտրաստավորելու և այլ գործողությունների համար [1]: Կոնվոլյուցիան երկու ֆունկցիաների, մեր դեպքում՝ պատկերի և կեռնելի համադրությունն է հետևյալ բանաձևով՝

$$(f * g)(t) = \int_{-\infty}^{+\infty} f(x)g(t - x)dx: \quad (1)$$

Կեռնելը մատրից է, որը ֆիլտրում և գտում է պատկերից անհրաժեշտ տեղեկությունը: Քանի որ պատկերը կարող ենք ներկայացնել որպես  $f(x, y)$  ֆունկցիա կախված երկու պարամետրերից՝ փիքսելի կոորդինատներից, ապա տվյալ վերլուծության դեպքում օգտագործում ենք երկչափանի կոնվոլյուցիա (2D convolution)՝

$$(f * g)(t, \tau) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} f(x, y)g(t - x, \tau - y)dxdy: \quad (2)$$

Ավելի պատկերավոր ներկայացնելու համար դիտարկենք նկ. 2-ը:



Նկ. 2. Կոնվոլյուցիայի կիրառումը մուտքային տվյալների վրա

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

Կոնվոլյուցիայի կիրառման արդյունքում ստանում ենք 148x148-չափանի մատրից: Տվյալ դեպքում կոնվոլյուցիան ոչ միայն անհրաժեշտ տեղեկատվությունը գտելու, այլ նաև մուտքային տվյալների պարզեցման համար է: Սակայն տվյալների չափողականության նվազեցման համար, ինչն անհրաժեշտ է հաշվարկային բարդություններից խուսափելու համար, անընդհատ կոնվոլյուցիոն ֆունկցիաների կիրառումը նպատակահարմար է:

Տվյալների չափողականության նվազման համար անհրաժեշտ է ընտրել այնպիսի մեթոդ, որի դեպքում տեղեկատվության կորուստը մաքսիմալ քիչ կլինի: Մասնավորապես՝ մեր վերլուծության դեպքում 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:

Վերջնական տվյալներն ունենալուց հետո անհրաժեշտ է որոշակի հավանականություն՝ նկարը առաջին, երկրորդ կամ երրորդ աստիճանում դասակարգելու համար: Քանի որ մեր տվյալները պատկանում են միայն մեկ դասին, այսինքն աշխատում ենք one-hot վեկտորներով, ապա նպատակահարմար է Softmax դասակարգչի կիրառումը որպես վերջին շերտ: Softmax-ը բինար լոգիստիկ ռեգրեսիայի ընդհանրացված տարբերակն է, որի բանաձևային տեսքը հետևյալն է՝

$$S(x_1, x_2, \dots, x_n) = \left( \frac{e^{x_1}}{\sum_{i=1}^n e^{x_i}}, \frac{e^{x_2}}{\sum_{i=1}^n e^{x_i}}, \dots, \frac{e^{x_n}}{\sum_{i=1}^n e^{x_i}} \right): \quad (3)$$

Վեկտորից երևում է, որը տարրերից յուրաքանչյուրը դրական է և գումարը՝ մեկ: Հետևաբար՝ սա այն հավանականային վեկտորն է, որը հնարավորություն է տալիս կատարել կանխատեսումներ, մեր դեպքում՝ երեք պիտակների համար:

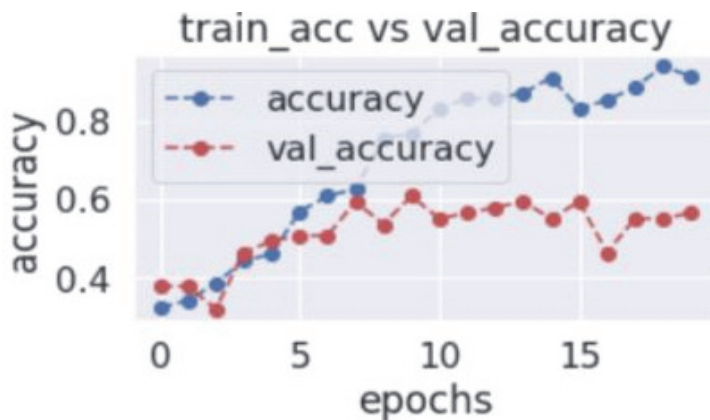
Շերտերից յուրաքանչյուրի սահմանումից զատ, անհրաժեշտ է սահմանել կորստի ֆունկցիան, որի մինիմալացման արդյունքում էլ գտնվում են մեր բոլոր շերտերի օպտիմալ պարամետրերը: Կորստի ֆունկցիան հետևյալն է՝

$$\frac{1}{n} \sum_{i=1}^n (f(x_i) - y_i)^2, \quad (4)$$

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՝ Adaptive Gradient Algorithm (AdaGrad) և Root Mean Square Propagation (RMSProp) [2, 3, 4]:

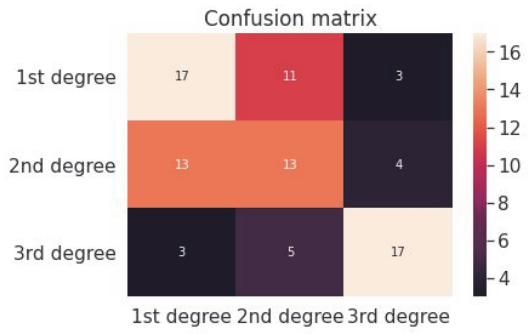
Մոդելի կիրառման համար ընդհանուր տվյալների բազան բաժանվել է վարժեցման և թեստավորման ենթաբազմությունների, իսկ վարժեցման 20%-ը օգտագործվել է որպես վալիդացիոն բազմություն, այսինքն հիպերպարամետրերի վարժեցման համար: Որպեսզի խուսափենք վարժեցման բազմությունում միևնույն դասից նկարների անընդմեջ կրկնությունից, պատահական ձևով վերցվում են 128 նկարներ տարբեր դասերից, և մոդելները կիրառվում են այդ բազմության վրա: Նման բազմությունները կոչվում են epoch-ներ, և մեր վերլուծության դեպքում դրանց քանակը 20-ն է: Վարժեցման ենթաբազմությունների ճշգրտությունը ներկայացված է նկ. 3-ում:



Նկ. 3. Ենթաբազմությունների ճշգրտությունների դինամիկան

Մոդելի ճշգրիտ աշխատանքն ապահովելու համար անհրաժեշտ է ստանալ հնարավորինս մոտ արժեքներ ունեցող վարժեցման, վալիդացիոն և վերջնական ճշգրտություններ: Մշակված մոդելի վերջնական ճշգրտությունը 54.65% է:

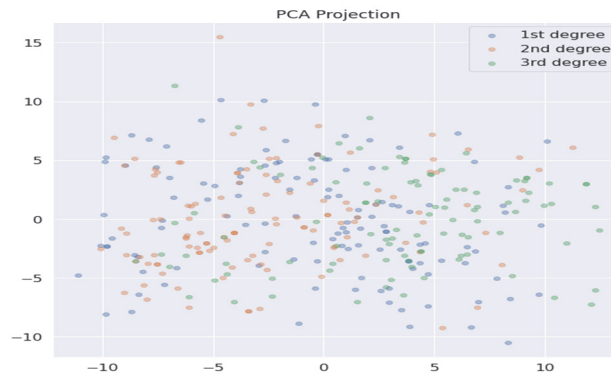
Պատկերների ստացված դասակարգման արդյունքը ներկայացնենք Confusion Matrix-ի միջոցով (նկ. 4-ում):



Նկ. 4. Վալիդացիոն ենթաբազմության վրա կիրառված Confusion Matrix

Նկ. 4 -ում օրդինատների առանցքը ցույց է տալիս իրական պիտակները, իսկ արքսիսներինը՝ կանխատեսված: Մասնավորապես՝ առաջին տողի առաջին սյունը ցույց է տալիս, որ 17 նկար, որոնք կանխատեսվել էին որպես առաջին դասի պատկերներ, իրականում էլ պատկանում են առաջին դասին: Մինչդեռ երկրորդ տողի առաջին սյունը ցույց է տալիս, որ 13 նկար կանխատեսվել էին որպես առաջին աստիճանի պատկերներ, սակայն իրականում պատկանում են երկրորդ դասին:

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



Նկ. 5. Տվյալների բազայի պատկերումը երկչափ տարածությունում PCA մեթոդով

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

**Եզրակացություն:** Վերջնական ճշգրտության արդյունքը պայմանավորված է երկու գործոնով՝ մշակված մոդելով և օգտագործվող տվյալների բազայով: PCA մոդելի արդյունքից կարելի է ենթադրել, որ մեր մշակած մոդելի վերջնական ճշգրտության համեմատաբար ցածր մակարդակը՝ 54.65%, պայմանավորված է տվյալների ի սկզբանե ըստ դասերի դասակարգման անհնարինությամբ և տվյալների բազայում նկարների սակավ քանակով:

Հետևաբար՝ ներդրումային ցանցի արդյունավետ վարժեցման համար անհրաժեշտ պայման են մուտքային տվյալների ավելի մեծ քանակը և հստակ տարանջատումը:

#### ԳՐԱԿԱՆՈՒԹՅԱՆ ՑԱՆԿ

1. **Simonyan K., Zisserman A.** Very Deep Convolutional Networks for Large-Scale Image Recognition // International Conference on Learning Representations (ICLR). – 2015. – P. 1 – 14, <https://arxiv.org/abs/1409.1556>
2. **Kingma D.P., Lei Ba J., Adam.** A Method for Stochastic Optimization // International Conference on Learning Representations (ICLR). - 2015. - P. 1 – 15, <https://arxiv.org/abs/1412.6980>
3. **Loshchilov I., Hutter F., Sgdr:** Stochastic Gradient Descent with Warm Restarts // International Conference on Learning Representations (ICLR). – 2017. – P. 1 – 16, <https://openreview.net/forum?id=Skq89Scxx>
4. **Bishop C.M.** Pattern Recognition and Machine Learning.- Springer Science+Business Media, LLC, 2006. – 758 p.
5. **Murphy K.P.** Machine Learning: A Probabilistic Perspective.- Massachusetts Institute of technology, 2012. – 1098 p.

**Г.Т. КИРАКОСЯН, А.К. МАИЛЯН**

#### **СОВЕРШЕНСТВОВАНИЕ СИСТЕМЫ КЛАССИФИКАЦИИ ОЖОГОВ С ПОМОЩЬЮ НЕЙРОННОЙ СЕТИ ПУТЕМ РАСШИРЕНИЯ БАЗЫ ДАННЫХ**

Представлен метод распознавания и классификации изображений ожогов с помощью нейронной сети. Для разработки метода использовалась 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, нейронные слои, пиксели, контролируемое обучение.

G.T. KIRAKOSSIAN, A.K. MAYILYAN

## IMPROVING THE BURN CLASSIFICATION SYSTEM BY A NEURAL NETWORK BY DATABASE AUGMENTATION

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

**Keywords:** Convolutional Neural Network, Neural layer, pixels, supervised learning.

ՀՏԴ 004.421:371.27

### Հ.Ա. ՃԱՆՃԱՊԱՆՅԱՆ

#### ԱՂԻ ՇԱՄԻՐԻ ՇԵՄԱՅԻՆ ՍԻՆԵՄԱՅԻ ԱԶԴԵՑՈՒԹՅՈՒՆԸ ՔՈՄՓՅՈՒԹԵՐԱՅԻՆ ՑԱՆՑԵՐԻ ԱՐՏԱԴՐՈՂԱԿԱՆՈՒԹՅԱՆ ԿՐԱ

Քոմպյուտերային ցանցերի արագագործության և անվտանգության ապահովումը կարևոր է նրանց շահագործման ընթացքում: Աղի Շամիրի  $(k,n)$  շեմային սխեման բանալիների կառավարման արդյունավետ մեթոդներից է: Այն մի կողմից՝ ապահովում է ցանցի անվտանգությունը, սակայն մյուս կողմից՝ հանգեցնում է արագագործության նվազման:

Աշխատանքում կատարված է ցանցային համակարգի արագագործության նվազման գնահատում՝ Աղի Շամիրի բանալիների կառավարման  $(k,n)$  շեմային սխեմայի կիրառման դեպքում:

**Առանցքային բաներ.** քոմպյուտերային ցանց, արագագործություն, անվտանգություն, շեմային սխեմա, գաղտնիքի բաշխում, Լագրանժի միջարկում, արտադրողականություն:

**Ներածություն:** Աղի Շամիրի մեթոդով բանալու բաժանումը գաղտնագրման ալգորիթմ է, որի ժամանակ բանալին (գաղտնիքը) բաժանվում է  $n$  մասերի և բաշխվում ցանցում մասնակցող յուրաքանչյուրի մեջ: Բանալին վերականգնելու համար անհրաժեշտ է միավորել բոլոր այդ մասերը կամ դրանցից մի քանիսը: Ցանկացած  $k$  կամ ավելի շատ մասերի իմացությունը գաղտնիքը դարձնում է հեշտ հաշվելի: Ցանկացած  $(k-1)$  կամ ավելի քիչ մասերի իմացությունը գաղտնիքը թողնում է բոլորովին անորոշ այն առումով, որ դրա բոլոր հնարավոր արժեքները հավասար հավանական են [1]:

Գաղտնիքի ստացման խնդիրը լուծելու համար օգտատերը պետք է ցանցի մասնակիցներից պահանջի և ստանա գաղտնիքի (բանալու)  $(k-1)$  հատ մասեր (այդ մասերը ներկայացնում են  $(k-1)$  կարգի բազմանդամից հաշվված կետեր՝