

Detection of Microaneurysms Using Fundus Images

Divya Padakanti¹, Shanti Sree Piniseti², Rajitha Bantu³, Swapna Padakanti^{4 1,2,3} Assistant Professor, Dept of ECE,

Indur Institute of Engineering and Technology, Siddipet, Telangana, India

⁴Assistant Professor, Dept of CSE,

Ellenki college of Engineering and Technology, patelguda, Telangana, India Corresponding Author *:

divya.padakanti419@gmail.com

ఫండస్ ఇమేజ్‌లను ఉపయోగించి మైక్రోఅన్యూరిజమ్‌ల గుర్తింపు

దివ్య పడకంటి¹, శాంతి శ్రీ పినిశెట్టి², రజిత బంటు³, స్వప్న పడకంటి^{4 1,2,3} అసిస్టెంట్ ప్రొఫెసర్,

ECE విభాగం,

ఇందూర్ ఇన్స్టిట్యూట్ యొక్క ఇంజనీరింగ్ మరియు టెక్నాలజీ, సిద్దిపేట, తెలంగాణ, భారతదేశం

⁴ అసిస్టెంట్ ప్రొఫెసర్, విభాగం యొక్క సిఎస్ఈ,

ఎల్లెంకి కళాశాల యొక్క ఇంజనీరింగ్ మరియు టెక్నాలజీ, పటేల్‌గూడ, తెలంగాణ, ఇండియా

కరస్పాండింగ్ రచయిత *: divya.padakanti419@gmail.com

వియక్త

ప్రపంచవ్యాప్తంగా అంధత్వానికి ప్రధాన కారకం మరియు రెటీనా వ్యాధులలో ఒకటి డయాబెటిక్ రెటీనోపతి (DR). DR యొక్క ముందస్తు గుర్తింపు మైక్రోఅన్యూరిజమ్స్ (MA) యొక్క ఆవిష్కరణ ద్వారా సహాయపడుతుంది, ఇది మొదటి క్లినికల్ గుర్తు యొక్క డాక్టర్. కాబట్టి, ముందుగానే గుర్తింపు మరియు చికిత్స చేయవచ్చు మీ దృష్టిని కోల్పోకుండా నిరోధించండి. ఫండస్ చిత్రాలలో, MA ని సూచించడానికి చిన్న ఎరుపు చుక్కలను ఉపయోగిస్తారు. అయితే, మానవ కంటి చూపును ఉపయోగించి ఫండస్ చిత్రాలను విశ్లేషించడం అప్పుడప్పుడు సవాలుగా ఉంటుంది. మైక్రోఅన్యూరిజమ్‌లను గుర్తించగల

నమూనాను అభివృద్ధి చేయడానికి మెరుగైన Res U-Net ఆర్కిటెక్చర్తో లోతైన అభ్యాసం కోసం ఒక నమూనాను ఈ పరిశోధనలో వివరించబడింది. సవాళ్లను అధిగమించడానికి Res Net రూపొందించబడింది. అత్యంత శిక్షణ లోతైన నాడీ సంబంధిత నెట్వర్క్లు. నాడీ నెట్వర్క్ డిజైన్ను ఇలా పిలుస్తారు U -నెట్ అంటే ప్రధానంగా చిత్ర విభజన కోసం ఉపయోగించబడుతుంది. మా మోడల్ ఉంది E-Ophtha మరియు IDRiD నుండి డేటాను ఉపయోగించి శిక్షణ పొందారు. లోతైన అభ్యాసం ఇటీవల వాటిలో ఒకటిగా ప్రాముఖ్యతను సంతరించుకుంది వివిధ పరిశ్రమలలో పనితీరును మెరుగుపరచడానికి అత్యంత ప్రభావవంతమైన వ్యూహాలు; వైద్య చిత్రాల విశ్లేషణ కూడా ఉన్నాయి. మరియు వర్గీకరణ. వీడియో మరియు ఇమేజ్ గుర్తింపు, వైద్య చిత్ర విశ్లేషణ, చిత్ర వర్గీకరణ, చిత్ర విభజన వంటి వాటిలో వీటి ఉపయోగాలు ఉన్నాయి. ఈ అధ్యయనంలో, మైక్రోఅన్యూరిజమ్లను గుర్తించడానికి మేము అనేక పద్ధతులను పరిశీలించాము మరియు మూల్యాంకనం చేసాము.

ముఖ్య పదాలు : మైక్రోఅన్యూరిజం, డయాబెటిక్ రెటీనోపతి (DR), ఫండస్ ఇమేజెస్, సెగ్మెంటేషన్, రెస్ యు- నెట్, డీప్ లెర్నింగ్

1 పరిచయం

డయాబెటిక్ రెటీనోపతి, కొన్నిసార్లు డయాబెటిక్ కంటి వ్యాధి అని పిలుస్తారు, ఇది డయాబెటిస్ మెల్లిటస్ రెటీనాను దెబ్బతీసే ఒక రుగ్మత. ఇది దీనికి ప్రధాన కారణం డయాబెటిస్ ఉన్న రోగులు ప్రమాదంలో ఉన్నారు. అ ప్రపంచం ఆరోగ్య సంస్థ (WHO) నివేదిక [13] రాష్ట్రాలు అది డాక్టర్ ఉంది ది ప్రాథమిక కారణం యొక్క

అభివృద్ధి చెందని దేశాలలో అంధత్వం. DR ని ముందుగానే గుర్తించడం మరియు చికిత్స చేయడం ద్వారా దృష్టి నష్టం ప్రమాదం తగ్గుతుంది. రెటీనా చిత్రాలను విశ్లేషించడం వల్ల డయాబెటిక్ రెటీనోపతి (DR) వంటి రెటీనా పరిస్థితులను గుర్తించడంలో సహాయపడుతుంది, ఇది డయాబెటిక్ వ్యక్తులలో రక్తంలో చక్కెర స్థాయిలు పెరగడం వల్ల వస్తుంది. రెటీనా రక్తనాళాల వ్యాసంలో స్థానికీకరించిన మార్పులను రెటీనా

మైక్రోఅన్యూరిజమ్స్ అంటారు. ఈ విస్తరణ వల్ల సాధారణ ప్రవాహ నమూనా దెబ్బతింటుంది. ఈ మైక్రోఅన్యూరిజమ్లలో ఎండోథెలియల్ పనిచేయకపోవడం వల్ల కలిగే లీకేజ్ మరియు రెటీనా ఎడెమా క్రమంగా దృష్టిని కోల్పోయేలా చేస్తుంది.


మొదటి సూచన DR అనేది మైక్రోఅన్యూరిజమ్స్ (MA), ఇది ఇలా వ్యక్తమవుతుంది చిన్న, వృత్తాకార, ఎర్రటి మచ్చలు ఆన్ ఫలితంగా రెటీనా పాత్ర గోడలు బలహీనపడటం. ఇది పదునైన సరిహద్దులను కలిగి ఉంటుంది మరియు 125 μm కంటే తక్కువగా ఉంటుంది. చిత్రం 1లో వివరించినట్లుగా, మైఖేల్ మరియు ఇతరులు [8] MA ని ఆరు వర్గాలుగా విభజించారు. AOSLO ప్రతిబింబం మరియు సాంప్రదాయ ఫ్లోరోసెంట్ ఇమేజింగ్ను గుర్తించడానికి ఉపయోగించారు MA యొక్క వివిధ రూపాలు.

చాలా కారకాలు, సహా తక్కువ తీర్మానం, అసమానమైన చిత్రం తొలగింపు, ప్రతిబింబం, మీడియా ఊబకాయం, మరియు చిన్నది పరిమాణం, దానిని సవాలుగా చేయండి నేత్ర వైద్యులు కు మైక్రోఅన్యూరిజమ్లను గుర్తించడం. ఈ పత్రం యొక్క ప్రధాన లక్ష్యం మెరుగైన U -నెట్ ఆర్కిటెక్చర్ను ఉపయోగించడం. లోతైన అభ్యాస నమూనాను సృష్టించడానికి మరియు రైలు అది కు గుర్తించు సూక్ష్మ నాడి వ్యవస్థ. కృత్రిమ తెలివితేటలు (AI) మరియు యంత్రం అభ్యాస పద్ధతులు తెలిసిన గా "లోతైన నేర్చుకోవడం" అనుకరించు ఎలా ప్రజలు నేర్చుకోండి నిర్దిష్టమైన రకాలు యొక్క సమాచారం. లోతైన నేర్చుకోవడం ఉంది ఒక కీలక భాగం డేటా సైన్స్. ఇందులో పని, మేము గుర్తించు సూక్ష్మ రక్తనాళముల కుహరము బయోమెడికల్ ఇమేజ్ సెగ్మెంటేషన్ కోసం డీప్ లెర్నింగ్ మోడల్ని ఉపయోగించి ఫండస్ చిత్రాలలో. కంటి లోపల, ది మూలాధారము ఉంది ది వెనుక ఉపరితలం. ఇది కలిగి ఉంటుంది యొక్క ది ఫోవియా, ఆప్టిక్ డిస్క్, రెటీనా, మక్యూలా, మరియు రక్త నాళాలు. ఇవి చిత్రాలు సహాయం లో ది రోగ నిర్ధారణ, పర్యవేక్షణ, మరియు చికిత్స యొక్క కన్ను పరిస్థితులు విభజన అనేది ఒక ప్రక్రియ, దీనిలో మనం ఒక నిర్దిష్ట ప్రాంతాన్ని గుర్తించవచ్చు లేదా గుర్తించవచ్చు. బయోమెడికల్ రంగంలో చిత్రం



విభజన, యు-నెట్ ఉంది విస్తృతంగా ఉపయోగించబడింది. ది ప్రాథమిక ఉపయోగం యొక్క ది యు-నెట్ న్యూరల్ నెట్వర్క్ డిజైన్ ఉంది చిత్రం విభజన. ది పదనిర్మాణ శాస్త్రం యొక్క ది రెటీనా నాళాలు చెయ్యవచ్చు నిర్ధారణ అవ్వండి వద్ద ది ప్రారంభ స్క్రినింగ్ దశ కు అంచనా వేయండి వారి ఆరోగ్యం. గాయాలు అటువంటి అధికమైన సూక్ష్మ నాడి వ్యవస్థ వక్రత, మరియు పాత్ర సంకుచితం తరచుగా రూపం లో ది రెటీనా నాళాలు సమయంలో ది ప్రారంభ దశలు యొక్క ది వ్యాధి ప్రక్రియ.





2 సాహిత్యం సమీక్ష

మైక్రోఅన్యూరిజమ్లను గుర్తించడం సవాలుతో కూడుకున్నది ఎందుకంటే దీనికి నైపుణ్యం కలిగిన నేత్ర వైద్యుడు అవసరం. ఈ సమస్యలను పరిష్కరించడానికి గతంలో అనేక పరిష్కారాలు అందించబడ్డాయి. ఈ భాగంలో మైక్రోఅన్యూరిజమ్లను గుర్తించడానికి గతంలో సూచించిన కొన్ని పద్ధతుల గురించి మనం మాట్లాడుతాము.

[5] లో సూచించబడిన పని మైక్రోఅన్యూరిజం గుర్తింపు కోసం లోతైన అభ్యాస-ఆధారిత కంప్యూటర్-సహాయక విధానాన్ని వివరిస్తుంది. మోడల్ యొక్క ఖచ్చితత్వాన్ని పెంచడానికి ఐదు పొరలు ఉపయోగించబడతాయి, వీటిలో మాక్సెట్ యాక్టివేషన్ ఫంక్షన్ మరియు సాఫ్ట్‌మాక్స్ వర్గీకరణ పొరను ఉపయోగించి డ్రాప్‌అవుట్ శిక్షణ ఉన్నాయి. తక్కువ తప్పుడు సానుకూల రేటు మరియు MA అభ్యర్థి వెలికితీత కోసం అత్యధునిక ఫలితాలతో, ఈ విధానం కొన్ని పబ్లిక్ గా యాక్సెస్ చేయగల డేటాసెట్లపై ధృవీకరించబడింది మరియు డయాబెటిక్ మాస్ స్క్రీనింగ్కు ప్రయోజనకరంగా ఉంటుంది.

[6] లో మైక్రోఅన్యూరిజమ్లను గుర్తించడానికి ఒక ఫోకస్ పద్ధతి. ఇమేజ్ ప్రాసెసింగ్‌లో, ముఖ్యంగా ఆబ్జెక్ట్ డిటెక్షన్, సెమాంటిక్ సెగ్మెంటేషన్ మరియు ఇమేజ్ వర్గీకరణ వంటి పనులలో అటెన్షన్ మెకానిజమ్లను తరచుగా ఉపయోగిస్తారు. ప్రిడిక్షన్ సెట్ పునరావృతమయ్యే తగిన ఆబ్జెక్ట్ బౌండరీ ఫ్రేమ్‌కు కలుస్తుందని హామీ ఇచ్చే అటెన్షన్ నెట్‌వర్క్ ప్రతిపాదించబడింది, ఇది పరిమాణాత్మకంగా వస్తువు శోధనకు బలహీనమైన దిశ, మరియు ఖచ్చితత్వాన్ని పెంచుతుంది యొక్క వస్తువు గుర్తింపు. శ్రద్ధ యంత్రాంగం యొక్క లోపం ఏమిటంటే ఇది మోడల్ యొక్క బరువులను పెంచుతుంది, ఇది ప్రక్రియను నెమ్మదిస్తుంది.

[7] లో సమర్పించబడిన పరిశోధన మైక్రోఅన్యూరిజమ్స్ యొక్క ప్రారంభ రోగ నిర్ధారణ కోసం ఎక్సైజ్డ్ రక్తనాళ విశ్లేషణను ఉపయోగించడాన్ని సూచించే అసమానతలను కనుగొంది. వెతుకుతున్న ప్రక్రియలో ఫండస్ చిత్రాలలో మైక్రోఅన్యూరిజమ్స్, సాధ్యమైనంత ఉత్తమమైనది ఎంపిక ఆకుపచ్చ సబ్-బ్యాండ్ ఛానల్ యొక్క బిక్యూబిక్ ఇంటర్పోలేషన్ రక్తనాళ గుర్తింపు ద్వారా రెటీనా ఫండస్ ఇమేజ్ లైట్

స్మాటింగ్ను విచ్ఛేదనం చేశారు. పినాకిల్పై తిరిగే క్రాస్-సెక్షనల్ ప్రొఫైల్ విచారణ మరియు స్థానిక అత్యంత తీవ్రమైన పిక్సెల్లు స్థిరపరచబడ్డాయి ప్రాదేశిక అతిపెద్ద పిక్సెల్లు ఉపయోగించారు వివిధ అంశాలను మూల్యాంకనం చేయండి గుణకాలు. గుణకం ఈ అధ్యయనంలో వివిధ రకాల సామర్థ్యాలు మరియు సగటు ప్రామాణిక విచలనం యొక్క సంఖ్యా విలువలను పరిశీలించారు. మైక్రోఅన్యూరిజం పోటీని అంచనా వేయడానికి, సగటు యొక్క వ్యాప్తి మరియు వివిధ డేటాసెట్ల నుండి సేకరించిన తయారీ సమితితో ప్రామాణిక విచలనం అంచనాలను ఉపయోగిస్తారు.

[8] లో, ప్రతి సంభావ్య MA అభ్యర్థిని మోల్లెట్ వేవ్లెట్ ఆధారంగా అభ్యర్థి గుర్తింపు సాంకేతికతను ఉపయోగించి కనుగొంటారు. MA మరియు MA కాని వస్తువుల మధ్య తేడాను గుర్తించే రెండు వివక్షత కలిగిన నిఘంటువులను నేర్పుకోవడం తదుపరి దశ. ఈ నిఘంటువులు కనుగొనబడిన అభ్యర్థి వస్తువులను వర్గీకరించడానికి ఉపయోగించబడతాయి. ప్రస్తుత పద్ధతులతో పోల్చినప్పుడు ప్రతిపాదిత MA గుర్తింపు విధానం దాదాపు 2-15 శాతం సగటు సున్నితత్వాన్ని కలిగి ఉందని మూల్యాంకనాలు చూపిస్తున్నాయి.


[9] లో సూచించబడిన అధ్యయనం MA కోసం ఒక నవల విభజన పద్ధతిని అందించడానికి ప్రాంత పెరుగుదల, వాటర్షెడ్ మరియు కాంట్రాస్ట్ నార్మలైజేషన్ పద్ధతులను మిళితం చేస్తుంది. చిత్రం గతంలో మధ్యస్థ వడపోతను ఉపయోగించి ప్రాసెస్ చేయబడిన తర్వాత 2-D గాస్సియన్ను వర్తింపజేయబడింది. రెండవది, అవి ఫండస్ ఇమేజ్ యొక్క ప్రామాణిక విచలనాన్ని ఉపయోగించి కాంట్రాస్ట్ నార్మలైజేషన్ను వర్తింపజేశారు, ఆపై వారు దీనిని తయారు చేశారు రీజియన్ గ్రోయింగ్ మోడల్ వాటర్షెడ్ గ్రేడియంట్ ఇమేజ్ని ఉపయోగించి అభ్యర్థి ప్రాంతం కనిపిస్తుంది మరియు గుర్తించదగినది. వారు గుర్తించడానికి K-NN వర్గీకరణను ఉపయోగించడం ద్వారా 84.6 శాతం నిర్దిష్టత రేటును సాధించారు ఫోటోలలో MA.

3 పద్ధతి


మైక్రోఅన్యూరిజమ్లను గుర్తించడం సవాలుతో కూడుకున్నది ఎందుకంటే దీనికి నైపుణ్యం కలిగిన నేత్ర వైద్యుడు అవసరం. ఈ సమస్యలను పరిష్కరించడానికి గతంలో అనేక పరిష్కారాలు అందించబడ్డాయి. ఈ భాగంలో మైక్రోఅన్యూరిజమ్లను గుర్తించడానికి గతంలో సూచించిన కొన్ని పద్ధతుల గురించి మనం మాట్లాడుతాము.

[5] లో సూచించబడిన పని వివరిస్తుంది a అధిక రక్తపోటు, మధుమేహం మరియు అధిక రక్తపోటు రెటీనోపతి, మరియు ఆర్టెరియోస్క్లెరోసిస్ వంటి పరిస్థితుల గుర్తింపు కోసం, ఆటోమేటిక్ విభజన యొక్క రెటీనా చిత్రాలు కీలకమైనవి కంప్యూటర్-సహాయక వైద్యంలో పని చిత్ర విశ్లేషణ. రెటీనా నాళాలను గుర్తించడం ద్వారా, డయాబెటిక్ రెటీనోపతి - దృష్టి నష్టానికి ప్రధాన కారణం - పరిస్థితులలో ముందుగానే గుర్తించవచ్చు. తక్కువ తప్పుడు సానుకూల రేటు మరియు MA అభ్యర్థి వెలికితీతకు అత్యాధునిక ఫలితాలతో, ఈ విధానం కొన్ని బహిరంగంగా అందుబాటులో ఉన్న డేటాసెట్లపై ధృవీకరించబడింది మరియు డయాబెటిక్ మాస్ స్క్రీనింగ్కు ఉపయోగపడుతుంది.

[6] లో, మైక్రోఅన్యూరిజమ్ల గుర్తింపు అనేది ఒక అటెన్షన్ మెకానిజం మరియు MA లు మరియు రక్త నాళాల సాపేక్ష ప్రాదేశిక పంపిణీపై ఆధారపడి ఉంటుంది. మా అటెన్షన్ మాడ్యూల్ ప్రత్యేకంగా చిన్న లక్ష్య గుర్తింపుతో అనుబంధించబడిన నిస్సార-పొర నెట్వర్క్ లక్షణాలపై దృష్టి పెడుతుంది. అటెన్షన్ మెకానిజమ్లు మోడల్కు అదనపు బరువులను జోడించడంలో లోపాన్ని కలిగి ఉంటాయి, ఇది నెమ్మదిస్తుంది ప్రక్రియ. ఈ విభాగం వివరణాత్మక వర్ణనను అందిస్తుంది మా సూచించిన విభజన సాంకేతికత. ఉపయోగించడం ఒక ముందస్తు శిక్షణ పొందిన నెట్వర్క్ చేస్తుంది ది U -నెట్ సెగ్మెంటేషన్ ప్రక్రియ తులనాత్మకంగా సులభం



1(a) ఫండ్స్ చిత్రం




చిత్రం 1(బి)- నేల నిజం యొక్క ఫండ్స్ చిత్రం

Fig. 1(a) లోని రెటీనా చిత్రంలో చిన్న ఎర్రటి మచ్చలు లేదా గుర్తుల ద్వారా మైక్రోఅన్యూరిజమ్‌లు చూపబడతాయి. అందువల్ల, మనం ఆ చిన్న ఎర్రటి మచ్చలను విభజనలో కనుగొని వర్గీకరించాలి. మా నమూనాకు శిక్షణ ఇవ్వడానికి, మనకు అనేక రెటీనా చిత్రాలు మరియు సారూప్య చిత్రాల ముసుగులు ఉన్నాయి. ముసుగులు తప్పనిసరిగా ఆ చిన్న ఎర్రటి మచ్చలను కనుగొని లేబుల్ చేసే చిత్రం. ముసుగులకు మరో పేరు గ్రౌండ్ ట్రూత్ పిక్చర్స్.

Fig. 1(b) చిత్రంలో పిక్సెల్‌లు చిన్న ఎరుపు మచ్చలతో ఉంచబడినట్లు లేదా గుర్తించబడినట్లు మనం స్పష్టంగా చూడవచ్చు, అక్కడ మైక్రోఅన్యూరిజమ్స్ ఉన్నాయి ప్రస్తుతం, అందువలన మేము అతివ్యాప్తి ఒక

చిత్రం తో మరొకటి, మనం చెయ్యవచ్చు చూడండి ఇవి వ్యాధి ఉన్న ప్రదేశాలు. ఇంటర్నెట్‌లో అందుబాటులో ఉన్న సాఫ్ట్‌వేర్ లేదా ఇమేజ్ లేబుల్‌లను ఉపయోగించి మనం ఈ గ్రౌండ్ ట్రూత్ ఇమేజ్‌లను మాన్యువల్‌గా నిర్మించవచ్చు.

ప్రవాహం చార్ట్



ఇమేజ్ ప్రీప్రాసెసింగ్ మార్పిడి

యొక్క ఆర్జిబి కు ల్యాబ్ ప్రీ-



ప్రాసెసింగ్

శిక్షణ కోసం నెట్వర్క్లోకి ఫీడ్ చేయడానికి ముందు ఫండస్ చిత్రాలను ముందే ప్రాసెస్ చేయాలి ఎందుకంటే దాని లోపాలలో ముఖ్యమైన శబ్దం, అసమాన ప్రకాశం మరియు పేలవమైన కాంట్రాస్ట్ ఉన్నాయి. అసలు ఫండస్ ఇమేజ్ మరియు రెటీనా నాళాల యొక్క మాన్యువల్ గా గుర్తించబడిన వాస్కులర్ మ్యాప్ చిత్రాలు 1(A) మరియు 1(B) లలో ప్రదర్శించబడ్డాయి. గ్రేస్కేల్ గా మార్చబడిన తర్వాత, ఫండస్ చిత్రాలు ప్రామాణికం చేయబడతాయి. మార్పిడి సమీకరణం ఈ క్రింది విధంగా చూపబడింది:

$$\text{నేను బూడిద రంగు } \frac{1}{4} \text{ లు } 0:299 \times \text{నేను } p \text{ } 0:587 \times \text{నేను జి } p \text{ } 0:114 \times \text{నేను బి (1)}$$

వాటిలో నేను , నేను జి మరియు నేను బి ఫండస్ చిత్రాల యొక్క RGB ఛానల్ భాగాలు. Eq లో చూపిన విధంగా. (1) , నేను బూడిద రంగులో ఉన్నాను ప్రాసెసింగ్ ఫలితం. ఇది ప్రామాణీకరించబడింది మరియు ప్రామాణీకరణ సమీకరణం.



మెడికల్ ఇమేజింగ్ యొక్క అన్ని రంగాలలో, ముఖ్యంగా సమకాలీన నేత్ర వైద్యంలో, ఇమేజ్ ప్రాసెసింగ్, విశ్లేషణ మరియు కంప్యూటర్ దృష్టి పద్ధతులు క్రమంగా విస్తరిస్తున్నాయి. రెటీనా చిత్రాల నాణ్యతను మెరుగుపరచడానికి, ప్రీప్రాసెసింగ్ దశలను ఉపయోగిస్తారు. గణనీయమైన శబ్దం, అస్థిరమైన ప్రకాశం మరియు పేలవమైన కాంట్రాస్ట్ వంటి దాని లోపాల కారణంగా, ఫండస్ చిత్రాలను ముందుగా ప్రాసెస్ చేయాలి. ముందు తినిపించబడుతోంది ది నెట్వర్క్ కోసం శిక్షణ సమయంలో ప్రీప్రాసెసింగ్, చిత్రం యొక్క ప్రారంభంలో ఆకుపచ్చ ఛానల్‌ను సంగ్రహిస్తారు మరియు దాని కాంట్రాస్ట్ తరువాత మెరుగుపడుతుంది.



ఎందుకంటే తీవ్రమైన కాంట్రాస్ట్ ఆకుపచ్చ ఛానెల్‌లో, మైక్రోఅన్యూరిజమ్స్ సులభంగా కనిపిస్తాయి. చిత్రం 1 ఎరుపు, ఆకుపచ్చ మరియు ఇన్‌పుట్ ఇమేజ్ నుండి తిరిగి పొందబడిన నీలి ఛానెల్‌లు.

(అ)

(బి)



(సి)

(డి)

చిత్రం 1 . నాలుగు దశలు యొక్క ప్రీప్రాసెసింగ్:

(a) అసలు ఆర్జిబి రంగు రెటీనా చిత్రం

(b) కత్తిరించబడింది గ్రీన్-ఛానల్ చిత్రం

(c) మెరుగుపరిచిన గ్రీన్-ఛానల్ చిత్రం

(d) చివరి చిత్రం తర్వాత గామా దిద్దుబాటు.

గ్రేస్కేల్ చిత్రాన్ని ఉత్పత్తి చేయడానికి కలర్ రెటీనా ఫండస్ ఛాయాచిత్రం యొక్క ఎరుపు (R), ఆకుపచ్చ (G) మరియు నీలం (B) భాగాల నుండి ప్రకాశం మార్పిడిని సమీకరణం (1) గణిస్తుంది.

బూడిద రంగు స్థాయి = $0.299 * \text{ఆర్} + 0.587 \text{ తెలుగు} * \text{గ} + 0.114 \text{ తెలుగు i n లో} * \text{బి}$


బయోలాజికల్ ఇమేజ్ ప్రాసెసింగ్లో, CLAHE అనేది ఒక ఉపయోగకరమైన టెక్నిక్, ఎందుకంటే

ఇది సాధారణంగా ముఖ్యమైన ప్రముఖ భాగాలకు ప్రాప్యతను సమర్థవంతంగా పెంచుతుంది. రెటీనా చిత్రాలపై, ఆప్టిక్ డిస్క్ యొక్క సరిహద్దులను సంగ్రహించడానికి స్థానిక కాంట్రాస్ట్‌ను మెరుగుపరచడానికి మరియు అసమాన నేపథ్యాలను సరిచేయడానికి కాంట్రాస్ట్ లిమిటెడ్ అడాప్టివ్ హిస్టోగ్రామ్ ఈక్వలైజేషన్ (CLAHE) ఉపయోగించబడింది. ప్రత్యేకంగా, CLAHE అనేది దాచిన లక్షణాలను గుర్తించడానికి ఉపయోగించబడుతుంది, ఉదాహరణకు ఆప్టిక్ డిస్క్ యొక్క కాంట్రాస్ట్‌ను మెరుగుపరచడం వంటివి. ఫండస్ చిత్రాలు దాచిన రక్తం నాళాలు. కింది సూత్రం ఉపయోగించబడింది నిర్ణయించడానికి తీవ్రత యొక్క ప్రతి పిక్సెల్:

$$b' = b + \mu \text{ సగటు} - \mu \text{ సగటు}$$

ఇక్కడ μ సగటు కావలసిన సగటు తీవ్రత, μ సగటు స్థానిక సగటు తీవ్రత, మరియు B , B' అనేవి ప్రారంభ మరియు ఇటీవలి పిక్సెల్‌లు. వరుసగా పరిమాణ విలువలు. ఇది విధానం రెటీనా ఉపరితలం వద్ద ఏర్పడే మైక్రోఅన్యూరిజమ్‌లను పెంచుతుంది.

మొత్తం మీద చిత్రాలను సమం చేసే హిస్టోగ్రామ్ ఈక్వలైజేషన్, CLAHE తర్వాత వస్తుంది. CLAHE తో పాటు, కాంట్రాస్ట్‌ను మరింత తీవ్రతరం చేయడానికి ఇది జరుగుతుంది. గాస్సియన్ ఫిల్టరింగ్ అదనపు శబ్దాల ఉనికిని తొలగిస్తుంది. CLAHE, హిస్టోగ్రామ్ ఈక్వలైజేషన్ మరియు గాస్సియన్ ఫిల్టర్ చేసిన వాటి అవుట్‌పుట్ Fig. 5.6 లో ప్రదర్శించబడింది. ఫలితంగా, సమాన ప్రకాశం మరియు మెరుగుదల ఉంది. విరుద్ధంగా ది చివరి ముందుగా ప్రాసెస్ చేయబడిన ఫోటోలు. లో ఆర్డర్ కు గుర్తించు ది ఉనికి యొక్క $M_h s$, శబ్దం ఉనికిని తొలగించడం ద్వారా మృదువైన చిత్రం పొందబడుతుంది



అనుకూల హిస్టోగ్రాం సమీకరణ:

(a) గ్రే-లెవల్ ఫండస్ చిత్రం (బి) హిస్టోగ్రాం సమానీకరణ చిత్రం


లోతైన నేర్పుకోవడం

డీప్ లెర్నింగ్ టెక్నిక్లను ఉపయోగించి, ముఖ్యంగా కన్వల్యూషనల్ న్యూరల్ నెట్వర్క్లు (CNN లు) మరియు $\square$ -నెట్లను ఉపయోగించి ఎక్స్డెట్లను గుర్తించారు. వాటికి చేతితో తయారు చేసిన లక్షణాలు అవసరం లేదు కాబట్టి, అవి ఇటీవలి సంవత్సరాలలో విస్తృతంగా స్వీకరించబడింది, .కన్వల్యూషనల్ న్యూరల్ నెట్వర్క్లు (CNN లు) అనేది ఒక రకమైన కృత్రిమ న్యూరల్ నెట్వర్క్, ఇది దృశ్య దృష్టి విశ్లేషణ కోసం లోతైన అభ్యాసంలో ఎక్కువగా ఉపయోగించబడుతుంది. కనీసం ఒకదానిలో వాటి పొరలలో, CNN లు గణిత శాస్త్రాన్ని ప్రత్యామ్నాయం చేస్తాయి సాధారణ మాతృక గుణకారం కోసం కన్వల్యూషన్ అని పిలువబడే ప్రక్రియ. వీటిని ఇమేజ్ ప్రాసెసింగ్ మరియు గుర్తింపులో ఉపయోగిస్తారు మరియు ప్రత్యేకంగా పిక్సెల్ డేటాను నిర్వహించడానికి తయారు చేస్తారు . .

మల్టీలేయర్ పెర్సెప్ట్రాన్లు CNN లుగా క్రమబద్ధీకరించబడతాయి. సాధారణంగా, మల్టీలేయర్ పెర్సెప్ట్రాన్లు పూర్తిగా అనుసంధానించబడిన నెట్వర్క్లు, అంటే ఒక పొరలోని ప్రతి న్యూరాన్ పై పొరలోని ప్రతి ఇతర న్యూరాన్తో జతచేయబడుతుంది. ఈ నెట్వర్క్ల "పూర్తి కనెక్టివిటీ" వాటిని డేటాను అతిగా

అమర్చడానికి హాని చేస్తుంది.


ఇన్పుట్, దాచబడిన, మరియు అవుట్పుట్ పొరలు తయారు చేయు పైకి ఒక కన్వల్యూషన్ న్యూరల్ నెట్వర్క్. కన్వల్యూషన్ న్యూరల్ నెట్వర్క్ యొక్క దాచిన పొరలు ఒకటి లేదా అంతకంటే ఎక్కువ కన్వల్యూషన్-పెర్ఫార్మింగ్ లేయర్లను కలిగి ఉంటాయి. సాధారణంగా, పొర యొక్క ఇన్పుట్ మ్యాట్రిక్స్ తో కన్వల్యూషన్ కెర్నల్ యొక్క డాట్ ఉత్పత్తిని చేసే పొర ఇందులో భాగం. ఈ ఉత్పత్తి యొక్క యాక్టివేషన్ ఫంక్షన్, ఇది తరచుగా ప్రొబెనియస్ అంతర్గత ఉత్పత్తి, ఇది ReLU . కింది పొర యొక్క ఇన్పుట్ అనేది కన్వల్యూషన్ కెర్నల్ పొర యొక్క ఇన్పుట్ మ్యాట్రిక్స్ వెంట కదులుతున్నప్పుడు కన్వల్యూషన్ ఆపరేషన్ ద్వారా ఉత్పత్తి చేయబడిన ఫీచర్ మ్యాప్. ఇతర పొరలు, సహా పూర్తిగా కలపడం కనెక్ట్ చేయబడింది, మరియు సాధారణీకరణ పొరలు, తరువాత రండి. పూలింగ్, CNN లలో ఒక రకమైన నాన్-లీనియర్ డౌన్ శాంప్లింగ్ మరొక కీలక ఆలోచన. వివిధ రకాల నాన్-లీనియర్ ఫంక్షన్లను ఉపయోగించి పూలింగ్ను అమలు చేయవచ్చు, గరిష్ట పూలింగ్ అత్యంత ప్రజాదరణ పొందింది. ఇన్పుట్ ఇమేజ్ విభజించబడింది ఒక సేకరణ యొక్క దీర్ఘచతురస్రాలు, మరియు గరిష్టంగా ఉంది కోసం అవుట్పుట్ ప్రతి యొక్క ఇవి ఉప ప్రాంతాలు.



యు- నెకర:

క్లాసిక్ కన్వల్యూషనల్ న్యూరల్ నెట్వర్క్ నుండి ఉద్భవించిన Unet , మొదట 2015లో అభివృద్ధి చేయబడింది మరియు విస్తరించే మరియు కుదించే మార్గాన్ని ఉపయోగించడం ద్వారా బయోమెడికల్ పిక్చర్ సెగ్మెంటేషన్ ను నిర్వహించడానికి ఉపయోగించబడింది. పూర్తిగా పోలిస్తే మెలికలు తిరిగిన నెట్వర్క్లలో, U-Net ప్రతి కన్వల్యూషన్ యొక్క చెల్లుబాటు అయ్యే భాగాలను మాత్రమే ఉపయోగిస్తుంది కాబట్టి ఇది వేగంగా ఉంటుంది. ప్రాథమిక ఒక సాధారణ కాంట్రాక్టు నెట్వర్క్కు వరుస పొరలను జోడించడం అనేది భావన, ప్రత్యామ్నాయం అప్సాంప్లింగ్ ఆపరేటర్లు కోసం పూలింగ్ కార్యకలాపాలు. అందువలన, ఈ పొరలు అవుట్పుట్ యొక్క రిజల్యూషన్ ను పెంచుతాయి. ఒక సాధారణ కన్వల్యూషనల్ న్యూరల్ నెట్వర్క్ యొక్క పని బయోలాజికల్ అప్లికేషన్లలో ఇన్పుట్ ఇమేజ్ మరియు అవుట్పుట్ లేబుల్తో ఇమేజ్ వర్గీకరణ కాబట్టి, మనం ఒక వ్యాధి ఉందో లేదో నిర్ధారించడం, కానీ అసాధారణత యొక్క స్థానాన్ని కూడా గుర్తించడం...


ఇది "U" ఆకారాన్ని కలిగి ఉన్నట్లు కనిపిస్తుంది. రెండు ప్రధాన భాగాలతో, డిజైన్ సుష్టంగా ఉంటుంది. ప్రాథమిక కన్వల్యూషనల్ ప్రక్రియ చేస్తుంది పైకి ఎడమ భాగం, తెలిసినది గా ది కాంట్రాక్టింగ్ మార్గం, అయితే స్థానాంతరం చెందింది 2D కన్వల్యూషనల్ పొరలు కుడి భాగాన్ని తయారు చేస్తాయి, దీనిని ఎక్స్పాన్సివ్ పాత్ అని పిలుస్తారు. ఇంకా, కాంట్రాక్టింగ్ మరియు ఎక్స్పాండింగ్ పాత్ల మధ్య క్రాస్-కనెక్షన్ల కారణంగా మరింత ఖచ్చితమైన సెగ్మెంటేషన్ అవుట్పుట్ ఉత్పత్తి అవుతుంది. ఒక సాధారణ కన్వల్యూషనల్ నెట్వర్క్, కాంట్రాక్టింగ్ పాత్ రూపొందించబడింది యొక్క పునరావృతం మెలికలు, ప్రతి ఒక్కటి తరువాత గరిష్టంగా పూలింగ్ ఆపరేషన్ మరియు సరిదిద్దబడిన లీనియర్ యూనిట్ (ReLU). సంకోచం ప్రాదేశిక సమాచారాన్ని తగ్గిస్తూ ఫీచర్ సమాచారాన్ని పెంచుతుంది. కాంట్రాక్టింగ్ నుండి అధిక-రిజల్యూషన్ లక్షణాలను ఉపయోగించి అప్-కన్వల్యూషన్లు మరియు సంయోగాల శ్రేణిని ఉపయోగించడం. మార్గం, ది విశాలమైన దారి అనుసంధానిస్తుంది ది అంతరిక్షం మరియు లక్షణం సమాచారం.



రెస్ U- నెకర :

Res U-Net అంటే Deep Residual U-Net. ఎన్కోడర్-డీకోడర్ డిజైన్ సెమాంటిక్ సెగ్మెంటేషన్‌ను దృష్టిలో ఉంచుకుని రూపొందించబడింది. ఇది హ్యూమన్ పిక్చర్ సెగ్మెంటేషన్, బ్రెయిన్ ట్యూమర్ సెగ్మెంటేషన్ మరియు రిమోట్ సెన్సింగ్ ఇమేజ్ అనాలిసిస్‌తో సహా వివిధ రంగాలకు వర్తింపజేయబడింది. పూర్తిగా కన్వల్యూషనల్ న్యూరల్ నెట్‌వర్క్, Res U-Net తక్కువ పారామితులతో గొప్ప పనితీరును సాధించడానికి తయారు చేయబడింది. ప్రస్తుత UNET ఆర్కిటెక్చర్‌తో పోలిస్తే, t మంచిది. RESUNET డీప్ రెసిడ్యూవల్ లెర్నింగ్ మరియు UNET ఆర్కిటెక్చర్‌ను ప్రభావితం చేస్తుంది. U-Net మాదిరిగానే, Res U-Net కూడా దీనితో రూపొందించబడింది ఒక ఎన్కోడింగ్ నెట్‌వర్క్, డీకోడింగ్ నెట్‌వర్క్ మరియు ఒకదాని నుండి మరొకదానికి వంతెన. U -నెట్ రెండు 3×3 కన్వల్యూషనల్‌లను ఉపయోగిస్తుంది, ప్రతి దాని తర్వాత ఒక ReLU యాక్టివేషన్ ఫంక్షన్ ఉంటుంది. ఈ పొరలు మార్చబడతాయి. బయటకు

కోసం ఒక ముందే సక్రియం చేయబడినది అవశేషం బ్లాక్ లో ది రెస్ యు-నెట్ దృశ్యం.





ఎన్నోడర్

ఎన్నోడర్ వివిధ ఎన్నోడర్ బ్లాక్ల ద్వారా ఇన్పుట్ ఇమేజ్ను పాస్ చేయడం ద్వారా నెట్వర్క్ ఒక అబ్స్ట్రాక్ట్ ప్రాతినిధ్యాన్ని నేర్చుకోవడానికి సహాయపడుతుంది. ప్రీ-యాక్టివేటెడ్ రెసిడ్యూవల్ బ్లాక్ను ఎన్నోడర్ యొక్క మూడు ఎన్నోడర్ బ్లాక్ల నిర్మాణంలో ఉపయోగిస్తారు. ప్రతి ఎన్నోడర్ బ్లాక్ యొక్క అవుట్పుట్ మ్యాచింగ్ డీకోడర్ బ్లాక్గా పనిచేస్తుంది. దాటవేయి కనెక్షన్. లో ది రెండవ మరియు మూడవది ఎన్నోడర్ బ్లాక్స్, ప్రారంభ 3×3 మెలికలు తిరిగిన స్థితి పొర ఒక అడుగు దూరంలో ఉంది 2 తగ్గించడానికి ప్రాదేశిక కొలతలు (ఎత్తు మరియు వెడల్పు) ఫీచర్ మ్యాప్లు. స్ప్రెడ్ విలువ 2 అయినప్పుడు, స్పేషియల్ కొలతలు సగానికి తగ్గించబడ్డాయి, నుండి 256 నుండి 128 వరకు.

వంతెన

అ ముందుగా సక్రియం చేయబడిన అవశేష బ్లాక్ తో ఒక అడుగు ముందుకు వేయు విలువ యొక్క రెండు ఉంది కూడా ఒక భాగం యొక్క ది వంతెన.

డీకోడర్

సెగ్మెంటేషన్ మాస్క్ను సృష్టించడానికి వేరే ఎన్కోడర్ బ్లాక్ నుండి స్కిప్ కనెక్షన్లను మరియు బ్రిడ్జ్ నుండి ఫీచర్ మ్యాప్ను ఉపయోగించడం ద్వారా డీకోడర్ మెరుగైన సెమాంటిక్ ప్రాతినిధ్యాన్ని నేర్చుకుంటుంది. మూడు డీకోడర్ బ్లాక్లు డీకోడర్ను తయారు చేస్తాయి; ప్రతి బ్లాక్ తర్వాత, ఫీచర్ సంఖ్య ఛానెల్లు తగ్గించబడ్డాయి మరియు ఫీచర్ మ్యాప్ యొక్క ప్రాదేశిక కొలతలు రెట్టింపు చేయబడ్డాయి.

U-Net ఒక పరిష్కారాన్ని కనుగొనడానికి కట్టుబడి ఉంది. ఇది ప్రతి పిక్సెల్ను వర్గీకరిస్తుంది కాబట్టి, ఇన్పుట్ మరియు అవుట్పుట్ ఒకే పరిమాణాన్ని కలిగి ఉంటాయి, ఇది సరిహద్దులను గుర్తించడానికి

మరియు వేరు చేయడానికి అనుమతిస్తుంది. ఉదాహరణకు, 2×2 ఇన్పుట్ ఇమేజ్, ఈ అధ్యయనంలో, U-Net బ్యాక్బోన్‌ను ఉపయోగించి ఎండ్-టు-ఎండ్ సెగ్మెంటేషన్ అమలు చేయబడింది, ఇది సమయ వినియోగాన్ని గణనీయంగా తగ్గిస్తుంది మరియు పనితీరును మెరుగుపరుస్తుంది. అదనంగా, సూపర్ పిక్సెల్ డేటా నమూనాలను సంగ్రహించడానికి ఉపయోగించబడుతుంది, అసమతుల్యత మరియు చిన్న డేటాసెట్‌ల సవాళ్లను అధిగమిస్తుంది.

ముందస్తు శిక్షణ పొందిన మోడల్ :

ప్రాసెస్ చేయబడిన మరియు విభజించబడిన రెటీనా ఫండస్ చిత్రాలను వర్గీకరించడానికి అధిక-పనితీరు నమూనాలు ఎంపిక చేయబడ్డాయి; • కొత్త CNN మోడల్‌ను సృష్టించండి మరియు ప్రాసెస్ చేయబడిన మరియు విభజించబడిన రెటీనా ఫండస్ చిత్రాలను ఉపయోగించి దానిని మొదటి నుండి శిక్షణ ఇవ్వండి.


చిత్రం మెరుగుదల :

గ్రీన్ ఛానల్ ఎక్స్‌ట్రాక్షన్, కాంట్రాస్ట్ లిమిటెడ్ అడాప్టివ్ హిస్టోగ్రామ్ ఈక్వలైజేషన్ (CLAHE) మరియు ఇల్యూమినేషన్ కరెక్షన్ ఉపయోగించి అసలు చిత్రాన్ని మెరుగుపరచారు;

చిత్రం విభజన :

ప్రాంతం యొక్క వడ్డీ (ROI) అటువంటి గా రెటీనా ఫండస్ చిత్రాల నుండి విభజించబడిన రక్త నాళాలు, మాక్యులర్ ప్రాంతం మరియు ఆప్టిక్ నాడి; సాధారణంగా చెప్పాలంటే, రక్తస్రావం రెటీనాలో ఎంత లోతుగా ఉందో బట్టి "చుక్క," "మచ్చ," లేదా "జ్వాల ఆకారంలో" ఉండవచ్చు. మొదటి వైద్యపరంగా గుర్తించదగిన

లక్షణాలు డాక్టర్ సూక్ష్మనాళికలు, ఇవి ఉన్నాయి గోళాకార, స్థానికీకరించిన కేశనాళిక విస్తరణ. వ్యాకోచాలు దృష్టిని దెబ్బతీయవు, కానీ అవి సాధారణంగా ఒంటరిగా లేదా సమూహాలలో చిన్న ఎర్రటి చుక్కలుగా కనిపిస్తాయి. కలిసి, రక్తస్రావం మరియు మైక్రోఅన్యూరిజమ్లను "ఎరుపు గాయాలు" అని పిలుస్తారు. మట్టి రెస్యూ-నెట్



మల్టీ రెస్ యు-నెట్ మోడల్, రెండు కన్వల్యూషనల్ లేయర్ సీక్వెన్స్ కోసం మొదటగా ప్రస్తుతించబడిన సూచించబడిన మల్టీ రెస్ బ్లాక్ను ప్రత్యామ్నాయం చేస్తుంది. మల్టీ రెస్ యొక్క ప్రతి బ్లాక్ కోసం. సాధారణ కన్వల్యూషన్ బ్లాక్ల కంటే ఇందులో ఎక్కువ పారామితులు చేర్చబడ్డాయి. ఇది మూడు కన్వల్యూషన్ లేయర్లు, భారీ కాన్కటనేషన్, ఐడెంటిటీ మ్యాపింగ్ మరియు ఇన్పుట్ను అనుమతించే పార్ట్కల్ కనెక్షన్ ఫీచర్ను కలిగి ఉంది మిగిలిన లక్షణాలను లింక్ చేయండి. మేము ఒక పరామితిని నిర్దేశిస్తాము. ఎన్ని నియంత్రిస్తుంది N ఆ బ్లాక్లోని కన్వల్యూషనల్ పొరలు ఫిల్టర్లను ఉపయోగిస్తాయి. వాటి మధ్య సారూప్య సంబంధాన్ని కాపాడుకోవడానికి మేము α విలువను ఈ క్రింది విధంగా లెక్కిస్తాము అసలు U-Net మరియు సూచించబడిన మోడల్ యొక్క పరామితి లెక్కించబడతాయి:

$$n = \alpha \times F$$

ఇక్కడ, ఎఫ్. ప్రాతినిధ్యం వహిస్తుంది పరిమాణం యొక్క ఫిల్టర్లు లో ది సరిపోలిక డేటాసెట్ తయారీ

డేటాను విభజించడానికి ఇమేజ్ మరియు మాస్క్ ఫైల్లను కలిగి ఉన్న శిక్షణ సెట్తో మనం డేటాసెట్ను నిర్మించాలి. ఫండస్ ఫోటోలు, వీటిని మనం IEEE మరియు వంటి వివిధ వెబ్సైట్ల నుండి పొందవచ్చు. ఈ-ఆప్రా, రెడీ ఉండండి ఉంచబడింది ఇమేజ్ ఫోల్డర్.. ది డేటాసెట్ మేము డౌన్లోడ్ చేయబడింది నుండి [20] ఉంది ఈ ప్రయోగంలో ఉపయోగించబడింది. ఇమేజ్ ఫోల్డర్లో మనం ఉంచే చిత్రాల యొక్క వ్యాఖ్యానాలు లేదా గ్రౌడ్ ట్రూత్ చిత్రాలు మాస్క్ ఫోల్డర్కు జోడించబడతాయి. లో మనం ఇమేజ్ డేటాసెట్ను పొందిన విధంగానే, గ్రౌడ్ ట్రూత్ డేటాను కూడా పొందవచ్చు. పిక్చర్ మరియు మాస్క్ డేటా యొక్క కొలతలు మరియు పొడిగింపులు ఒకే విధంగా ఉండేలా డేటాసెట్ను నిర్వహించడం అవసరం. డేటాసెట్కు.png పొడిగింపు లేకపోతే, మనం దానిని మన ప్రాజెక్ట్లో ఉపయోగించాము కాబట్టి దానిని మార్చాలి.

మూల్యాంకనం మెట్రిక్స్

మా మోడల్ పనితీరును పరిశీలించడానికి అనేక పారామితులు మాకు అనుమతిస్తాయి, కానీ ఈ ప్రక్రియలో సహాయపడే నాలుగు ప్రధానమైనవి iou_score, ఖచ్చితత్వం, సున్నితత్వం మరియు విశిష్టత. ట్రూ పాజిటివ్లు, ట్రూ నెగటివ్లు, ఫాల్స్ పాజిటివ్లు మరియు ఫాల్స్ నెగటివ్లతో పాటు మా మోడల్లో మేము లెక్కించిన iou_score మరియు ఖచ్చితత్వం ఈ పారామితులకు ఆధారం .

$$\text{Sensitivity} = \frac{(\text{నాకు నచ్చినది})}{(\text{నాకు Positives} + \text{False (నాకు నచ్చింది)})}$$

$$\text{Specificity} = \frac{(\text{True Negatives})}{(\text{tives} + (\text{నాకు నచ్చినది}))}$$

4 ఫలితాలు మరియు ముగింపు

మోడల్ [5] లో పనిచేసేది లోతైన నాడీ నెట్వర్క్‌ను కలిగి ఉంది, ఇది కొన్ని లక్షణాలను విస్మరించి పనితీరును ప్రదర్శించడానికి కారణమవుతుంది. అధ్వాన్నంగా ఉంది. దీనికి విరుద్ధంగా, మా నమూనా ఈ సమస్యలను పరిష్కరించడానికి సహాయపడే Res Net ఆర్కిటెక్చర్‌ను ఉపయోగిస్తుంది. [6] లో సూచించిన పనిలోని నమూనా శ్రద్ధ యంత్రాంగం అనే సంక్లిష్టమైన సాంకేతికతను ఉపయోగించింది, అయితే లోతైన అభ్యాసం చాలా సరళమైనది మరియు ఏకైకది మూడు దశలు అవసరం: మొదట, డేటాసెట్‌ను సిద్ధం చేయండి; రెండవది, ముందుగా శిక్షణ పొందిన నెట్వర్క్‌ను ఉపయోగించి మోడల్ కోడ్‌ను వ్రాయండి [23]; మరియు మూడవది, కోడ్‌ను అమలు చేయండి. [7] యొక్క పనిలో మైక్రోఅన్యూరిజమ్‌లను గుర్తించే పద్ధతి డైరెక్షనల్ క్రాస్-సెక్షనల్ విశ్లేషణ, ఇది మరోసారి సంక్లిష్టమైన ప్రక్రియ. [8] లో ఇవ్వబడిన పనిలో సంభావ్య అల్గోరిథం అయిన కింది విధానం, MA మరియు నాన్-MA పిక్సెల్‌ల మధ్య తేడాను చూపుతుంది. దీనికి విరుద్ధంగా, మా మోడల్ చిత్రాలను మరియు గ్రౌండ్ సత్యాన్ని సులభంగా విభజించగలదు మరియు అవసరం లేదు ఏదైనా వర్గీకరణ మధ్య ఎంపి మరియు నాన్-MA పిక్సెల్‌లు. ఒక మోడల్ మే సులభంగా ఉండండి ప్రాథమిక కన్వల్యూషనల్‌తో సృష్టించబడింది మల్టీని ఉపయోగించి బ్లాక్‌లు మరియు పొరలు U-Net ఆర్కిటెక్చర్ పై అప్‌గ్రేడ్ అయిన Res U-Net. ఈ ప్రక్రియలో క్లిష్టమైన అంశం డేటాసెట్‌ను సిద్ధం చేయడం. మన మోడల్‌కు శిక్షణ ఇచ్చినప్పుడు, మనకు ఇవి లభిస్తాయి:

$$మీ_స్కోరు = 1.235, [1].$$

$$ఖచ్చితత్వం = 98.47\%,$$

పట్టిక నేను కలిగి ఉన్నాను ది పోలికలు యొక్క ది నమూనాలు ఏది మేము కలిగి ముందుగా చర్చించబడింది లో విభాగం II . గ్రేడ్.

పట్టిక I . మోడల్ పోలిక

మోడల్	పారామితులు			
	యోగ్యత	ఖచ్చితత్వం	సున్నితత్వం	విశిష్టత
మాది	1.1536	99.27%	93.82%	96.2%
మోడల్ 1.1.	ఉత్తర అమెరికా	ఉత్తర అమెరికా	ఉత్తర అమెరికా	95%
మోడల్ 2	ఉత్తర అమెరికా	ఉత్తర అమెరికా	86.8%	ఉత్తర అమెరికా
మోడల్ 3	ఉత్తర అమెరికా	ఉత్తర అమెరికా	88%	ఉత్తర అమెరికా
మోడల్ 4	ఉత్తర అమెరికా	95%	75%	ఉత్తర అమెరికా
మోడల్ 5	ఉత్తర అమెరికా	90%	90%	91%

నేటి అత్యంత అధునాతన పరిస్థితులలో ఒకటి డయాబెటిక్ రెటినోపతి. డయాబెటిక్ రెటినోపతిని ముందస్తుగా గుర్తించడం వల్ల రోగులు దృష్టి కోల్పోకుండా ఉంటారు. డయాబెటిక్ రెటినోపతికి పూర్వగామి ఉంది సూక్ష్మ నాడి వ్యవస్థ. ది మెరుగుపరచబడింది యు-నెట్ ఆర్కిటెక్చర్ ఉంది ఉద్యోగంలో ఉన్న కు గుర్తించు సూక్ష్మ నాడి వ్యాధులు. ResNet34 ను దాని వెన్నెముకగా ఉపయోగించే నాడి నెట్వర్క్ U-Net, జీవ చిత్రాలను విభజించడానికి ఉపయోగించబడుతుంది. ఈ మోడల్ ResNet34 ఎన్కోడర్లు మరియు డీకోడర్లను ఉపయోగిస్తుంది. U-Net యొక్క మెరుగైన వెర్షన్ అయిన Res Net, స్క్రిప్ కనెక్షన్ల భావనను అందిస్తుంది, ఇది శిక్షణ సమయాన్ని తగ్గిస్తుంది మరియు పనితీరును మెరుగుపరుస్తుంది. ఈ పరిశోధన మా విధానానికి విభిన్న విధానాలను విశ్లేషించే మరియు పోల్చే ఐదు కథనాలను మూల్యాంకనం చేసింది.

మాత్రమే ఈ అధ్యయనం కోసం ఉపయోగించిన ఫండస్ ఫోటోలను తీయడానికి ఒక రకమైన ఫండస్

కెమెరాను ఉపయోగించారు. వివిధ కెమెరాలు కొత్త ఫంక్షన్లను లేదా ఇమేజ్ నమూనాలను ప్రవేశపెట్టవచ్చు. సూచించిన మోడల్ యొక్క సాధారణీకరణ సామర్థ్యాన్ని మెరుగుపరచడానికి భవిష్యత్ పరిశోధనలో వివిధ రకాల ఫండస్ కెమెరాలతో తీసిన మరిన్ని ఫోటోలను చేర్చాలి.

ప్రస్తావనలు

- [1] డయాబెటిక్ రెటినోపతి - గూగుల్ వెతకండి
- [2] బోర్న్ ఆర్ ఆర్, మరియు ఇతరులు. కారణాలు ప్రపంచవ్యాప్తంగా దృష్టి నష్టం, 1990-2010: ఒక క్రమబద్ధమైన విశ్లేషణ. లాన్సెట్ గ్లోబల్ హెల్త్ 2013;1(6):339-49.
- [3] రెటినా సూక్ష్మ రక్తనాళము (రెటినాఅండ్మాకులా.కామ్)
- [4] సూక్ష్మ రక్తనాళము - ఒక అవలోకనం | సైన్స్ డైరెక్ట్ విషయాలు
- [5] హలోయి, ఎం., 2015. డీప్ న్యూరల్ నెట్వర్క్లను ఉపయోగించి మెరుగైన మైక్రోఅన్యూరిజం గుర్తింపు. *arXiv preprint arXiv:1505.04424*.
- [6] జాంగ్ ఎల్, ఫెంగ్ ఎస్, డువాన్ జి, లి వై, లియు జి. ఫండస్ చిత్రాలలో మైక్రోఅన్యూరిజంల గుర్తింపు అటెన్షన్ మెకానిజం ఆధారంగా. *జన్యువులు*. 2019; 10(10):817. <https://doi.org/10.3390/genes10100817>
- [7] జయ శీలన్, CX, 2015. తొలగించబడిన రక్తనాళ విశ్లేషణతో రెటినా ఫండస్ చిత్రాలను ఉపయోగించి మైక్రోఅన్యూరిజంలను ముందస్తుగా గుర్తించడం. *వాల్ట్రామ్*, 4, పేజీలు.1-
10. https://www.ripublication.com/ijpsp/ijpspv4n1_01.pdf
- [8] జావిడి, ఎం., పారైజా, హెచ్ఆర్ మరియు హరతి, ఎ., 2017. వివక్షత నిఘంటువు అభ్యాసం మరియు స్పార్స్ ప్రాతినిధ్యం ఉపయోగించి నాళాల విభజన మరియు మైక్రోఅన్యూరిజం గుర్తింపు. *బయోమెడిసిన్లో కంప్యూటర్ వద్దతులు మరియు కార్యక్రమాలు*, 139, పేజీలు 93-108.
- [9] ఫ్లెమింగ్, AD, ఫిలిప్, S, గోట్మ్యాన్, KA, విలియమ్స్, GJ, ఓల్సన్, JA మరియు ఫార్ప్, PF, 2007. డయాబెటిక్ రెటినోపతి స్క్రీనింగ్ కోసం ఎక్స్టెండ్డ్ ఆటోమేటెడ్ డిటెక్షన్. *ఫిజిక్స్ ఇన్ మెడిసిన్ & బయాలజీ*, 52 (24), పేజీ.7385.
- [10] రోన్నెబెర్గర్, ఓ., ఫిషర్, పి. మరియు బ్రోక్స్, టి., 2015, అక్టోబర్. యు-నెట్: కన్వల్యూషనల్ బయోమెడికల్ ఇమేజ్ సెగ్మెంటేషన్ కోసం నెట్వర్క్లు. *ఇన్ మెడికల్ ఇమేజ్ కంప్యూటింగ్ మరియు కంప్యూటర్-సహాయక జోక్యంపై అంతర్జాతీయ సమావేశం* (పేజీలు 234-241). స్ప్రింగర్, చామ్.
- [11] సిద్ధిక్, ఎన్., సిడికే, పి., ఎల్మిన్, సి. మరియు దేవభక్తుని, వి., 2020. యు-నెట్ మరియు వైద్య చిత్ర విభజన కోసం దాని వైవిధ్యాలు: సిద్ధాంతం మరియు అనువర్తనాలు. *arXiv preprint arXiv:2011.01118*.
- [12] 2018లో IEEE ఇంటర్నేషనల్ W E కాన్ఫరెన్స్ ఆన్ ఎలక్ట్రికల్ అండ్ కంప్యూటర్ ఇంజనీరింగ్ (W E CON-ECE),

- డిసెంబర్ 2018, పేజీలు 106-109, doi : 10.1109/W ECon-ECE .2018.8783182లో, "రెటినల్ బ్లడ్ వెసెల్ సెగ్మెంటేషన్ యూజింగ్ రెసిడ్యువల్ బ్లాక్ ఇన్ఫర్మార్షన్ టెన్సార్ U -నెట్ ఆర్కిటెక్చర్ అండ్ ఫజీ ఇన్ఫెరెన్స్ సిస్టమ్," T. మోస్టాఫిజ్, I . జారిన్, SA ఫట్టా, మరియు C . షహనాజ్.
- [13] MZ అలోమ్, సి. యాకోప్పిక్, TM తహా, మరియు VK అసరి, "న్యూక్లియైలు విభజన తో పునరావృత అవశేష కన్వల్యూషన్ న్యూరల్ నెట్వర్క్లు ఆధారిత U-Net (R2U-Net)," 2018, పేజీలు 228-233.
- [14] K . కవాగో, K . హటానో, S . మురకామి, H . లు, H . కిమ్, మరియు T . అయోకి, "ఆటోమేటిక్ "అవశేష U-Net మరియు M GVF పాముల ఆధారంగా ఫలాంజ్ ప్రాంతాల విభజన పద్ధతి", 2019లో 19వ అంతర్జాతీయ నియంత్రణ, ఆటోమేషన్ మరియు వ్యవస్థలపై సమావేశం (I CCAS), అక్టోబర్ 2019, పేజీలు 1046-1049, doi : 10.23919/I CCAS47443.2019.8971740.
- [15] హెచ్. లి, ఎ. జైగల్లో, మరియు బి. మెన్స్, "డీప్ రెసిడ్యూయల్ డైలేటెడ్ యు-నెట్ ఉపయోగించి ఆటోమేటిక్ బ్రెయిన్ స్ట్రక్చర్ సెగ్మెంటేషన్," 2018, పేజీలు 385-393.
- [16] ఎం. బాల్డియోన్-కాలిస్టో మరియు ఎస్కె లై-యుయెన్, "అడారెస్సు-నెట్: మెడికల్ ఇమేజ్ సెగ్మెంటేషన్ కోసం మల్టీఆబ్జెక్టివ్ అడాప్టివ్ కన్వల్యూషన్ న్యూరల్ నెట్వర్క్," న్యూరోకంప్యూటింగ్, 2019.
- [17] ఎన్. ఇబ్రహీమ్ మరియు ఎంఎస్ రెహమాన్, "మల్టీరిసూనెట్: మల్టీమోడల్ బయోమెడికల్ ఇమేజ్ సెగ్మెంటేషన్ కోసం యు-నెట్ ఆర్కిటెక్చర్ను పునరాలోచించడం," న్యూరల్ నెట్వర్క్స్, వాల్యూమ్. 121, పేజీలు 74-87, 2020
- [18] W. Yu , B . ఫాంగ్, Y . లియు, M. గావో, S . జెంగ్, మరియు Y . వాంగ్, "లివర్ వెస్సెల్స్ సెగ్మెంటేషన్ ఆధారిత 3d అవశేష U-NET," 2019, pp. 250-254.
- [19] హెచ్. లి, డి. చెన్, డబ్ల్యూహెచ్ నైలాన్, ఎంఇ డేవిస్, మరియు డి. లారెన్సన్, "కండిషనల్ రెసిడ్యూయల్ యు-నెట్తో మామోగ్రామ్లలో మెరుగైన బ్రెస్ట్ మాస్ సెగ్మెంటేషన్," ఇమేజ్ అనాలిసిస్ ఫర్ మూవింగ్ ఆర్గాన్, బ్రెస్ట్ మరియు థొరాసిక్ ఇమేజెస్, స్ప్రింగర్, 2018, పేజీలు 81-89.
- [20] <https://ieee-dataport.org/open-access/indian-diabetic-retinopathy-image-dataset-idrid>
- [21] యు-నెట్స్ తో రెస్నెట్ ఎన్కోడర్లు మరియు క్రాస్ కనెక్షన్లు | ద్వారా క్రిస్టోఫర్ థామస్ బి.ఎస్.సి. ఆనర్స్.
M AP | వైపు డేటా సైన్స్
- [22] ఆప్టాలోగ్గోస్కోపీ - వికీపీడియా
ఇబ్రహీమ్, ఎన్. మరియు రెహమాన్, ఎంఎస్, 2020. మల్టీరిసూనెట్: పునరాలోచన ది యు-నెట్ ఆర్కిటెక్చర్ మల్టీమోడల్ కోసం
- [23] బయోమెడికల్ చిత్రం విభజన

Detection of Microaneurysms Using Fundus Images

Divya Padakanti¹, Shanti Sree Piniseti², Rajitha Bantu³, Swapna Padakanti⁴ ^{1,2,3} Assistant Professor, Dept of ECE,

Indur Institute of Engineering and Technology, Siddipet, Telangana, India

⁴Assistant Professor, Dept of CSE,

Ellenki college of Engineering and Technology, patelguda, Telangana, India

Corresponding Author *: divya.padakanti419@gmail.com

Abstract

One of the retinal diseases and the main factor in blindness globally is diabetic retinopathy (DR). The early identification of DR is aided by the discovery of microaneurysms (MA), which is the first clinical sign of DR. Therefore, early detection and treatment can prevent you from losing your vision. In fundus images, little red dots are utilized to indicate MA. However, it can occasionally be challenging to analyze fundus images using human eyesight. A model for deep learning with improved Res U-Net architecture is described in this research in order to develop a model that can identify microaneurysms. Res Net was created to get around the challenges of training the extremely deep neural networks. The neural network design known as the U-net is primarily utilized for image segmentation. Our model was trained using data from E-Ophtha and IDRiD. Deep learning has lately risen to prominence as one of the most effective strategies for improving performance across a variety of industries; include analysis of medical images and categorization. They have uses in things like video and image identification, medical image analysis, image classification, image segmentation. In this study, we looked into and evaluated a number of methods for spotting microaneurysms.

Key words: Microaneurysm, Diabetic retinopathy (DR), Fundus images, Segmentation, Res U-Net, Deep learning

1 Introduction


Diabetic retinopathy, sometimes referred to as diabetic eye disease, is a disorder where diabetes mellitus damages the retina. It is a primary contributor to Patients with diabetes are at

danger. A World Health Organization (WHO) report [13] states that DR is the primary cause of blindness in underdeveloped nations. The risk of visual loss is decreased by early detection and treatment of DR. Analyzing retinal images aids in the detection of retinal conditions such as diabetic retinopathy (DR), which is brought on by elevated blood sugar levels in diabetic individuals. Localized changes in the retina's blood vessel diameter are known as retinal microaneurysms. The typical flow pattern is disrupted by this enlargement. Leakage and retinal edema caused by endothelial dysfunction in these microaneurysms can cause a progressive loss of vision.

The first indication of DR is microaneurysms (MA), which manifest as tiny, circular, red spots on the retina as a result of the vessel walls' weakening. It has sharp borders and is less than 125 μm . As illustrated in Fig. 1, Michael et al. [8] divided MA into six categories. AOSLO reflectance and traditional fluorescent imaging were used to identify the different forms of MA.

Many factors, including low resolution, uneven image elimination, reflection, media obesity, and small size, make it challenging for ophthalmologists to detect microaneurysms. This paper's main objective is to use the Enhanced U-Net architecture to create a deep learning model and train it to recognize microaneurysms. Artificial intelligence (AI) and machine learning techniques known as "deep learning" mimic how people learn specific kinds of information. Deep learning is a key component of data science. In this work, we detect microaneurysms in fundus pictures using a deep learning model for biomedical image segmentation. Inside the eye, the fundus is the rear surface. It consists of the fovea, optic disc, retina, macula, and blood vessels. These images aid in the diagnosis, monitoring, and treatment of eye conditions. Segmentation is a process where we identify or mark down a certain area. In the field of biomedical image segmentation, U-Net is extensively utilized. The primary use of the U-net neural network design is picture segmentation. The morphology of the retinal vessels can be diagnosed at the early screening phase to assess their health. Lesions such microaneurysms, excessive curvature, and vessel narrowing frequently form in the retinal vessels during the early

phases of the disease process.



2 Literature Review

The detection of microaneurysms has been challenging because it requires a skilled ophthalmologist. Numerous solutions have been presented in the past to address these issues. We'll talk about a few of the earlier suggested techniques for detecting microaneurysms in this part.

The work suggested in [5] outlines a deep learning-based computer-aided approach for

microaneurysm detection. Five layers are used to increase the model's accuracy, including dropout training using the maxout activation function and a SoftMax classification layer. With a low false positive rate and state-of-the-art outcomes for MA candidate extraction, this approach has been verified on a few publically accessible datasets and is beneficial for diabetic mass screening.

A focus method for identifying microaneurysms in [6]. In image processing, attention mechanisms are frequently employed, particularly in tasks like object detection, semantic segmentation, and image classification. An attention network was proposed that guarantees that the prediction set would iteratively converge to a suitable object boundary frame, provides a quantitatively weak direction for object search, and increases the accuracy of object recognition. The attention mechanism's drawback is that it increases the model's weights, which slows down the process.

The research presented in [7] found disparities that suggest the use of excised blood vessel analysis for the early diagnosis of microaneurysms. In the process of looking for microaneurysms in fundus images, the best possible option for the green sub-band channel of the retinal fundus image light smoothing by bicubic interpolation blood vessel detection was dissected. A rotating cross-sectional profile inquiry on the pinnacle and the local most extreme pixels fixed on territorial greatest pixels is used to evaluate various qualities. The coefficient of a variety of capacities and the numerical values of the factual parameters mean standard deviation are examined in this study. To assess the microaneurysm competition, the dispersion of mean and standard deviation estimations with the preparation set collected from various datasets is utilized.

In [8], every potential MA candidate is found using a candidate detection technique based on the Morlet wavelet. Learning two discriminative dictionaries that distinguish between MA and non-MA objects is the next step. These dictionaries are then used to categorize the found candidate objects. The evaluations show that the proposed MA detection approach has a greater

average sensitivity of about 2–15 percent when compared to current methods.

The study suggested in [9] combines region growth, watershed, and contrast normalization techniques to provide a novel segmentation method for MA. A 2-D Gaussian was applied after the image had previously been processed using median filtering. Secondly, they applied contrast normalization using the standard deviation of the fundus image, and then they made the candidate region visible and identifiable using the Region Growing model watershed gradient image. They achieved a specificity rate of 84.6 percent by using a K-NN classifier to identify MA in photos.


3 Methodology

The detection of microaneurysms has been challenging because it requires a skilled ophthalmologist. Numerous solutions have been presented in the past to address these issues. We'll talk about a few of the earlier suggested techniques for detecting microaneurysms in this part.

The work that is suggested in [5] explains a For the identification of conditions including hypertension, diabetes and hypertensive retinopathy, and arteriosclerosis, automatic segmentation of retinal pictures is a crucial task in computer-assisted medical image analysis. By identifying retinal vessels, diabetic retinopathy—the primary cause of visual loss—can be identified early among the conditions. With a low false positive rate and state-of-the-art results for MA candidate extraction, this approach has been verified on a few publically accessible datasets and is useful for diabetic mass screening.

In [6], the identification of microaneurysms is dependent on an attention mechanism and the relative spatial distribution of MAs and blood vessels. Our attention module focuses specifically on shallow-layer network properties associated with small target recognition. Attention mechanisms have the drawback of adding extra weights to the model, which slows down the process. This section will provide a detailed description of our suggested segmentation

technique. Using a pretrained network makes the U-net segmentation process comparatively easy



1a) Fundus image




Fig. 1(b)- Ground truth of fundus image

Microaneurysms are shown by the tiny red spots or markings in the retinal picture in Fig. 1(a). Therefore, we have to find and categorize those tiny red dots in segmentation. To train our model, we have a number of retinal images and masks of similar images. Masks are essentially an image that finds and labels those little red dots. Another name for masks is ground truth pictures.

In Fig. 1(b) image we can plainly see that pixels are placed or marked with tiny red dots where microaneurysms are present, thus if we overlay one image with another, we can see that these are the sites where disease is present. We can manually construct these ground truth images using

software or image labelers that are available on the internet.

Flow chart




Image Preprocessing

Conversion Of RGB to

Lab Pre-processing


Fundus images need to be pre-processed before being fed into the network for training because of its drawbacks, which include significant noise, uneven brightness, and poor contrast. The

original fundus image and the manually identified vascular map of the retinal vessels are displayed in Figures 1(A) and 1(B). After being converted to grayscale, the fundus images are standardized. The conversion equation is shown as follows:

$$I_{gray} = 0.299 \times I_r + 0.587 \times I_g + 0.114 \times I_b \quad (1)$$

Among them I_r , I_g and I_b are the RGB channel components of fundus images. As shown in Eq. (1), I_{gray} is the result of processing. It is standardized and the standardization equation.

In all areas of medical imaging, particularly in contemporary ophthalmology, image processing, analysis, and computer vision techniques are steadily expanding. To improve the quality of retinal images, preprocessing steps would be used. Due to its drawbacks, which include significant noise, inconsistent brightness, and poor contrast, fundus images must be pre-processed before being fed into the network for training. During preprocessing, the image's green channel is initially extracted, and its contrast is then improved. Because of the extreme contrast in the green channel, microaneurysms are easily visible. Figure 1 displays the red, green, and blue channels that were recovered from the input image.






Figure1 . Four stages of preprocessing:

(a) original RGB color retinal image

(b) cropped green-channel image

(c) enhanced green-channel image

(d) final image after gamma correction.

Equation (1) computes the brightness conversion from the red (R), green (G), and blue (B) components of the color retinal fundus photograph to produce the grayscale image.


$$\text{Gray Level} = 0.299 * R + 0.587 * G + 0.114 * B$$

In biological image processing, CLAHE is a helpful technique since it effectively increases accessibility to the typically significant prominent portions. On retinal pictures, contrast limited adaptive histogram equalization (CLAHE) was used to improve local contrast and rectify uneven backgrounds in order to extract the optic disk's boundaries. Specifically, CLAHE is utilized to detect hidden characteristics, such as enhancing the contrast of the fundus images concealed blood vessels. The following formula is used to determine the intensity of each pixel:

$$B' = B + \mu_{avgd} - \mu_{avgl}$$

where μ_{avgd} is the desired average intensity, μ_{avgl} is the local average intensity, and B, B' are the starting and most recent pixel size values, respectively. This approach enhances microaneurysms that form at the retina's surface.

Histogram equalization, in which the pictures are equalized on an overall basis, comes after CLAHE. This is done to further intensify the contrast, in addition to CLAHE. Gaussian filtering eliminates the existence of additional sounds. The output of CLAHE, histogram equalized, and Gaussian filtered is displayed in Fig. 5.6. As a result, there is equal illumination and improved contrast in the final preprocessed photos. In order to detect the existence of MAs, a smooth image is obtained by removing the presence of noise



Adaptive histogram equalization:

(a) gray-level fundus image (b) Histogram equalization image


Deep Learning

Exudates have been detected using deep learning techniques, particularly convolutional neural networks (CNNs) and U-net. Since they don't require hand-crafted characteristics, they have been widely embraced in recent years. Convolutional neural networks (CNNs) are a type of artificial neural network that is most frequently used in deep learning for visual vision analysis. In at least one of their layers, CNNs substitute a mathematical process known as convolution for general matrix multiplication. They are employed in image processing and recognition and are

made especially to handle pixel data..

Multilayer perceptrons are regularized into CNNs. Typically, multilayer perceptrons are completely linked networks, meaning that every neuron in one layer is coupled to every other neuron in the layer above. These networks' "full connectivity" makes them vulnerable to overfitting data..

The input, hidden, and output layers make up a convolutional neural network. The hidden layers of a convolutional neural network consist of one or more convolution-performing layers. Usually, a layer that does a dot product of the convolution kernel with the input matrix of the layer is part of this. The activation function of this product, which is often the Frobenius inner product, is ReLU. The following layer's input is a feature map that is produced by the convolution operation as the convolution kernel moves along the layer's input matrix. Other layers, including pooling, fully connected, and normalization layers, come next. Pooling, a type of non-linear down sampling, is another key idea in CNNs. Pooling can be implemented using a variety of non-linear functions, with max pooling being the most popular. The input image is divided into a collection of rectangles, and the maximum is output for each of these sub- regions.




U- Net:

Originating from the classic convolutional neural network, UNet was initially developed and


used in 2015 to handle biomedical picture segmentation through the use of an expanding and contracting path. Compared to fully convolutional networks, U-Net is faster since it just uses the valid portions of each convolution. The primary concept is to add consecutive layers to a typical contracting network, substituting upsampling operators for pooling operations. Thus, these layers raise the output's resolution. Since the job of a typical convolutional neural network is image classification, with an input image and an output label, in biological applications, we must not only determine whether a disease exists, but also pinpoint the location of the abnormality...


It appears to have a "U" form. With two main components, the design is symmetric. The basic convolutional process makes up the left part, known as the contracting path, while transposed 2D convolutional layers make up the right part, known as the expansive path. Furthermore, more accurate segmentation output is produced thanks to the cross-connections between the contracting and expanding paths. A typical convolutional network, the contracting path is made up of repeated convolutions, each followed by a max pooling operation and a rectified linear unit (ReLU). The contraction increases feature information while decreasing spatial information. Using a series of up-convolutions and concatenations using high-resolution features from the contracting path, the expansive pathway integrates the spatial and feature information.



Res U-Net:

Res U-Net stands for Deep Residual U-Net. The encoder-decoder design was created with semantic segmentation in mind. It was applied to a variety of fields, including human picture segmentation, brain tumor segmentation, and remote sensing image analysis. A fully convolutional neural network, Res U-Net is made to achieve great performance with less parameters. Compared to the current UNET architecture, it is better. RESUNET leverages Deep residual Learning and the UNET architecture. Similar to a U-Net, the Res U-Net is made up of an encoding network, a decoding network, and a bridge from one to the other. The U-Net employs two 3 x 3 convolutions, with a ReLU activation function after each. These layers are swapped out for a pre-activated residual block in the Res U-Net scenario.





Encoder

The encoder helps the network learn an abstract representation by passing the input image via various encoder blocks. The pre-activated residual block is used in the construction of the encoder's three encoder blocks. Each encoder block's output serves as the matching decoder block's skip connection. In the second and third encoder blocks, the initial 3×3 convolution layer has a stride of 2 to decrease the spatial dimensions (height and width) of the feature maps. When the stride value is 2, the spatial dimensions are cut in half, from 256 to 128.

Bridge

A pre-activated residual block with a stride value of two is also a part of the bridge.

Decoder

The decoder learns a better semantic representation by using the skip connections from a different encoder block and the feature map from the bridge to create a segmentation mask. Three decoder blocks make up the decoder; following each block, the number of feature channels is decreased and the spatial dimensions of the feature map are doubled.

U-Net is committed to finding a solution. Because it classifies each pixel, the input and output have the same size, which allows it to locate and differentiate borders. For instance, with a 2×2 input image, In this study, end-to-end segmentation is implemented using the U-Net backbone, which significantly reduces time consumption and improves performance. Additionally, super pixel is used to extract data samples, overcoming the challenges of imbalanced and tiny datasets

Pre-trained model:

High-performance models were chosen to classify the processed and segmented retinal fundus


images; • Create a new CNN model and train it from scratch using processed and segmented retinal fundus images

Image enhancement:

The original image was improved using green channel extraction, contrast limited adaptive histogram equalization (CLAHE), and illumination correction;

Image segmentation:

Region of Interest (ROI) such as blood vessels, macular region, and optic nerve segmented from retinal fundus images; Generally speaking, hemorrhages might be "dot," "blot," or "flame-shaped," depending on how deep they are in the retina. The first clinically noticeable symptoms of DR are microaneurysms, which are spherical, localized capillary dilatation. The dilations don't impair vision, but they typically show up as little red dots either alone or in clusters. Together, hemorrhages and microaneurysms are referred to as "red lesions." Multi ResU-Net



The Multi Res U-Net model substitutes the suggested Multi Res block, which was first presented in, for the two convolutional layer sequence. For every block of Multi Res. More parameters are included in it than in simple convolution blocks. It has three convolution layers, heavy concatenation, identity mapping, and a shortcut connection feature that allows input to link the remaining features. We designate a parameter N that regulates how many filters are used by the convolutional layers within that block. We calculate the value of N as follows in order to preserve a similar relationship between the original U-Net's and the suggested model's parameter counts:

$$N = \alpha \times F$$

Here, F represents the quantity of filters in the matching

Dataset Preparation

We must build a dataset with a training set that includes the Image and Mask files in order to segment the data. The fundus photos, which we can obtain from a variety of websites like IEEE and E-Opha, will be placed in the image folder.. The dataset we downloaded from [20] was used in this experiment. Annotations or ground truth images of the images we place in the image folders will be added to the mask folder. In the same manner as we obtain the image dataset, we can also obtain ground truth data. It is necessary to organize the dataset so that the dimensions and extensions of the picture and mask data are the same. If the dataset does not have a.png extension, we must convert it because we used it in our project.

Evaluation Metrix

Numerous parameters allow us to examine our model's performance, but the four main ones that aid in this process are iou_score, accuracy, sensitivity, and specificity. True Positives, True Negatives, False Positives, and False Negatives along with iou _score and accuracy that we computed in our model form the basis for these parameters.

$$\text{Sensitivity} = \frac{(\text{True Positives})}{(\text{True Positives} + \text{False Negatives})}$$

$$\text{Specificity} = \frac{(\text{True Negatives})}{(\text{True Negatives} + \text{False Positives})}$$

4 Results and Conclusion

The model employed in [5] had a deeper neural network, which could cause it to overlook some features and perform worse. In contrast, our model uses the Res Net architecture, which helps to solve these issues. The model in the work suggested in [6] used a complex technique called the attention mechanism, whereas deep learning is much simpler and only requires three steps: first, prepare the dataset; second, write the model's code using a pre-trained network [23]; and third, implement the code. The method for detecting microaneurysms in the work of [7] is directional cross-sectional analysis, which is once more a complex procedure. The following approach, which is a potential algorithm in the work given in [8], distinguishes between MA and non-MA pixels. In contrast, our model can segment images and ground truth with ease and does not require any categorization between MA and non-MA pixels. A model may be easily created with basic convolutional blocks and layers utilizing Multi Res U- Net, which is an upgrade over U-Net architecture. The only difficult aspect of the procedure is preparing the dataset. When we train our model, we obtain:

iou_score = 1.235,

Accuracy = 98.47% ,

Table I contains the comparisons of the models which we have earlier discussed in section II.

TABLE I. MODEL COMPARISION

Model	Parameters			
	$Iou_{\overline{r}}$ <i>sco</i> <i>e</i>	Accuracy	Sensitiv <i>ity</i>	Specifci <i>ty</i>
Ours	1.1536	99.27%	93.82%	96.2%
Model 1	NA	NA	NA	95%
Model 2	NA	NA	86.8%	NA
Model 3	NA	NA	88%	NA
Model 4	NA	95%	75%	NA
Model 5	NA	90%	90%	91%

One of the most advanced conditions nowadays is diabetic retinopathy. Early identification of diabetic retinopathy helps patients avoid losing their vision. A precursor to diabetic retinopathy is microaneurysms. The Enhanced U-Net architecture was employed to identify microaneurysms. The neural network U-Net, which uses ResNet34 as its backbone, is used to segment biological pictures. The model makes use of ResNet34 encoders and decoders. Res Net, an improved version of U-Net, offers the concept of skip connections, which shortens training time and improves performance. This research has evaluated five articles that analyze and compare different approaches to our approach.

Only one kind of fundus camera was used to take the fundus photos used for this study. Various cameras may introduce new functions or image patterns. Future research should include more photos taken with different kinds of fundus cameras in order to improve the suggested model's capacity for generalization.

References

- [1] diabetic retinopathy - Google Search
- [2] Bourne RR, et al. Causes of vision loss worldwide, 1990-2010: a systematic analysis. *Lancet Global Health* 2013;1(6):339–49.
- [3] Retinal Microaneurysm (retinaandmacula.com)
- [4] Microaneurysm - an overview | ScienceDirect Topics
- [5] Haloi, M., 2015. Improved microaneurysm detection using deep neural networks. *arXiv preprint arXiv:1505.04424*.
- [6] Zhang L, Feng S, Duan G, Li Y, Liu G. Detection of Microaneurysms in Fundus Images Based on an Attention Mechanism. *Genes*. 2019; 10(10):817. <https://doi.org/10.3390/genes10100817>
- [7] Jayaseelan, C.X., 2015. Early Detection of Microaneurysms Using Retinal Fundus Images With Removed Blood Vessel Analysis. *vol, 4*, pp.1-10. https://www.ripublication.com/ijpsp/ijpspv4n1_01.pdf
- [8] Javidi, M., Pourreza, H.R. and Harati, A., 2017. Vessel segmentation and microaneurysm detection using discriminative dictionary learning and sparse representation. *Computer methods and programs in biomedicine*, 139, pp.93-108.
- [9] Fleming, A.D., Philip, S., Goatman, K.A., Williams, G.J., Olson, J.A. and Sharp, P.F., 2007. Automated detection of exudates for diabetic retinopathy screening. *Physics in Medicine & Biology*, 52(24), p.7385.
- [10] Ronneberger, O., Fischer, P. and Brox, T., 2015, October. U-net: Convolutional networks for biomedical image segmentation. In *International Conference on Medical image computing and computer-assisted intervention* (pp. 234-241). Springer, Cham.
- [11] Siddique, N., Sidike, P., Elkin, C. and Devabhaktuni, V., 2020. U-Net and its variants for medical image segmentation: theory and applications. *arXiv preprint arXiv:2011.01118*.
- [12] T. Mostafiz, I. Jarin, S. A. Fattah, and C. Shahnaz, “Retinal Blood Vessel Segmentation Using Residual Block Incorporated U-Net Architecture and Fuzzy Inference System,” in 2018 IEEE International WIE Conference on Electrical and Computer Engineering (WIECON-ECE), Dec. 2018, pp. 106–109, doi: 10.1109/WIECON-ECE.2018.8783182.
- [13] M. Z. Alom, C. Yakopcic, T. M. Taha, and V. K. Asari, “Nuclei segmentation with recurrent residual convolutional neural networks based U-Net (R2U-Net),” 2018, pp. 228–233.
- [14] K. Kawagoe, K. Hatano, S. Murakami, H. Lu, H. Kim, and T. Aoki, “Automatic Segmentation Method of Phalange Regions Based on Residual U-Net and MSGVF Snakes,” in 2019 19th International Conference on Control, Automation and Systems (ICCAS), Oct. 2019, pp. 1046–1049, doi: 10.23919/ICCAS47443.2019.8971740.
- [15] H. Li, A. Zhygallo, and B. Menze, “Automatic brain structures segmentation using deep residual dilated U-net,” 2018, pp. 385–393.
- [16] JM. Baldeon-Calisto and S. K. Lai-Yuen, “AdaResU-Net: Multiobjective adaptive convolutional neural network for medical image segmentation,” *Neurocomputing*, 2019.

-
- [17] N. Ibtehaz and M. S. Rahman, "MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation," *Neural Netw.*, vol. 121, pp. 74–87, 2020
- [18] W. Yu, B. Fang, Y. Liu, M. Gao, S. Zheng, and Y. Wang, "Liver Vessels Segmentation Based on 3d Residual U-NET," 2019, pp. 250–254.
- [19] H. Li, D. Chen, W. H. Nailon, M. E. Davies, and D. Laurenson, "Improved breast mass segmentation in mammograms with conditional residual u-net," in *Image Analysis for Moving Organ, Breast, and Thoracic Images*, Springer, 2018, pp. 81–89.
- [20] <https://iee-dataport.org/open-access/indian-diabetic-retinopathy-image-dataset-idrid>
- [21] U-Nets with ResNet Encoders and cross connections | by Christopher Thomas BSc Hons. MIAP | Towards Data Science
- [22] Ophthalmoscopy - Wikipedia
- Ibtehaz, N. and Rahman, M.S., 2020. MultiResUNet: Rethinking the U-Net architecture for multimodal
- [23] Biomedical image segmentation. *Neural networks*, 121, pp.74-87.