LIETUVOS SVEIKATOS MOKSLŲ UNIVERSITETAS MEDICINOS AKADEMIJA

Diana Mačianskytė

## DI PAGRĮSTA INFRARAUDONŲJŲ SPINDULIŲ TERMOGRAFIJA BURNOS, VEIDO IR ŽANDIKAULIŲ SRITIES PATOLOGIJOMS APTIKTI

Daktaro disertacija Medicinos ir sveikatos mokslai, medicina (M 001)

Kaunas, 2025

Disertacija rengta 2013–2025 metais Lietuvos sveikatos mokslų universiteto Medicinos akademijos Medicinos fakulteto Radiologijos klinikoje.

## **Mokslinis vadovas**

prof. dr. Algidas Basevičius (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001).

## Mokslinis konsultantas

prof. dr. Rimas Adaškevičius (Kauno technologijos universitetas, technologijos mokslai, elektros ir elektronikos inžinerija – T 001).

# Disertacija ginama Lietuvos sveikatos mokslų universiteto Medicinos mokslo krypties taryboje:

## Pirmininkas

prof. dr. Evaldas Padervinskis (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001).

## Nariai:

prof. dr. Rymantė Gleiznienė (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001);

dr. Kristina Valatkevičienė (Lietuvos sveikatos mokslų universitetas, medicinos ir sveikatos mokslai, medicina – M 001);

prof. dr. Saulius Šatkauskas (Vytauto Didžiojo universitetas, gamtos mokslai, biologija – N 010);

prof. dr. Aivaras Ratkevičius (Londono Queen Mary universitetas, gamtos mokslai, biologija – N 010).

Disertacija ginama viešame Medicinos mokslo krypties tarybos posėdyje 2025 m. rugsėjo 5 d. 13.00 val. Lietuvos sveikatos mokslų universiteto prof. Vl. Lašo auditorijoje.

Disertacijos gynimo vietos adresas: A. Mickevičiaus g. 9, LT-44307 Kaunas, Lietuva.

LITHUANIAN UNIVERSITY OF HEALTH SCIENCES MEDICAL ACADEMY

Diana Mačianskytė

## AI-BASED INFRARED THERMOGRAPHY FOR DETECTING ORAL AND MAXILLOFACIAL PATHOLOGIES

Doctoral Dissertation Medical and Health Sciences, Medicine (M 001)

Kaunas, 2025

Dissertation has been prepared at the Department of Radiology of the Faculty of Medicine of the Medical Academy of the Lithuanian University of Health Sciences during the period of 2013–2025 year.

## **Scientific Supervisor:**

Prof. Dr. Algidas Basevičius (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001).

## **Scientific Consultant**

Prof. Dr. Rimas Adaškevičius (Kaunas University of Technology, Technological Sciences, Electrical and Electronic Engineering – T 001).

# The dissertation is defended at the Medical Research Council of the Lithuanian University of Health Sciences:

## Chairperson

Prof. Dr. Evaldas Padervinskis (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001).

## Members:

Prof. Dr. Rymantė Gleiznienė (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001);
Dr. Kristina Valatkevičienė (Lithuanian University of Health Sciences, Medical and Health Sciences, Medicine – M 001);
Prof. Dr. Saulius Šatkauskas (Vytautas Magnus University, Natural Sciences, Biology – N 010);
Prof. Dr. Aivaras Ratkevičius (Queen Mary University of London, Natural Sciences, Biology – N 010).

Dissertation will be defended at the open session of the Medical Research Council of the Lithuanian University of Health Sciences on the 5<sup>th</sup> of September 2025 at 1 p.m., in the Prof. VI. Lašas Auditorium of the Medical Academy of the Lithuanian University of Health Sciences.

Address: A. Mickevičiaus 9, LT-44307 Kaunas, Lithuania.

SA	NTRU	JMPOS	7	
ĮVA	DAS		8	
DA	RBO	TIKSLAS IR UŽDAVINIAI	10	
	Darb Darb Darb	o uždaviniai o naujumas ir mokslinis aktualumas o praktinė reikšmė	10 10 12	
1.	LITERATŪROS APŽVALGA			
	1.1. 1.2. 1.3. 1.4. 1.5. 1.6. 1.7.	Burnos, veido ir žandikaulių (BVŽ) patologijos Radiologiniai diagnostikos metodai Infraraudonųjų spindulių termografija (IRST) IRST taikymas medicinoje Dirbtinis intelektas ir mašininis mokymas Mašininio mokymosi atlikimo protokolas <i>k</i> NN klasterizacijos algoritmo taikymas medicininėje	13 14 17 20 23 30	
	18	diagnostikoje Literatūros apžvalgos santrauka	31	
2				
2.	2.1. 2.2. 2.3. 2.4. 2.5	Termografinio vaizdo BVŽ srityje registravimo protokolas Radiologinis BVŽ srities ištyrimas Tiriamųjų tinkamumo IRST tyrimui atrankos kriterijai BVŽ termografinio vaizdo (TV) vizualinė analizė ir segmentavimas TV veido ir burnos ertmės kontūru ir simetrijos ašies	38 41 42 43	
		aptikimas	45 45 46	
	2.6. 2.7.	Veido ir burnos ertmės dominančios srities (ROI) temperatūrinės asimetrijos aptikimas <i>k</i> NN klasterizavimo algoritmo taikymas BVŽ patologijoms		
		aptikti	52	
		<ul> <li>2.7.1. DI metodų taikymo poreikis</li></ul>	52 53 54 55	
		2.1.3. Stausune analize		

## TURINYS

3.	REZULTATAI				
	3.1.	Demografiniai, antropometriniai ir klinikiniai tiriamųjų			
		duomenys	59		
	3.2.	Temperatūrinės asimetrijos nustatymas IRST tyrimais	60		
		<ul> <li>3.2.1. Sveikų tiriamųjų TV vertinimas</li></ul>	. 60 . 64 . 70 . 72 . 73		
	3.3.	Termovaizdų klasterizavimas naudojant DI	83		
	3.4.	kNN metodo patikimumo BVŽ srities diagnostikoje			
		vertinimas	85		
4.	REZU	ULTATŲ APTARIMAS	88		
IŠVADOS					
SUMMARY					
LITERATŪROS SĄRAŠAS143					
MOKSLINĖS PUBLIKACIJOS152					
MOKSLINIŲ PUBLIKACIJŲ KOPIJOS154					
PRIEDAI182					
CURRICULUM VITAE					
PADĖKA192					

## **SANTRUMPOS**

BVŽ	_	burnos, veido ir žandikaulių
DI	_	dirbtinis intelektas (angl. Artificial Intelligence, AI)
GM	_	gilusis mokymasis (angl. Deep Learning, DL)
IRST	_	infraraudonųjų spindulių termografija (angl. Infrared Thermography, IRT)
kN	_	klaidingai neigiamas (angl. Falce Negative, FN)
<i>k</i> NN	_	k-artimiausias kaimynas (angl. k-Nearest Neighbor, kNN)
kТ	_	klaidingai teigiamas (angl. Falce Positive, FP)
KT	_	kompiuterinė tomografija
MM	_	mašininis mokymas (angl. Machine Learning, ML)
MRT	_	magnetinio rezonanso tomografija
nb	_	pikselių skaičius dešinės (kairės) burnos pusės TV, kurių temperatūra yra
		0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje veido pusėje
nv	_	pikselių skaičius dešinės (kairės) veido pusės TV, kurių temperatūra yra
		0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje veido pusėje
NP	_	tiriamieji su navikinės kilmės patologija
NT	_	neuroniniai tinklai (angl. Neural Networks, NN)
PET	_	pozitronų emisijos tomografija (angl. Positron Emission Tomography)
ROC	_	imties veikimo charakteristikos (angl. Receiver Operating Characteristic,
		ROC)
ROI	_	aktuali (dominanti) BVŽ sritis (angl. Region of Interest, ROI)
SCC	_	plokščiųjų ląstelių karcinoma (angl. Squamous Cell Carcinoma, SCC)
SS	_	sveiki savanoriai
ST	_	sveiki tiriamieji
SVM	_	atraminių vektorių mašina (angl. Support Vector Machine, SVM)
TmaksD	_	maksimali temperatūra dešinėje
<b>T</b> vidD	_	vidutinė temperatūra dešinėje
TmaksK	_	maksimali temperatūra kairėje
TvidK	_	vidutinė temperatūra kairėje
tN	_	teisingai neigiamas (angl. True Negative, TN)
tΤ	_	teisingai teigiamas (angl. True Positive, TP)
TV	—	termografinis vaizdas (termovaizdas)
UP	—	tiriamieji su uždegiminės kilmės patologija
°C	_	Celsijaus laipsnis
٥F	—	Farenheito laipsnis
$\Delta DEV_b$	_	absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių,
		priklausančių dešiniąjai ir kairiąjai burnos ertmės pusei.
$\Delta DEV_{v}$	_	absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių,
		priklausančių dešiniąjai ir kairiąjai veido pusei.
$\Delta T$	_	temperatūros skirtumas tarp kairės / dešinės pusių
$\Delta \pmb{T}$ b.maks	-	burnos maksimalių temperatūrų skirtumas (kairės / dešinės pusių)
$\Delta T$ b.vid	-	burnos vidutinių temperatūrų skirtumas (kairės / dešinės pusių)
$\Delta T_{v.maks}$	_	veido maksimalių temperatūrų skirtumas (kairės / dešinės pusių)
$\Delta T$ v.vid	_	veido vidutinių temperatūrų skirtumas (kairės / dešinės pusių)

## ĮVADAS

Burnos, veido ir žandikaulių (BVŽ) srities patologijos, įskaitant navikus, infekcijas, uždegiminius procesus ir kraujagyslių anomalijas, kelia didelius diagnostinius iššūkius dėl jų skirtingos etiologijos, sudėtingos klinikinės eigos ir dažnai nespecifinių simptomų [1, 2]. Siekiant užtikrinti ankstyvą patologijų aptikimą, diferencinę diagnostiką ir optimalų gydymo planavimą, būtina taikyti pažangias diagnostines priemones, kurios leidžia tiksliai įvertinti minkštųjų ir kaulinio audinių pakitimus, įvertinti patologinių procesų išplitimą, bei stebėti jų dinamiką [3]. Nors radiologiniai tyrimai, tokie kaip kompiuterinė tomografija (KT) ar magnetinio rezonanso tomografija (MRT), laikomi auksiniu standartu, tačiau jų taikymas dėl didelių sąnaudų, apšvitos ar kontrastinių medžiagų naudojimo nėra tinkamiausi profilaktinėms patikroms ar dažnam paciento būklės stebėjimui.

Alternatyvūs neinvaziniai metodai, tokie kaip infraraudonujų spindulių termografija (IRST), pastaraisiais metais sulaukia vis daugiau dėmesio dėl gebėjimo registruoti fiziologinius temperatūrų pokyčius, susijusius su suaktyvėjusia kraujotaka, audinių uždegiminės ar navikinės kilmės patologijomis [4]. IRST registruojama odos paviršiaus temperatūra gali atspindėti giliau lokalizuotus procesus, tokius kaip angiogenezė ar metabolinės veiklos pokyčiai. Esant tokiems pažeidimams, pažeistose vietose išsiskiria daugiau šilumos nei aplinkiniuose sveikuose audiniuose, nes augantiems navikams reikalingas intensyvus maistiniu medžiagu tiekimas, o piktybiniai procesai skatina nauju kraujagysliu tinklu susidaryma (angiogeneze) ir daro itaka pagrindinėms kraujagyslėms per angiogeninius augimo faktorius [5]. Būtent šis šilumos nuokrypis sudaro pagrinda IRST metodo taikymui klinikinėje praktikoje. Skirtingai nei KT, kuri pateikia detalu anatominių struktūrų vaizda, IRST suteikia informaciją apie funkcinius pokyčius, susijusius su pakitusia temperatūra, kuri gali pasireikšti dar prieš atsirandant matomiems audinių pakitimams. Navikinės patologijos atveju dėl angiogenezės susiformuoja aukštesnės temperatūros zonos, taip sąlygodamos aktyvesnį šilumos išskyrimą. Priešingai, išemijos ar naviko nekrozės atvejais dėl sumažėjusio kraujo pritekėjimo gali atsirasti vėsesnės zonos, kurios nulemia žemesnę temperatūrą paveiktoje srityje [6].

Nors IRST turi daug privalumų, tačiau yra ir apribojimų, kaip žemesnė erdvinė raiška, jautrumas išoriniams veiksniams ir individualių šiluminių savybių kintamumas. IRST negali pakeisti KT / MRT tyrimų, nes nesuteikia išsamios anatominės informacijos, bet gali būti naudojama, kaip pirminė neinvazyvi atrankos priemonė, leidžianti sumažinti nereikalingų KT / MRT

tyrimų skaičių arba, kai įtariami patologiniai pokyčiai, laiku nukreipti pacientą išsamesniam ištyrimui.

BVŽ srities diagnostikoje yra svarbus ne tik tikslus patologinės vietos nustatymas, bet ir savalaikis besiformuojančios patologijos prognozavimas [7, 8]. Tai gali būti atliekama pasitelkiant dirbtinio intelekto (DI) įrankius. Manoma, kad tokia diagnostinė strategija, integruojant mašininio mokymosi (MM) technologijas klinikinių sprendimų priėmimui, ateityje gali tapti viena svarbiausių inovacijų diagnostikoje [9–13].

Disertacinio darbo pirmame etape siekėme pritaikyti naujus IRST technologinius sprendimus BVŽ srities patologijos nustatymui. Kadangi BVŽ srities patologijos geriausiai ištirtos radiologiniais tyrimais, IRST tyrimų rezultatus, gautus analizuojant pacientų termografinius vaizdus (TV), validavome KT / MRT tyrimų rezultatais. Identifikavome pacientų BVŽ srities TV temperatūrinės asimetrijos zonas, kurios atitiko KT / MRT tyrime nustatytas naviko lokalizacijas [14]. Literatūros šaltiniuose, esant patologijai, atrankos kriterijumi pasirinkta temperatūros asimetrija didesnė nei 0,4 °C [15], tačiau nėra BVŽ srities tyrimų, kuriuose IRST aptiktos patologijos būtų patvirtintos radiologinių tyrimų duomenimis [4, 16].

Visgi svarbu patologija aptikti greitai ir ankstyvoje stadijoje. Antrame etape, darydami prielaida, kad DI irankiai gali padėti anksčiau aptikti nedideles  $\Delta T$  asimetrijas BVŽ srities TV, siekėme atrinkti su patologija susijusius požymiu vektorius ir juos panaudoti, kaip ivesties duomenis MM kNN (angl. k-Nearest Neighbor) klasterizatoriui [17]. Pastarasis, remiantis radiologiniu tyrimų rezultatais, buvo apmokytas atpažinti atrinktus požymius ir priimti tinkamą klasterizavimo sprendimą: yra / nėra patologijos. Tyrimo rezultatai parodė, kad MM kNN klasterizatorius, analizuodamas specialiai atrinktus aštuonis temperatūrinius požymius, gali patikimai atskirti patologinius ir sveikus pacientų BVŽ srities termovaizdus [18]. Tačiau šio metodo sėkmingam taikymui reikalingas tikslinis požymių atrinkimas ir optimalios k reikšmės nustatymas. Nepaisant šių iššūkių, šiame tyrime optimizuoto kNN taikymas IRST gali tapti greitu, neinvaziniu, ekonomišku ir lengvai prieinamu būdu anksti aptikti navikus. Ateityje, tyrimai turėtų būti sutelkti į MM modelių tobulinimą, gautus rezultatus patvirtinant radiologiniais tyrimais. Tai padėtu didinti šios technologijos tiksluma, patikimuma ir pritaikomuma BVŽ patologijų diagnostikoje.

## DARBO TIKSLAS IR UŽDAVINIAI

## Darbo tikslas

Įvertinti infraraudonųjų spindulių termografijos (IRST) ir dirbtinio intelekto (DI) taikymo galimybes, siekiant aptikti patologines būkles (navikinės ir uždegiminės kilmės) burnos, veido ir žandikaulių (BVŽ) srityje ir rezultatus palyginti su radiologinių tyrimų duomenimis.

## Darbo uždaviniai

- 1. Aptikti temperatūrinę asimetriją BVŽ srityje pagal IRST duomenis ir palyginti rezultatus su KT / MRT tyrimų duomenimis.
- 2. Pritaikyti termografinių vaizdų (TV) segmentavimą patologinių sričių nustatymui ir įvertinti jo diagnostinį tikslingumą.
- 3. Atrinkti su patologija susijusius temperatūrinius požymius ir panaudoti juos mašininio mokymosi *k*NN algoritmo apmokymui TV klasterizavimui į sveikus ir patologinius atvejus.
- 4. Įvertinti optimizuoto *k*NN klasterizavimo modelio patikimumą ankstyvai BVŽ srities patologijų diagnostikai, remiantis KT / MRT tyrimų duomenimis.

## Darbo naujumas ir mokslinis aktualumas

Pacientų, turinčių BVŽ srities patologijas, ankstyva diagnostika ir gydymo taktika dažnai yra sudėtinga [1, 2].

Disertaciniame darbe pirmą kartą integruojama IRST ir DI technologijų taikymo schema BVŽ srities patologinių (navikinės ir uždegiminės kilmės) būklių atpažinimui iš termografinių vaizdų, taikant objektyviais temperatūriniais požymiais paremtą analizę. Sukurtas optimizuotas kNN klasterizavimo algoritmas, apmokytas pagal atrinktus temperatūrinius požymius. Svarbu tai, kad diagnostinio metodo validavimui pirmą kartą panaudoti objektyvūs radiologiniai KT ir MRT tyrimų duomenys, užtikrinant ne subjektyvią, o vaizdiniais tyrimais pagrįstą rezultatų vertinimo sistemą [14, 18].

Literatūros analizės metu neaptikta analogiškų tyrimų BVŽ srityje, kuriuose būtų taikytas toks kompleksinis metodinis derinys, optimizuoto DI algoritmo integracija su IRST ir klinikinių atvejų patvirtinimas objektyviais vaizdiniais metodais. Iki šiol publikuotuose darbuose dažnai akcentuojama temperatūros asimetrijos svarba patologijų atpažinimui, o termogramos interpretuojamos klinikinių simptomų pagrindu, be objektyvaus vaizdinio patvirtinimo [16]. Nors DI modeliai dažnai naudoja daugybę požymių, publikuotuose darbuose pasigendama optimizuoto požymių rinkinio įtraukimo ir rezultatų patikros naudojant objektyvius KT / MRT tyrimų duomenis [4].

Atlikti tyrimai atskleidė, kad IRST metodas, taikant temperatūrinės asimetrijos analizę tarp simetrinių paciento veido ir burnos ertmės kairės / dešinės pusių, parodė panašų patologinių židinių (navikinės / uždegiminės kilmės) aptikimo tikslumą, kaip standartizuoti radiologinės diagnostikos KT / MRT metodai. Tai patvirtina IRST potencialą aptikti patologines vietas, matomas TV, kaip aukštesnės temperatūros sritis, todėl galėtų būti taikomas BVŽ srities patologijoms aptikti.

Disertaciniame darbe atlikti tyrimai taip pat atskleidė, kad siekiant surasti asimetrinės temperatūros pokyčius simetrinėse BVŽ srities dalyse, tikslinga naudoti vaizdo apdorojimo algoritmą, tiksliam dominančios tyrimo srities (angl. *Region of Interest, ROI*) aptikimui [14]. Nustatėme, kad didelius ir paviršiuje lokalizuotus BVŽ srities navikus galima lengvai aptikti be papildomo vaizdo apdorojimo (segmentacijos). Tačiau mažų, giliai ar abipus lokalizuotų navikų atveju būtina atlikti ROI segmentaciją patologinės vietos išryškinimui, nes temperatūrinė asimetrija gali būti neryški. Literatūros šaltiniuose IRST technologijos taikytos tik veido, bet ne burnos ertmės tyrimams [4, 19, 20]. Šiame darbe pirmą kartą parodyta, kad burnos ertmės ROI segmentavimas yra informatyvesnis nei veido ROI, nes burnos srityje šilumos pasiskirstymą lemia plonesni audiniai ir gleivinė, todėl temperatūriniai pokyčiai fiksuojami jautriau.

Atrinkti specifiniai aštuoni požymių vektoriai, apibūdinantys temperatūrines charakteristikas [18], buvo panaudoti MM kNN klasterizatoriaus apmokinimui ir testavimui [18]. Apmokytas optimizuotas kNN algoritmas, vertinantis ne pagal vieną požymį, o kompleksiškai, gebėjo sėkmingai atlikti įvesties požymių vektorių priskyrimą skirtingoms grupėms, atitinkamai yra / nėra patologija. Išskirti trys statistiškai reikšmingi požymiai, kurie labiausiai diferencijuoja tarp grupių ir turi potencialą būti taikomi, kaip šiluminiai biomarkeriai, papildantys kNN klasterizavimo rezultatus ir stiprinantys ankstyvos diagnostikos galimybes BVŽ srityje.

Taip pat pademonstruota, kad *k*NN binarinio klasterizavimo (sveiki / patologiniai atvejai) patikimumas, pagrįstas apskaičiuotomis tikslumo, jautrumo ir specifiškumo reikšmėmis, buvo geras, vertinant, kaip algoritmas geba atpažinti pacientų TV su navikine patologija (atitinkamai 94,1 proc., 77,9 proc. ir 94,9 proc., n = 46) [18] ar visus patologinius atvejus (naviko / uždegiminės kilmės, atitinkamai 90,63 proc., 98,25 proc. ir 92,31 proc., n = 94). Optimizuotas *k*NN binarinio klasterizavimo modelis patikimai atpažino TV ir tiksliai suskirstė pacientus į sveikų ir patologinių atvejų grupes, pasiekdamas aukštą tikslumą, jautrumą ir specifiškumą, bei AUC reikšmę ~0,9.

Atliktas pilotinis tyrimas užpildo esamas spragas – pateiktas optimizuotas algoritmas ne tik remiasi patikimais termografiniais požymiais, bet ir objektyviai patvirtintas KT/MRT tyrimų duomenimis. Tai rodo klinikinį patikimumą ir ateityje gali tapti perspektyviu papildomu neinvaziniu diagnostikos įrankiu.

## Darbo praktinė reikšmė

Šiuo metu BVŽ srities navikų aptikimui ir diagnozės patvirtinimui "auksiniu standartu" laikomi KT tyrimas ir histologinė verifikacija. Tačiau, šie metodai nėra visiškai saugūs pacientui ir dažnai taikomi tik pažengusiose ligos stadijose, kai jau yra aiškiai matomi anatominiai pakitimai. Dėl šios priežasties, siekiant ankstyvosios navikinio proceso diagnostikos, būtų tikslinga naudoti IRST, kuria fiksuojami temperatūriniai pokyčiai audiniuose gali padėti aptikti patologinius procesus dar prieš atsirandant klinikiniams simptomams. Kadangi BVŽ navikai dėl suaktyvėjusios kraujotakos paveiktoje srityje išskiria daugiau šilumos nei sveiki aplinkiniai audiniai, IRST leidžia užfiksuoti ir išmatuoti šiuos temperatūrinius pokyčius, suteikdama papildomą diagnostinę informaciją.

Šio tyrimo metu pritaikytas IRST vaizdų apdorojimo optimizuotas algoritmas leidžia BVŽ srityje aptikti vietas, kuriose pasireiškia asimetriniai temperatūros pokyčiai. Siekiant įvertinti IRST taikymą klinikinėje praktikoje, BVŽ srities patologijų diagnostikoje, būtina atlikti TV duomenų patikrinimą, lyginant juos su KT / MRT rezultatais.

Disertacinio darbo rezultatai leidžia pagrįstai teigti, kad toks metodas galėtų būti naudojamas, kaip papildoma neinvazinė priemonė klinikinėje praktikoje, ypač pradiniam patologijos išskyrimui ir pacientų srautų pirminiam rūšiavimui. Siekiant padidinti IRST diagnostinį tikslumą, būtina DI metodų integracija, kuri leistų automatizuotai atpažinti pažeidimus ir pateiktų automatinį vertinimą, siekiant užtikrinti patikimesnę diagnostiką ir išvengti šališkumo ar neteisingos gautų rezultatų interpretacijos.

## 1. LITERATŪROS APŽVALGA

## 1.1. Burnos, veido ir žandikaulių (BVŽ) patologijos

Burnos, veido ir žandikaulių (BVŽ) sistema – tai sudėtinga anatominė struktūra, atliekanti svarbiausias funkcines ir estetinės išraiškos funkcijas. Ji apima veido kaulus, žandikaulius, dantis, temporomandibulinius sąnarius, raumenis, kraujagysles, nervus ir minkštuosius audinius, kurie kartu užtikrina kalbos, ryjimo, kvėpavimo, kramtymo ir mimikos funkcijas. Dėl savo sudėtingos anatominės sandaros ir įvairių funkcijų BVŽ sistema yra ypač pažeidžiama traumų, uždegiminių, degeneracinių ir navikinių procesų. Jos sveikata ir vientisumas yra būtini bendrai žmogaus savijautai ir gyvenimo kokybei.

BVŽ sritis dėl savo anatominės sandaros ir nuolatinio kontakto su burnos ertmės mikroflora yra ypač jautri uždegiminėms ligoms. Šios patologijos dažniausiai išsivysto dėl bakterinių infekcijų, tačiau gali būti ir virusinės, grybelinės ar autoimuninės kilmės [21]. Uždegiminiai procesai gali apimti kaulus, minkštuosius audinius, seilių liaukas, dantų šaknis ir netoliese esančias anatomines struktūras, tokias kaip sinusai ar limfmazgiai. Dažniausiai pasitaikančios uždegiminės ligos BVŽ srityje yra odontogeninės infekcijos, kurios kyla iš dantų ir jų šaknų uždegimų. Negydytos odontogeninės infekcijos formuoja pūlingus minkštųjų audinių židinius tokius kaip abscesai ir flegmonos, galinčius plisti į aplinkines struktūras [22]. Osteomielitas, arba kaulinio audinio uždegimas, dažniausiai vystosi kaip negydytų infekcijų komplikacija. BVŽ sritis dažnai pažeidžiama seilių liaukų uždegimų (sialadenitų) ir prienosinių ančių infekcijų (sinusitų), kurie gali būti tiek bakterinės, tiek virusinės kilmės.

Kita reikšminga BVŽ patologijų grupė yra neoplastiniai procesai, kurie apima gerybinius ir piktybinius navikus. BVŽ srities navikai sudaro apie 5 proc. visų žmogaus kūno navikų ir 20–30 proc. visų galvos bei kaklo navikų [23]. Šie dariniai gali išsivystyti kauluose, minkštuosiuose audiniuose, seilių liaukose, o jų poveikis priklauso nuo naviko tipo, augimo pobūdžio ir invaziškumo [24]. Gerybiniai navikai auga lėtai, išlieka lokalizuoti ir neplinta į aplinkinius audinius [25], tuo tarpu piktybiniai navikai pasižymi greitu, invazyviu augimu, gali pažeisti gretimas struktūras ir metastazuoti į limfmazgius ar tolimus organus. Šių navikų kilmė dažnai siejama su epiteliniais, jungiamojo audinio, kauliniais ar kraujagysliniais elementais [26]. Dėl svarbių BVŽ srities funkcijų tiek gerybiniai, tiek piktybiniai navikai gali reikšmingai paveikti paciento gyvenimo kokybę, sukeldami funkcinius sutrikimus, tokius kaip rijimo, kalbėjimo ar kvėpavimo problemos, bei estetinius pokyčius, lemiančius veido asimetriją ar deformacijas. BVŽ navikai skirstomi pagal histologinę kilmę, vertinant augimo pobūdį, invaziškumo laipsnį ir gebėjimą metastazuoti į limfmazgius ar tolimus organus.

Piktybiniai navikai, tokie kaip plokščiųjų ląstelių karcinoma (angl. *Squamous Cell Carcinoma, SCC*), sudaro daugiau nei 90 proc. visų burnos ertmės piktybinių darinių [27]. Šie navikai dažniausiai diagnozuojami vėlyvosiose stadijose, nes jų pradiniai simptomai dažnai būna nespecifiniai arba nepastebimi. Pacientai neretai kreipiasi į gydytoją tik tada, kai atsiranda ryškūs klinikiniai požymiai, tokie kaip skausmas, patinimas, kraujavimas, rijimo ar kvėpavimo sutrikimai. Dėl šios priežasties liga gali būti nustatoma tik tada, kai navikas yra išplitęs į aplinkinius audinius ar limfmazgius. Ankstyva diagnostika yra esminė siekiant pagerinti gydymo efektyvumą, sumažinti chirurginės intervencijos apimtį ir padidinti paciento išgyvenamumą. Tam pasiekti svarbu atlikti reguliarias profilaktines apžiūras, naudoti radiologinės diagnostikos tyrimus, tokius kaip ultragarsas, KT ir magnetinio rezonanso tomografija (MRT).

Dėl piktybinių navikų agresyvumo ir polinkio plisti į limfmazgius bei tolimus organus, ankstyva diagnostika yra itin svarbi. Laiku nustatyta liga leidžia pradėti kompleksinį gydymą, kuris paprastai apima chirurginį naviko pašalinimą, radioterapiją, chemoterapiją ar imunoterapiją. Gydymo strategija parenkama atsižvelgiant į naviko histologinį tipą, dydį, išplitimo laipsnį ir bendrą paciento būklę. Laiku nustatyta diagnozė ir naujausi gydymo metodai gali padėti sumažinti mirtingumą ir pagerinti pacientų išgyvenamumą bei gyvenimo kokybę.

### 1.2. Radiologiniai diagnostikos metodai

Radiologinė diagnostika yra neatsiejama šiuolaikinės medicinos dalis, leidžianti tiksliai vizualizuoti vidaus anatomines struktūras, anksti aptikti patologinius pokyčius ir užtikrinti intervencijų planavimą bei stebėseną. Šiuolaikiniai radiologinės diagnostikos metodai, tokie kaip rentgenografija, KT, MRT, ultragarsas ir branduolinės medicinos tyrimai, suteikia gydytojams galimybę be papildomos intervencijos analizuoti organų, kaulų ir minkštųjų audinių būklę.

Rentgenografija – tai radiologinės diagnostikos metodas, naudojantis rentgeno spindulius kūno vidinėms struktūroms pavaizduoti. BVŽ srities patologijos vertinimui dažniausiai taikomas ekstraoralinės rentgenografijos tyrimo metodas, atliekant pritaikomąsias veido kaulų, prienosinių ančių rentgenogramas ir ortopantomogramas, kas leidžia analizuoti dideles anatomines sritis, aptikti kaulų lūžius, cistas, navikus, sąnario degeneracinius pokyčius bei sinusų ligas. Vertinant minkštuosius audinius, smulkius kaulinius defektus ar sudėtingas patologijas rentgenogramų informatyvumas yra ribotas, todėl esant patologijos įtarimui tikslinga atlikti išsamesnius radiologinius tyrimus.

Kompiuterinės tomografijos radiologinės diagnostikos metodas paremtas rengeno spindulių slopinimo skirtingo tankio audiniuose principu, kuris leidžia gauti detalius ašinius žmogaus kūno vaizdus. BVŽ srities patologijų diagnostikoje KT laikoma "aukso standartu", kadangi užtikrina kompleksinį patologijos vertinimą, suteikdama išsamią informaciją tiek apie kaulines struktūras, tiek apie minkštuosius audinius. Gerybiniai kaulinio audinio dariniai, tokie kaip odontogeninės keratocistos, radikulinės cistos ir ameloblastomos, KT vaizduose pasižymi būdingais požymiais, leidžiančiais tiksliai juos atskirti nuo kitų patologijų [28]. Piktybiniai minkštųjų audinių ar kaulinio audinio navikai, tokie kaip plokščiųjų ląstelių karcinoma, osteosarkoma ar metastazės, geriausiai matomi KT tyrime su kontrastiniu vaizdo sustiprinimu, kuris leidžia aiškiai vizualizuoti minkštųjų audinių bei kraujagyslių struktūras, tiksliai įvertinti naviko išplitimą, kaulo destrukciją, bei įtarti galimą perineuralinį plitimą [29]. Dėl savo tikslumo KT leidžia anksti ir gana tiksliai aptikti patologinius pokyčius, kurie nematomi įprastinės rentgenografijos metu.

Magnetinio rezonanso tomografija neinvazinis radiologinės diagnostikos metodas pagristas stipraus magnetinio lauko ir radijo bangu naudojimu vaizdams gauti. Skirtingai nei rentgenografija ar KT, MRT nenaudoja jonizuojančiosios spinduliuotės, bei išsiskiria itin aukšta minkštujų audinių kontrasto raiška ir detalia anatominių struktūrų vizualizacija, todėl yra vienu iš svarbiausių tyrimų, vertinant BVŽ srities onkologines ligas. Gerybiniai navikai, tokie kaip pleomorfinės adenomos, švanomos ir hemangiomos, turi būdingus MRT signalus, kurie palengvina jų diferencijavimą [30]. Tuo tarpu tiriant piktybinius navikus, tokius kaip SCC, adenoidinę cistinę karcinomą ir sarkomas, MRT reikalingas naviko ribu ir lokalaus išplitimo įvertinimui, įskaitant galima perineuralini plitima ir greta esančių kraujagyslių invazija [31]. Be to, difuzijos ir perfuzijos sekos, analizuojančios darinio vandens molekulių judėjimą ir kraujotaką, padeda išryškiti naviko piktybiškumo požymius, taip padidinant MRT diagnostikos tiksluma [32]. MRT itin veiksmingas seiliu liauku patologijos diagnostikoje, nustatant tiek akmenlige, tiek ūmini ar lėtini sialadenitą, autoimunines ligas ar navikinę patologiją [33]. Infekcinės kilmės minkštujų audinių infiltracinių pakitimų metu MRT naudingas vertinant santyki su giliosiomis kaklo fascijomis, kas yra svarbu gydymo planavimui [34]. "Aukso standartu" MRT laikoma temporomandibulinio sanario diagnostikoje, vertinant sąnarinį diską ir jo galimas dislokacijas, sinovinį skystį, aplinkinius minkštuosius audinius, uždegimines ir degeneracines temporomandibulinio sanario būkles, tokias kaip reumatoidinis artritas ar osteoartritas [35]. Nors MRT yra labai informatyvus metodas, leidžiantis tiksliai įvertinti minkštųjų audinių būklę ir patologinius pokyčius, jis nėra pats tinkamiausias pasirinkimas, kai reikia detaliai analizuoti kaulinį audinį. Šioje srityje auksiniu standartu išlieka KT, kuri leidžia tiksliai vizualizuoti kaulų struktūrą ir patologinius pakitimus. Be to, MRT tyrimas trunka gerokai ilgiau nei KT, todėl KT yra lengviau prieinamas ir praktiškesnis pasirinkimas.

Ne ką mažiau svarbūs diagnostikos metodai BVŽ patologijos diagnostikoje vra pozitronu emisijos tomografija (PET) ir vieno fotono emisijos kompiuterinė tomografija (SPECT/KT), kuri sujungia vieno fotono emisijos kompiuterinės tomografijos (SPECT) funkcinių vaizdų galimybes su KT anatominiais vaizdais, leidžiančiais tiksliai lokalizuoti patologinius pakitimus [36]. Šie radiologiniai tyrimai leidžia įvertinti organizmo ląstelių metabolizmą ir funkcinius pokyčius, suteikdami išsamią informaciją apie ligos eigą molekuliniame lygmenyje. Šių tyrimų metu naudojami radioaktyvius žymekliai, kurie kaupiasi tam tikruose audiniuose ar organuose, kas leidžia stebėti biologinius procesus organizme realiu laiku. Šis metodas padeda vertinti metabolinius pokyčius, ankstyvas patologijas ir navikinius procesus, dar prieš atsirandant struktūriniams pakitimams. PET-KT yra ypač svarbus piktybinių BVŽ naviku diagnostikoje, nes leidžia tiksliai nustatyti ligos stadiją, aptikti recidyvus ir ivertinti gydymo efektyvuma. Šis metodas dažniausiai naudojamas SCC atvejais, kur jis padeda identifikuoti pirminio naviko lokalizacija. limfmazgių ir tolimasias metastazes, taip pagerindamas stadijos nustatymo tiksluma [37]. Osteosarkomos ir chondrosarkomos atvejais PET-KT leidžia atskirti agresyvius ir lėtai augančius navikus bei įvertinti jų atsaką į gydymą [38]. Be to, šis metodas naudingas diagnozuojant seilių liaukų piktybinius navikus, padedant atskirti gerybinius darinius nuo piktybiniu ir aptikti metastazes [39]. PET-KT taip pat plačiai naudojamas uždegiminių ir infekcinių būklių diagnostikoje, įskaitant osteomielitą ir bisfosfonatų sukeltą žandikaulio osteonekrozę (BRONJ). Jis leidžia aptikti aktyvius uždegiminius procesus ir diferencijuoti infekcija nuo naviko recidyvo onkologiniams pacientams, gydomiems bisfosfonatais [40]. PET-KT taikomas temporomandibulinio sąnario uždegimui diagnozuoti, ypač reumatoidinio artrito atvejais, kai reikalingas tikslus uždegiminių pokyčių įvertinimas [41]. Be onkologinių ir uždegiminiu būkliu, PET-KT taip pat naudojamas metaboliniu kaulu ligu, tokiu kaip Pageto liga, diagnostikai, kuomet padidėjusi radioaktyviojo žymens akumuliacija rodo aktyvius kaulinio audinio procesus, leidžiančius aptikti ligos progresavima [42]. PET ir SPECT yra nepakeičiamos medicinos priemonės, suteikiančios gydytojams galimybę stebėti biologinius procesus organizme realiuoju laiku ir diagnozuoti ligas jų ankstyviausiose stadijose, tačiau tai nėra pirminės BVŽ diagnostikos metodai.

Dar vienas ne mažiau svarbus BVŽ srities diagnostikos metodas yra ultragarsinė diagnostika, kuri yra ypač naudinga vertinant paviršinius minkštųjų audinių darinius, seilių liaukų pakitimus, limfmazgių patologijas, kraujagyslių anomalijas bei tam tikrus temporomandibulinio sąnario pažeidimus. Nors gilesnių struktūrų ir kaulinių patologijų diagnostikai pirmenybė teikiama KT ir MRT, ultragarsas išlieka svarbi pirminė diagnostikos priemonė, leidžianti realiu laiku įvertinti paviršinius pakitimus, bei esant indikacijoms, atlikti minimaliai invazines procedūras.

#### 1.3. Infraraudonųjų spindulių termografija (IRST)

Infraraudonujų spindulių termografija (IRST) - tai neinvazinis tyrimo metodas, leidžiantis užfiksuoti ir analizuoti kūno ar objektu skleidžiama šilumine spinduliuote [43, 44]. Ši technologija remiasi infraraudonuju spindulių aptikimu ir jų konvertavimu i temperatūrinius žemėlapius, kurie atspindi paviršiaus temperatūros pasiskirstymą. Mokslininkai ir inžinieriai aktyviai tyrinėja infraraudonosios spinduliuotės fizikines savybes, siekdami tobulinti šiluminio vaizdavimo sistemas, kurios gali būti naudojamos medicinoje, pramonėje, saugumo ir kitose srityse. Fizikiniu požiūriu infraraudonieji spinduliai yra elektromagnetinių bangų spektro dalis, kurių dažniai yra tarp matomos šviesos ir mikrobangu diapazono [45]. Jie sklinda kaip nematoma spinduliuotė, kurią sugeria, atspindi arba perduoda įvairios medžiagos, priklausomai nuo ju šiluminių savybių. Ši savybė leidžia IRST būti itin efektyviu įrankiu ne tik medicinoje, bet ir inžineriniuose tyrimuose, kur būtina stebėti temperatūrinius pokyčius realiuoju laiku. IRST principas slypi tame, kad visi objektai, kurių temperatūra vra virš absoliutaus nulio, skleidžia infraraudonuosius spindulius. Infraraudonuosius spindulius fiksuoja specialios kameros, kurios dažniausiai naudoja mikrobolometrinius jutiklius. Šie jutikliai aptinka temperatūros pokyčius, įvertindami, kiek infraraudonosios spinduliuotės skleidžia objektas. Gautą informaciją jie paverčia elektroniniais signalais, kurie vėliau apdorojami ir paverčiami skaitmeniniu temperatūros vaizdu. Temperatūros vertės apskaičiuojamos naudojant sudėtingus algoritmus, pagristus Planko ir Stefan-Boltzmanno dėsniais [46]. Planko dėsnis nusako, kaip objektas spinduliuoja energija skirtinguose bangos ilgiuose, o Stefan-Boltzmanno dėsnis padeda apskaičiuoti bendrą išspinduliuojamos energijos kiekį, priklausomai nuo objekto temperatūros. Planko dėsnis rodo, kad bet kuris objektas, kurio temperatūra viršija absoliutu nuli (-273,15 °C arba 0 K, Kelvinu), skleidžia elektromagnetines bangas. Šios spinduliuotės intensyvumas priklauso nuo bangos ilgio ir objekto temperatūros, t. y. kuo kūnas karštesnis, tuo didesnė energija išspinduliuojama trumpesnio bangos ilgio diapazone [46]. Dėsnis taip pat leidžia apskaičiuoti, kokio bangos ilgio spinduliuotė dominuoja tam tikroje temperatūroje, o tai yra itin svarbu infraraudonųjų spindulių termografijoje, nes leidžia tiksliai nustatyti objekto temperatūrą per nuotolį [47]

Stefan-Boltzmanno dėsnis aprašo ryši tarp kūno temperatūros ir jo skleidžiamos šiluminės spinduliuotės. Pagal ši dėsni, kuo aukštesnė objekto temperatūra, tuo daugiau šiluminės energijos jis išspinduliuoja. Dėsnis grindžiamas, kad absoliučiai juodojo kūno (t. v., idealaus objekto, kuris visiškai sugeria ir išspinduliuoja energija) spinduliuojama energija didėja proporcingai jo absoliučios temperatūros ketvirtajam laipsniui. Tai reiškia, kad net nedidelis temperatūros padidėjimas smarkiai padidina skleidžiamos energijos kieki [48]. IRST šis dėsnis naudojamas objekto paviršiaus temperatūros aptikimui pagal jo spinduliuojama infraraudonąją energiją. Kadangi tikri objektai dažniausiai nėra tobuli juodieji kūnai, šis dėsnis taikomas atsižvelgiant i emisijos koeficienta (ɛ). Šis koeficientas parodo, kokia dali energijos realus objektas išspinduliuoja, palyginti su idealiu juoduoju kūnu [46]. Emisijos koeficientas – dydis, nusakantis objekto gebėjima išspinduliuoti šilumine energija, palvginti su idealiu juoduoju kūnu, kuris sugeria ir išspinduliuoja visa į jį krentančią elektromagnetinę spinduliuotę. Emisijos koeficientas visada svyruoja tarp 0 ir 1, kai  $\varepsilon = 1$  reiškia, kad objektas yra tobulas juodasis kūnas, o kai  $\varepsilon = 0$  reiškia, kad objektas visiškai neatspindi ir neišspinduliuoja šiluminės energijos. Daugumos realiu medžiagu emisijos koeficientas yra mažesnis nei 1 ir priklauso nuo temperatūros, paviršiaus struktūros ir bangos ilgio. Pavyzdžiui, žmogaus oda turi aukštą emisijos koeficientą (~0,98), todėl termovizijos kameromis galima tiksliai matuoti kūno temperatūrą ir aptikti patologines būkles. Netiksli emisijos koeficiento vertė gali lemti temperatūros matavimo klaidas, todėl termoviziniai prietaisai dažnai leidžia reguliuoti šį parametrą pagal tiriama paviršių. Emisijos koeficientas gali būti apskaičiuojamas teoriškai pagal Stefan-Boltzmanno dėsnį, eksperimentiniu būdu naudojant lyginamaja analizę su juoduoju kūnu, arba laboratoriniais metodais naudojant spektrometrus [49].

Šiais dėsniais pagrįstos kameros gali registruoti infraraudonąją spinduliuotę, kurios bangos ilgis yra nuo 0,9 iki 14 mikrometrų ( $\mu$ m). Šis spektras apima trumpųjų, vidutinių ir ilgųjų bangų infraraudonuosius spindulius. Trumpųjų bangų infraraudonieji spinduliai (0,9–1,4  $\mu$ m) dažniausiai naudojami optiniuose jutikliuose ir telekomunikacijų technologijose. Vidutinių bangų infraraudonieji spinduliai (1,4–3  $\mu$ m) taikomi infraraudonųjų spindulių spektroskopijoje, medicininėje diagnostikoje ir cheminėje analizėje, nes leidžia tiksliai aptikti ir išanalizuoti medžiagų sudėtį bei struktūrą. Ilgųjų bangų infraraudonieji spinduliai (3–14  $\mu$ m) yra pagrindinis termografijoje naudojamas diapazonas, nes šis spinduliavimas leidžia tiksliai užfiksuoti objektų skleidžiamą šiluminę energiją ir sukurti temperatūrinius žemėlapius [50]. Infraraudoniesiems spinduliams jautrūs detektoriai surenka objektų skleidžiamą šilumą ir paverčia ją elektriniais signalais. Šie signalai, atspindintys skirtingas temperatūras, yra apdorojami jutiklių sistemoje, kuri juos konvertuoja į skaitmeninę informaciją. Galiausiai, specialus procesorius analizuoja šiuos duomenis ir sukuria termografinį vaizdą, kuriame temperatūrų skirtumai išreiškiami spalvomis: šiltesnės vietos rodomos šviesesnėmis spalvomis, o šaltesnės – tamsesnėmis. Toks vizualizavimas leidžia lengvai aptikti temperatūros pokyčius įvairiose srityse – nuo medicinos iki inžinerijos ir saugumo sistemų.

Nors apie infraraudonosios spinduliuotės galimą panaudojimą vaizdavimo tikslais buvo galvojama jau ilgą laiką, praktinis termovizijos įgyvendinimas pradėjo formuotis 1920-aisiais ir 1930-aisiais metais [11]. Ankstyvosiose termogramose vaizdas buvo pateikiamas nespalvotas, tačiau jau nuo 1970 metų, tobulėjant infraraudonųjų spindulių ekranams termogramas buvo galima vertinti spalvinėje skalėje, kuriose aukštesnės temperatūros zonos pavaizduotos šiltomis spalvomis (raudona, oranžinė, geltona), o žemesnės temperatūros zonos pavaizduotos šaltesnėmis spalvomis (mėlyna, violetinė). Šio proceso pasekoje atsirado galimybė ne tik vertinti šiluminius pokyčius dinamikoje, tačiau ir išskirti dominančios srities lokalius išskirtinės temperatūros taškus.

Anksčiausiai dokumentuotas IRST pritaikymas buvo Pirmojo pasaulinio karo metais. Tuo metu infraraudonąją spinduliuotę vaizduojančios technologijos buvo tyrinėjamos kaip būdas aptikti priešo taikinius ir stebėti karių judėjimą esant prastam matomumui. Ankstyvieji šiluminio vaizdavimo įrenginiai buvo ganėtinai primityvūs, lyginant su šiuolaikiniais analogais, tačiau jie padėjo tvirtus pagrindus šios technologijos praktiniam pritaikymui. Vėliau šie įrenginiai tapo neatsiejama karinio taikymo dalimi, įskaitant žvalgybą, stebėjimą, taikinio nustatymą ir naktinio regėjimo galimybes.

Technologinio progreso metu IRST prasiskverbė ir į pramonės sritis, siūlydama nekontaktinį būdą įvertinti mašinų, infrastruktūros ir procesų būklę. Pramonės srityse IRST gali būti naudojama aptinkant įprastų temperatūrų nuokrypius, bei nustatant potencialų įrangos gedimą ar sutrikimą. IRST pramonėje tapo lengvai prieinama 1970-siais–1980-siais metais, kas leido gamintojams aptikti defektus, nesklandumus ar nesuderinamumus produktuose ir medžiagose. Vėliau, tobulėjant šiluminėms kameroms, IRST tapo neatskiriama energijos auditavimo ir efektyvumo vertinimo dalimi.

#### 1.4. IRST taikymas medicinoje

Medicinos srityje IRST buvo pradėta taikyti nuo 20-to amžiaus vidurio, kuomet mokslininkai ir gydytojai pradėjo eksperimentuoti su šiluminio vaizdavimo technikomis, siekiant stebėti odos temperatūru pokyčius, bei aptikti galimas patologijas. Pirminiai IRST pritaikymai buvo dermatologijos ir kraujagyslių sistemos patologijos srityse. Šie tyrimai leido IRST vis labiau integruoti i klinikinę praktiką su perspektyva tapti nauju diagnostiniu irankiu medicinoje. Pasitelkiant IRST vaizdų analizei skirtus algoritmus, galima aptikti smulkius paviršiaus temperatūru skirtumus, teikiančius informacija tiek apie fiziologinius organizmo procesus, tiek apie galima patologija ar bendra sveikatos būkle. Žmogaus kūno audiniai ir organai pasižymi skirtingomis šiluminėmis charakteristikomis. Lokalias odos temperatūros pokyčio sritis gali itakoti daugelis ligu ir (arba) patologiju, taip pat psichofiziologiniai reiškiniai (pvz., navikai, uždegimai, infekcijos, karščiavimas, lėtinės skausmo ligos, nervų sistemos funkcijos pokyčiai ir kt.) [51–53]. Odos paviršiaus temperatūra visada yra visu šiluminių procesu, vykstančių po oda, suma. Todėl priimant klinikinius sprendimus reikėtų atsižvelgti į poodinius fiziologinius procesus. Pavyzdžiui hipotermijos metu, kad išvengti papildomu šilumos nuostolių, odos kraujagyslės susitraukia, kraujotaka centralizuojasi, ko pasekoje stebimas odos paviršiaus temperatūros sumažėjimas. Tuo tarpu hipertermijos atveju, siekiant atvėsinti organizma, kraujagyslės išsiplėčia, kas lemia padidėjusią odos paviršiaus temperatūrą [54]. Žmogaus kūnas pasižymi dvipuse simetrija, kuri vra svarbi tiek anatominiu, tiek funkciniu požiūriu. Organai, kraujagyslių tinklas ir nerviniai rezginiai išsidėsto abipus kūno simetrijos ašies beveik vienodai, užtikrindami sklandžią organizmo veiklą ir pusiausvyrą. Vienas svarbiausių šios simetrijos fiziologinių aspektų yra šilumos pasiskirstymas, kuris sveikam žmogui paprastai išlieka vienodas abiejose kūno pusėse. Ši tolygu temperatūros pasiskirstyma palaiko subalansuota kraujotaka, medžiagų apykaita ir termoreguliacijos mechanizmai. Sveikam žmogui termograma rodo vienodus ir simetriškus, kūna į dvi dalis dalinančios plokštumos atžvilgiu, odos paviršiaus temperatūros svyravimus, o skirtumai pasirinktose vietose yra labai maži (< 0,2 °C). Pagrindinį vaidmenį šiame balanse atlieka kapiliarų tinklo veikla, arterioveninės kraujotakos santykis bei autonominė nervų sistema, kurios užtikrina, kad šiluminė homeostazė būtų išlaikoma visame organizme. Ženklesni kūno temperatūros simetrijos skirtumai gali rodyti kraujagyslių patologijas, nervų pažeidimus ar uždegiminius procesus. Todėl bet koks matomas temperatūros pokytis vienoje kūno pusėje gali būti vertinamas kaip galimas sveikatos sutrikimų požymis, reikalaujantis tolimesnio tyrimo. Užfiksuodami ir analizuodami šiuos paviršiaus temperatūros pokyčius, gydytojai gali gauti neikainojamos informacijos apie pagrindines patologijas, kas padėtų priimti klinikinius sprendimus ir efektyviai stebėti gydymo atsaką.

Tuo tarpu veido oda, kaip labiausiai atidengta kūno dalis yra veikiama tiek vidinių fiziologinių procesų, tiek įvairių aplinkos veiksnių. Kadangi veido oda gausiai vaskuliarizuota, jos temperatūra, reaguodama į kraujotakos sutrikimus, žmogaus emocinę būklę, metabolinius procesus ar išorinius veiksnius, dinamiškai keičiasi.

Nustatyta, kad patologinę zoną supančios srities audinių temperatūra yra šiek tiek aukštesnė nei įprasto audinio, o patologijos paveiktose srityse stebimi akivaizdūs temperatūros svyravimai [15, 55]. Tačiau, kartais patologijos srityje stebima lokaliai sumažėjusios temperatūros sritis. Nepaisant šių skirtumų, termografinio tyrimo metu svarbu nustatyti hipervaskuliarizacijos vietą ir laiku nukreipti pacientą tolimesniam radiologiniam ištyrimui.

Šiuo metu IRST kaip diagnostinis metodas yra kliniškai patvirtinta tik keliose medicinos srityse. Ji plačiai taikoma krūties vėžio ankstyvoje diagnostikoje, nes padeda aptikti kraujotakos ir metabolinius pokyčius, susijusius su naviku formavimusi [56]. Neurologijoje ir skausmo sindromu vertinime IRST naudojama diagnozuojant neuropatijas, kompleksinio regioninio skausmo sindromą ir kraujotakos sutrikimus esant migrenai ar neaiškios kilmės galvos skausmams [57]. Periferinių kraujotakos sutrikimų diagnostikoje ji efektyviai padeda aptikti arterinės ir veninės kraujotakos sutrikimus, taip pat kraujotakos nepakankamumą [58]. Ortopedijoje ir sporto medicinoje termografija leidžia vizualizuoti raumenų pertempimus, sausgyslių uždegimus, sąnarių pažeidimus bei stebėti traumų gijimą ir sekti reabilitacijos progresą [59]. Dermatologijoje ji taikoma piktybinių odos navikų, hemangiomų, randų ir uždegiminių odos ligų diagnostikai [60]. Pooperacinės būklės ir žaizdų gijimo stebėjime termografija leidžia anksti aptikti kraujotakos sutrikimus, uždegimus ar audinių nekrozę, taip užtikrinant savalaikę komplikacijų prevencija [61].

Kadangi termografija yra funkcinis vaizdų gavimo metodas, jos efektyvumui užtikrinti naudojami įvairūs kompiuteriniai algoritmai, leidžiantys analizuoti ir interpretuoti temperatūrų pasiskirstymą, asimetriją ir šiluminius pokyčius. Krūties navikų diagnostikoje naudojami algoritmai padeda nustatyti hipertermijos sritis, kraujagyslių struktūrinius pakitimus ir temperatūros skirtumus atitinkamose simetrinėse srityse. Temperatūros skirtumas tarp simetriškų krūties sričių didesnis ar lygus 1 °C laikomas reikšmingu ir gali būti susijęs su naviko vystymusi [62]. Priklausomai nuo individualaus metabolizmo aktyvumo ir krūties liaukų kraujotakos ypatumų, vidutinės temperatūros skirtumai tarp kairiosios ir dešiniosios krūties gali siekti 1,4 °C visoje krūtyje ir iki 1,5 °C spenelio srityje [62]. Nedideli temperatūros skirtumai tarp krūtų termogramose dažniausiai parodo fiziologines disfunkcijas, tačiau moterims, kurių krūtyse nėra navikinių pakitimų, krūties paviršiaus temperatūra paprastai išlieka beveik simetriška, be aiškių aukštesnės temperatūros taškų [52]. Naudojami algoritmai leidžia aptikti kraujagyslių tinklus (neovaskuliarizaciją), būdingus piktybiniam procesui ir naudojami fraktalinės analizės metodai kraujagyslinio tinklo tankio ir chaotiškumo įvertinimui [63]. IRST metodai taip pat leidžia analizuoti krūties temperatūros pokyčius po šalto dirgiklio poveikio (pvz., šalto oro ekspozicijos). Navikinis audinys linkęs išlaikyti aukštesnę temperatūrą, o sveiki audiniai atvėsta greičiau. Toliau, remiantis šiais parametrais, gautos termogramos dirbtinio intelekto (DI) algoritmų pagalba yra klasterizuojamos. Konvoliuciniai neuroniniai tinklai (NT) (angl. *Convolutional Neural Networks*, *CNNs*) yra apmokomi atpažinti karštus taškus, įvertinant temperatūrų pasiskirstymą simetriškose krūties vietose [64].

Dermatologijoje naudojami vaizdu segmentavimo algoritmai, skirti piktybiniu dariniu aptikimui pagal ju šilumines charakteristikas. Vaizdu apdorojimui naudojami DI modeliai, tokie kaip ResNet ir EfficientNet, kurie remiantis šiluminiu duomenų analize, leidžia automatizuotai klasifikuoti vaizdus pagal odos būklę. DI algoritmai apmokomi atpažinti karštuosius taškus, temperatūros skirtumus tarp simetriškų kūno pusių, bei sritis, kurių temperatūra yra žemesnė nei aplinkinio audinio. Karštieji taškai – tai lokalizuotos sritys, kurių temperatūra yra aukštesnė nei aplinkinių audinių, ir jie dažnai siejami su uždegiminiais procesais, bakterinėmis ar virusinėmis infekcijomis bei piktybiniais navikais, kuriuose, dėl padidėjusios medžiagų apykaitos, susidaro hiperterminės sritys (pvz., melanoma). Temperatūros skirtumai tarp simetriškų kūno vietų gali rodyti kraujotakos sutrikimus ar neurologines ligas. Tuo tarpu hipoterminių taškų buvimas, kai tam tikros sritys yra vėsesnės nei aplinkinė oda, gali reikšti gerybinius navikus ar randinius audinius, kuriuose sumažėjusi kraujotaka. Algoritmai leidžia nustatyti šilčiausias ir šalčiausias odos vietas, o piktybiniai odos dariniai dažniausiai rodo staigius temperatūros pokyčius, lyginant su aplinkiniais audiniais.

Neurologijoje naudojama šiluminės asimetrijos analizė, kuri aptinka temperatūrų skirtumą tarp sveikos ir pažeistos kūno pusės. Dinaminiai kraujotakos pokyčių analizės metodai leidžia stebėti temperatūros pokyčius laike, nes uždegiminės ir neuropatinės būklės pasižymi skirtingu temperatūros svyravimu. Tai leidžia diferencijuoti patologines būkles pagal jų šiluminį atsaką. Taip pat naudojami DI modeliai, tokie kaip LSTM (angl. *Long Short-Term Memory*), kurie leidžia stebėti temperatūros pokyčius per tam tikrą laiką [65]. Ši analizė leidžia nustatyti skausmo kilmę ir padeda atskirti, ar skausmas yra neuropatinis, susijęs su kraujotakos sutrikimais, ar atsiradęs dėl uždegimo. Analizuodami šiuos duomenis, DI algoritmai gali atpažinti netipinius šilumos pasiskirstymo modelius, kurie gali rodyti patologinius procesus organizme. Traumatologijoje ir ortopedijoje taikomi automatiniai algoritmai, skirti atpažinti uždegimo paveiktas sritis. Jie identifikuoja vietas su padidėjusia temperatūra, nes tai gali būti raiščių ir sausgyslių uždegimo, hematomų ar kaulų lūžių požymis. Sportinių traumų dinaminė analizė leidžia stebėti temperatūros pokyčius po fizinio krūvio, nes uždegimo paveikti audiniai ilgiau išlaiko šilumą, lyginant su sveikais audiniais. Taip pat DI pagalba, panaudojant konvoliucinius NT, prognozuojamos sportinės traumos, automatizuotai atrenkant kūno vietas, turinčias padidėjusią traumos riziką.

BVŽ srities patologijų diagnostikoje IRST šiuo metu nėra kliniškai patvirtintas metodas. Nors kai kurie tyrimai nagrinėja jos naudą vertinant uždegiminių procesų, kraujotakos sutrikimų ar žandikaulio sąnario patologijas [4, 16, 21], tačiau nėra pakankamai mokslinių įrodymų ir, svarbiausia, klinikinio validavimo, kad IRST galėtų būti patikimai naudojama šioje srityje. Dėl šios priežasties BVŽ srities patologijų diagnostikai vis dar pirmenybė teikiama radiologiniams tyrimams, tokiems kaip rentgenografija, KT ir MRT, kurie užtikrina aukštesnį diagnostinį tikslumą ir yra plačiai taikomi klinikinėje praktikoje.

#### 1.5. Dirbtinis intelektas ir mašininis mokymas

Dirbtinis intelektas (DI) yra informacinių technologijų sritis, siekianti sukurti mašinas ar sistemas, galinčias savarankiškai atlikti užduotis, naudojant žmogaus intelekto modelį. Tai apima mokymąsi, problemų sprendimą, sprendimų priėmimą, kalbos atpažinimą ir suvokimą. DI technologijų plėtra leidžia kurti sistemas, kurios analizuoja duomenis, mokosi iš patirties ir savarankiškai priima sprendimus, mažindamos žmogaus įsikišimo poreikį ir tai aktualu šiuolaikinėje sveikatos sistemoje [66].

DI hierarchija (1.5.1 pav.) apima įvairius intelekto lygmenis, klasifikuojamus pagal jų sudėtingumą, gebėjimus ir taikymo sritis [67]. Pagal intelekto gebėjimus DI skirstomas į siaurąjį DI (angl. *Narrow/Weak AI*), bendrąjį DI (angl. *General/Strong AI*) ir superintelektą (angl. *Super AI*). Siaurasis DI apima specializuotus modelius, sukurtus atlikti konkrečią užduotį, ir negali veikti už savo pradinio programavimo ribų. Siaurasis DI naudoja įvairius mašininio mokymosi (MM) (angl. *Machine Learning, ML*), giliojo mokymosi (GM) (angl. *Deep Learning, DL*) ir hibridinių modelių algoritmus (1.5.2 pav.).



1.5.1 pav. Schematinė DI hierarchinė sistema

Modifikuota pagal [68].



1.5.2 pav. Siaurojo DI kategorijų schema

Mėlyname ir žydrame fone pateikti atitinkamai dažniausiai ir rečiau taikomi algoritmai: SVM – atraminių vektorių mašina, *k*NN – *k*-artimiausias kaimynas, LDA – linijinė diskriminantinė analizė, ANN – dirbtiniai neuroniniai tinklai, CNN – konvoliuciniai neuroniniai tinklai, Resent-50 ir VGG-16 – giliojo mokymosi CNN, LSTM – ilgos trukmės trumpalaikė atmintis, ESN – rekurentinio neuroninio tinklo tipas, DBN – gilusis tikimybinių paslėptųjų sluoksnių tinklas ir kiti. Bendrasis DI – teorinis lygmuo, kuriame sistema gali mokytis, mąstyti ir spręsti problemas kaip žmogus, prisitaikyti prie naujų situacijų ir savarankiškai priimti sprendimus. Šiuo metu, toks DI lygmuo dar nėra sukurtas, tačiau tai yra ilgalaikis DI mokslinių tyrimų tikslas. Superintelektas – hipotetinis DI lygmuo, kuris pranoktų žmogaus intelektą visose srityse, pasižymėtų kūrybiškumu, emociniu suvokimu ir gebėjimu savarankiškai daryti mokslinius atradimus.

Sparčiai didėjantis medicininių vaizdų duomenų kiekis ir jų sudėtingumas neišvengiamai didina gydytojų darbo krūvį [69, 70]. Pastaraisiais metais DI pradėtas plačiai taikyti medicinoje, siekiant analizuoti šiuos milžiniškus duomenų rinkinius ir išskirti svarbiausią informaciją [69, 71]. DI orientuotas į intelektualių užduočių, kurias paprastai atlieka žmonės, automatizavimą, o MM yra vienas iš būdų šiam tikslui pasiekti [72], kai kompiuterinės sistemos mokosi iš duomenu ir patirties, kad galėtu priimti sprendimus arba atlikti prognozes be aiškiai užprogramuotų taisyklių. MM algoritmais paremti DI modeliai pasižymi puikiu tikslumu analizuojant ir apdorojant vaizdinius duomenis, o ju veikimas medicinoje vis labiau prilvgsta specialistu gebėjimams [73]. Šis mokymosi procesas grindžiamas įvairiais algoritmais, kurie skirstomi į tris pagrindines kategorijas: prižiūrimą mokymasi (angl. Supervised Learning), neprižiūrimą mokymąsi (angl. Unsupervised Learning) ir stiprinamajį mokymasi (angl. Reinforcement Learning) [74]. Šiuo metu prižiūrimas mokymasis yra dažniausiai naudojama mokymo metodika medicininiu vaizdu analizėje [75].

Prižiūrimo mokymosi metu algoritmas mokosi iš duomenų rinkinio, kuriame kiekvienam įėjimo duomenų taškui priskirta teisinga išėjimo reikšmė. Modelis analizuoja šiuos duomenis, kuria ryšius tarp įėjimų ir išėjimų, o vėliau gali prognozuoti naujus rezultatus. Klasterizacijos algoritmai skirti priskirti duomenis tam tikrai kategorijai. Regresijos algoritmai prognozuoja skaitines reikšmes. Logistinė regresija dažniausiai taikoma dviejų klasių problemoms spręsti. Medicinoje logistinė regresija naudojama navikų diagnostikai, siekiant prognozuoti, ar navikas yra piktybinis ar gerybinis, remiantis paciento klinikiniais rodikliais, tokiais kaip naviko dydis, forma, kraujagyslių tinklo pokyčiai ir termografiniai duomenys [76]. k-artimiausių kaimynų metodas (kNN) klasterizuoja vaizdą pagal jo artimiausių kaimynų balsus duomenų erdvėje [77]. Kuo daugiau kaimynų priklauso tam tikrai klasei, tuo didesnė tikimybė, kad objektas bus priskirtas tai pačiai klasei. Sprendimų medžiai sudaro hierarchinę struktūrą, kur kiekviename lygyje atliekamas taisyklėmis pagrįstas sprendimas, pavyzdžiui, vertinant paciento simptomus medicininėje diagnostikoje; jei temperatūra aukšta, tikrinami kiti rodikliai, kol nustatoma diagnozė. Atsitiktiniai miškai (angl. Random Forest) (1.5.3 pav.) apjungia kelis sprendimų medžius, taip padidindami tikslumą.

Atramos vektorių mašina (angl. *Support Vector Machine, SVM*) (1.5.4 pav.) ieško geriausios ribos (hiperplokštumos) tarp skirtingų klasių duomenų, kad juos aiškiai atskirtų [78, 79]. Šis metodas ypač naudingas, kai duomenys nėra lengvai atskiriami įprastais būdais, todėl dažnai taikomas medicinoje [80–84], pavyzdžiui, nustatant, ar rentgeno nuotraukoje matomas navikas yra gerybinis ar piktybinis. Naivusis Bajesas yra tikimybinis klasifikavimo algoritmas, kuris vertina duomenų priklausomybę tam tikrai klasei pagal Bajeso teoremą [85]. Medicinoje jis dažnai naudojamas ligų diagnostikai, pavyzdžiui, prognozuojant paciento vėžio riziką [86–89] pagal jo klinikinius duomenis (kraujo tyrimų rezultatus, amžių, simptomus). Jei pacientas turi tam tikrus požymius, modelis apskaičiuoja tikimybę, kad jie atitinka tam tikrą ligą. Kiekvienas šių metodų turi skirtingus pritaikymo būdus ir yra pasirenkamas priklausomai nuo analizuojamų duomenų tipo bei siekiamų rezultatų.



**1.5.3 pav.** Atsitiktinių miškų (angl. Random Forest) klasifikavimo schemos diagrama, kuri apjungia kelis sprendimų medžius



1.5.4 pav. Atramos vektorių mašinos diagrama (SVM)

Sprendimų hiperplokštuma su maksimaliomis ribomis suskirsto duomenis į dvi klases, kur atramos vektorius yra pavyzdinis taškas hiperplokštumos riboje. Modifikuota pagal [78].

Neprižiūrimame mokymęsi algoritmai nėra aprūpinti iš anksto pažymėtais duomenimis, todėl jie patys turi aptikti duomenyse paslėptus dėsningumus ir struktūras [75]. Šio tipo mokymasis dažnai naudojamas klasterizavimui ir patologijos aptikimui, kai siekiama grupuoti duomenis pagal panašumus ar rasti išsiskiriančius atvejus [90]. K-vidurkių (angl. *K-means*) algoritmas skirsto duomenis į K klasterių, optimizuodamas grupių centrus taip, kad kiekvienas duomenų taškas priklausytų artimiausiam centrui (1.5.5 pav.). Šis metodas efektyvus dideliems duomenų rinkiniams, tačiau reikalauja iš anksto nustatyti klasterių skaičių. Tuo tarpu hierarchinis klasterizavimas (angl. *hierarchical clustering*) (1.5.6 pav.) sukuria medžio tipo struktūrą, kurioje duomenys jungiami į klasterius hierarchiniu būdu [91], kas leidžia analizuoti duomenų sąsajas įvairiais lygmenimis.



1.5.5 pav. K-vidurkių algoritmo schematinis vaizdas



1.5.6 pav. Hierarchinio klasterizavimo schematinis vaizdas

Stiprinamasis mokymasis (angl. *Reinforcement Learning*) yra DI mokymosi metodas, kuriame sistema veikia dinamiškoje aplinkoje be iš anksto pateiktų teisingų atsakymų [78]. Algoritmas analizuoja savo veiksmus ir, atsižvelgdamas į gautus rezultatus, optimizuoja sprendimus taip, kad per ilgą laikotarpį pasiektų kuo geresnių rezultatų. Tai reiškia, kad modelis palaipsniui kaupia patirtį ir prisitaiko prie kintančių aplinkos sąlygų. Tuo tarpu, Q-mokymosi (angl. *Q-Learning*) DI metodas leidžia mokytis tinkamų sprendimų per bandymus ir klaidas. Jo išplėstinė versija, gilusis Q-mokymasis (angl. *Deep Q-Network*), naudoja neuroninius tinklus, kad sumodeliuotų sudėtingas aplinkas ir apdorotų didžiulius duomenų kiekius.

Giluminiai NT (angl. *Deep Neural Networks*) pasižymi pažangia DI architektūra, paremta daugiasluoksniais neuroniniais tinklais, gebančiais atlikti sudėtingus duomenų apdorojimo ir prognozavimo uždavinius. Šie tinklai veikia imituodami žmogaus smegenų neuronų ryšius, naudodami kelis tarpusavyje sujungtus dirbtinių neuronų sluoksnius. Pirmasis yra įvesties sluoksnis (angl. *input layer*), kuris priima pradinius duomenis, kaip vaizdai, tekstas ar signalai. Toliau seka paslėptieji sluoksniai (angl. *hidden layers*),

kurie atlieka duomenų transformaciją bei mokosi atpažinti svarbiausius požymius; kuo daugiau šių sluoksnių, tuo tinklas yra "gilesnis" ir gali išmokti sudėtingesnius modelius. Galiausiai, išvesties sluoksnis (angl. *output layer*) pateikia galutinę prognozę arba suskirstymą į klases (1.5.7 pav.).



1.5.7 pav. Schematinė giluminio neuroninio tinklo diagrama

(A) – paprasčiausias neuroninio tinklo modelis (perceptronas), turintis tik įvesties ir išvesties sluoksnius, kur įvesties duomenų parametrai tiesiogiai konvertuojami į išvesties rezultatus per svorius, jungiančius įvestį ir išvestį. (B) – trijų sluoksnių ANN (arba daugiasluoksnis perceptronas), kur pirmasis sluoksnis – įvesties sluoksnis – priima įvesties duomenis (X), antrasis – paslėptasis sluoksnis – naudojamas duomenų transformacijai ir savybių išskyrimui, kad įvestis būtų tinkamai suskirstyta, o trečiasis – išvesties sluoksnis – pateikia galutinį rezultatą. Išvesties sluoksnio neuronų skaičių lemia suskirstymo kategorijų skaičius, o jo išvesties reikšmė (Y) yra ANN modelio prognozuojama reikšmė. Modifikuota pagal [92].

Priklausomai nuo struktūros ir paskirties, giluminiai NT skirstomi į kelias pagrindines kategorijas. Viena jų – dirbtiniai NT (angl. Artificial Neural Networks) arba baziniai NT, kurie turi įvesties (paslėptuosius) ir išvesties sluoksnius, naudojami įvairioms prognozėms ir suskirstymui į klases. Kita giluminių NT kategorija – konvoliuciniai NT (angl. Convolutional Neural Networks), kurie skirti vaizdų analizei ir atpažinimui, kur filtrai ir konvoliuciniai sluoksniai padeda išryškinti reikšmingus bruožus. Tuo tarpu, pasikartojantys NT (angl. Recurrent Neural Networks) yra pritaikyti sekų duomenims, tokiems kaip natūralios kalbos apdorojimas, o patobulinta versija, ilgos trukmės trumpalaikės atminties tinklai (angl. *Long Short-Term Memory, LSTM*), leidžia išsaugoti ir apdoroti ilgesnes sekas be informacijos praradimo [93]. Šios skirtingos tinklų architektūros leidžia GM būti plačiai pritaikomam įvairiose srityse, nuo vaizdų ir kalbos atpažinimo iki duomenų generavimo ir prognozavimo, pvz., burnos navikų aptikimui ir prognozavimui [94, 95].

### 1.6. Mašininio mokymosi atlikimo protokolas

Mašininio mokymo (MM) protokolas yra sistemingas procesas (1.6.1 pav.), apimantis duomenu rinkima, paruošima, modelio kūrima, mokyma, vertinima ir diegima. Visų pirma, surinkti duomenys yra apdorojami ir vėliau padalijami i mokymo, validavimo ir testavimo rinkinius. Priklausomai nuo užduoties tipo, pasirenkamas tinkamas algoritmas. Kadangi duomenu kiekis ir kokybė tiesiogiai lemia modelio veikimo tiksluma, prieš mokymo procesa duomenys turi būti tinkamai standartizuojami. Pirmiausia būtina mažinti triukšmus, kad būtų pašalinti nereikalingi duomenų trukdžiai, tačiau išlaikant svarbias ypatybes. Taip pat, svarbu segmentuoti vaizdus ir išskirti aktualias sritis (angl. Region of Interest, ROI), kad modelis galėtų analizuoti tik reikšmingas struktūras. Be to, siekiant išvengti netikslių rezultatų dėl mažos imties, būtina sukaupti pakankama duomenų rinkinį. Šiems tikslams pasiekti naudojami tokie metodai kaip vaizdų triukšmo mažinimas (angl. image denoising), segmentavimas (angl. segmentation) ir duomenų papildymas (angl. augmentation), kurie leidžia pagerinti modelio mokymosi procesa, sumažinti klaidų tikimybę ir padidina diagnostikos tikslumą [96–101]. Jei modelis veikia tiksliai ir patikimai, jis išbandomas su naujais, realiais duomenimis, siekiant įvertinti jo praktinį pritaikomumą. Po diegimo modelis nuolat stebimas, kad būtų užtikrintas jo veikimo stabilumas. Jei laikui bėgant modelio tikslumas mažėja arba keičiasi duomenų struktūra, jis atnaujinamas papildomai apmokant su nauja informacija. Kai modelis yra pakankamai patikimas, jis įdiegiamas į realią aplinką, kur gali būti naudojamas automatizuojant užduotis. Visgi priimant galutinius sprendimus svarbi specialisto / radiologo žinios ir patirtis [102].



1.6.1 pav. Duomenų apdorojimo sistemos schema

## 1.7. *k*NN klasterizacijos algoritmo taikymas medicininėje diagnostikoje

*k*-artimiausių kaimynų (*k*NN) klasterizacija yra viena iš MM rūšių [17]. Pagrindinė kNN algoritmo esmė, kad pirmiausia mokymo duomenu rinkinys yra vaizduojamas požymių erdvėje, o tada nepažymėti ir nesugrupuoti įvesties pavyzdžiai perduodami i mokymo rinkini, naudojant tam tikra atstumo skaičiavimo formule [103]. Kiekvienas duomenu taškas mokymo rinkinio požymių erdvėje yra susiejamas su šiuo rinkiniu [104]. Lyginant požymius, atpažistami k-artimiausių duomenų požymiai ir sudaromos kaimynystės grupės. Tada taikomas balsavimo principas, kuriuo suskaičiuojamas dažniausiai pasitaikantis grupavimas tarp k-artimiausiu kaimynu, o grupė, kuri surenka daugiausiai balsu, priskiriama tiriamam pavyzdžiui, kaip galutinis rezultatas [17]. Šis metodas veikia lygindamas atstumus tarp duomenų taškų [105]. Kiekvienas duomenų taškas yra lyginamas su kitais, ir jam surandami k-artimiausių kaimynų duomenys. Taip grupuojami panašūs duomenys, remiantis jų artumu vienas kitam [106]. Skirtingi mastelio požymiai gali iškreipti grupavimo rezultatus, nes didesnio diapazono reikšmės gali dominuoti apskaičiuojant atstumus tarp taškų. Siekiant išvengti šios problemos, naudojamos įvairios duomenų normalizavimo ir standartizavimo technikos. Min-Max normalizavimas (angl. Min-Max Scaling) perkelia visas reikšmes į intervalą [0, 1], kad nė vienas požymis nebūtu per daug itakingas. Z standartizacija (angl. Z-score) normalizuoja duomenis, atimant jų vidurkį ir padalijant iš standartinio nuokrypio, taip užtikrinant, kad skirtingi požymiai turėtų panašų pasiskirstyma. Jei duomenyse yra daug požymiu, kurie gali būti koreliuoti tarpusavyje arba pertekliniai, gali būti taikoma pagrindiniu komponentu analizė, kuri sumažina dimensijų skaičių, išsaugant svarbiausia informacija. Tinkamai parinktos duomenu apdorojimo technikos padeda pagerinti kNN algoritmo veikima ir užtikrinti tikslesne klasterizacija. Atstumui tarp duomenų taškų apskaičiuoti dažniausiai naudojami skirtingi metodai, priklausomai nuo duomenu pobūdžio [107]. Jei duomenvs vra erdviniai arba turi aiškia geometrinę struktūrą, dažniausiai taikomas Euklido atstumas, kuris matuoja tiesų atstumą tarp dviejų taškų [108]. Jis tinkamas daugeliui bendrų atvejų, kai duomenys turi aiškiai apibrėžtą geometrinę erdvę [109]. Jei duomenys sudaryti iš atskirų reikšmių arba yra tinkamesni tinklelio tipo struktūrai, gali būti naudojamas Manheteno atstumas, kuris matuoja atstumą judant tik horizontaliai ir vertikaliai. Kai analizuojami tekstiniai duomenys, dažnai taikomas Kosinusinio panašumo matas, kuris nustato, kaip panašiai duomenu taškai išsidėstę pagal krypti erdvėje, o ne pagal tiesiogini atstumą. Optimali atstumo metrika pasirenkama eksperimentuojant su skirtingais matavimo metodais ir vertinant modelio tiksluma [109]. kNN klasterizacija yra lengvai suprantamas ir efektyvus metodas, kai duomenų kiekis yra mažas, nes skaičiavimai atliekami greitai [110]. Tačiau, kai duomenų rinkinys tampa didelis, algoritmas sulėtėja, nes kiekvienam naujam taškui reikia apskaičiuoti atstumą iki daugybės kitu tašku. Tai padidina skaičiavimo laika ir gali apsunkinti metodo taikymą dideliuose duomenų rinkiniuose. Kad kNN klasterizacija veiktų greičiau su dideliais duomenų rinkiniais, dažnai naudojamos specialios duomenų struktūros, kurios pagreitina artimiausių kaimynų paiešką [105]. Vienas iš tokių metodų yra k-d medžiai (angl. k-d trees), kurie padeda efektyviai suskirstyti duomenis į mažesnes grupes, kad nereikėtų tikrinti kiekvieno taško atskirai. Kitas metodas – rutuliniai medžiai (angl. ball trees), kurie leidžia dar greičiau surasti artimiausius kaimynus, ypač kai duomenys turi daug skirtingų požymių ar matmenų. Šie optimizavimo būdai sumažina skaičiavimų kieki ir padaro algoritmą tinkamesnį dideliems duomenų rinkiniams.

Labai svarbu tinkamai nustatyti hiperparametrą k, nes jis tiesiogiai veikia klasterizacijos tikslumą [111]. kNN parametras k nustato, kiek artimiausių kaimynų bus naudojama sprendimui priimti klasterizacijos metu. Jei k yra per mažas (k = 1), algoritmas gali būti jautrus atsitiktiniams triukšmo taškams, todėl duomenys gali būti neteisingai sugrupuoti. Kita vertus, jei k yra per didelis (k = 50), algoritmas gali išlyginti skirtumus tarp skirtingų grupių ir sujungti jas į vieną, net jei jos iš tikrųjų yra skirtingos. Todėl reikia rasti optimalų k, kuris užtikrintų tiek pakankamą detalumą, tiek stabilų grupavimą. Optimalus k dažniausiai parenkamas naudojant k vertės paiešką, pvz., per

kryžminį patikrinimą (angl. *cross-validation*), ieškant reikšmės, kuri užtikrina mažiausią klasterizavimo klaidą. Nors *k*NN klasterizacija nėra tokia populiari, kaip K-vidurkių ar DBSCAN, ji vis tiek naudojama įvairiose srityse. Šis metodas taikomas biologinių duomenų analizėje, pavyzdžiui, genetinių sekų grupavimui. Be to, *k*NN klasterizacija taikoma tekstinių dokumentų grupavimui, pavyzdžiui, pacientų ligos istorijų, mokslinių straipsnių ar ataskaitų suskirstymui į temines kategorijas. Tai leidžia automatizuotai analizuoti medicininius įrašus, atpažinti panašius klinikinius atvejus ir efektyviau organizuoti informaciją pagal diagnozes, gydymo metodus ar tyrimų rezultatus.

kNN gali būti taikomas tiek dviejų, tiek daugelio grupių klasterizavimui. Tai reiškia, kad jis gali grupuoti duomenis į dvi ar daugiau skirtingu kategorijų, priklausomai nuo duomenų struktūros ir užduoties pobūdžio [109]. kNN klasterizacijoje kiekvienas klasteris turi savo specifinį požymių rinkinį, kuris leidžia modeliui atskirti vieną grupę nuo kitos. Tai reiškia, kad duomenys skirstomi pagal tam tikrus kriterijus, kurie būdingi tik tam klasteriui. Kiekvienas klasteris sudaromas taip, kad jame esantys taškai būtų kuo panašesni vienas i kita, o skirtingu klasteriu taškai būtu kuo labiau skirtingi. Algoritmai ieško bendrų savybių, pvz., spalvos, dydžio, formos, statistinių rodiklių ar elgsenos modelių, kurie padeda sukurti atskiras grupes. Pavyzdžiui, jei kNN naudojamas odos ligu diagnostikai, kiekviena liga gali turėti specifinius požymius: melanoma gali būti atpažistama pagal netaisyklinga apgamu formą ir tamsią spalvą, psoriazė pasižymi pleiskanojančiais odos plotais, o egzema – paraudimu ir niežuliu. Modelis, analizuodamas naują atvejį, nustato, kokių požymių jis turi, ir lygina su žinomais pavyzdžiais. Artimiausių kaimynų klasterizacija leidžia nustatyti, kuriai ligai naujas atvejis yra labiausiai panašus.

Kai *k*NN naudojamas dviejų grupių klasterizavimui, kiekvienas duomenų taškas priskiriamas vienai iš dviejų galimų kategorijų (pvz., teigiamas arba neigiamas, taip arba ne). Pavyzdžiui, jei modelis mokomas nustatyti, ar paciento odos pažeidimas yra gerybinis ar piktybinis, kiekvienas naujas atvejis bus analizuojamas pagal artimiausių kaimynų duomenis. Jei odos pažeidimo charakteristikos (pvz., spalva, storis, forma, tekstūra) yra panašios į gerybinių atvejų daugumą, modelis priskirs jį gerybiniam tipui. Jei jis labiau panašus į piktybinius atvejus, bus priskirtas piktybiniam tipui.

Kaip minėta, *k*NN gali būti naudojamas ir tada, kai reikia suskirstyti duomenis į daugiau nei dvi grupes [107]. Pavyzdžiui, jei duomenys priklauso trims grupėms (A, B, C), kiekvienam naujam duomenų taškui algoritmas suranda *k*-artimiausių kaimynų ir pagal daugumos principą priskiria jį vienai iš tų grupių (1.7.1 pav.). Tai gali būti naudojama medicinoje, pavyzdžiui, plaučių ligų diagnostikoje pagal rentgeno vaizdus. Tarkime, modelis turi nustatyti, ar plaučių rentgeno nuotraukoje matoma pneumonija, tuberkuliozė

ar plaučių neoplastinis procesas. *k*NN algoritmas analizuoja naujo paciento rentgeno vaizdą ir lygina jį su anksčiau tirtų pacientų, kuriems nustatyta rentgenologinė diagnozė, vaizdais. Jei dauguma artimiausių kaimynų vaizdų priklauso tam tikrai diagnozei, naujasis atvejis taip pat priskiriamas tai pačiai kategorijai.



1.7.1 pav. kNN klasterizacijos schematinė diagrama

X reiškia testuojamą objektą, kurį reikia identifikuoti, o *k* reikšmė nustatyta kaip 7. Tai reiškia, kad išanalizuojamos septynios artimiausios kaimynystės ypatybės. Kadangi iš septynių artimiausių kaimynų X dažniausiai priklauso A grupei, tai reiškia, kad objektas greičiausiai priklausys šiai grupei. Todėl X bus priskirtas A grupei ir tai bus laikoma galutiniu rezultatu. Modifikuota pagal [77].

*k*NN algoritmo branduolio funkcijos leidžia pritaikyti "svėrimo" strategijas, kurios padeda tiksliau klasterizuoti ar prognozuoti rezultatus. Optimalios branduolio funkcijos pasirinkimas priklauso nuo duomenų struktūros ir užduoties pobūdžio. *k*NN kiekvienam kaimynui suteikia vienodą balsą klasterizacijoje, tačiau "svėrimas" gali pagerinti modelio tikslumą. Kai naudojamas vienodas svoris (angl. *uniform Kernel*), visi *k* artimiausi kaimynai turi vienodą įtaką klasterizacijai. Šios funkcijos privalumas yra tai, kad ji sumažina nutolusių duomenų taškų įtaką, todėl klasterizacija tampa tikslesnė.

Kai *k*NN taikomas klasterizavimui, kiekvienas naujas duomenų taškas lyginamas su jau esamais duomenimis ir priskiriamas klasteriui, kuriam priklauso dauguma jo artimiausių *k* kaimynų. Pavyzdžiui, jei medicininiuose duomenyse pacientų grupės formuojamos pagal simptomus ar genetinius požymius, *k*NN gali padėti identifikuoti pacientų grupes su panašiais ligos požymiais [76, 112, 113], net jei tos grupės nebuvo iš anksto apibrėžtos.

#### 1.8. Literatūros apžvalgos santrauka

BVŽ srities navikinės ligos gali sukelti rimtų pasekmių, jei jos nėra laiku diagnozuojamos ir tinkamai gydomos. DI įrankių pagalba gauta ankstyva diagnozė leidžia efektyviai taikyti kompleksinį gydymą, kuris gali apimti chirurginį naviko pašalinimą, radioterapiją, chemoterapiją ar imunoterapiją, siekiant sustabdyti ligos progresavimą ir pagerinti paciento būklę [94, 95, 114–116].

Šiuolaikinėje medicinoje KT laikoma "aukso standartu" BVŽ srities ligų diagnostikoje, nes suteikia išsamią informaciją tiek apie kaulines struktūras, tiek apie minkštuosius audinius. Be to, šis tyrimas yra greitas ir lengvai atliekamas, todėl jis ypač tinkamas skubiai diagnostikai ir tiksliam patologinių pokyčių vertinimui.

IRST kol kas nėra kliniškai patvirtinta metodika BVŽ srities patologiju diagnostikoje. Naujausi IRST pasiekimai išplėtė jos potenciala naudoti BVŽ srities patologijos aptikimui [14, 18] ir galėtų būti naudingas papildant esamas diagnostines technikas, tokias kaip KT ir MRT. Vis dėlto, literatūros šaltinių paieškoje nepavyko surasti išsamių palygynamųjų darbų. IRST vaizdinimo tikslumą ir patikimumą BVŽ srities patologijų aptikimui padidintų ir technologių pažanga, kaip aukštos raiškos terminių kamerų kūrimas ir tobulinimas. Be to, MM algoritmų sukūrimas ir pritaikymas termografinių vaizdų analizei galėtu potencialiai padėti tiksliau ir efektyviau diagnozuoti BVŽ srities patologijas [117]. Siekiant, kad IRST taptų realia klinikinės praktikos dalimi, reikia sukurti algoritmus, bei apmokyti kompiuterine sistema automatizuoto patologijos atpažinimo gautuose termografiniuose vaizduose, kaip jau yra pritaikyta plaučių ir krūties audinio patologijų nustatymo atvejais (1.8.1 pav.). Šiuo tikslu, pagrindinėms sudėtingų duomenų rinkinių vpatybėms aptikti, gali būti panaudojami įvairūs MM įrankiai [80, 81, 118]. Tačiau, kol kas nėra efektyvių irankių, skirtų automatiniam (yra ar nėra patologijos) žmogaus veido ir burnos ertmės termovaizdų klasterizavimui.



 1.8.1 pav. Plaučių (viršuje) ir krūties audinio (apačioje) pjūvio vaizdai
 Mikroskopinis H&E dažyto audinio vaizdas (A, C) ir infraraudonųjų spindulių vaizdas (B, D) [119].

Ši technologija yra perspektyvi, ypač pasitelkiant MM algoritmus termografinių vaizdų analizei, kurie gali padėti tiksliau identifikuoti patologinius pokyčius, sumažinti diagnostines klaidas ir automatizuoti temperatūrinių anomalijų aptikimą. Tuo tarpu *k*NN klasterizacija leidžia atrasti natūralias grupes duomenų rinkinyje, remiantis jų panašumu, ir gali būti naudingas diagnostikos sistemose, kuriose nėra iš anksto apibrėžtų ligų požymių [17]. MM modelių taikymas termografinių vaizdų analizėje gali padėti optimizuoti ligų diagnostiką, gerinant patologinių pokyčių diferenciaciją ir suteikiant papildomą įrankį ankstyvajai ligų diagnostikai.

Atsižvelgiant į aukščiau pateiktą informaciją, disertaciniame darbe siekėme gauti naujų žinių apie IRST technologijos tinkamumą BVŽ srities patologijų diagnostikoje. Kadangi, dar nėra efektyvių neinvazyvių diagnostikos metodų greitam patologijos nustatymui pacientų BVŽ srityje, ypač ankstyvoje stadijoje, dėl to yra svarbu ieškoti naujų technologinių sprendimų, kurie galėtų padėti greičiau nustatyti anomalinių židinių formavimąsi, o taip pat
leistų sekti jų klinikinę dinamiką. Mes pasirinkome pritaikyti IRST technologijas BVŽ srities klinikiniuose tyrimuose, kurios kol kas dar nėra taikomos klinikinėje diagnostikoje, tačiau turi didelį potencialą tiek paciento pirminės diagnostinės apžiūros vertinimui, tiek ir ankstyvesnio patologinio darinio nustatymui bei jo dinamikos sekimui. Disertaciniame darbe, derinant IRST / DI technologijas, įvertinome jų diagnostinį potencialą pacientų BVŽ srities patologijų aptikimui ir, kas yra itin svarbu, tyrimų rezultatus validavome radiologinėje diagnostikoje naudojamomis KT / MRT technologijomis.

# 2. METODIKA

Pacientų klinikinis tyrimas atliktas vadovaujantis 2.1 pav. pateikta darbų eigos schema.



2.1 pav. Darbų eigos schema

# 2.1. Termografinio vaizdo BVŽ srityje registravimo protokolas

Termografinis vaizdas (TV) buvo užfiksuotas naudojant FLIR E8 infraraudonųjų spindulių šiluminę kamerą (FLIR Systems, Inc., JAV). Tačiau, šiam tikslui gali būti naudojama bet kuri kita šiluminė kamera.

Kadangi įvairūs veiksniai gali turėti įtakos termografinio vaizdo duomenims, visi tiriamieji prieš tyrimą buvo įspėjami laikytis tam tikrų apribojimų. Kelios valandos prieš tyrimą jie turėjo vengti veido srities mechaninio dirginimo, pavyzdžiui, masažų, kremų naudojimo ar intensyvių fizinių pratimų. Taip pat buvo rekomenduojama nevartoti vaistų, atsisakyti šilto, šalto ir tonizuojančio maisto bei gėrimų, kurie galėtų paveikti odos temperatūrą ir iškreipti tyrimo rezultatus. Siekiant išvengti galimos rentgeno spindulių ar intraveninės kontrastinės medžiagos įtakos temperatūriniams svyravimams, prieš atliekant KT tyrimą visi pacientai buvo ištirti vienodomis sąlygomis, laikantis to paties termografinio protokolo [14, 120, 121], kurio metu buvo užtikrinta, kad:

- tyrimo metu nebūtų skersvėjo, būtų išjungti oro kondicionieriai,
- prie tiriamojo nebūtų aukštą temperatūrą skleidžiančių šaltinių,
- būtų pastovi kambario temperatūra (20–22 °C) ir drėgmė, be tiesioginių saulės spindulių,
- būtų atlikta 15 min. tiriamojo aklimatizacija patalpoje,
- tiriamasis bent kelias valandas iki tyrimo būtų nerūkęs,
- būtų patikrinta su tiriamuoju susijusi informacija medicininėje kortelėje (vardas ir pavardė, lytis, amžius, pagrindinis nusiskundimas, tabako ir alkoholio vartojimo istorija, jautrumas, ankstesnės ir esamos ligos, vartojami medikamentai),
- atliekant matavimus, visi tiriamieji sėdėtų kiek įmanoma tiesiai,
- IRST kamera su fotografavimo ir automatinio fokusavimo funkcija pozicionuota tiriamojo galvos lygyje, 1 m. atstumu (2.1.1 pav.),
- IRST kamera registruojami TV tiriamojo veido tiesinėje projekcijoje ir išsižiojus,
- sekos pabaigoje patikrintas užregistruoto TV įrašas ir vaizdų atkuriamumas ir atliktas patikrinimas su KT aptiktais pakitimais.



2.1.1 pav. Tiriamojo burnos / veido srities termografinių vaizdų registravimo su IRST technologija aplinka

Užregistruoti tiriamųjų veido paviršiaus temperatūrų profiliai dviejose būsenose, susičiaupus ir maksimaliai išsižiojus, buvo išsaugomi IRST kameroje. Vėliau buvo atliekamas pirminis ju apdorojimas ir gauti duomenys išsaugomi kompiutervie. Kadangi užregistruotas TV vra radiometrinė JPEG formato byla, todėl tolimesnei analizei ji buvo konvertuojama i MAT formato duomenų bylas naudojant TV apdorojimo programinę įrangą "ThermaCam Researcher 2.1" (gamintojas "FLIR Systems, Inc.", JAV). Matlab R2014b (gamintojas The MathWorks, Inc., JAV) panaudota duomenu analizei ir modeliavimui. Kiekviename užregistruotame vaizde yra informacija apie temperatūros diapazoną, datą ir laiką, radiometrinio tyrimo partametrai (emisijos koeficientas, atstumas tarp kameros ir objekto, kūno spinduliavimo koeficientas, atmosferos temperatūra, atmosferos pralaida (transmisija), santykinė drėgmė, ir kt.), termokameros skalės parametrai, o taip pat paskutinėje eilutėje užfiksuojama kadro informacija (2.1.2 pav.). Kiekvieno tyrimo sukauptų vaizdų analizė pirmiausia pradedama nuo suformuotos duomenų struktūros patikrinimo (2.1.1 lentelė). Kadangi duomenų struktūroje temperatūros yra išreikštos Kelvino vienetais, atliekamas temperatūrų konvertavimas į Celsijaus skalę. Suformuota 320 × 240 dydžio temperatūros reikšmių matrica toliau naudojama, kaip tyrimui reikalingi duomenys.

#### Structure = IR\_Custom: [320×240 double] IR\_Custom\_DateTime: [2015 11 1 0 6 16] IR\_Custom\_ObjectParam: [0.9800 2 293.1500 293.1500 0.3000 0.9930 0 293.1500 293.1500 1] IR\_Custom\_Scaling: [1×9 double] IR\_Custom\_FrameInfo: [1 0]

#### 2.1.2 pav. MAT formato suformuota duomenų struktūra

2.1.1 lentelė.	Termografijos	seanso aplinkos	sąlygos	[14]
	0 0 0	1		

Įvesties dydis	Spinduliavimo koeficientas, kaip objekto paviršiaus savybė	Patalpos tempera- tūra (°C)	Santykinė drėgmė (proc.)	Tiriamojo aklimatizaci- ja patalpoje (min.)	Atstumas tarp tiriamojo ir kameros (m)
Nustatytos vertės	0,98	$22\pm0,\!1$	$60\pm 5$	$15 \pm 0,2$	1

Pastaba: matavimai atlikti kontroliuojamoje aplinkoje, kaip nurodyta lentelėje.

## 2.2. Radiologinis BVŽ srities ištyrimas

Atlikus termografinius matavimus, visiems tiriamiesiems buvo atliktas galvos / kaklo srities KT tyrimas, be ir su intraveniniu kontrastavimu, naudojant kontrastinę medžiagą sol. Omnipaque 80 ml (GE Healthcare AS, Norvegija). Visiems pacientams galvos / kaklo KT tyrimas atliktas Kauno klinikų Radiologijos klinikoje "Toshiba Aquilion ONE" aparatu (Canon Medicininės sistemos, Japonija). Galvos / kaklo KT tyrimas pradėtas apžvalginiais galvos / kaklo srities vaizdais dvejose projekcijose: tiesinėje ir šoninėje. Pagal gautus planavimo vaizdus parengti ašiniai galvos / kaklo vaizdai. Visiems pacientams tyrimas atliktas taikant vienodus skenavimo parametrus, kur pasirinktas skenavimo žingsnio storis 1 mm. Gauti KT vaizdai vertinti gydytojo radiologo (specializuoto šioje srityje).

Siekiant išvengi jonizuojančios spinduliuotės žalingo poveikio sveikiems savanoriams, gavus papildoma leidima, buvo atliktas galvos / kaklo minkštujų audinių MRT tyrimas, nenaudojant intraveninės kontrastinės medžiagos. Galvos / kaklo MRT tyrimas atliktas Kauno kliniku Radiologijos klinikoje 1,5 teslos Siemens Magnetom Avanto aparatu (Siemens medicininės sistemos; Erlangenas, Vokietija). Tiriamieji tyrimo metu privalėjo gulėti ypač ramiai. Galvos / kaklo MRT tyrimams naudota 8 kanalų galvos ritė ir 4 kanalų kaklo ritė, kurios tyrimo metu uždedamos tiriamajam ant galvos ir kaklo srities. Galvos / kaklo MRT tyrimas atliktas trijose plokštumose: ašinėje, sagitalinėje ir koronarinėje. Naudotos skenavimo sekos: aukštos rezoliucijos T1 turbo aidų seka (angl. turbo Spin Echo, TSE), pasikartojantis laikas TR = 1100 ms, aido laikas TE = 19 ms, apžvalgos laukas (angl. field of view, FOV = 200 × 200 mm, gauti ašiniai pjūviai (n = 46). Aukštos rezoliucijos T2W turbo inversijos atkūrimo seka (angl. Turbo Inversion Recovery Magnitude, TIRM), TR = 4000 ms, TE = 40 ms, FOV =  $240 \times 240$  mm, koronariniai pjūviai (n = 28) ir ašiniai pjūviai (n = 28). Aukštos rezoliucijos T2W turbo aidu seka (angl. Turbo Spin Echo, TSE), pasikartojantis laikas TR = 5484 ms, aido laikas TE = 76 ms, apžvalgos laukas (angl. *field of view*, FOV) =  $300 \times 300$  mm, gauti sagitaliniai pjūviai (n = 28) ir ašiniai pjūviai (n = 28). Difuzijos (angl. Diffusion Weighted Image, DWI) ir tariamojo difuzijos koeficiento seka (angl. Apparent Diffusion Coefficient, ADC), naudojant MRT seką diff stir b 50 400 700. Gauti MRT vaizdai vertinti specializuoto VBŽ srityje gydytojo radiologo.

## 2.3. Tiriamųjų tinkamumo IRST tyrimui atrankos kriterijai

Tiriamųjų, atitinkančių įtraukimo kriterijus, kurie po klinikinio įvertinimo buvo nukreipti į KT procedūrą patologijos patvirtinimui / atmetimui Lietuvos sveikatos mokslų ligoninės Kauno klinikų (Kauno klinikų) Radiologijos klinikoje užfiksuota 70, visiems pasiūlyta dalyvauti klinikiniame tyrime. Atsisakiusių dalyvauti tyrime nebuvo, tačiau 5 iš jų į tyrimą nebuvo įtraukti dėl žemiau paminėtų neatitikimo kriterijų. Vėliau, buvo gautas papildomas leidimas sveikų savanorių (SS) grupės suformavimui (n = 29). Bendras tyrime dalyvavusių skaičius 94, iš kurių 39 sveiki pacientai ir 55 pacientai, kuriems KT / MRT tyrimu nustatyta patologija (2.3.1 pav.).



2.3.1 pav. Schematinis tiriamųjų suskirstymas į grupes

Į tyrimą įtraukti pacientai, atitinkantys įtraukimo kriterijus:

- pasirašyta asmens informavimo ir sutikimo forma,
- $\geq 18$  m. amžius,
- KT procedūra atliekama pirmą kartą, esant klinikiniams simptomams,
- anamnezėje nėra BVŽ srities chirurginių intervencijų,
- anamnezėje nėra paskirto BVŽ srities medikamentinio gydymo.

Esant nors vienam žemiau išvardintų kriterijų, pacientai į tyrimą neįtraukti:

- BVŽ srities chirurginės intervencijos,
- paskirtas BVŽ srities medikamentinis gydymas,
- 24 val. iki tyrimo buvo naudota fizinė terapija, ultragarsas, akupunktūra,

- tiriamasis maudėsi, buvo baseine ar kitaip sportavo 1 val. prieš tyrimą,
- tiriamasis 1 val. prieš tyrimą gėrė kavos, rūkė ar vartojo alkoholį,
- tiriamos kūno vietos buvo nuskustos 4 val. iki tyrimo,
- tiriamasis turėjo padidėjusią kūno temperatūrą, ar buvo nudegęs saulėje,
- esant ūminiam/lėtiniam grybeliniam sinusitui,
- esant difuzinei, ne Hodžkino limfomai,
- esant veido randams, kurie priskiriami patologiniams hipoterminiam pažeidimams [121].

## 2.4. BVŽ termografinio vaizdo (TV) vizualinė analizė ir segmentavimas

Gauti tiriamųjų veido ir burnos ertmės TV buvo analizuojami dviem etapais. Pirmiausia, atlikta vizualinė vaizdų analizė, kurios metu įvertintas temperatūros pasiskirstymas veido ir burnos srityse, bei galimi temperatūriniai nukrypimai nuo normos. Kai kuriems tiriamiesiems patologiniai pokyčiai buvo matomi iš karto, kadangi tam tikrose TV vietose išryškėjo padidintos temperatūros zonos, būdingos uždegiminiams ar navikiniams procesams. Tačiau, kai kurių pacientų TV akivaizdžių pokyčių nebuvo pastebėta, todėl dominančios srities (ROI) išskyrimui ir aiškesniam analizavimui vaizdas buvo segmentuojamas, t. y. suskirstomas į segmentus pagal absoliutinės temperatūros dydį. Spalvų žemėlapis yra reprezentatyvi priemonė veido patologijoms įvertinti. Izolinijų skaičius ir reikšmės parenkamos automatiškai pagal veido srities mažiausias ir didžiausias temperatūrines reikšmes. Patologinė sritis turi skirtingą (didesnę) temperatūrą ir gali būti išryškinta kita spalva nei likusi veido dalis.

2.4.1 pav. pateiktas to paties paciento veido / burnos srities patologijos vaizdas, nustatytas naudojant KT (2.4.1 pav., A), ir su IRST gautos pakitusios temperatūros sritys prieš ir po TV segmentacijos (2.4.1 pav., B, C). Svarbu pažymėti, kai navikas yra didelio dydžio, paveiktą zoną galima lengvai aptikti iš TV be jokio papildomo vaizdų apdorojimo [14].



2.4.1 pav. Paciento su veido / burnos patologija KT ir IRST vaizdai

KT tyrimo pjūvis ašinėje plokštumoje (A) su navikinėmis masėmis veido kairėje. TV frontalinėje plokštumoje pacientui išsižiojus; burnos ertmės kairėje stebima vizualiai aukštesnės temperatūros zona (B) ir tas pats TV atlikus segmentavimo procedūrą (C).

Automatinis vaizdų segmentavimas buvo atliekamas naudojant Matlab R2014b programinę įrangą (gamintojas The MathWorks, Inc., JAV) (žr. 1 priedą). Segmentavimo procesas apėmė pradinį vaizdo apdorojimą, slenkstinės analizės taikymą, klasterizaciją, bei morfologines operacijas, siekiant optimizuoti segmentavimo tikslumą. Naudoti metodai apėmė Nobuyuki Otsu sukurtą algoritmą [122], kuris automatiškai aptiko optimalią slenkstinę reikšmę, bei K-vidurkių segmentaciją, leidusią grupuoti pikselius pagal temperatūrinius požymius. Be to, buvo taikomos morfologinės operacijos, tokios kaip erozija (pašalina mažus nereikšmingus segmentus) ir dilatacija (išryškina objektų kontūrus, kad jie būtų aiškesni analizei), skirtos pašalinti nereikšmingus artefaktus ir išryškinti segmentuotų zonų ribas. Gautos segmentuotos sritys buvo analizuojamos naudojant segmentuotų sričių analizės "regionprops" funkciją, siekiant atpažinti jų savybes ir lokalizaciją.

Kadangi segmentuotuose vaizduose patologija ne visada buvo aiškiai matoma, tolimesniuose analizės etapuose buvo siekiama pasitelkti parametrinę analizę. Tam buvo atliktas veido ir burnos ertmės kontūrų aptikimas, leidžiantis identifikuoti anatomines ribas ir atlikti detalią temperatūros pokyčių analizę. Taip pat buvo taikomas simetrijos ašies suradimo metodas, skirtas įvertinti temperatūros pasiskirstymo simetriškumą tarp veido pusių.

### 2.5. TV veido ir burnos ertmės kontūrų ir simetrijos ašies aptikimas

#### 2.5.1. Veido kontūro aptikimas IRST vaizduose

Veido kontūro aptikimui buvo taikytas Prewitt'o metodas [123], kuris leidžia aptikti visus TV esančius ryškius veido srities kraštus, išryškindamas temperatūros pokyčių ir anatominių struktūrų ribas. Tai gradientu pagrįstas metodas, atrenkantis taškus (pikselius), kuriuose gradiento dydis yra didžiausias. Kraštas aptinkamas ieškant maksimalių verčių pirmoje vaizdo išvestinėje.

Kiekviena TV gradiento komponentė gali būti apskaičiuota naudojant konvoliuciją, kuri leidžia aptikti, kaip temperatūros pokytis pasiskirsto skirtingomis kryptimis. Taip apskaičiuojama gradiento reikšmė tiek horizontalia, tiek vertikalia kryptimis, kaip parodyta atitinkamai 2.1 ir 2.2 lygtyse [124]:

$$\nabla_x = I(x, y) \times G_x \tag{2.1},$$

$$\nabla_{y} = I(x, y) \times G_{y} \tag{2.2},$$

čia I(x, y) yra pradinė termovizinių duomenų matrica (vaizdas); × reiškia dvimatę konvoliucijos operaciją,  $G_x$  horizontalioji kaukė, kuri aptinka pokyčius iš kairės į dešinę; o  $G_y$  yra vertikalioji kaukė, kuri aptinka pokyčius iš viršaus į apačią, kurią galima apibūdinti atitinkamai naudojant 2.3 ir 2.4 lygtis:

$$G_{x} = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$$

$$G_{y} = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix}$$
(2.3),
(2.4),

Kiekvieno pikselio gradiento reikšmė buvo apskaičiuojama naudojant dydžio išraišką, taikant 2.5 lygtį:

$$|\nabla(x, y)| = \sqrt{\nabla_x^2 + \nabla_y^2}$$
(2.5),

čia  $|\nabla(x, y)|$  – gradiento dydis arba stiprumas,  $\nabla_x$  ir  $\nabla_y$  – tai atitinkami daliniai išvestiniai pagal x ir y kryptis, rodantys, kaip staigiai keičiasi funkcijos reikšmė kiekvienoje iš šių krypčių.

Ši metodika leidžia nustatyti, kuriose vaizdo vietose temperatūros pokyčiai yra didžiausi, o tai ypač svarbu patologinių sričių identifikavimui. Kuo didesnė  $|\nabla(x, y)|$  reikšmė, tuo staigesnis temperatūros pokytis (pvz., aiškus kontūras tarp skirtingų zonų). Kuo mažesnė  $|\nabla(x, y)|$  reikšmė, tuo vienodesnė temperatūra toje zonoje. Apskaičiavus vaizdo gradiento dydį, pikseliai su didelėmis gradiento dydžio reikšmėmis buvo laikomi kraštiniais pikseliais. Prewitt'o metodas buvo pasirinktas dėl jo paprastumo ir mažos skaičiavimo apkrovos. Originalus tiriamojo veido TV ir gradiento vaizdas pateikti 2.5.1.1 pav.



2.5.1.1 pav. Originalus žmogaus veido TV ir gradiento vaizdas

Pateiktas tiriamojo veido vaizdas užregistruotas su IRST (A) ir kompiuterio apskaičiuotas veido gradiento vaizdas (B). Pastaba: tiriamajam nebuvo nustatyta BVŽ patologija.

## 2.5.2. Veido simetrijos ašies aptikimas IRST vaizduose

Veido simetrijos ašies aptikimas prasideda nuo veido kontūrinių taškų išskyrimo, naudojant kraštų aptikimo algoritmus, tokius kaip Prewitt'o filtras. Norint aptikti žmogaus veido simetrijos ašies orientaciją ir padėtį, reikalingi tik išoriniai veido krašto taškai. Žmogaus veido išoriniai kontūrai (2.5.2.1 pav., A) buvo aptikti naudojant daugiakampio apvalkalo išskyrimo algoritmą (angl. *convex hull algorithm*), kuris leidžia tiksliai apibrėžti veido

formą, išskiriant išorines daugiakampio briaunas [125]. Daugiakampis apvalkalas – tai pikselių rinkinys, kuris sudaro mažiausią išgaubtą daugiakampį, apimantį visus vaizdo kraštinius pikselius. Šis daugiakampis suformuojamas taip, kad apimtų visus kontūrą formuojančius taškus. Po kraštų aptikimo buvo gautas pikselių rinkinys, atitinkantis veido išorinius kraštus. Gautas daugiakampis apvalkalas buvo vizualizuotas, kaip uždara laužtinė linija aplink veido struktūrą, leidžianti tiksliai atvaizduoti jo ribas. Jeigu smakro srities temperatūra yra artima kaklo temperatūrai, galutinis apatinės veido dalies kontūras ne visada tiksliai atspindi tikrąjį kontūrą. Tokiu atveju reikalingas kelių taškų koordinačių pakeitimas rankiniu būdu.



2.5.2.1 pav. Tiriamojo veido kontūro ir simetrijos ašies aptikimas

Pateiktas tiriamojo veido vaizdas užregistruotas su IRST: veido išorinio kontūro taškų išgaubto daugiakampio aptikimas (A) ir simetrijos ašies aptikimas (B). Pastaba: tiriamajam nebuvo nustatyta patologija BVŽ srityje. Temperatūrinė skalė pateikta dešinėje.

Šis metodas buvo svarbus tolimesniems analizės etapams, įskaitant simetrijos ašies aptikimą, temperatūrinės asimetrijos skaičiavimams bei patologinių sričių identifikavimui.

Ašiai identifikuoti išorinį daugiakampį aproksimavom elipse, pritaikant mažiausių kvadratų metodą (angl. *Least Squares Fitting*). Pagrindinis tikslas – rasti tokią elipsės lygtį, kuri geriausiai atitiktų veido kontūro taškus. Tai atliekama minimizuojant skirtumus tarp realių kontūro taškų ir teorinės elipsės kreivės [126]. Kadangi kontūro taškai tiksliai nesutampa su elipse, tada turėtume 2.6 pavidalo lygtį:

$$ax_i^2 + bx_iy_i + cy_i^2 + dx_i + ey_i + f = r_i$$
(2.6).

čia a, b, c, d, e ir f yra elipsės lygties koeficientai, kuriuos reikia rasti,  $x_i, y_i$  – konkretūs kontūro taškai,  $r_i$  yra liekana (angl. *residual*), kuri parodo, kiek vienas taškas nukrypsta nuo elipsės modelio. Kadangi ši lygtis turi daug

nežinomųjų ir kiekvienam taškui sudaroma atskira lygtis, sudaroma lygčių sistema. Susidaręs lygčių rinkinys yra išsprendžiamas naudojant mažiausių kvadratų metodą, kuris leidžia apskaičiuoti koeficientus a, b, c, d, e ir f taip, kad liekana būtų kuo mažiausia. Lygčių sistemą galima parašyti 2.7 matricos forma:

$$\begin{pmatrix} x_1^2 & x_1y_1 & y_1^2 & x_1 & y_1 & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_i^2 & x_iy_i & y_i^2 & x_i & y_i & 1 \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ x_m^2 & x_my_m & y_m^2 & x_m & y_m & 1 \end{pmatrix} \begin{pmatrix} a \\ b \\ c \\ d \\ e \end{pmatrix} = \begin{pmatrix} r_1 \\ \vdots \\ r_2 \\ \vdots \\ r_m \end{pmatrix}$$
(2.7),

Pirmoji matrica (kairėje) yra duomenų matrica, kurioje pateikiamos kontūro taškų koordinatės ( $x_i$ ,  $y_i$ ), gautos iš veido gaubtinės. Antroji matrica (viduryje) atspindi ieškomus elipsės lygties koeficientus (a, b, c, d, e ir f), kurie nusako elipsės formą, pasvirimą ir dydį. Šių parametrų vertės turi būti apskaičiuotos taip, kad kuo tiksliau atitiktų realių duomenų pasiskirstymą. Trečioji matrica (dešinėje) yra liekanų (angl. *residuals*) vektorius, kuris rodo skirtumus tarp teorinio elipsės modelio ir realių duomenų taškų. Šis vektorius leidžia įvertinti klaidų dydį ir, naudojant mažiausių kvadratų metodą, minimizuoti šiuos skirtumus taip, kad būtų nustatyta optimali elipsės forma.

Kriterijus, pagal kurį vertinamas modelio tikslumas, yra kvadratinių likučių suma *S*, kuri buvo apskaičiuota pagal 2.8 lygtį:

$$S = \sum_{i=1}^{m} r_i^2 \longrightarrow \min$$
 (2.8),

tuomet, taikant 2.9–2.11 lygtis, apskaičiuojamos elipsės centro koordinatės  $(x_c, y_c)$  ir pasvirimo kampas  $\Theta$ , kuris nurodo didžiosios elipsės ašies kryptį [127]. Šis kampas leidžia vertinti, kaip elipsė yra pasvirusi veido kontūro atžvilgiu, o centro koordinatės apibrėžia jos tikslią padėtį TV:

$$x_c = \frac{cd - bf}{b^2 - ac} \tag{2.9},$$

$$y_c = \frac{af - bd}{b^2 - ac} \tag{2.10},$$

$$\Theta = \begin{cases} 0, \text{ jeigu } b = 0, a < c; \\ \frac{1}{2}\pi, \text{ jeigu } b = 0, a > c; \\ \frac{1}{2}\operatorname{ctan}^{-1}\left(\frac{a-c}{2b}\right), \text{ jeigu } b \neq 0, a < c; \\ \frac{\pi}{2} + \frac{1}{2}\operatorname{ctan}^{-1}\left(\frac{a-c}{2b}\right), \text{ jeigu } b \neq 0, a > c. \end{cases}$$
(2.11),

čia  $x_c$  ir  $y_c$  – atitinkamai apskaičiuota elipsės centro x ir y koordinatės taškai.

Elipsės ilgesnioji ašis buvo laikoma pagrindine veido simetrijos linija, pagal kurią kairioji ir dešinioji veido pusės buvo vertinamos atskirai. Panaudojant aptiktą simetrijos ašį (žr. 2.5.2.1 pav., B) buvo atlikta temperatūros pasiskirstymo analizė, kurioje lygintos abiejų veido pusių temperatūrinės savybės.

Tuo atveju, kai smakro srities temperatūra yra artima kaklo temperatūrai, galutinis apatinės veido dalies kontūras negali tiksliai atspindėti tikrojo kontūro. Tokiu atveju būtinas interaktyvus kelių taškų koordinačių pakeitimas rankiniu būdu. Todėl simetrijos ašies aptikimas, vertinant abipusį temperatūrų pasiskirstymą, papildomai buvo tikslintas koreguojant automatiškai sugeneruotą išorinio kontūro taškų padėtį rankiniu būdu. Siekiant užtikrinti didesnį tikslumą ir sumažinti paklaidą, šis procesas buvo pakartotas penkis kartus kiekvienam pacientui, kad būtų pasiektas kuo tikslesnis temperatūros pasiskirstymo vertinimas.

#### 2.5.3. Burnos ertmės TV kontūro ir simetrijos ašies aptikimas

Burnos ertmės kontūro kraštai buvo gauti taikant panašius metodus kaip ir veido kontūro aptikime, tačiau dėl sudėtingos ir netaisyklingos burnos formos elipsės pritaikymas burnos sričiai buvo netikslus. Burnos ertmė nėra artima elipsei, todėl vietoj elipsės buvo pasirinktas centroido metodas, leidžiantis rasti geometrinės figūros centrą. Šis metodas pagrįstas visų kontūro taškų centro koordinatėmis, o ne pritaikyta idealia geometrine kreive. Simetrijos ašies *x* koordinatė buvo aptikta taikant 2.12 lygtį:

$$x_c = \frac{x_1 + x_2 + \dots + x_k}{k}$$
(2.12),

Ši lygtis nusako visų kontūro taškų centroido (masės centro) x koordinatę, kur  $x_1, x_2, ..., x_k$  yra atskirų kontūro taškų x koordinatės; k – bendras kontūro taškų skaičius, naudojamas skaičiavime,  $x_c$  – apskaičiuota centroido koordinatė išilgai x ašies. Simetrijos ašis yra vertikali tiesė, statmena x ašiai, kuri eina per tašką  $x_c$  – burnos ertmės kontūro centrą. Ši ašis naudojama tiriamąjį lauką padalyti į dvi atskiras termovizines burnos ertmės sritis – kairiąją ir dešiniąją pusę, leidžiant atskirai analizuoti gleivinės temperatūrų pasiskirstymą ir nustatyti galimus asimetrijos požymius (2.5.3.1 pav.).



2.5.3.1 pav. Tiriamojo burnos ertmės kontūro ir simetrijos ašies aptikimas

Pastaba: tiriamajam nebuvo nustatyta patologija BVŽ srityje. Pateiktas burnos ertmės kontūro vaizdas (punktyrinė linija) ir simetrijos ašis (statmena ištisinė linija). Temperatūrinė skalė pateikta dešinėje.

## 2.6. Veido ir burnos ertmės dominančios srities (ROI) temperatūrinės asimetrijos aptikimas

Po veido ir burnos ertmės simetrijos ašių aptikimo buvo atliekamas temperatūrų pasiskirstymo vertinimas, siekiant įvertinti galimą temperatūrų asimetriją. Pirmiausia buvo apskaičiuojamos vidutinės temperatūros reikšmės abiejose veido pusėse ir lyginamos tarpusavyje. Vidutinės temperatūros reikšmės dešinėje ir kairėje veido ar burnos ertmės pusėse skirtumas gali būti išreikštas 2.13 lygtimi:

$$\Delta T = \left| \frac{1}{N_K} \sum_{i=1}^{N_K} T_{Ki} - \frac{1}{N_D} \sum_{i=1}^{N_D} T_{Di} \right|$$
(2.13),

čia  $T_{Ki}$  ir  $T_{Di}$  yra atitinkamai *i* pikselį atitinkanti temperatūra kairėje ir dešinėje pusėje;  $N_K$  ir  $N_D$  – atitinkamai kairėje ir dešinėje pusėje esančių pikselių skaičius.

Jei skirtumas tarp vidutinių temperatūrų buvo pakankamai reikšmingas, jis buvo laikomas asimetrijos rodikliu, galinčiu rodyti patologinius procesus.

Tačiau, jei skirtumas tarp vidutinių temperatūrų buvo per mažas ir nepakankamai informatyvus diagnostikai, buvo analizuojamos maksimalios temperatūrų vertės, kas padėjo aptikti lokalias aukštesnės temperatūros zonas. Be to, buvo vertinamas artimą maksimaliai temperatūrai turinčių taškų skaičius ir jų pasiskirstymas patologinėje srityje. Veido ar burnos ertmės dešinės (kairės) pusės TV taškų skaičius, kurio temperatūra  $\Delta T$  dydžio laipsniu mažesnė už maksimalią priešingos pusės temperatūrą, buvo apskaičiuotas naudojant abiejų pusių histogramas, taikant 2.14 formulę:

$$n = \begin{cases} \sum_{i=i_{T_{K_{maks}}}}^{N_{HK}} n_{Ki}, \text{ jeigu } T_{K_{maks}} > T_{D_{maks}} + \Delta T; \\ \sum_{i=i_{T_{D_{maks}}}}^{N_{HD}} n_{Di}, \text{ jeigu } T_{D_{maks}} > T_{K_{maks}} + \Delta T; \\ 0, \text{ jeigu } |T_{D_{maks}} - T_{K_{maks}}| < \Delta T. \end{cases}$$

$$(2.14),$$

čia  $T_{D_{\text{maks}}}$ ,  $T_{K_{\text{maks}}}$  – atitinkamai maksimali dešiniosios ir kairiosios pusės temperatūra,  $i_{T_{D_{\text{maks}}}}$  ir  $i_{T_{K_{\text{maks}}}}$  – indekso reikšmės, atitinkančios maksimalią temperatūrą atitinkamoje pusėje,  $N_H$  – bendras analizuojamų pikselių skaičius kairėje ir dešinėje pusėje ir  $n_i$  – pikselių skaičius atitinkamoje veido pusėje, kur temperatūra viršija nustatytą ribą.  $N_H$  apskaičiuojamas pagal užsiduotą temperatūros žingsnį tarp gretimų izoterminių linijų  $\partial T$  pagal 2.15 formulę:

$$N_{H} = \left[\frac{T_{\text{maks}} - T_{\text{min}}}{\partial T}\right]$$
(2.15),

čia  $\partial T$  – segmento temperatūrų diapazonas arba temperatūrų skirtumas tarp gretimų izoterminių linijų.

Toliau, analogiškai buvo vertinama burnos ertmės temperatūrų asimetrija, lyginant vidutines ir maksimalias burnos ertmės dešinės ir kairės pusių temperatūras. Aptikus reikšmingą temperatūrų asimetriją, buvo atliktas patologinės srities vaizdo segmentavimas. Šis procesas padėjo tiksliau išryškinti temperatūros pokyčių zonas ir įvertinti jų pasiskirstymą. Buvo vertinama konkreti veido ar burnos pusė, siekiant nustatyti izotermines linijas-kontūrus, kuriuose temperatūra išlieka pastovi.

Segmentavimui buvo taikomas slenkstinis metodas (angl. *thresholding*), kuris leidžia išskirti skirtingas temperatūros sritis naudojant iš anksto nustatytas temperatūros ribas. Šis metodas naudoja po dvi temperatūros ribas, kad TV atskiras segmentas būtų paverstas dvejetainiu (angl. *binary image*). Tai reiškia, kad tik tam tikrame temperatūros intervale esantys pikseliai yra išskiriami kaip reikšmingi, o visi kiti pikseliai priskiriami fonui.  $\partial T$  (segmento temperatūrų diapazonas arba temperatūrų skirtumas tarp gretimų izoterminių linijų) apibrėžia temperatūrų skirtumą tarp gretimų izoterminių sričių, todėl segmentavimas leidžia tiksliai nustatyti temperatūrinių pokyčių ribas. Kiekvienas pikselis TV turi tam tikrą temperatūros reikšmę, kuri gali skirtis priklausomai nuo temperatūrų pasiskirstymo tiriamoje srityje.  $\partial T$  reikšmė nurodo, kiek laipsnių skiria dvi gretimas temperatūros ribas TV. Jei  $\partial T$  yra mažas, tai vaizdas segmentuojamas į daug smulkių temperatūrų intervalų, leidžiančių matyti labai tikslius temperatūrinius pokyčius. Jei  $\partial T$  yra didelis, tai segmentacija bus grubesnė, išskiriant tik didesnius temperatūrinius skirtumus. Mažesnis  $\partial T$  suteikia tikslesnį šiluminį vaizdą, o didesnis  $\partial T$  leidžia lengviau vizualizuoti bendrą temperatūrų pasiskirstymą.

Po segmentavimo gautas spalvų žemėlapis yra svarbi priemonė veido patologijų pozicijai įvertinti. Izoterminių linijų skaičius ir reikšmės nustatomos automatiškai, remiantis veido srities minimaliomis ir maksimaliomis temperatūromis, taip užtikrinant objektyvų šilumos pasiskirstymo vaizde vertinimą. TV duomenys buvo analizuojami atsižvelgiant į temperatūros skirtumus tarp veido odos ir burnos gleivinės (epitelio), lyginant paveiktą ir sveiką puses. Patologinė sritis, kurioje stebimi reikšmingi pokyčiai, dėl aukštesnės temperatūros vizualiai išryškinta kontrastinga spalva, leidžiančia lengviau identifikuoti galimus pakitimus.

Toliau, šio tyrimo metu nustatyta veido ir burnos pusės TV asimetrinės temperatūros vieta ir palyginta su KT duomenimis. Po atlikto KT tyrimo gauta informacija apie patologijos buvimą ar nebuvimą bei aptikta pažeidimo lokalizacija buvo panaudota kuriant binarinį klasių vektorių. Tai reiškia, kad pagal KT duomenis kiekvienas tiriamasis buvo priskirtas vienai iš dviejų kategorijų: su patologiniais pakitimais arba be jų.

Tokiu būdu, remiantis apskaičiuotomis temperatūrų reikšmėmis, kiekvienam pacientui buvo sukurtas požymių vektorius, kuris apibūdina unikalius TV duomenis.

## 2.7. *k*NN klasterizavimo algoritmo taikymas BVŽ patologijoms aptikti

### 2.7.1. DI metodų taikymo poreikis

Vizualiai ar po aktualios srities išskyrimo ne visuose termografiniuose vaizduose buvo galima patikimai identifikuoti patologinę sritį. Todėl pasitelkėme dirbtinio intelekto (DI) ir mašininio mokymosi (MM) algoritmus, gebančius atpažinti patologiją pagal individualiai parinktus požymius (žr. žemiau). Pacientų grupavimui į sveikų ir sergančių grupes pasirinktas kNN klasterizavimo metodas [128], kuris yra tinkamas, kai nėra daug duomenų apmokymui. Modelis buvo apmokytas identifikuoti patologinius pokyčius.

Kadangi tyrime siekėme atskirti patologinius atvejus nuo sveikų, buvo pasirinktas binarinis klasterizavimas, kuriame pacientai buvo suskirstyti į dvi grupes: su patologija ir be patologijos. *k*NN klasterizacijos kriterijumi buvo pasirinkta temperatūrų asimetrija tarp veido ir burnos simetriškų pusių, aukštos temperatūros taškų pasiskirstymas, bei temperatūros deviacijų skirtumai, kurie leido efektyviai nustatyti galimus patologinius pokyčius TV.

## 2.7.2. Požymių vektoriaus formavimas

Siekiant identifikuoti patologiją, naudojant termovaizduose išskirtas ROI sritis buvo sukurtas požymių vektorius, sudarytas iš aštuonių skirtingų temperatūrinių požymių (2.7.2.1 lentelė). Šiuo tikslu, kiekvienam tiriamajam buvo analizuojamos atskirų pikselių temperatūros keturiose skirtingose srityse, t. y. kairės ir dešinės pusės veido bei burnos ertmės TV.

Požymis	Reikšmė
$\Delta T_{v.vid}$ (°C)	Vidutinių temperatūrų skirtumas tarp dešinės ir kairės veido pusių
$\Delta T_{b.vid}$ (°C)	Vidutinių temperatūrų skirtumas tarp dešinės ir kairės burnos ertmės pusių
$\Delta T_{v.maks}$ (°C)	Maksimalių temperatūrų skirtumas tarp dešinės ir kairės veido pusių
$\Delta T_{b.maks}$ (°C)	Maksimalių temperatūrų skirtumas tarp dešinės ir kairės burnos ertmės pusių
$n_{\nu}$	Pikselių skaičius TV dešinėje (kairėje) veido pusėje, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje veido pusėje
nb	Pikselių skaičius TV dešinėje (kairėje) burnos ertmės pusėje, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje burnos ertmės pusėje
$\Delta DEV_{v}$	Absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai veido pusei
$\Delta DEV_b$	Absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai burnos ertmės pusei

**2.7.2.1 lentelė.** Atrinkti požymiai, apibūdinantys temperatūrinį pasiskirstymą, naudoti požymių vektoriaus sudarymui

Pastaba: TV - termografinis vaizdas.

Kiekvienam pacientui suformuoti požymių vektoriai buvo naudojami TV klasterizavimui į sveikų ir sergančių grupes. Vienos veido ar burnos ertmės pusės TV pikselių skaičius, kurio temperatūra 0,4 laipsniu aukštesnė už maksimalią priešingos pusės temperatūrą, buvo apskaičiuotas naudojant

abiejų pusių histogramas. Šis vektorius tapo pagrindu algoritmo mokymui, identifikuojant naujus sveikus ir patologinius atvejus pagal TV duomenis.

#### 2.7.3. Termovaizdų klasterizavimas naudojant kNN

Sveikų tiriamųjų ir pacientų, turinčių skirtingas burnos ar žandikaulių srities patologijas (navikinės arba uždegiminės kilmės), apdoroti TV duomenys buvo saugomi kompiuterio atmintyje, kaip požymių matricos. Šios matricos leido suskirstyti tiriamuosius į dvi grupes: sergančius (1), jei buvo nustatyta navikinės ar uždegiminės kilmės patologija, ir sveikus (0), jei patologijos nebuvo. Tokia struktūra leido TV klasterizavimui taikyti MM algoritmus (2 priedas).

Šiame tyrime tiriamųjų TV grupavimui buvo naudojama *k*NN klasterizavimo algoritmas, paremtas atstumų nustatymu tarp grupuojamų duomenų. *k*NN gerai veikia ir mažuose duomenų rinkiniuose, kurie neturi daug požymių. Todėl *k*NN klasterizacijos modelis suskirsto tiriamuosius duomenis į pasirinktas grupes aptikdamas mažiausius skirtumus tarp atitinkamų reikšmių. Šiame tyrime, *k*NN pagrįstas funkcijų vektoriais ir klasteriais iš mokymo duomenų rinkinio, taikant 2.16 formulę:

$$d = \sum_{n=1}^{p} (x_n^{\text{test}} - x_n^{\text{mok}})$$
(2.16),

čia p – požymių vektoriaus dydis,  $x_n^{\text{test}}$  – testuojamo TV požymio imties vektoriaus reikšmė,  $x_n^{\text{mok}}$  – sistemos apmokymui naudojamo TV vektoriaus reikšmė.

Suformuotos požymių vektorinės reikšmės lyginamos su treniravimo metu sukurtomis požymių matricos reikšmėmis. Kadangi duomenų klasterizavimas buvo pagrįstas artimiausio kaimyno metodu, kiekvieno tiriami BVŽ srities TV išskirtų požymių duomenys buvo priskiriami artimiausiam kaimynui, kuris atstovavo atitinkamą tiriamųjų grupę.

Tyrimo metu, tokie požymių vektoriai buvo apskaičiuoti visiems tiriamiesiems. Po to, duomenų rinkinys buvo atsitiktinai suskirstytas į du pogrupius, skirtus mokymui ir testavimui. Mokymo pogrupis apima tik pusę duomenų, t. y. 48 pacientų TV: 24 tiriamųjų TV, neturinčių jokios patologijos, ir 24 tiriamųjų TV, kuriuose pagal KT buvo nustatyta patologija. Kad užtikrintume modelio stabilumą ir rezultatų patikimumą, mokymo ir testavimo rinkinių padalijimo procedūra buvo kartojama 24 kartus, kiekvieną kartą pasirenkant skirtingus duomenų rinkinius mokymui ir testavimui. Tokiu būdu buvo užtikrinta, kad modelis būtų treniruojamas ir testuojamas su įvairiais duomenų rinkiniais, taip išvengiant atsitiktinių veiksnių įtakos rezultatams. *k*NN klasterizavimo algoritmas priskiria naujus duomenis klasei, lygindamas juos su duomenimis iš mokymo duomenų rinkinio. Kadangi bandymo duomenų rinkinyje tikrosios kategorijos yra žinomos (patvirtintos KT vertinimo duomenimis), galima įvertinti *k*NN modelio tikslumą – nustatyti, kiek teisingai modelis priskiria stebėjimus tinkamoms kategorijoms. Tai leidžia įvertinti algoritmo našumą ir jo gebėjimą tiksliai klasterizuoti naujus duomenis.

#### 2.7.4. Diagnostinio tikslumo įvertinimas

Pateikto metodo klasterizavimo teisingumui įvertinti buvo suformuota maišaties matrica (angl. *confusion matrix*) ir apskaičiuotos tikslumo, jautrumo ir specifiškumo reikšmės [129]. Maišaties matrica buvo sudaryta siekiant įvertinti modelio klasterizacijos tikslumą, lyginant prognozuotas kategorijas su tikrosiomis diagnozėmis. Joje buvo apskaičiuoti keturi pagrindiniai atvejų tipai: 1) teisingai teigiami (tT) (angl. *True Positive, TP*), kai modelis teisingai nustatė patologiją, 2) teisingai neigiami (tN) (angl. *True Negative, TN*), kai modelis tiksliai identifikavo, kad pacientas neturi patologijos, 3) klaidingai teigiami (kT) (angl. *False Positive, FP*), kai modelis neteisingai priskyrė patologiją sveikam asmeniui ir 4) klaidingai neigiami (kN) (angl. *False Negative, FN*), kai modelis praleido esamą patologiją ir klaidingai priskyrė asmenį sveikųjų grupei (2.7.4.1 lentelė).

Charakteristika	Žymėjimas su patologija	Žymėjimas be patologijos	Reikšmė
Teigiamas	tT (teisingai teigiamas)	kT (klaidingai teigiamas)	tT + kT
Neigiamas	kN (klaidingai neigiamas)	tN (teisingai neigiamas)	kN + tN
Reikšmė	tT + kN	kT + tN	

2.7.4.1 lentelė. Maišaties matricos sudarymo atvejai

Klasterizavimo tikslumas, kuris parodo, kokia dalis visų modelio prognozių buvo teisingos, apskaičiuojamas lyginant visų teisingai nustatytų atvejų (tiek teigiamų, tiek neigiamų) skaičių su bendru visų atliktų prognozių skaičiumi. Tai leidžia įvertinti bendrą modelio veikimą Jis apskaičiuojamas pagal 2.17 formulę:

$$Tikslumas = \frac{tT + tN}{tT + tN + kT + kN}$$
(2.17).

Klasterizavimo jautrumas, kuris parodo, kokią dalį tikrai sergančių pacientų modelis sugebėjo teisingai atpažinti, apskaičiuojamas lyginant teisingai nustatytų teigiamų atvejų skaičių su visais tikraisiais teigiamais atvejais, įskaitant tuos, kuriuos modelis klaidingai priskyrė sveikųjų grupei. Tai reiškia, kad kuo didesnė šio rodiklio vertė, tuo modelis geriau aptinka patologinius sergančių tiriamųjų atvejus. Jautrumas apskaičiuojamas pagal 2.18 formulę:

$$Jautrumas = \frac{tT}{tT + kN}$$
(2.18).

Specifiškumas, kuris parodo, kokią dalį iš tikrųjų sveikų pacientų modelis teisingai atpažino kaip sveikus, apskaičiuojamas lyginant teisingai nustatytų neigiamų atvejų skaičių su visais tikraisiais neigiamais atvejais, įskaitant tuos, kuriuos modelis klaidingai priskyrė sergančiųjų grupei. Kuo didesnė specifiškumo vertė, tuo modelis geriau atskiria nepatologinius sveikų pacientų atvejus ir sumažina klaidingai teigiamų rezultatų skaičių. Jis apskaičiuojamas pagal 2.19 formulę:

Specifiškumas = 
$$\frac{tN}{tN + kT}$$
 (2.19).

Galiausiai, apskaičiuoti jautrumo ir specifiškumo rodikliai grafiškai atvaizduoti imties veikimo charakteristikų analizės (angl. Receiver Operating Characteristic, ROC) kreivėje, kuri vizualizuoja modelio gebėjimą atskirti teigiamus ir neigiamus atveius, keičiant klasterizacijos slenkstine reikšme, kas lemia skirtingus jautrumo ir specifiškumo derinius [129]. Ši kreivė leidžia ne tik palyginti skirtingus modelius, bet ir priimti sprendimus dėl jų praktinio taikymo. Kaip parodyta 2.7.4.1 pav., grafike ROC kreivė prasideda taške (0,0), kuris reiškia, kad modelis niekada negrupuoja atvejų, kaip teigiamų, ir baigiasi taške (1,1), kai modelis visus atvejus priskiria teigiamai grupei. ROC kreivėje x ašis svyruoja nuo 0 iki 1 ir atspindi 1 – specifiškumą, tai yra klaidingai teigiamu rezultatu dažni, o y ašis atspindi jautruma (tikrujų teigiamų rezultatų dažnį) [130]. Tai reiškia, kad judant x ašimi į dešinę, didėja klaidingai teigiamų prognozių skaičius, o judant y ašimi į viršų, didėja teisingai nustatytų teigiamų atvejų skaičius. Modelis yra tuo geresnis, kuo aukščiau kreivė kyla i kairiaja grafiko dali, nes tai rodo dideli jautruma ir maža klaidingai teigiamų prognozių skaičių.



2.7.4.1 pav. Testavimo geba pasižyminčių požymių ROC kreivė

Punktyrinė linija žymi, kai x = y. Plotas po ROC kreive AUC (angl. *Area Under the Curve*) – paskaičiuotas parametras, padedantis įvertinti klasterizacijos modelio tikslumą. Kuo didesnis AUC, tuo geresnis modelio gebėjimas teisingai atskirti teigiamus ir neigiamus atvejus, atitinkamai: modelis tobulas (AUC = 1,0), labai geras (AUC > 0,9), gero tikslumo (AUC tarp 0,8 ir 0,9), vidutinio tikslumo (AUC tarp 0,5 ir 0,7) ir diagnostinės vertės neturi, nes grupuoja atsitiktinai (AUC = 0,5) [129–131].

#### 2.7.5. Statistinė analizė

Kiekvienas TV veido ir burnos ertmės kontūras apskaičiuotas kartojant penkis kartus. Statistinė duomenų analizė buvo atliekama naudojant *Microsoft Excel* programinę įrangą (Microsoft, JAV) ir *IBM SPSS* 22 programine įranga (IBM Corp., NY, JAV). Skaitinių duomenų vidurkiai pateikiami su standartiniais nuokrypiais (SD), kas leidžia įvertinti reikšmių sklaidą. Norint palyginti vidurkius buvo taikomas Stjudento t testas, kai lyginami duomenys tarp dviejų grupių ir naudojama vienfaktorinė dispersinė analizė ANOVA (parametrinis testas) ar Kruskal-Wallis testas (neparametrinis testas), kai lyginamos daugiau nei dvi grupės. Statistinė normalumo analizė atlikta taikant Shapiro-Wilk testą. Vidurkių skirtumai laikomi statistiškai reikšmingais, kai p < 0,05. Matematiniam termovaizdų veido ir burnos ertmės kontūrų nustatymui ir klasterizacijos algoritmų kūrimui buvo naudota *MATLAB* programinė įranga (The Math Works, Inc., JAV). Histogramų braižymui naudota statistinė *SPSS 22* programa.

## **3. REZULTATAI**

# 3.1. Demografiniai, antropometriniai ir klinikiniai tiriamųjų duomenys

Klinikinis tyrimas atliktas Lietuvos sveikatos mokslų universiteto ligoninės Kauno klinikų Radiologijos klinikoje, gavus Kauno regioninio biomedicinių tyrimų etikos komiteto leidimą (2014 m. birželio 3 d. Nr. BE-2-31). Tiriamieji, išsamiai susipažinę su tyrimų, pasirašė asmens informavimo ir sutikimo formą. Įtraukimas į tyrimą vyko 2014–2016 metais.

Moksliniame tyrime dalyvavo 94 pacientai: iš jų 55 (58,5 proc.) priskirti tiriamųjų grupei su patologiniais pakitimais ir 39 (41,5 proc.) priskirti tiriamųjų grupei be patologinių pakitimų. Pacientų demografiniai, antropometriniai ir klinikiniai duomenys pateikti 3.1.1 lentelėje.

Demografiniai duomenys	Su patologiniais pakitimais (n = 55)	Be patologinių pakitimų (n = 39)	
Amžiaus ribos (metais)	18-86	20-64	
Vidutinis amžius (metais) ± SEM	$53,3\pm2,53$	$33,5 \pm 2,03$	
Moterys, n (proc.)	30 (54,5)	17 (43,6)	
Vyrai, n (proc.)	25 (45,5)	22 (56,4)	
Iš viso, n (proc.)	55 (100)	39 (100)	
KT / MRT nustatyta patologijos vieta			
Dešinė pusė, n (proc.)	20 (36,4)	0 (0)	
Kairė pusė, n (proc.)	23 (41,8)	0 (0)	
Abipus, n (proc.)	12 (21,8)	00 (0)	
Vyrų / moterų patologijos vieta			
Vyrai, dešinė pusė, n (proc.)	13 (52)	0 (0)	
Vyrai, kairė pusė, n (proc.)	10 (40)	0 (0)	
Vyrai, abipus, n (proc.)	2 (8)	0 (0)	
Moterys, dešinė pusė, n (proc.)	8 (26,7)	0 (0)	
Moterys, kairė pusė, n (proc.)	13 (43,3)	0 (0)	
Moterys, abipus, n (proc.)	9 (30)	0 (0)	

3.1.1 lentelė. Demografiniai ir klinikiniai tiriamųjų duomenys

Šiame tyrime buvo išskirtos šios pacientų grupės: sveikų tiriamųjų (ST) grupė, kurią sudarė sveiki savanoriai (SS) ir asmenys, kuriems KT ar MRT tyrimų metu nebuvo nustatyta jokių struktūrinių pakitimų ar patologinių darinių. Tiriamųjų su patologiniais pakitimais grupes sudarė pacientai su navikinės (NP), uždegiminės (UP) ir mišrios (UP / NP) kilmės patologija. Navikinės kilmės patologija buvo nustatyta radiologinio tyrimo metu ir vėliau patvirtinta histopatologiškai. Uždegiminės kilmės patologija, tokia kaip abscesas, celiulitas, sinusitas, limfadenitas, sialadenitas, odontogeninės ar kitos kilmės infekciniai uždegiminiai pakitimai, buvo nustatyti KT tyrimo metu ir patvirtinti klinikinių tyrimų duomenimis.

## 3.2. Temperatūrinės asimetrijos nustatymas IRST tyrimais

## 3.2.1. Sveikų tiriamųjų TV vertinimas

Sveikiems tiriamiesiems (ST grupė, n = 39), vertinant keturias pagrindines analizuojamas sritis, nebuvo nustatyta statistiškai reikšmingų temperatūrinių asimetrijų. Tai reiškia, kad temperatūrinis pasiskirstymas tarp simetriškų veido ir burnos sričių buvo tolygus, be ryškių temperatūrinių skirtumų, kurie galėtų rodyti patologinius pokyčius. 3.2.1.1 pav. pateikti sveiko tiriamojo veido (A) ir burnos ertmės (B) priekinės projekcijos TV žemėlapių pavyzdžiai.



3.2.1.1 pav. Sveiko tiriamojo veido ir burnos kontūro bei simetrijos ašies aptikimas

Simetrijos ašis (ištisinė linija) yra didžioji elipsės (punktyrinė linija) ašis. Pateiktos sveiko tiriamojo termogramos frontalinėje plokštumoje (A) ir išsižiojus (B). Pastaba: veido ir burnos ertmės termogramose nėra temperatūrinės asimetrijos. Temperatūrinė skalė pateikta dešinėje.

TV buvo apdoroti dviem etapais (žr. Metodai ir 1 priedas), taikant algoritmines kontūro aptikimo procedūras, išorinio veido kontūro ir burnos ertmės aktualios srities (ROI) aptikimui bei simetrijos ašies padėties suradimui. Apskaičiuoti veido ir burnos ertmės ROI termografinio vaizdo kairės / dešinės pusės temperatūrų požymiai pateikti 3.2.1.1 lentelėje.

**3.2.1.1 lentelė.** Vieno sveiko tiriamojo (3.2.2.1 pav.) TV temperatūrų požymiai nustatyti kairiosios / dešiniosios veido ir burnos ertmės ROI pusėse

	ROI	<i>Т<sub>vidK</sub></i> (°С)	T <sub>maksK</sub> (°C)	T <sub>vidD</sub> (°C)	T <sub>maksD</sub> (°C)	$\Delta T_{vid}$ (°C)	$\Delta T_{maks}$ (°C)	$\Delta DEV$	<b>n</b> v/b
ST	v	$33,\!47\pm0,\!039$	36,17	$\textbf{33,}\textbf{64} \pm \textbf{0,}\textbf{004}$	36,03	0,17	0,14	0,02	0
	b	$34,92 \pm 0,023$	36,97	$35,03 \pm 0,013$	36,78	0,11	0,19	0,08	0

ST – sveikas tiriamasis, kuriam KT tyrimo metu nebuvo aptikta patologija, ROI – aktuali veido / burnos ertmės sritis, v – veidas, b – burnos ertmė,  $T_{vidK}$  ir  $T_{maksK}$  – atitinkamai vidutinė ir maksimali temperatūra kairėje,  $T_{vidD}$  ir  $T_{maksD}$  – atitinkamai vidutinė ir maksimali temperatūra dešinėje,  $\Delta T_{vid}$  ir  $\Delta T_{maks}$  – atitinkamai vidutinės ir maksimalios temperatūros skirtumas tarp kairės / dešinės pusių,  $\Delta DEV$  – deviacijų skirtumas tarp visų pikselių, priklausančių dešinėje (kairėje) veido ar burnos pusėse, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje veido ar burnos pusėje. Vidurkiai ± SD.

Visiems į tyrimą įtrauktiems ST grupės tiriamiesiems (n = 39) keturių tirtų sričių termografiniuose vaizduose nebuvo akivaizdžios temperatūrinės asimetrijos (p < 0,05, taikant Stjudento t testą): veido kairėje / dešinėje pusėse, atitinkamai 33,78 ± 1,693 °C ir 33,82 ± 1,617 °C, bei burnos ertmės kairėje / dešinėje pusėse, atitinkamai 35,73 ± 1,613 °C ir 35,74 ± 1,642 °C. Šiems tiriamiesiems paskaičiuoti vidutinių temperatūrų skirtumai ( $\Delta T_{vid}$ ) tarp kairės / dešinės veido ir burnos ertmės pusių (atitinkamai, 0,12 ± 0,21 °C ir 0,14 ± 0,19 °C), bei maksimalių temparatūrų skirtumai ( $\Delta T_{maks}$ ) tarp kairės / dešinės veido ir burnos ertmės pusių (atitinkamai, 0,062 ± 0,19 °C ir 0,075 ± 0,25 °C) taip pat reikšmingai nesiskyrė (p < 0,05). Be to, apskaičiuotas pikselių skaičius TV dešinėje (kairėje) veido ir burnos ertmės pusėse, kurių temperatūra yra 0,4 °C aukštesnė už maksimalią temperatūrą priešingoje veido ir burnos ertmės pusėse buvo atitinkamai 0,086 ± 0,07 ir 0,11 ± 0,06 (p < 0,05). ST grupės tiriamųjų TV temperatūrinių požymių skirtumo pasiskirstymo histogramos, palygintos su normaliojo skirstinio kreive, pateiktos 3.2.1.2 pav.



3.2.1.2 pav. ST grupės sklaidos histogramos su normaliojo skirstinio kreivėmis pagal veido ir burnos ertmės vidutinius ir maksimalius temperatūrinius požymius

Histogramų rinkinys pateiktas pagal parinktus keturis temperatūrinius požymius. Paskaičiuotos veido / burnos ertmės sričių vidutinių (kairėje) ir maksimalių (dešinėje) temperatūrų skirtumo tarp dešinės ir kairės pusių reikšmės, atitinkamai veido srityje **(A, B)** ir burnos ertmės srityje **(C, D)**. Vidutinių temperatūrų skaičiavimas pagrįstas visų pikselių temperatūrų sumavimu vienoje veido arba burnos ertmės, kontūrais apribotos srities, pusėje ir padalinamos iš tų taškų skaičiaus. Kiekvienam požymiui sudaryta histograma su tiriamųjų atvejų skaičiumi (n = 39) yra pateikta y ašyje, naudojant x ašies intervalą nuo -1,5 iki 1,5 su 0,2 pločio stulpeliais. Pastaba: kiekvienas stulpelis rodo, kiek atvejų patenka į konkretų intervalą. Normaliojo skirstinio kreivė (raudona punktyrinė linija) atspindi pasiskirstymą pagal kiekvieno kintamojo vidurkį ir standartinį nuokrypį.

Visiems ST ir SS grupės tiriamiesiems (atitinkamai 3.2.1.2 ir 3.2.1.3 pav.) buvo stebima maža temperatūrų skirtumų sklaida ir tolygus pasiskirstymas. Šių grupių histogramų pasiskirstymas yra simetriškas ir koncentruotas aplink nulį, kas rodo požymių pusiausvyrą ir nedidelį kraštutinių reikšmių skaičių. Tokie rezultatai atspindi normalią termoreguliaciją, be ryškių regioninių temperatūros skirtumų, kurie galėtų reikšti patologinius procesus. Maža sklaida temperatūrų pasiskirstyme taip pat rodo, kad šilumos perdavimas audiniuose vyksta tolygiai, be reikšmingų šuolių, o tai būdinga sveikam audiniui su normalia kraujotaka.



**3.2.1.3 pav.** SS grupės sklaidos histogramos su normaliojo skirstinio kreivėmis pagal veido ir burnos ertmės vidutinius ir maksimalius temperatūrinius požymius

Histogramų rinkinys pateiktas pagal parinktus keturis temperatūrinius požymius. Paskaičiuotos veido / burnos ertmės sričių vidutinių (kairėje) ir maksimalių (dešinėje) temperatūrų skirtumo tarp dešinės ir kairės pusių reikšmės, atitinkamai veido srityje **(A, B)** ir burnos ertmės srityje **(C, D)**. Vidutinių temperatūrų skaičiavimas pagrįstas visų pikselių temperatūrų sumavimu vienoje veido arba burnos ertmės, kontūrais apribotos srities, pusėje ir padalinamos iš tų taškų skaičiaus. Kiekvienam požymiui sudaryta histograma su tiriamųjų atvejų skaičiumi (n = 29) yra pateikta y ašyje, naudojant x ašies intervalą nuo –1,5 iki 1,5 su 0,2 pločio stulpeliais. Pastaba: kiekvienas stulpelis rodo, kiek atvejų patenka į konkretų intervalą. Normaliojo skirstinio kreivė (raudona punktyrinė linija) atspindi pasiskirstymą pagal kiekvieno kintamojo vidurkį ir standartinį nuokrypį.

#### 3.2.2. Klinikinių atvejų su navikinės kilmės patologija TV vertinimas

Pacientams, kuriems diagnozuota navikinė patologija (n = 27) (gėrybiniai / piktybiniai, atitinkamai 4 / 23) termovaizduose buvo reikšmingi temperatūrų skirtumai (p < 0,05), lyginant su ST grupės analogiškais duomenimis. NP grupės pacientų TV  $\Delta T_{vid}$  tarp kairės / dešinės pusių, paskaičiuotas veido ir burnos ertmės ROI srityje, atitinkamai buvo 0,21 ± 0,1 °C ir 0,39 ± 0,1 °C, o  $\Delta T_{maks}$  paskaičiuotas veido ir burnos ertmės ROI srityje, atitinkamai buvo 0,20 ± 0,14 °C ir 0,49 ± 0,18 °C. NP grupės tiriamiesiems reikšmingi skirtumai gauti vertinant burnos ertmės ROI srities požymius (p < 0,05), lyginant su tokiais duomenimis ST grupėje. Taipogi, šių tiriamųjų TV apskaičiuotas pikselių skaičius dešinėje (kairėje) veido ir burnos ertmės pusėse, kurių temperatūra yra 0,4 °C aukštesnė už maksimalią temperatūrą priešingoje veido ir burnos ertmės pusėse buvo atitinkamai 2,48 ± 1,85 ir 48,57 ± 22,6 (p < 0,05).

Žemiau pateikiami keli reprezentatyvūs navikinės patologijos klinikiniai atvejai, kai IRST tyrimuose BVŽ srityje nustatyta skirtingo dydžio temperatūrinė asimetrija: akivaizdžiai matoma, mažai matoma arba nematoma, kurių temperatūrinės charakteristikos detalizuotos 3.2.2.1 lentelėje.

	ROI	T <sub>vidK</sub> (°C)	T <sub>maksK</sub> (°C)	T <sub>vidD</sub> (°C)	T <sub>maksD</sub> (°C)	∆T <sub>vid</sub> (°C)	Δ <i>T<sub>maks</sub></i> (°C)	$\Delta DEV$	<b>n</b> v/b
NP #1	v	34,42 ± 0,019	36,45	33,55 ± 0,017	36,23	0,87	0,22	0,0183	0
	b	37,84 ± 0,023	38,97	37,29 ± 0,217	38,33	0,55	0,64	0,15	35
NP #2	v	$35,50 \pm 0,054$	38,14	$35,52 \pm 0,032$	37,96	0,28	0,18	0,044	0
	b	$36,85 \pm 0,001$	38,15	36,91 ± 0,017	38,57	-0,06	-0,42	0,093	143
NP #3	v	32,83 ± 0,015	35,01	32,94 ±0,001	36,12	-0,11	-1,11	0,031	0
	b	35,84 ± 0,085	37,82	35,88 ± 0,062	37,88	-0,04	-0,06	0,17	125

**3.2.2.1 lentelė.** Trijų klinikinių atvejų su navikine patologija (NP), pateiktų 3.2.2.1–3.2.2.3 pav., TV temperatūriniai požymiai

NP – navikinė patologija, ROI – dominanti sritis, v – veidas, b – burnos ertmė,  $T_{vidK}$  ir  $T_{maksK}$  – vidutinė ir maksimali temperatūra kairėje,  $T_{vidD}$  ir  $T_{maksD}$  – vidutinė ir maksimali temperatūra dešinėje,  $\Delta T_{vid}$  ir  $\Delta T_{maks}$  – vidutinės ir maksimalios temperatūros skirtumas tarp kairės / dešinės pusių,  $\Delta DEV$  – deviacijų skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai veido ir burnos ertmės pusei,  $n_{v/b}$  – pikselių skaičius TV dešinėje (kairėje) veido ar burnos pusėse, kurių temperatūra yra 0,4 °C aukštesnė už maksimalią temperatūrą priešingoje veido ar burnos pusėje. Vidurkiai ± SD.

3.2.2.1 pav. pateiktas pirmasis klinikinis atvejis, kai po pirminės apžiūros, pastebėjus asimetrinę kairės veido pusės deformaciją apatinio žandikaulio srityje, pacientas nukreiptas atlikti KT tyrimą.



**3.2.2.1 pav.** Pirmo klinikinio atvejo diagnostiniai vaizdai, kai IRST matoma akivaizdi temperatūrinė asimetrija

Viršuje: KT tyrimo kauliniu langu pjūvis ašinėje plokštumoje (A) ir MRT aukštos rezoliucijos T1 turbo aidų seka su intraveniniu kontrastavimu, ašinis pjūvis (B) su navikinėmis masėmis apatinio žandikaulio kairėje pusėje. Viduryje histologinis pjūvis (C) su patvirtinta apatinio žandikaulio fibrozinės displazijos diagnoze. Histologiniame pjūvyje matomos gausios smulkios, osteoblastais neapsuptos jauno kaulinio audinio trabekulės, tarp kurių išvešėjęs fibrozinis audinys su gausiais, mitotiškai neaktyviais fibroblastais. Apačioje: termografinis vaizdas (TV) frontalinėje plokštumoje pacientui susičiaupus (D) ir pacientui išsižiojus burnos ertmės sritis prieš vaizdo segmentaciją (E) ir po segmentavimo procedūros (F). Pastaba: rodyklė rodo temperatūrinės asimetrijos sritį prieš (E) ir po (F) segmentacijos. Temperatūrinė skalė dešinėje.

Radiologinių tyrimų metu, kairėje apatinio žandikaulio pusėje buvo pastebėtas heterogeninės struktūros ekspansinis darinys (3.2.2.1 pav., A, B), remodeliuojantis kaulą ir ženkliai ploninantis žievinį sluoksnį. Žievinio sluoksnio defekto ir darinio plitimo į aplinkinius minkštuosius audinius nebuvo stebėta. Šiam pacientui buvo histologiškai patvirtinta gerybinio pobūdžio navikinė patologija (3.2.2.1 pav., C), ir nustatyta apatinio žandikaulio fibrozinės displazijos diagnozė. IRST tyrimo metu užregistruoti TV taip pat parodė temperatūrine asimetrija toje veido pusėje, kurioje buvo klinikiniais tyrimais nustatytas pažeidimas (3.2.2.1 pav., D). Be to, tiksliai sutapo IRST ir KT/MRT metodais nustatyta patologijos anatominė zona (lokalizacija). Vidutinių temperatūrų skirtumas ( $\Delta T_{vid}$ ) tarp simetriškų veido sričių siekė 0,87 °C. Tuo tarpu, burnos ertmės TV (3.2.2.1 pav., E) buvo stebima akivaizdi temperatūrinė asimetrija. Patologinė sritis matoma, kaip aukštesnės temperatūros sritis. Aukščiausia temperatūra toje zonoje siekė > 38 °C (žr. 3.2.2.1 lentelės NP #1 atveji). Šiuo atveju, temperatūrinė asimetrija buvo matoma ir be papildomo vaizdo segmentavimo. Tačiau, atlikus segmentavimo procedūra, patologinė zona tapo dar labiau išryškinta (3.2.2.1 pav., F).

3.2.2.2 pav. pateiktas antrasis navikinės patologijos atvejis, kai pacientas po klinikinės apžiūros buvo nukreiptas KT procedūrai dėl skausmingos dešinės pusės žando gleivinės. Šiuo atveju, veido deformacija buvo nežymi ir sunkiai vertinama dėl netaisyklingo sakandžio, tačiau KT ašiniame vaizde (3.2.2.2 pav., A) buvo matyti plati kaulinės destrukcijos zona dešinėje apatinio žandikaulio pusėje. Šiam pacientui histologiškai buvo patvirtintas piktybinis minkštujų audinių navikas, t. y. plokščialąstelinė karcinoma (SCC G3) (3.2.2.2 pav., C). Nepaisant didelės apimties apatinio žandikaulio destrukcijos, to paties paciento atitinkamame TV buvo aptiktas tik nedidelis vidutiniu temperatūrų skirtumas ( $\Delta T_{vid}$ ) ir maksimalių temperatūrų skirtumas ( $\Delta T_{maks}$ ) tarp kairės ir dešinės burnos ertmės pusių (3.2.2.2 pav., E): atitinkamai 0,06 °C ir 0,42 °C (žr. 3.2.2.1 lentelės NP #2 atvejį). Tačiau, panaudojus vaizdo segmentavimą ROI zonoje, paveiktoje pusėje išryškėjo aukštesnės temperatūros sritis (3.2.2.2 pav., F). Šiuo atveju, tik atlikus TV segmentavimo procedūra atsirado matomas patologinės zonos išryškėjimas, kur aukščiausia temperatūra siekė 39,0 °C.



**3.2.2.2 pav.** Antro klinikinio atvejo diagnostiniai vaizdai, kai IRST matoma maža temperatūrinė asimetrija

Viršuje: KT tyrimo kauliniu langu pjūvis ašinėje plokštumoje (A) ir MRT aukštos rezoliucijos T1 turbo aidų seka su intraveniniu kontrastavimu, ašinis pjūvis (B) su destrukcinėmis masėmis apatinio žandikaulio dešinėje pusėje. Viduryje, histologinis pjūvis (C) su patvirtinta blogai diferencijuotos plokščiųjų ląstelių karcinomos (SCC G3) diagnoze. Histologiniame pjūvyje matomos solodiškai besidėstančios, labai polimorfiškos navikinės ląstelės stambiais, chromatingais branduoliais ir santykinai negausia citoplazma, gausios mitozės, aiškaus ragėjimo nestebima, stroma gausi su pavieniais limfocitais. Apačioje: termografinis vaizdas (TV) frontalinėje plokštumoje pacientui susičiaupus (D) ir pacientui išsižiojus, burnos ertmės sritis prieš vaizdo segmentaciją (E) ir po segmentavimo procedūros (F). Pastaba: rodyklė rodo temperatūrinės asimetrijos sritį prieš (E) ir po (F) segmentacijos. Temperatūrinė skalė dešinėje. Tačiau, kai kuriais atvejais patologiniai pakitimai BVŽ srityse gali būti labai minimalūs arba vizualiai nepastebimi (3.2.2.3 pav.).



**3.2.2.3. pav.** Trečio klinikinio atvejo diagnostiniai vaizdai, kai IRST nėra matoma temperatūrinė asimetrija

Viršuje: KT tyrimo kauliniu langu pjūvis ašinėje plokštumoje (A) ir MRT aukštos rezoliucijos T1 turbo aidų seka su intraveniniu kontrastavimu, ašinis pjūvis su patologinėmis masėmis nosiaryklės dešinėje ir lokalia kietojo gomurio destrukcine zona. Viduryje, histologinis pjūvis (C) su patvirtinta vidutiniškai diferencijuotos plokščių ląstelių karcinomos (SCC G2) diagnoze. Histologiniame pjūvyje matomos solidiškai besidėstančios, nežymiai polimorfiškos navikinės ląstelės stambiais, chromatingais branduoliais ir vidutiniu kiekiu citoplazmos. Aiškūs ragėjimo židiniai ("keratininiai perlai"), stroma gausi, su gausiais limfocitais ir plazmocitais. Apačioje: termografinis vaizdas (TV) frontalinėje plokštumoje pacientui susičiaupus (D) ir pacientui išsižiojus, burnos ertmės sritis prieš vaizdo segmentaciją (E) ir po segmentavimo procedūros (F). Pastaba: rodyklė rodo temperatūrinės asimetrijos sritį prieš (E) ir po (F) segmentacijos. Temperatūrinė skalė dešinėje. Trečiuoju atveju, klinikinio tyrimo metu pacientas skundėsi silpnu skausmu giliai burnos ertmėje, todėl buvo nukreiptas atlikti KT procedūrą. Šiuo navikinės patologijos atveju kliniškai buvo stebima labai nedidelė burnaryklės lateralinės sienelės deformacija dešinėje pusėje. Pacientui KT tyrimo vaizduose buvo stebima minkštojo gomurio ir dešinės parafaringinės srities išplitusi minkštųjų audinių infiltracija su kietojo gomurio destrukcija.

Pateiktuose radiologiniuose vaizduose (3.2.2.3 pav., A, B) stebimos patologinės masės nosiaryklės dešinėje su lokalia kietojo gomurio destrukcija. Histologiškai pacientui buvo patvirtinta vidutiniškai diferencijuota plokščių ląstelių karcinomos diagnozė (3.2.2.3 pav., C). Šiuo atveju, pacientui susičiaupus, veido termogramoje reikšmingo temperatūrinės asimetrijos nebuvo pastebėta (3.2.2.3 pav., D), o vidutinių temperatūrų skirtumas tarp abiejų veido pusių buvo tik 0,1 °C (žr. 3.2.2.1 lentelės NP #3 atvejį). Net ir išsižiojus, termografiniame vaizde nebuvo matomo aiškaus vidutinių temperatūrų skirtumo tarp dešinės ir kairės burnos ertmės pusių (3.2.2.3 pav., E). Tačiau, dominančios patologinės ROI srityje pritaikius vaizdo segmentavimo algoritmą, išryškėjo lokali aukštos temperatūros zona, esanti giliai burnos ertmėje (3.2.2.3 pav., F).

3.2.2.4 pav. pateiktos NP grupės pacientų temperatūrinės asimetrijos pasiskirstymo histogramos pagal veido ir burnos ertmės termogramose analizuotas vidutines ( $\Delta T_{vid}$ ) ir maksimalias ( $\Delta T_{maks}$ ) požymių reišmes. Akcentuotina, kad NP grupės pacientų TV temperatūrų pasiskirstymo charakteristikas atspindinčios histogramos yra plačiai išsidėsčiusios, lyginant su ST grupės tiriamųjų analogiškais duomenimis (žr. 3.2.5 skyrių). Tai rodo, kad temperatūrinis pasiskirstymas pažeistoje srityje nėra tolygus, o temperatūrų reikšmės pasižymi didele sklaida, kas yra būdinga patologiniam audiniui su pakitusia kraujotaka. Be to, kai kurios histogramos rodo bimodalumą (dvi viršūnes) ar mažą asimetriją.



3.2.2.4 pav. NP grupės sklaidos histogramos su normaliojo skirstinio kreivėmis pagal veido ir burnos ertmės vidutinius ir maksimalius temperatūrinius požymius

Histogramų rinkinys pateiktas pagal parinktus keturis temperatūrinius požymius. Paskaičiuotos veido / burnos ertmės sričių vidutinių (kairėje) ir maksimalių (dešinėje) temperatūrų skirtumo tarp dešinės ir kairės pusių reikšmės, atitinkamai veido srityje **(A, B)** ir burnos ertmės srityje **(C, D)**. Vidutinių temperatūrų skaičiavimas pagrįstas visų pikselių temperatūrų sumavimu vienoje veido arba burnos ertmės, kontūrais apribotos srities, pusėje ir padalinamos iš tų taškų skaičiaus. Kiekvienam požymiui sudaryta histograma su tiriamųjų atvejų skaičiumi (n = 27) yra pateikta y ašyje, naudojant x ašies intervalą nuo –1,5 iki 1,5 su 0,2 pločio stulpeliais. Pastaba: kiekvienas stulpelis rodo, kiek atvejų patenka į konkretų intervalą. Normaliojo skirstinio kreivė (raudona punktyrinė linija) atspindi pasiskirstymą pagal kiekvieno kintamojo vidurkį ir standartinį nuokrypį.

#### 3.2.3. Klinikinių atvejų su uždegiminės kilmės patologija TV vertinimas

Daliai tirtų pacientų, KT tyrimu nustatyta uždegiminės kilmės patologija (UP grupė, n = 28), kuri buvo aptikta ir TV. UP grupės pacientų TV temperatūrinių požymių  $\Delta T_{vid}$  reikšmės, tarp kairės / dešinės veido ir burnos ertmės pusių ROI, buvo atitinkamai 0,21 ± 0,1 °C ir 0,28 ± 0,1 °C, o  $\Delta T_{maks}$  reikšmės atitinkamai siekė 0,19 ± 0,14 °C ir 0,45 ± 0,18 °C. UP grupėje, apskaičiuotas pikselių skaičius TV dešinėje (kairėje) veido ir burnos ertmės pusėse, kurių temperatūra yra 0,4 °C aukštesnė už maksimalią temperatūrą priešingoje veido ir burnos ertmės pusėse buvo atitinkamai  $4,42 \pm 1,75$  °C ir  $21,13 \pm 13,4$  °C.

UP grupės histogramos (3.2.3.1 pav.), panašiai kaip ir NP grupės, buvo plačiai pasiskirsčiusios ir, priešingai nei ST grupėje, išsiskyrė reikšmių įvairove. Kai kurių UP grupės histogramų pasiskirstymas yra netolygus, asimetriškas ar turi kelias viršūnes, o reikšmės išsidėsčiusios plačiame intervale. Tai rodo, kad požymiai šioje grupėje kinta nevienodai ir dažnai pasitaiko kraštutinės reikšmės.



3.2.3.1 pav. UP grupės sklaidos histogramos su normaliojo skirstinio kreivėmis pagal veido ir burnos ertmės vidutinius ir maksimalius temperatūrinius požymius

Histogramų rinkinys pateiktas pagal parinktus keturis temperatūrinius požymius. Paskaičiuotos veido / burnos ertmės sričių vidutinių (kairėje) ir maksimalių (dešinėje) temperatūrų skirtumo tarp dešinės ir kairės pusių reikšmės, atitinkamai veido srityje **(A, B)** ir burnos ertmės srityje **(C, D)**. Vidutinių temperatūrų skaičiavimas pagrįstas visų pikselių temperatūrų sumavimu vienoje veido arba burnos ertmės, kontūrais apribotos srities, pusėje ir padalinamos iš tų taškų skaičiaus. Kiekvienam požymiui sudaryta histograma su tiriamųjų atvejų skaičiumi (n = 28) yra pateikta y ašyje, naudojant x ašies intervalą nuo –1,5 iki 1,5 su 0,2 pločio stulpeliais. Pastaba: kiekvienas stulpelis rodo, kiek atvejų patenka į konkretų intervalą. Normaliojo skirstinio kreivė (raudona punktyrinė linija) atspindi pasiskirstymą pagal kiekvieno kintamojo vidurkį ir standartinį nuokrypį. Akcentuotina, kad UP grupės pacientų TV temperatūrų skirtumų sklaida, lyginant su NP grupe, buvo panaši (žr. 3.2.5 skyrių). Rezultatai patvirtina, kad tiek uždegiminiai procesai, tiek navikinė patologija sąlygoja didesnius temperatūrinės asimetrijos svyravimus burnos ertmėje.

### 3.2.4. Klinikinių atvejų su mišria patologija TV vertinimas

Kadangi NP ir UP grupės nepasižymėjo aiškiais skirtumais (žr. 3.2.5 skyrių), todėl jos buvo apjungtos, suformuojant 55 pacientų imtį su mišriais patologiniais pokyčiais (NP / UP grupė). Histogramos pateiktos 3.2.4.1 pav.



3.2.4.1 pav. UP / NP grupės sklaidos histogramos su normaliojo skirstinio kreivėmis pagal veido ir burnos ertmės vidutinius ir maksimalius temperatūrinius požymius

Histogramų rinkinys pateiktas pagal parinktus keturis temperatūrinius požymius. Paskaičiuotos veido / burnos ertmės sričių vidutinių (kairėje) ir maksimalių (dešinėje) temperatūrų skirtumo tarp dešinės ir kairės pusių reikšmės, atitinkamai veido srityje (A, B) ir burnos ertmės srityje (C, D). Vidutinių temperatūrų skaičiavimas pagrįstas visų pikselių temperatūrų sumavimu vienoje veido arba burnos ertmės, kontūrais apribotos srities, pusėje ir padalinamos iš tų taškų skaičiaus. Kiekvienam požymiui sudaryta histograma su tiriamųjų atvejų skaičiumi (n = 55) yra pateikta y ašyje, naudojant x ašies intervalą nuo -1,5 iki 1,5 su 0,2 pločio stulpeliais. Pastaba: kiekvienas stulpelis rodo, kiek atvejų patenka į konkretų intervalą. Normaliojo skirstinio kreivė (raudona punktyinė linija) atspindi pasiskirstymą pagal kiekvieno kintamojo vidurkį ir standartinį nuokrypį.
NP / UP grupės apskaičiuotos  $\Delta T_{vid}$  reikšmės tarp kairės / dešinės pusių veido ir burnos ertmės TV buvo atitinkamai 0,21 ± 0,1 °C ir 0,34 ± 0,1 °C, o  $\Delta T_{maks}$  reikšmės buvo atitinkamai 0,19 ± 0,14 °C ir 0,46 ± 0,18 °C. Šie skirtumai tarp burnos ertmės požymių buvo statistiškai reikšmingi (p < 0,05), lyginant su tokiais duomenimis ST grupėje. NP / UP grupės apskaičiuotas pikselių skaičius TV dešinėje (kairėje) veido ir burnos ertmės pusėse, kurių temperatūra yra 0,4 °C aukštesnė už maksimalią pemteratūrą priešingoje veido ir burnos ertmės pusėse buvo atitinkamai 3,17 ± 1,85 ir 29,6 ± 19,3.

#### 3.2.5. Visų klinikinių atvejų palyginamasis TV vertinimas

Siekiant įvertinti pasirinktų požymių skirtumus bei jų pasiskirstymus tarp įvairių tiriamųjų grupių, buvo atlikta duomenų statistinė analizė (3.2.5.1 lentelė). Duomenys suskirstyti į grupes: SS, ST, UP, NP ir UP / NP, kurios reprezentuoja skirtingus tiriamųjų atvejus (žr. Darbo metodika, 2.3.1 pav.). Kiekvienoje grupėje analizuoti aštuoni atrinkti temperatūriniai požymiai ( $\Delta T_{v.vid}$ ,  $\Delta T_{b.vid}$ ,  $\Delta T_{v.maks}$ ,  $\Delta T_{b.maks}$ ,  $n_v$ ,  $n_b$ ,  $\Delta DEV_v$ , ir  $\Delta DEV_b$ ), atspindintys atrinktų temperatūrinių požymių veido / burnos ertmės, tarp kairės / dešinės pusių, skirtumus.

Požymis	Vidurkis	Std	Min.	25 proc.	50 proc.	75 proc.	Maks.					
SS tiriam	SS tiriamųjų grupė (n = 29)											
$\Delta T_{v.vid}$	-0,06709	0,120268	-0,258	-0,1481	-0,0855	0,0048	0,1504					
$\Delta T_{v.maks}$	-0,00397	0,041335	-0,1059	-0,0506	0	0	0,0526					
$\Delta T_{b.vid}$	-0,00832	0,165093	-0,3971	-0,0981	-0,0309	0,0867	0,283					
$\Delta T_{b.maks}$	0,011486	0,044931	-0,0592	0	0	0,0522	0,1161					
$\Delta DEV_{v}$	0,035893	0,023952	0,0021	0,0172	0,0328	0,0477	0,087					
$\Delta DEV_b$	0,013845	0,021034	0,00037	0,0042	0,0101	0,0157	0,1155					
$n_{v}$	0	0	0	0	0	0	0					
n <sub>b</sub>	0	0	0	0	0	0	0					

**3.2.5.1 lentelė.** Pasirinktų aštuonių požymių statistinės charakteristikos SS, ST, UP, NP ir UP / NP tiriamųjų grupėse

# 3.2.5.1 lentelės tęsinys

Požymis	Vidurkis	Std	Min.	25 proc.	50 proc.	75 proc.	Maks.
ST tiriam	ųjų grupė (	n = 39)					
$\Delta T_{v.vid}$	-0,03522	0,135296	-0,258	-0,1464	-0,0467	0,0747	0,2417
$\Delta T_{v.maks}$	-0,00758	0,104813	-0,3792	-0,0516	0	0,0491	0,2964
$\Delta T_{b.vid}$	-0,00811	0,180142	-0,3971	-0,1404	-0,0316	0,11375	0,3818
$\Delta T_{b.maks}$	0,019569	0,12395	-0,2596	-0,0255	0	0,0549	0,3896
$\Delta DEV_{v}$	0,039551	0,027541	0,0021	0,01855	0,0356	0,053	0,1369
$\Delta DEV_b$	0,027264	0,035208	0,000367	0,00545	0,0124	0,029	0,1515
$n_v$	0,051282	0,223456	0	0	0	0	1
nb	0	0	0	0	0	0	0
UP tiriam	ųjų grupė (	(n = 28)					
$\Delta T_{v.vid}$	0,07933	0,27262	-0,3267	-0,10295	0,03745	0,22	0,742
$\Delta T_{v.maks}$	-0,0192	0,264428	-0,6443	-0,13415	-0,016	0,13285	0,7034
$\Delta T_{b.vid}$	0,03946	0,35519	-0,7533	-0,18013	0,05205	0,2255	0,8143
$\Delta T_{b.maks}$	0,18399	0,53974	-0,9531	-0,11648	0,2028	0,423725	1,3652
$\Delta DEV_{v}$	0,11901	0,32373	0,0023	0,01975	0,0514	0,092625	1,7508
$\Delta DEV_b$	0,12965	0,10798	0,0105	0,052825	0,10475	0,186675	0,4213
$n_{v}$	4,42857	21,2034	0	0	0	0	112
nb	21,1071	44,1976	0	0	0	26,25	212
NP tiriam	ųjų grupė (	(n = 27)					
$\Delta T_{v.vid}$	0,062107	0,303831	-0,8983	-0,0828	0,0243	0,23075	0,7816
$\Delta T_{v.maks}$	0,040811	0,263094	-0,5054	-0,1203	0	0,2025	0,5669
$\Delta T_{b.vid}$	0,065111	0,558457	-0,6759	-0,3433	0,0076	0,30825	1,9834
$\Delta T_{b.maks}$	0,024315	0,680047	-1,7773	-0,3011	0,0216	0,4237	1,4516
$\Delta DEV_{v}$	0,040074	0,03147	0,0066	0,01945	0,0352	0,0437	0,1192
$\Delta DEV_b$	0,123878	0,117843	0,0054	0,0434	0,0878	0,1744	0,4896
$n_{v}$	2,111111	7,95339	0	0	0	0	41
nb	41,37037	78,01388	0	0	0	27	257

Požymis	Vidurkis	Std	Min.	25 proc.	50 proc.	75 proc.	Maks.						
UP / NP ti	UP / NP tiriamųjų grupė (n = 55)												
$\Delta T_{v.vid}$	0,07088	0,285804	-0,8983	-0,0887	0,0252	0,2214	0,7816						
$\Delta T_{v.maks}$	0,010253	0,26307	-0,6443	-0,1356	-0,0108	0,15145	0,7034						
$\Delta T_{b.vid}$	0,052053	0,461965	-0,7533	-0,226	0,0089	0,2255	1,9834						
$\Delta T_{b.maks}$	0,105607	0,612224	-1,7773	-0,2554	0,1676	0,43055	1,4516						
$\Delta DEV_{v}$	0,08026	0,233375	0,0023	0,01945	0,0371	0,0738	1,7508						
$\Delta DEV_b$	0,126816	0,111915	0,0054	0,0473	0,094	0,1817	0,4896						
$n_{v}$	3,290909	16,01929	0	0	0	0	112						
nb	31,05455	63,33726	0	0	0	26,5	257						

3.2.5.1 lentelės tęsinys

n – imties dydis, Std – standartinis nuokrypis, Min. – mažiausia reikšmė, 25 proc. – pirmasis kvartilis, 50 proc. – medianinė reikšmė, 75 proc. – tračiasis kvartilis, Maks. – didžiausia reikšmė,  $\Delta T_{v.vid}$  ir  $\Delta T_{b.vid}$  – vidutinių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $\Delta T_{v.maks}$  ir  $\Delta T_{b.maks}$  – maksimalių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $n_v$  ir  $n_b$  – pikselių skaičius termografinio vaizdo dešinėje (kairėje), atitinkamai veido ir burnos ertmės, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalių temperatūros nuokrypių skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai, atitinkamai veido ir burnos ertmės, pusei.

Siekiant įvertinti tiriamųjų požymių pasiskirstymo ypatumus tarp grupių be patologijos (ST) ir su patologijomis (UP / NP), duomenys buvo sunormalizuoti dėl didesnės UP / NP grupės imties, kad būtų užtikrintas rezultatų palyginamumas.

Atlikus palyginamąją analizę paaiškėjo, kad ST grupėje požymių reikšmės yra labiau koncentruotos aplink nulį, o UP / NP grupėje pasiskirstymas yra platesnis. 3.2.5.1 pav. pateiktos normaliojo pasiskirstymo kreivės, apskaičiuotos remiantis sunormalizuotais duomenimis dviem pasirinktiems požymiams,  $\Delta T_{v,vid}$  ir  $\Delta T_{b,vid}$ .



3.2.5.1 pav. Pagal normalizuotus duomenis apskaičiuotos ST ir UP / NP grupių, veido ir burnos ertmės vidutinių temperatūrų požymių normaliojo skirstinio kreivės

Pateiktos normaliojo skirstinio kreivės pagal du požymius  $\Delta T_{vvid}$  (**A**) ir  $\Delta T_{b,vid}$  (**B**). Kiekvienam požymiui sudaryta normaliojo skirstinio kreivė, apskaičiuota pagal normalizuotus duomenis yra pateikta *y* ašyje, naudojant *x* ašies intervalą nuo –1,5 iki 1,5. ST (oranžinė) kreivė yra siauresnė ir aukštesnė, būdinga normaliam pasiskirstymui. UP / NP (neryškiai violetinė) kreivė yra vizualiai žemesnė ir platesnė, rodanti padidėjusią duomenų sklaidą bei galimus nukrypimus nuo normalumo.

Šių požymių duomenų pasiskirstymas buvo aproksimuotas taikant skirtingas Gauso funkcijas pagal normaliojo skirstinio prielaidą. Aproksimacijos tikslumas įvertintas remiantis R<sup>2</sup> koeficientu, kurio reikšmės parodė labai gerą pritaikytų modelių atitikimą eksperimentiniams duomenims. Papildomai buvo atlikta duomenų aproksimacija remiantis RSS ir RMSE rodikliais, kurie taip pat parodė gerą pritaikytų kreivių atitikimą eksperimentiniams duomenims (žr. 3.2.5.2 lentelę). Lentelėje pateiktas tiriamųjų grupių (SS, ST, UP, NP) duomenų aproksimacijos tikslumo įvertinimas, taikant tris Gauso funkcijos modelius: viengubą (1G), dvigubą (2G) ir asimetrinį (Asim). Aproksimacijos kokybė vertinta trimis statistiniais rodikliais: RSS (likučių kvadratų suma), RMSE (kvadratinė vidutinė paklaida) ir R<sup>2</sup> (determinacijos koeficientas). Mažesnės RSS ir RMSE bei didesnė R<sup>2</sup> reikšmė rodo geresnį modelio atitikimą eksperimentiniams duomenims.

**3.2.5.2 lentelė.** Duomenų aproksimacijos tikslumo rodiklių palyginimas tarp grupių, taikant skirtingas Gauso funkcijas

		1G	2G	Asim
RSS	SS	402,2692715	421,9770381	416,9108004
	ST	616,4387768	645,9284031	632,8333431
	UP	179,2161333	181,4993716	179,5937378
	NP	206,7837393	216,4022529	214,1619483
RMSE	SS	0,969189846	0,030656248	0,492400513
	ST	1,186444231	0,0581744	0,791825622
	UP	0,646738136	0,556369592	0,632683301
	NP	0,851217793	0,516328334	0,616246302
$\mathbb{R}^2$	SS	0,88461168	0,999884553	0,97021613
	ST	0,88202706	0,99971637	0,947453131
	UP	0,844993978	0,885285478	0,851657917
	NP	0,800539243	0,926611503	0,895459462

SS, ST, UP ir NP – reprezentuoja skirtingus tiriamųjų atvejus (žr. Darbo metodika, 2.3.1 pav.), RSS – likučių kvadratų suma; kuo mažesnė reikšmė, tuo geresnis modelio atitikimas duomenims, RMSE – kvadratinė vidutinė paklaida; mažesnė reikšmė rodo tikslesnę aproksimaciją, R<sup>2</sup> – determinacijos koeficientas; 1G – vienguba Gauso funkcija, 2G – dviejų Gausų funkcijų suma, Asim – asimetrinė Gauso funkcija. Paryškintas pažymėjimas parodo geriausią eksperimentinių duomenų aproksimaciją ir leidžia įvertinti, kuris modelis kiekvienai grupei suteikė tiksliausią atitikimą.

3.2.5.3 lentelė pateikta detalesnė analizė, atlikta taikant vienos Gauso funkcijos aproksimaciją, kurioje nurodytos kiekvienos kreivės pagrindinės charakteristikos: maksimali reikšmė (amplitudė), jo padėtis pagal temperatūros ašį (maks. vieta), kreivės plotis bei determinacijos koeficientas R<sup>2</sup>. Šie rodikliai leidžia įvertinti skirtingų grupių pasiskirstymų formą, sklaidą ir nuokrypį nuo simetrijos. Pastebima, kad ST ir SS grupių duomenys pasižymi siauresnėmis (mažesnio pločio) ir aukštesnėmis (didesnės amplitudės) kreivėmis bei aukštesnėmis R<sup>2</sup> reikšmėmis, rodančiomis geresnį atitikimą teoriniam normaliam pasiskirtymui. Tuo tarpu UP ir NP grupėse kreivės yra platesnės, žemesnės, o atitikimas normalumo prielaidai mažesnis, kas sutampa su ankstesne vizualine analize ir patvirtina didesnį duomenų išsibarstymą šiose grupėje.

**3.2.5.3 lentelė.** Duomenų aproksimacijos su normalinio skirstinio kreivėmis statistinė analizė tarp grupių, taikant viengubą Gauso funkciją

Gru	ıpės	Maks.	Maks. vieta	Plotis	Imtis (n)	<b>R</b> <sup>2</sup>
$\Delta T_{v.vid}$	SS	9,700929713	-0,15257323	0,27	29	0,892718748
	ST	10,16807086	-0,10588639	0,38	39	0,892089014
	UP	4,569081033	-0,03944224	0,55	28	0,872162483
	NP	5,478033605	-0,00676673	0,42	27	0,826070724
	UP / NP	9,973242976	-0,01719771	0,48	55	0,89799711
$\Delta T_{b.vid}$	SS	7,870725609	-0,064343501	0,33	29	0,879832094
	ST	9,164497779	-0,06840499	0,39	39	0,892031409
	UP	3,393118493	-0,064175755	0,75	28	0,631175379
	NP	2,321891298	-0,088283489	1,09	27	0,581421505
	UP / NP	5,593478024	-0,070288805	0,89	55	0,79535542
$\Delta T_{v.maks}$	SS	9,683404606	-0,051169697	0,15	29	0,994798713
	ST	10,48438935	-0,066147333	0,19	39	0,951725072
	UP	4,739492598	-0,081466123	0,51	28	0,878799456
	NP	4,7954186	-0,065180615	0,42	27	0,728213928
	UP / NP	9,1730118	-0,067855003	0,5	55	0,890344529
$\Delta T_{b.maks}$	SS	7,626893455	-0,027573795	0,18	29	0,994362055
	ST	8,893235744	-0,039228143	0,2	39	0,897880563
	UP	3,506930213	0,241537927	0,51	28	0,504624116
	NP	2,210430115	-0,019207612	0,99	27	0,528943467
	UP / NP	4,543646756	0,089238746	1,01	55	0,62589206

SS, ST, UP, NP ir UP / NP – reprezentuoja skirtingus tiriamųjų atvejus (žr. Darbo metodika, 2.3.1 pav.),  $\Delta T_{v.vid}$  – vidutinių temperatūrų skirtumas tarp dešinės ir kairės veido pusių,  $\Delta T_{b.vid}$  – vidutinių temperatūrų skirtumas tarp dešinės ir kairės burnos ertmės pusių,  $\Delta T_{v.maks}$  – maksimalių temperatūrų skirtumas tarp dešinės ir kairės veido pusių,  $\Delta T_{b.maks}$  maksimalių temperatūrų skirtumas tarp dešinės ir kairės pusių, Maks. – didžiausia Gauso funkcijos reikšmė (kreivės amplitudė), Maks. vieta – temperatūra, ties kuria pasiekiama maksimali kreivės reikšmė, plotis – Gauso kreivės plotis, nusakantis reikšmių sklaidą aplink maksimumą, Imtis – atvejų skaičius (n), R<sup>2</sup> – determinacijos koeficientas, rodantis modelio atitikimą eksperimentiniams duomenims (R<sup>2</sup> = 1 reiškia idealų atitikimą).

Tarpgrupinis pasirinktų temperatūrinių požymių palyginimas leidžia įvertinti duomenų sklaidą, ekstremalias vertes bei jų pasiskirstymą. Įžvelgiami kai kurie esminiai skirtumai tarp grupių tiek centrinių tendencijų, tiek duomenų sklaidos atžvilgiu. Statistinė analizė, atlikta vienkrypte dispersine analize (ANOVA), parodė statistiškai reikšmingus skirtumus tarp penkių tiriamųjų grupių  $\Delta T_{v,vid}$ ,  $n_b$  ir  $\Delta DEV_b$  požymių atžvilgiu (žr. 3.2.5.4 lentelę). Kitų penkių vertintų požymių atveju reikšmingų skirtumų nenustatyta (žr. 3.2.5.4 lentelę). Šiuos rezultatus vizualiai pagrindžia ir stačiakampės diagramos (angl. *boxplot*) analizė (3.2.5.2–3.2.5.4 pav.), rodanti, kad aukštesnės  $\Delta T_{v.vid}$ ,  $n_b$  ir  $\Delta DEV_b$  požymių reikšmės būdingos patologinėms pacientų grupėms, o žemesnės – SS ir ST grupėms. Diagrama leidžia vizualiai įvertinti tarpgrupinius skirtumus bei požymio centralizacijos ir dispersijos pobūdį. Stebimi statistiškai reikšmingi skirtumai tarp patologinių ir sveikų tiriamųjų grupių (3.2.5.5 lentelė ir 3 priedas).

Požymis	р	Reikšmingumas	Efekto dydis (η <sup>2</sup> )	η² interpretacija
$\Delta DEV_b$	3,75E-10	+++	0,249444	+++
nb	0,001327	++	0,09745	++
$\Delta T_{v.vid}$	0,031457	+	0,0591	+
$\Delta DEV_{v}$	0,316213	_	0,026815	+
$n_{v}$	0,517197	_	0,018495	+
$\Delta T_{b.maks}$	0,57266	_	0,016597	+
$\Delta T_{v.maks}$	0,854929	_	0,007659	_
$\Delta T_{b.vid}$	0,891163	_	0,006413	_

**3.2.5.4 lentelė.** Temperatūrinių požymių statistinis reikšmingumas ir efekto dydis tarp tiriamųjų grupių

Lentelėje pateikti temperatūriniai požymiai įvertinti dviem aspektais: remiantis p verte, ir efekto dydžiu ( $\eta^2$ ). Statistinio reikšmingumo žymėjimo simboliai: (+++) labai reikšmingas skirtumas (p < 0,001), (++) reikšmingas ( $0,001 \le p < 0,01$ ), (+) silpnai reikšmingas ( $0,01 \le p < 0,05$ ), (-) nereikšmingas skirtumas ( $p \ge 0,05$ ). Efekto dydžio vertinimo simboliai: (+++) didelis poveikis ( $\eta^2 \ge 0,14$ ), (++) vidutinis poveikis ( $0,06 \le \eta^2 < 0,14$ ), (+) mažas poveikis ( $0,01 \le \eta^2 < 0,06$ ), (-) nereikšmingas poveikis ( $\eta^2 < 0,01$ ).



3.2.5.2 pav. Stačiakampės diagramos pateikiančios visų tiriamųjų grupių  $\Delta T_{v,vid}$  požymio reikšmės pasiskirstymą grupėse

Vertikalioji ašis –  $\Delta T_{vvid}$  požymio reikšmė, horizontali ašis – tiriamųjų grupės, rombai – nutolusios reikšmės, horizontalios linijos rodo \*p < 0,05, \*\*p ≤ 0,01.



**3.2.5.3 pav.** Stačiakampės diagramos pateikiančios visų tiriamųjų grupių n<sub>b</sub> požymio reikšmės pasiskirstymą grupėse

Vertikalioji ašis –  $n_b$  požymio reikšmė, horizontali ašis – tiriamųjų grupės, rombai – nutolusios reikšmės, horizontalios linijos rodo \*\*\* $p \le 0,001$ .



3.2.5.4 pav. Stačiakampės diagramos pateikiančios visų tiriamųjų grupių ΔDEV<sub>b</sub> požymio reikšmės pasiskirstymą grupėse

Vertikalioji ašis –  $\Delta DEV_b$  požymio reikšmė, horizontali ašis – tiriamųjų grupės, rombai – nutolusios reikšmės, horizontalios linijos rodo \*\*\*p  $\leq 0,001$ .

medianos, s	klaidos (IQR)	) ir statistin	is reikšmingumas	1	01.
Požymis	ST mediana	ST IQR	UP / NP mediana	UP / NP IQR	р
$\Lambda T$	0.047	0.221	0.025	0.210	0.024

3.2.5.5 lentelė. Temperatūriniu požvmiu palvginimas tarp ST ir UP / NP grupiu:

Požymis	ST mediana	ST IQR	UP / NP mediana	UP / NP IQR	р
$\Delta T_{v.vid}$	-0,047	0,221	0,025	0,310	0,024
$\Delta T_{b.vid}$	-0,032	0,254	0,009	0,451	0,830
$\Delta DEV_{v}$	0,036	0,034	0,037	0,054	0,473
$\Delta DEV_b$	0,012	0,024	0,094	0,134	0,000
$n_{v}$	0,000	0,000	0,000	0,000	0,191
nb	0,000	0,000	0,000	26,500	0,000
$\Delta T_{v.maks}$	0,000	0,101	-0.011	0,287	0,969
$\Delta T_{b.maks}$	0,000	0,080	0,168	0,686	0,144

Pateiktos ST ir UP / NP grupių temperatūrinių požymių medianos, IQR (interkvartilinis rėžis, parodantis reikšmių sklaidą tarp 25 proc. ir 75 proc. kvartilių) ir p reikšmės (Mann–Whitney U testas). Reikšmingi skirtumai (p < 0,05) nustatyti požymiams  $\Delta T_{v,vid}$ ,  $\Delta DEV_b$  ir  $n_b$ , rodančiais jų diagnostinį potencialą.

		L			ST							UP	NP					
·	_	ΔΤν.vid	$\Delta T_{v:maks}$	$\Delta T_{b.vid}$	$\Delta T_{b.maks}$	ΔDEV	$\Delta DEV_b$	'n	$\Delta T_{v.vid}$	$\Delta T_{v,maks}$	$\Delta T_{b.vid}$	$\Delta T_{b.maks}$	ΔDEV	$\Delta DEV_b$	'n	n <sub>b</sub>		
	n <sub>b</sub>	-0,13	0,07	0,25	-0,08	0,16	0,05	-0,11	0,29	0,20	0,38	0,06	-0,06	0,79	0,05	1,00	-	-0,6
	nv	-0,15	-0,06	0,11	0,05	0,23	-0,03	-0,05	0,19	0,26	-0,14	-0,22	0,09	0,14	1,00	0,05	-	-0,4
	$\Delta DEV_b$	-0,12	0,02	0,15	-0,07	0,22	0,11	-0,04	0,33	0,32	0,30	0,12	-0,10	1,00	0,14	0,79		0.4
UP / NP	$\Delta DEV_{v}$	-0,11	-0,62	0,09	0,29	0,01	0,20	0,00	-0,05	-0,10	-0,03	0,01	1,00	-0,10	0,09	-0,06		-0,2
	$\Delta T_{b.maks}$	0,20	0,11	-0,16	0,11	-0,14	0,22	-0,08	0,20	-0,04	0,73	1,00	0,01	0,12	-0,22	0,06		
	$\Delta T_{b.vid}$	0,07	0,09	-0,06	-0,05	-0,05	0,03	-0,05	0,20	0,11	1,00	0,73	-0,03	0,30	-0,14	0,38	-	0,0
	$\Delta T_{v.maks}$	0,02	0,04	-0,07	-0,05	0,07	-0,10	0,08	0,29	1,00	0,11	-0,04	-0,10	0,32	0,26	0,20		
	$\Delta T_{v.vid}$	0,10	0,02	0,19	0,10	0,07	0,03	0,33	1,00	0,29	0,20	0,20	-0,05	0,33	0,19	0,29	-	0,2
	nv	0,10	-0,01	-0,25	-0,25	0,56	0,02	1,00	0,33	0,08	-0,05	-0,08	0,00	-0,04	-0,05	-0,11		
	$\Delta DEV_b$	0,15	-0,11	0,20	0,34	0,15	1,00	0,02	0,03	-0,10	0,03	0,22	0,20	0,11	-0,03	0,05	-	0,4
	$\Delta DEV_{v}$	-0,02	0,25	0,05	0,07	1,00	0,15	0,56	0,07	0,07	-0,05	-0,14	0,01	0,22	0,23	0,16		
ѕт	$\Delta T_{b.maks}$	0,08	0,11	0,64	1,00	0,07	0,34	-0,25	0,10	-0,05	-0,05	0,11	0,29	-0,07	0,05	-0,08		0,6
	$\Delta T_{b.vid}$	0,12	0,15	1,00	0,64	0,05	0,20	-0,25	0,19	-0,07	-0,06	-0,16	0,09	0,15	0,11	0,25		0,0
	$\Delta T_{v.maks}$	0,42	1,00	0,15	0,11	0,25	-0,11	-0,01	0,02	0,04	0,09	0,11	-0,62	0,02	-0,06	0,07	1	0.8
	$\Delta T_{v.vid}$	1,00	0,42	0,12	0,08	-0,02	0,15	0,10	0,10	0,02	0,07	0,20	-0,11	-0,12	-0,15	-0,13		1,0
																		1.0

Papildomai atlikta koreliacinė analizė, pateikta šiluminiame žemėlapyje (3.2.5.5 pav.), atskleidė temperatūrinių požymių tarpusavio ryšius ST ir UP / NP grupėse.



Pearson koreliacijos koeficiento (r) šiluminis žemėlapis, vaizduojantis temperatūrinių požymių tarpusavio ryšius ST ir UP / NP grupėse. Kiekvienoje langelio sankirtoje nurodyta r reikšmė, kuri parodo koreliacijos stiprumą ir kryptį tarp dviejų požymių: reikšmės artimos +1 žymi stiprią teigiamą koreliaciją, artimos –1 stiprią neigiamą, o reikšmės arti 0 nurodo ryšio nebuvimą. Spalvų intensyvumas atspindi koreliacijos stiprumą: tamsesnės spalvos reiškia stipresnius ryšius. Pastaba: UP / NP grupėje dominuoja stiprios teigiamos koreliacijos, o ST grupėje silpnesni ar neigiami ryšiai.

UP / NP grupėje nustatytos stiprios teigiamos koreliacijos tarp požymių  $\Delta T_{b.vid}$ ,  $\Delta T_{b.maks}$  ir  $\Delta DEV_b$  (r > 0,73), taip pat tarp  $n_b$  ir  $\Delta DEV_b$  (r  $\approx$  0,79), rodančios glaudų jų tarpusavio ryšį. ST grupėje koreliaciniai ryšiai buvo silpnesni arba neigiami, pavyzdžiui, tarp  $\Delta T_{v.vid}$  ir  $\Delta DEV_v$  nustatyta reikšminga neigiama koreliacija (r  $\approx$  -0,62). Šie rezultatai leidžia daryti prielaidą, kad

patologinėse grupėse požymiai yra ne tik aukštesni pagal reikšmes, bet ir labiau susiję tarpusavyje, o tai gali būti aktualu sudarant požymių rinkinius diagnostiniams ar prognozavimo modeliams. Atlikta statistinė analizė leido įvertinti, kurie iš naudotų temperatūrinių požymių pasižymi ryškesniu diferenciaciniu potencialu, analizuojant jų reikšmes tarp skirtingų tiriamųjų grupių. Stebėtos tendencijos rodo, kad dalis požymių nuosekliai atskiria sveikus ir patologinius atvejus, o jų tarpusavio sąveikos bei sklaidos pobūdis patvirtina jų informatyvumą. Šių duomenų statistinė analizė buvo atlikta siekiant geriau suprasti klasterizavimui atrinktų aštuonių temperatūrinių požymių pasiskirstymą tarp grupių ir įvertinti jų potencialų informatyvumą.

#### 3.3. Termovaizdų klasterizavimas naudojant DI

Remiantis suformuotais aštuoniais požymių vektoriais (3.3.1 lentelė), pagal 46 pacientų termografinių vaizdų duomenis, buvo suformuotos dvi grupės: sveikų tiriamųjų arba pacientų be navikinės patologijos (ST grupė, n = 23), kuriems KT tyrimu nenustatyta navikinės kilmės patologija ir pacientų, kuriems KT tyrimu nustatyta navikinės kilmės patologija VBŽ srityje (NP grupė, n = 23) [18].

**3.3.1 lentelė.** Suformuotų požymių vektorių reikšmės ST ir NP grupių tiriamiesiems

Grupė	Δ <i>T<sub>v.vid</sub></i> (°C)	ΔT <sub>v.maks</sub> (°C)	nv	Δ <b>D</b> EV <sub>v</sub>	Δ <i>T<sub>b.vid</sub></i> (°C)	ΔT <sub>b.maks</sub> (°C)	nb	$\Delta DEV_b$
ST (n = 23)	0,14 ± 0,037	0,15 ± 0,038	$0,086 \pm 0,07$	0,117 ± 0,128	0,16 ± 0,032	$0,22 \pm 0,036$	$\begin{array}{c} 0,304 \pm \\ 0,19 \end{array}$	0,063 ± 0,015
NP (n = 23)	$0,23 \pm 0,087*$	0,22 ± 0,062	2,48 ± 21,85	0,041 ± 0,012	$0,46 \pm 0,0143$	$\begin{array}{c} 0,56 \pm \\ 0,169 \end{array}$	48,57± 22,6*	$0,139 \pm 0,043*$

ST – sveiki tiriamieji, NP – tiriamieji su navikine patologija,  $\Delta T_{v.vid}$  ir  $\Delta T_{b.vid}$  – vidutinių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $\Delta T_{v.maks}$  ir  $\Delta T_{b.maks}$  – maksimalių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $n_v$  ir  $n_b$  – pikselių skaičius termografinio vaizdo dešinėje (kairėje), atitinkamai veido ir burnos ertmės, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalią temperatūrą priešingoje veido / burnos ertmės pusėje,  $\Delta DEV_v$  ir  $\Delta DEV_b$  – absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai, atitinkamai veido ir burnos ertmės, pusei. Vidurkiai ± SD, \*p < 0,05.

Svarbu paminėti, kad šio tyrimo etapo metu atrankos kriterijumi pasirinkus temperatūros asimetriją didesnę nei 0,4 °C [14, 15], pacientų grupėje be navikinės patologijos galėjo būti įtraukti ir pavieniai pacientai su mažais uždegiminės kilmės pakitimais.

Išanalizavus 46 pacientų TV [18], algoritmo apmokymui atsitiktinai parinkti 24 pacientų veido ir burnos ertmės TV: 12 tiriamųjų TV, neturinčių jokios patologijos ir 12 tiriamųjų TV, kuriuose pagal KT nustatyta navikinė patologija. Mokymo ir testavimo rinkinių padalijimo procedūra buvo kartojama 12 kartų, kas leido įvertinti modelio gebėjimą prisitaikyti prie įvairių duomenų.

Antrame tyrimo etape, į IRST tyrimus įtraukus sveikus savanorius (SS grupė, n = 29), pagal visų ištirtų 94 pacientų TV duomenis, buvo naujai suformuotos dvi tiriamųjų grupės. Viena grupė – papildyta sveikų tiriamųjų, SS / ST grupė (n = 39), toliau įvardijama kaip ST grupė, kuriems KT ar MRT tyrimas neparodė jokių reikšmingų struktūrinių ar uždegiminių pokyčių. Kita grupė – pacientų su mišriais patologiniais pokyčiais, NP / UP grupė (n = 55), kuriems nustatyta navikinė ar uždegiminės kilmės patologija VBŽ srityje. Šioms grupėms suformuoti požymių vektoriai pateikiami 3.3.2 lentelėje.

3.3.2 lentelė.	Suformuotų	požymių	vektorių	reikšmės	ST ir	NP/UP	grupių
tiriamiesiems							

Grupė	ΔT <sub>v.vid</sub> (°C)	ΔT <sub>v.maks</sub> (°C)	Nv	$\Delta DEV_{v}$	ΔT <sub>b.vid</sub> (°C)	Δ <i>T</i> b.maks (°C)	пь	$\Delta DEV_b$
ST (n = 39)	0,12 ± 0,037	$0,062 \pm 0,038$	$0,086 \pm 0,07$	0,04 ± 0,012	0,14 ± 0,032	0,075 ± 0,036	0,11 ± 0,06	0,027 ± 0,015
NP/UP (n = 55)	0,21 ± 0,087*	$0,193 \pm 0,062$	3,17 ± 1,85	0,08 ± 0,012	$0,34 \pm 0,143$	0,46 ± 0,169	29,6 ± 19,3*	0,123 ± 0,043*

ST – sveiki tiriamieji, NP / UP – tiriamieji su mišria patologija,  $\Delta T_{v.vid}$  ir  $\Delta T_{b.vid}$  – vidutinių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $\Delta T_{v.maks}$  ir  $\Delta T_{b.maks}$  – maksimalių temperatūrų skirtumas tarp dešinės ir kairės, atitinkamai veido ir burnos ertmės, pusių,  $n_v$  ir  $n_b$  – pikselių skaičius termografinio vaizdo dešinėje (kairėje), atitinkamai veido ir burnos ertmės, kurių temperatūra yra 0,4 laipsniu aukštesnė už maksimalią tempeteratūrą priešingoje veido / burnos ertmės pusėje,  $\Delta DEV_v$  ir  $\Delta DEV_b$  – absoliučių temperatūros nuokrypių skirtumas tarp visų pikselių, priklausančių dešiniąjai ir kairiąjai, atitinkamai veido ir burnos ertmės, pusei. Vidurkiai ± SD, \* p < 0,05.

Išanalizavus 94 pacientų TV duomenis, algoritmo apmokymui atsitiktinai parinkti 48 pacientų VBŽ srities TV: iš jų 24 TV tiriamųjų, neturinčių jokios patologijos, ir 24 TV tiriamųjų, kuriems KT tyrimu nustatyta patologija. Mokymo ir testavimo rinkinių padalijimo procedūra buvo kartojama 24 kartus, kas leido įvertinti modelio gebėjimą prisitaikyti prie įvairių duomenų.

# 3.4. *k*NN metodo patikimumo BVŽ srities diagnostikoje vertinimas

Siekiant įvertinti pasirinkto *k*NN klasterizacijos modelio veikimo tikslumą ir klaidingų grupavimų dažnį, buvo suformuota maišaties matrica ir apskaičiuotos tikslumo, jautrumo ir specifiškumo reikšmės. Atpažinimo tikslumas buvo vertinamas pagal teisingai identifikuotų TV skaičių, lyginant su bendru gautų duomenų kiekiu. Suformuotos maišaties matricos patikrinimui buvo atlikta imties veikimo charakteristikų analizė (ROC).

Pirmojo etapo metu [18], vertinant kaip algoritmas geba atpažinti pacientų TV su navikine patologija, tyrimo rezultatai parodė 94,1 proc. klasterizavimo tikslumą (AUC = 0,8769), su 77,9 proc. jautrumu ir 94,9 proc. specifiškumu.

3.4.1 pav. pateikta ROC kreivė, atspindinti neparametrinį jautrumo ir specifiškumo santykį visame verčių diapazone. Rezultatai parodė, kad modelis pasižymi geru diagnostiniu efektyvumu, kadangi apskaičiuotas plotas po ROC kreive yra tarp 0,8 ir 0,9. Tai reiškia, kad pagal šį apskaičiuotą plotą, atsitiktinai parinkus vieno paciento su navikine patologija duomenis ir vieno tiriamojo duomenis be tokios patologijos, modelis teisingai priskirs aukštesnę riziką pacientui, turinčiam patologiją, maždaug 88 proc. atvejų. Toks rezultatas rodo pakankamai aukštą diagnostinį tikslumą, ypač turint omenyje, kad jautrumas siekė 77,9 proc., o specifiškumas – net 94,9 proc. Taigi, tyrimo pirmojo etapo metu gauti rezultatai atskleidė, kad adaptuotas kNN klasterizacijos algoritmas leido patikimai suskirstyti pacientus į sveikų ir navikinių patologinių atvejų grupes [18].



3.4.1 pav. Tiriamųjų grupės su navikine patologija imties veikimo charakteristikų analizės (ROC) kreivė

Punktyrinė linija žymi, kai x = y. Apskaičiuotas plotas po ROC kreive AUC siekė 0,8769. AUC reikšmė tarp 0,8 ir 0,9 interpretuojama kaip "labai geras" klasifikacinis gebėjimas patikimai atskirti pacientus su patologiniais pokyčiais nuo sveikų asmenų [129–131].

Antrojo etapo metu, vertinant kaip adaptuotas algoritmas geba atpažinti pacientų su visomis patologijomis atvejų (navikinės ir uždegiminės kilmės) TV duomenis, tyrimo rezultatai parodė 90,63 proc. klasterizavimo tikslumą (AUC = 0,8927), su 98,25 proc. jautrumu ir 92,31 proc. specifiškumu.

3.4.2 pav. pateikta mišrios patologinės grupės (NP / UP grupė) imties veikimo charakteristikų analizės (ROC) kreivė.



3.4.2 pav. Tiriamųjų grupės su skirtingomis patologijomis imties veikimo charakteristikų analizės (ROC) kreivė

Apskaičiuotas plotas po ROC kreive AUC siekė 0,8927. AUC reikšmė tarp 0,8 ir 0,9 interpretuojama kaip "labai geras" klasifikacinis gebėjimas patikimai atskirti pacientus su patologiniais pokyčiais nuo sveikų asmenų [129–131].

Apskaičiuotas plotas po ROC kreive (AUC) 0,8927 rodo labai gerą modelio diagnostinį tikslumą. Šiuo atveju, atsitiktinai parinkus vieną teigiamą ir vieną neigiamą atvejį, modelis teisingai identifikuos jų klasę daugiau nei 89 proc. atvejų. Itin aukštas jautrumas (98,25 proc.) rodo, kad modelis beveik visais atvejais teisingai atpažįsta patologiją turinčius pacientus, o aukštas specifiškumas (92,31 proc.) reiškia, kad sveiki asmenys taip pat dažniausiai klasifikuojami teisingai.

# 4. REZULTATŲ APTARIMAS

Tiksli ir ankstyva burnos, veido ir žandikaulių (BVŽ) srities navikų diagnostika apsunkinama dėl sudėtingos anatomijos ir dažnai netipinės bei kliniškai menkai išreikštos simptomatikos. Šiuo metu nėra greitų, neinvazinių ir kliniškai patikimų metodų, leidžiančių laiku identifikuoti šiuos pakitimus ir inicijuoti tinkamą gydymą.

Disertaciniame darbe, siekėme surasti naujus technologinius sprendimus BVŽ srities navikinių patologijų ankstyvam nustatymui. Tuo tikslu, buvo įvertintas infraraudonųjų spindulių termografijos (IRST) diagnostinio potencialo pritaikomumas klinikiniuose tyrimuose patologinių darinių aptikimui pacientų BVŽ srityje, rezultatus validuojant KT / MRT tyrimų duomenimis. Šiame tyrime pirmą kartą atliktas kompleksinis BVŽ srities diagnostikos metodų palyginimas, kuriame IRST duomenys buvo susieti su KT ir MRT tyrimų rezultatais, parodant, kad termogramose nustatytos temperatūros asimetrijos zonos sutapo su radiologiškai identifikuotomis navikų lokalizacijomis [14].

Kitų autorių tyrimuose dažniausiai remiamasi klinikiniais požymiais ar simptomais, tačiau neatliekamas vaizdinis objektyvus palyginimas su aukso standarto tyrimais [16, 21]. Atliktame tyrime, automatiniam BVŽ srities patologiju aptikimui buvo pritaikytas kNN klasterizatorius ir ivertintas jo potencialas navikinių patologijų atpažinimui [18]. Pademonstravome, kad, remiantis KT / MRT ir histologinio tyrimo rezultatais, apmokytas kNN algoritmas, analizuodamas specialiai parinktus aštuonis temperatūrinius požymius, gali patikimai atpažinti navikines patologijas pacientų BVŽ srityje ir suskirstyti įvesties duomenis į sveikų ir navikinių patologijų atvejų grupes. Tvrimo rezultatai parodė 94,1 proc. klasterizavimo tikslumą (AUC = 0.8769), su 77,9 proc. jautrumu ir 94,9 proc. specifiškumu. Tai rodo, kad kNN klasterizatorius kartu su IRST technologija gali būti veiksminga neinvazinė priemonė BVŽ srities navikų aptikimui. Be to, šiame tyrime kNN algoritmas buvo ne tik pritaikytas, bet ir specialiai optimizuotas BVŽ srities patologiniu būkliu identifikavimui, remiantis tikslingai atrinktais temperatūriniais požymiais, kas leidžia kalbėti apie tikslini, diagnostikai pritaikyta modelį, o ne bendro pobūdžio DI taikyma. Kitu autorių darbuose kNN dažniausiai naudotas kaip vienas iš kelių lyginamųjų algoritmų šalia SVM ar CNN, tačiau dažnai be aiškios požymių atrankos strategijos ar pritaikymo konkrečioms anatominių sričiu patologijoms [4].

Tyrimas parodė, kad *k*NN klasterizavimo algoritmas geba aptikti temperatūrinius pokyčius, būdingus tiek navikinės, tiek uždegiminės kilmės BVŽ

srities patologijoms, patvirtindamas, jog temperatūrinė asimetrija nėra specifinis vien navikinės kilmės pažeidimų požymis, ji gali pasireikšti ir esant uždegiminės kilmės patologijai. Todėl savo tyrimuose taip pat siekta i kNN klasterizavimo algoritma itraukti papildoma tiriamuju grupę su uždegiminės kilmės patologijomis ir duomenis suskirstyti i tris atskiras grupes: sveiku tiriamuju, pacientu su navikinės kilmės ir pacientu su uždegiminės kilmės patologija. Visgi rezultatu analizė parodė, kad abiejų grupių su patologiniais požymiais, navikės ir uždegiminės kilmės, duomenu rinkiniai nebuvo reikšmingai skirtingi (p > 0.05), kas rodo, jog jų temperatūriniai požymiai gali būti panašūs. Dėl šios priežasties kNN klasterizavimo metodo taikymas, pasirenkant tris klasterius, kai tiriamuju imtis grupėse nėra didelė, nebūtų tikslingas. Todėl, atlikdami išsamų ištirtų visų 94 pacientų duomenų vertinimą, nuspręsta taikyti kNN binarini klasterizavimo metoda, grupuojant visus duomenis į dvi atskiras grupes: sveikus (itraukiant sveikus savanorius) ir mišrius patologinius atvejus (apimant tiek navikinės, tiek uždegiminės kilmės patologijas). Antrosios klasterizacijos rezultatai parodė 90,63 proc. tiksluma (AUC = 0,8927), su 98,25 proc. jautrumu ir 92,31 proc. specifiškumu. Šiuo atveju, adaptuoto klasterizavimo algoritmo tikslumas sumažėjo, palyginti su tikslumu, gautu nustatant tik navikinės kilmės patologija atvejus. Vis dėlto, padidėjes jautrumo rodiklis lėmė ROC kreivės ploto padidėjima iki 0,89. Tai rodo, kad modelis pasižymi geru bendru diagnostiniu tikslumu ir geba veiksmingai aptikti patologijas, nors tam tikra klaidu tikimybė vis dar išlieka. Be to, itraukus papildomą sveikų savanorių grupę, pasižyminčią minimaliu temperatūriniu kintamumu, sumažėjo požymių, tokių kaip  $n_v$ ,  $n_b$ ,  $\Delta DEV_v$ ,  $\Delta DEV_b$ , įtaka klasterizavimui. Kadangi kNN modelis vertina ne pavienius požymius, o visą požymių rinkini, sumažėjęs sveikos grupės duomenų dispersiškumas galėjo sukurti glaudžius tašku klasterius, kurie klasterizacinėje erdvėje tampa sunkiau atskiriami nuo kai kurių patologinių atvejų. Tai, tikėtina, prisidėjo prie bendro klasterizatoriaus tikslumo sumažėjimo, o rezultatai pabrėžia, kad papildomos grupės įtraukimas ir požymių pasiskirstymo analizė yra svarbūs modelio optimizavimui. Nepaisant papildomu sveikų ir uždegiminės kilmės patologijos atvejų įtraukimo, modelis išlaikė gerus klasterizavimo parametrus, patvirtinančius jo diagnostinį patikimumą.

Statistinių rodiklių analizė leido identifikuoti požymius, pasižyminčius didesniu diferenciaciniu jautrumu tarp tiriamųjų grupių, kas liudija apie jų potencialų informatyvumą vertinant fiziologinius ir patologinius skirtumus. Reikšmingiausiu skirtumu tarp tiriamųjų grupių išsiskyrė  $\Delta T_{v.vid}$ ,  $n_b$  ir  $\Delta DEV_b$  požymiai. Šių požymių reikšmės ST grupėje buvo aiškiai neigiamos, o UP / NP grupėje yra teigiamos, rodančios nuoseklų ir kryptingą pokytį tarp sveikų ir patologinių būklių. Tokia aiški diferenciacija rodo, kad  $\Delta T_{v.vid}$ ,  $n_b$  ir  $\Delta DEV_b$  turi didelį potencialą veikti kaip šiluminiai biomarkeriai, skirti būklių

atskyrimui. Be to, koreliacinė analizė parodė, kad patologinėse grupėse (UP ir NP) šie požymiai pasižymi glaudžiais tarpusavio ryšiais, tarp  $\Delta T_{h,vid}$ ,  $\Delta T_{b,maks}$  ir  $\Delta DEV_b$  nustatytos stiprios teigiamos koreliacijos (r > 0,73), o tarp  $n_b$  ir  $\Delta DEV_b$  koreliacijos koeficientas siekė net r  $\approx 0.79$ , rodvdamas tvirta požymiu saveika patologijos salygomis. Priešingai, sveiku asmenu grupėse (ypač ST) šie ryšiai buvo silpni, fragmentiški arba neigiami, pavyzdžiui, tarp  $\Delta T_{vvid}$  ir  $\Delta DEV_v$  ST grupėje fiksuota neigiama koreliacija (r  $\approx -0.62$ ), o kiti tarpusavio ryšiai nesiekė statistinio reikšmingumo ar buvo artimi nuliui. Tai rodo, kad būtent patologinės būklės sukuria stipresnį ir nuoseklesnį tarpusavio ryšių tinklą tarp temperatūrinių požymių, o sveikų individų grupėse šių požymių elgsena yra labiau nepriklausoma, kas gali būti susiję su fiziologiniu homeostazės palaikymu. Tai dar labiau sustiprina šių požymių diagnostinį pagrįstumą, ne tik kaip atskirų rodiklių, bet ir kaip tarpusavyje susijusio požymių rinkinio, būdingo patologinėms būklėms. Vadovaujantis biomarkerių vertinimo principais, jautrumu, specifiškumu ir praktiniu pritaikomumu [132, 133],  $\Delta T_{v,vid}$ ,  $n_b$  ir  $\Delta DEV_b$  atitinka esminius reikalavimus. Atsižvelgiant į jų neinvazyvuma, matavimo objektyvuma ir stabilu pasireiškima tarp skirtingu grupių, šie požymiai gali būti svarstomi kaip galimi kandidatai ankstyvosios diagnostikos ar atrankos vertinimo modeliuose [134]. Svarbu pažymėti, kad literatūroje nebuvo rasta analogišku tyrimu, kuriuose būtu taikytas kompleksinis metodinis požiūris, apjungiantis IRST, požymių atranką ir optimizuoto kNN klasterizatoriaus apmokyma, o diagnostinio metodo patikimumas patvirtintas naudojant objektyvius KT / MRT tyrimų duomenis. Šie rezultatai sudaro prielaidą tolesnei duomenų analizės plėtrai taikant mašininio mokymosi metodus, kurių tikslas kompleksiškai įvertinti požymių visumos struktūrą ir modeliuoti požymiais grįstą grupių diferenciaciją duomenų erdvėje.

Atsižvelgiant į klasterizavimo modelio jautrumą temperatūrinių požymių pokyčiams ir siekiant užtikrinti optimalų grupių atskyrimą, buvo būtina nustatyti tinkamą temperatūros skirtumo ribą. Remiantis mūsų ir kitų autorių publikuotais duomenimis [14, 15, 18], klasterizavimo procese temperatūros skirtumo ( $\Delta T$ ) reikšmė buvo nustatyta kaip 0,4 °C. Toks pasirinkimas leido pasiekti subalansuotą jautrumo ir specifiškumo santykį, sumažinant tiek klaidingai teigiamų, tiek klaidingai neigiamų atvejų skaičių. Vis dėlto,  $\Delta T$  yra reguliuojamas modelio parametras, kurio reikšmė gali būti koreguojama pagal situaciją. Pavyzdžiui, pasirinkus mažesnę  $\Delta T$  reikšmę (pvz., 0,2 °C), modelio jautrumas padidėja, tačiau kartu didėja klaidingai teigiamų atvejų skaičius. Tai ypač aktualu onkologinėje diagnostikoje, kur klaidingai neigiamas rezultatas, t. y., nepastebėta ar klaidingai priskirta patologija, gali turėti labai rimtų pasekmių, įskaitant pavėluotą diagnozę ir blogesnę ligos prognozę. Tokiais atvejais siekiama sumažinti klaidingai neigiamų rezultatų riziką net ir tuo atveju, jei padidėja klaidingai teigiamų atvejų skaičius. Kadangi klaidingai teigiami rezultatai dažniausiai lemia tik papildomą ištyrimą, jie yra mažiau pavojingi nei nepastebėta onkologinė liga. Todėl  $\Delta T$  reikšmės parinkimas turi būti vertinamas kompleksiškai, bei atsižvelgiant į klinikinę situaciją, bei galimas diagnostinių klaidų pasekmes.

Šiame tvrime, automatiniam tiriamuju suskirstymui i grupes pasirinktas kNN algoritmas, nes jis yra greitas, tikslus ir plačiai naudojamas MM metodas. Jis išsiskiria paprastumu ir efektyvumu, ypač dirbant su mažesnėmis duomenų imtimis, todėl tampa vertingu įrankiu medicininėje diagnostikoje [77]. Be to, kNN yra neparametrinis metodas, todėl jam nereikia iš anksto numatyti duomenų pasiskirstymo. Tai leidžia algoritmui prisitaikyti prie sudėtingų ir netaisyklingų medicininių duomenų struktūrų, kurios dažnai pasitaiko klinikiniuose tyrimuose. Vis dėlto, kNN klasterizavimo metodo taikymas BVŽ srities patologiju aptikimui susiduria ir su tam tikrais iššūkiais. Vienas didžiausių iššūkių yra medicininių vaizdų kokybė ir tinkamų požymių parinkimas, nes klasterizavimo tikslumas tiesiogiai priklauso nuo to, kokie duomenų požymiai yra parenkami ir naudojami analizei. Be to, kNN algoritmas lygina kiekvieną testini pavyzdį su visais mokymo duomenimis, todėl, esant didelėms duomenų bazėms, jo veikimas gali sulėtėti ir pareikalauti dideliu skaičiavimo ištekliu. Galiausiai, tinkamo kaimynu skaičiaus k pasirinkimas yra labai svarbus, nes jis daro tiesioginę įtaką klasterizavimo tikslumui. Per mažas k gali lemti modelio jautruma triukšmui (per didelė dispersija), o per didelis k gali prastinti gebėjimą atskirti duomenų klases (per didelis šališkumas), todėl būtina rasti optimalų balansą tarp šių veiksnių.

Atliekant literatūros analizę, pastebėta, kad tik nedaugelis palyginamųjų tyrimų nagrinėjo *k*NN metodo efektyvumą navikinės kilmės patologijos aptikimui. Pavyzdžiui, tyrimai, skirti smegenų navikų diagnostikai, parodė, kad naudojant *k*NN algoritmą buvo pasiektas 86,58 proc. tikslumas, o tai yra didesnė reikšmė negu tiems patiems duomenims įvertinti taikytas slenksčių nustatymo metodas (82,64 proc.) [135]. Tuo tarpu kitų autorių atliktuose tyrimuose taikytas *k*NN algoritmas dermatologijoje odos vėžio klasterizavimui pasiekė įspūdingą 98 proc. tikslumą, kas parodo jo efektyvumą medicininėje diagnostikoje [136].

Literatūros duomenimis, be *k*NN algoritmo, BVŽ srities navikų aptikimui buvo naudojami ir kiti MM bei DI metodai, tokie kaip gilusis mokymasis, ypač konvoliuciniai neuroniniai tinklai (CNN), kurie rodo didelį potencialą ankstyvoje vėžio diagnostikoje ir gali padėti priimti tikslesnius klinikinius sprendimus ar padėti įvertinti efektyvesnes pacientų priežiūros procedūras [9], tačiau tam būtini dideli duomenų masyvai. Taip pat yra tyrimo duomenų, rodančių, kad atraminių vektorių mašininis mokymas (SVMs), atsitiktinių miškų (RF) metodas ar dirbtiniai neuroniniai tinklai (ANNs) gali pagerinti diagnostinį tikslumą BVŽ srities chirurgijoje ir pooperacinėje stebėsenoje [137]. Šiais tyrimais atskleista, kad pažangių algoritmų taikymas klinikinėje praktikoje leidžia žymiai padidinti BVŽ srities navikų atpažinimo tikslumą, prisidedant prie ankstyvos diagnostikos ir individualizuotų gydymo metodų kūrimo. Tai padeda užtikrinti tikslesnę ligos diagnostiką, efektyvesnį gydymo planavimą ir geresnius pacientų gydymo rezultatus, bet turi būti pakankamai didelės klinikinės imtys.

Svarbu paminėti, kad moksliniuose tvrimuose nebuvo vertintos IRST pritaikymo galimybės, kaip perspektyvaus patikros metodo, ankstyvai burnos navikinės patologijos atrankai, taipogi nėra palyginamųjų tyrimų, kurie būtų validuoti KT / MRT tyrimų duomenimis. Disertaciniame darbe iš veido ir burnos ertmės termografinių vaizdų buvo išgauti svarbūs temperatūriniai požymiai. Vėliau jie buvo panaudoti apmokinant kNN klasterizatorių, siekiant tiksliai atskirti sveikus ir patologinius atvejus. Šis metodas leido veiksmingai atskirti sveikus asmenis nuo pacientu, turinčiu navikinės ar uždegiminės kilmės pakitimus [18]. Tuo tarpu, Dong atliktame tyrime [138], naudojant IRST, buvo pritaikytas patobulintas Gauso atraminių vektorių mašininis algoritmas (SVM), siekiant nustatyti kaklo limfmazgių metastazes. Kiti mokslininkai naudojo dvišalius tekstūros požymius IRST vaizdams ir taikė k-vidurkių (angl. k-Means) bei miglotojo k-vidurkių (angl. fuzzv k-Means) klasterizacijos metodus, siekiant aptikti navikus burnos srityje [139]. Visi IRST taikymo BVŽ srities naviku aptikimui tyrimai buvo atlikti tik su mažomis imtimis, todėl trūksta didesnės apimties klinikinių tyrimų, kurie leistų patvirtinti šio metodo patikimumą ir klinikini pritaikomumą.

Kaip neinvazinis metodas, IRST turi didelį potencialą BVŽ srities navikų diagnostikoje, nes leidžia anksti aptikti su naviko vystymusi susijusius temperatūros pokyčius ir gali tapti vertingu įrankiu klinikinėje praktikoje. Tačiau, kad IRST technologija būtų pilnai integruota į kasdienę medicinos praktiką, būtina atlikti papildomus tyrimus, kurie padėtų standartizuoti vaizdų atlikimo protokolus, pašalinti išorinių veiksnių įtaką ir patvirtinti metodo tiksluma bei veiksminguma įvairiose pacientų grupėse. Nors IRST rodo perspektyvias galimybes BVŽ srities navikų aptikimui, vis dar išlieka keletas neištirtų ar nepakankamai išanalizuotų aspektų, tokių kaip taikomų protokolų standartizavimas ar naviku aptikimo gylis. Šiuo metu dar nėra visuotinai priimto IRST metodo BVŽ srities navikų tyrimui atlikti. Sąlygų kintamumas, iskaitant aplinkos temperatūra, paciento padėtį ir įrangos kalibravima, gali lemti nevienodus rezultatus. Be to, kadangi IRST fiksuoja tik paviršinius temperatūros pokyčius, šis metodas gali būti mažiau efektyvus giliai esančių navikų aptikimui, jei jie nesukelia reikšmingų šiluminių pokyčių paviršiuje. Naviko gylio ir paviršinių temperatūros pokyčių tarpusavio sąsajos dar nėra iki galo ištirtos, todėl būtinas papildomas mokslinis patvirtinimas.

Daugelyje ankstesnių tyrimų IRST vaizdai buvo analizuojami taikant neoptimizuota ROI parinkima, dėl ko į analize patekdavo ir nereikšmingi aplinkiniai audiniai, galimai maskuojantys mažas ar giliai lokalizuotas patologijas. Šiame tyrime ROI buvo fiksuojami pacientui išsižiojus, vertinant temperatūros asimetrija tarp kairės ir dešinės veido bei burnos ertmės pusiu [14, 18], kitaip nei ankstesniuose darbuose, kur analizuotos skirtingos anatominės sritys [4, 16]. Sveikiems asmenims reikšminga temperatūrinė asimetriia nenustatvta, o patologijos atveju  $\Delta T$  tarp pusiu siekė > 0.4 °C ir atitiko KT / MRT bei histologinių tyrimų rezultatus. Ypač reikšmingas šio tyrimo aspektas yra burnos srities ROI, kuris pasirodė turintis didesnį diagnostinį jautruma nei veido ROI. Disertaciniame darbe gauti duomenys rodo, kad pacientams, kuriems diagnozuota navikinės kilmės patologija, temperatūriniai požymiai, gauti atlikus burnos ertmės TV segmentavimą, yra labiau informatyvūs nei veido srityje. Šis skirtumas galimai susijes su burnos gleivinės termoreguliacinėmis savybėmis ir mažesne paviršinių audinių įvairove, kas leidžia aiškiau užfiksuoti temperatūrinius asimetrijos pokyčius. Tokia išvada, kiek žinoma, literatūroje iki šiol nebuvo pateikta.

Nepaisant optimizuotų vaizdų analizės metodų ir aukšto IRST diagnostinio jautrumo, dalis nustatytos temperatūrinės asimetrijos variacijų gali būti paaiškinama papildomais veiksniais, nesusijusiais su pačia patologija, bet turinčiais įtakos rezultatų interpretacijai. Šiame tyrime nustatytas temperatūrinės asimetrijos svyravimas galėjo būti paveiktas tiriamuju grupiu nehomogeniškumo, dalyviai skyrėsi lytimi, amžiumi, etnine kilme ir socialine ekonomine padėtimi, nors šie veiksniai nebuvo tiriami atskirai. Mokslinėje literatūroje pažymima, kad BVŽ srities navikai dažniausiai nustatomi vyresniems, tabaka ar alkoholi vartojantiems asmenims, kurių mityba prasta, o burnos sveikatos priežiūra nepakankama [140]. Be šių demografinių ypatumų, įtakos galėjo turėti ir fiziologiniai veiksniai, tokie kaip kraujotakos intensyvumas, prakaitavimas ar odos savybės, kurie nėra lengvai kontroliuojami. Taip pat galimas aplinkos temperatūros poveikis, nors tyrimo metu visi pacientai aklimatizavosi 15 minučių kambario temperatūroje, šis laikas žiemos ar vasaros ekstremaliomis sąlygomis galėjo būti nepakankamas. Kadangi duomenys buvo renkami skirtingais metu laikais, šie išoriniai veiksniai galėjo paveikti kai kuriu termogramu asimetrijos vertinima. Vis dėlto, nepaisant šiu kintamųjų, tyrime taikytas IRST metodas išliko efektyvus, temperatūrinė asimetrija patologijos vietoje buvo patikimai aptinkama.

Literatūroje [141] iškelta hipotezė, jog temperatūriniai pokyčiai nėra pastebimi tol, kol navikai nėra pakankamai dideli, t. y. kol nepasiekia tokio dydžio, kuris sukeltų nekrozę, dėl ko TV analizėje fiksuojamos šaltos dėmės. Vis dėlto, iki šiol trūksta išsamių tyrimų, nagrinėjančių temperatūrinių pokyčių priklausomybę nuo naviko stadijos ir (arba) dydžio. Atkreiptinas dėmesys, kad disertaciniame darbe pateiktuose KT / MRT vaizduose nekrozės zonų nebuvo, tačiau IRST užregistruotuose TV aiškiai aptiktos asimetrinės temperatūros pokyčių vietos tik tada, kai buvo pritaikytas MM klasterizavimo algoritmas pasirinktai ROI. Tai dar kartą patvirtina, kad infraraudonųjų spindulių TV leidžia aptikti temperatūrinius pokyčius, kuriuos sukelia naviko vystymasis. Šie pokyčiai atsiranda dėl angiogenezės, todėl navikas galėtų būti nustatytas gerokai anksčiau nei pasireiškia matomi anatominiai pakitimai.

Dar viena problema kyla tais atvejais, kai navikas yra lokalizuotas abipus, nes tai gali apsunkinti IRST diagnostiką. Tokiu atveju, navikas būtų atpažįstamas tik atlikus vaizdų segmentaciją, nes dėl jo abipusės lokalizacijos gali neatsirasti reikšmingos temperatūrinės asimetrijos, kuri naudojama patologiniams pokyčiams aptikti. Taipogi nedidelė arba nežymi temperatūrinė asimetrija gali būti nepastebėta dėl labiau išreikšto riebalinio audinio, kuris yra veiksmingas šilumos izoliatorius. Todėl be specialių algoritminių skaičiavimų gali būti sunku aptikti nedidelį temperatūrinį pokytį. Kai reikšmingos temperatūrinės asimetrijos nėra, patologijos aptikimui svarbūs kiti požymiai, tokie kaip aukštos temperatūros taškų nustatymas ir jų skaičiaus įvertinimas, kas leidžia algoritmui tiksliau identifikuoti galimus patologinius pakitimus, net jei temperatūriniai skirtumai yra minimalūs.

IRST efektyvumas diagnozuojant BVŽ srities navikus ankstyvose stadijose, lieka ribotai ištirtas. Įvairūs navikų tipai, kaip gerybiniai ar piktybiniai, lokalizuoti minkštuosiuose ar kauliniame audiniuose gali pasireikšti skirtingais temperatūriniais požymiais, todėl reikalingas detalesnis jų tyrimas. Siekiant pagerinti diagnostinį tikslumą, būtina integruoti IRST su kitais vaizdiniais metodais (KT / MRT) bei dirbtinio intelekto analize.

Šiame tyrime toks kompleksinis požiūris pirmą kartą buvo pritaikytas BVŽ srityje, pademonstruojant jo veiksmingumą. Tačiau plačiam klinikiniam pritaikymui būtini tolimesni tyrimai su didesnėmis ir labiau diferencijuotomis imtimis, taikant standartizuotus analizės protokolus. Kol šie aspektai neišspręsti, IRST taikymas išlieka perspektyvus, bet ribotas.

Iki šiol, IRST buvo plačiai naudojamas ankstyvai krūties vėžio diagnostikai [142–144], tačiau turimi duomenys, susiję su burnos ir veido navikinės kilmės patologijos aptikimu, yra riboti ir nepakankamai argumentuoti [139]. Taip pat svarbu paminėti, kad pagal naujausias sveikatos priežiūros gaires [145, 146], termografija, kaip atrankinės diagnostikos procedūra, dar nėra patvirtinta nei vienoje klinikinės diagnostikos srityje. Nors JAV Maisto ir vaistų administracija (FDA) yra suteikusi leidimą naudoti infraraudonųjų spindulių termografiją, kaip papildomą metodą krūties navikų vertinimui, ji nėra patvirtinta kaip savarankiška diagnostikos priemonė [147]. Melanomos atveju tokio oficialaus pritaikymo nėra. COVID-19 pandemijos metu IRST taikymas išplito kaip papildoma priemonė kūno temperatūros stebėsenai, tačiau tai buvo orientuota į greitą pirminį vertinimą, o ne į sistemingą integraciją į formalius klinikinės diagnostikos protokolus [148, 149]. Todėl IRST vis dar laikomas eksperimentiniu įrankiu, kurio taikymo diagnostikai pagrįstumui būtini papildomi moksliniai įrodymai ir reglamentavimas.

Ateities tyrimų kryptys, susijusios su IRST taikymu BVŽ srities navikų aptikimui, turėtų būti orientuotos į tikslumo didinimą, standartizavimą ir klinikinę integraciją. Svarbu sukurti visuotinai priimtas gaires, apimančias paciento pozicionavimą, aplinkos temperatūros kontrolę ir įrangos kalibravimą, siekiant sumažinti duomenų variabilumą tarp tyrimų. Taip pat svarbu sukurti efektyvesnius metodus terminių vaizdų išankstiniam apdorojimui ir analizei, kad būtų užtikrintas geresnis rezultatų tikslumas ir vienodas vertinimas. Be to, būtina tobulinti termovizorių jautrumą ir skiriamąją gebą, siekiant tiksliau fiksuoti smulkius temperatūrinius skirtumus kurie gali būti svarbūs ankstyvai navikų diagnostikai. Šių aspektų gerinimas leistų IRST metodui tapti patikima ir plačiai pritaikoma diagnostikos priemone klinikinėje praktikoje [150].

# IŠVADOS

- 1. DI pagrįstas IRST metodas gali patikimai aptikti patologiją BVŽ srityje ir gauti rezultatai gerai sutapo su KT / MRT duomenimis.
- Dideli ir paviršiniai navikai BVŽ srityje aptinkami IRST vaizduose be segmentavimo, tačiau mažiems ir giliai ar abipus lokalizuotiems dariniams būtina segmentacija dėl silpnos temperatūrinės asimetrijos. Informatyvesnis yra burnos ertmės ROI segmentavimas, kadangi burnoje temperatūros pokyčiai fiksuojami jautriau dėl gleivinės ypatybių.
- 3. Atrinkti aštuoni temperatūros pasiskirstymą apibūdinantys požymiai  $(\Delta T_{v.vid}, \Delta T_{b.vid}, \Delta T_{v.maks}, \Delta T_{b.maks}, n_v, n_b, \Delta DEV_v, \Delta DEV_b)$  sudarė pagrindą sėkmingam kNN klasterizatoriaus taikymui. Dalis jų  $(\Delta T_{v.vid}, n_b \text{ ir } \Delta DEV_b)$  išsiskyrė, kaip statistiškai reikšmingi ir labiausiai diferencijuojantys tarp grupių. Šie požymiai gali būti taikomi, kaip šiluminiai biomarkeriai, papildantys kNN klasterizavimo rezultatus ir stiprinantys ankstyvosios diagnostikos galimybes BVŽ srityje.
- Optimizuotas kNN binarinis klasterizavimo modelis patikimai atpažino ir tiksliai suskirstė pacientų TV į sveikų ir patologinių atvejų grupes, pasiekdamas aukštą tikslumą, jautrumą, specifiškumą (90–98 proc.), bei AUC reikšmę ~0,9.

### Tyrimo apribojimai

Pagrindinis tyrimo trūkumas gali būti susijęs su vėlyvąja patologijos stadija, nes daugumai tirtų pacientų pakitimai jau buvo išreikšti ir sukėlė specifinius simptomus. Norint aptikti patologiją ankstyvosiose stadijose, pacientai turi būti ištirti prieš tai, kuomet jiems pasireiškia ligos simptomai. Deja, šiuo metu tik keli pacientai atitiko šį kriterijų.

Giliai lokalizuotų pakitimų vertinimas išlieka iššūkiu, kol jie nėra pakankamai dideli, tačiau taikant vaizdų segmentavimą, galima juos tiksliau aptikti, išryškinant patologinius pokyčius ir taip pagerinant diagnostikos tikslumą.

Dar vienas trūkumas galėtų būti susijęs su tiksliai neįvertinta temperatūra smilkininio apatinio žandikaulio sąnario zonoje, naudojant priekinę žmogaus veido projekciją. Tam reikia naudoti šoninę projekciją, tačiau tokiomis aplinkybėmis abi veido pusės turi būti idealiai pozicionuotos tuo pačiu kampu ir atstumu, o tai yra ganėtinai sunku atlikti.

Be to, kad algoritmas galėtų būti naudojamas kaip neinvazinis atrankinės diagnostikos metodas reikia duomenų iš didesnių pacientų grupių. Tuo tikslu ateityje planuojama į klasterizavimo grupes įtraukti daugiau atvejų ir atlikti daugiau eksperimentinių bandymų.

# SUMMARY

AI	_	Artificial Intelligence
AUC	_	Area Under the Curve
СТ	_	Computed Tomography
IRT	_	Infrared Thermography
<i>k</i> NN	_	k-Nearest Neighbor
ML	_	Machine Learning
MRI	_	Magnetic Resonance Imaging
<b>n</b> f	_	Number of pixels in the right (or left) side of the facial TI with a
		temperature at least 0.4 °C higher than the maximum temperature on the opposite side
<b>N</b> m	_	Number of pixels in the right (or left) side of the mouth TI with a temperature at least 0.4 °C higher than the maximum temperature on the opposite ride
омм		Oral Maxillofacial and Mandibular
	_	Region of Interest
SCC	_	Squamous Cell Carcinoma
SUU		Support Vector Machine
TI		Thermographic Image
11 T		Mean temperature on the left side
T meanL		Mean temperature on the right side
T meank		Maximum temperature on the left side
T maxL	_	Maximum temperature on the right side
		Difference in absolute temperature deviations between all nivels on the
		right and left sides of the face
∆DEV	_	Difference in absolute temperature deviations between all nivels on the
		right and left sides of the mouth
$\Lambda T$	_	Temperature difference between the left and right sides
	_	Difference in maximum facial temperatures between left and right sides
$\Delta \mathbf{I}_{j.max}$	_	Difference in mean facial temperatures between left and right sides
∆ <b>1</b> j.mean ∧ <b>T</b>	_	Difference in maximum mouth temperatures between left and right sides
∆∎ m.max ∧ <b>T</b>	_	Difference in maximum mouth temperatures between left and right sides
⊥∆ <b>I</b> m.mean	_	Difference in mean mouth temperatures between left and right sides

#### **INTRODUCTION**

Pathologies of the oral, maxillofacial and mandibular (OMM) region, including neoplasms, infections, inflammatory conditions, and vascular anomalies, present substantial diagnostic challenges due to their heterogeneous etiology, complex clinical progression, and frequently nonspecific symptomatology [1, 2]. To enable early detection, differential diagnosis, and optimal treatment planning, the application of advanced imaging modalities is essential. These tools facilitate accurate evaluation of soft and osseous tissue alterations, delineation of the extent of pathological involvement, and longi-

tudinal monitoring of disease progression [3]. Although radiological examinations such as computed tomography (CT) or magnetic resonance imaging (MRI) are considered the gold standard, their application requires costs, radiation or the use of contrast agents. For these reasons, they are not the most suitable methods for preventive examinations or frequent monitoring of the patient's condition.

Alternative non-invasive methods such as infrared thermography (IRT) have received increasing attention in recent years due to their ability to record physiological temperature differences associated with changes in blood flow, tissue inflammation or neoplastic pathologies [4]. Temperature variations recorded on the skin surface using IRT may reflect deeper pathological processes such as angiogenesis or altered metabolic activity [5]. Unlike CT, which provides detailed anatomical visualization, IRT offers insights into functional alterations, particularly in thermal regulation, which may precede observable structural changes in tissues. In neoplastic conditions, areas of elevated temperature can be observed in affected regions due to angiogenesis, which increases local blood flow and consequently enhances heat emission. Conversely, in cases of ischemia or tumor necrosis, cooler areas may be detected, as reduced perfusion leads to lower surface temperature in the affected tissue [6].

IRT cannot replace CT, as it lacks the detailed anatomical information that CT provides. However, it may serve as a non-invasive pre-screening tool, helping to reduce unnecessary CT/MRI examinations or facilitating timely referral for advanced imaging when pathological changes are suspected.

However, in the diagnostic assessment of the OMM region, not only precise localization of pathology is essential, but also the timely prediction of emerging pathological changes [7, 8]. This can be achieved through the application of artificial intelligence (AI) tools. The integration of machine learning (ML) technologies into clinical decision-making processes represents a promising direction and is expected to play a pivotal role in the future advancement of radiological diagnostics [9–13].

In the first stage of this dissertation, we aimed to apply new IRST technological solutions for the earlier detection of pathologies in the OMM area. Since pathologies in the OMM area are best investigated by radiological examinations, the results of IRT examinations obtained by analyzing thermographic images (TI) of patients were validated by CT/MRI examinations. We identified the areas of temperature asymmetry in the TIs of the OMM area of patients, which corresponded to the tumor localizations determined by CT/MRI examination [14]. In the literature, in the presence of pathology, the temperature asymmetry greater than 0.4 °C was chosen as the selection criterion [15], however, there are no studies in the OMM area in which

pathologies detected by IRT would be confirmed by radiological examination data [4, 16].

However, early and rapid detection of pathology remains critically important. In the second stage of the study, based on the assumption that AI-based tools could facilitate earlier identification of subtle  $\Delta T$  asymmetries, we aimed to extract statistical features characterizing the temperature distribution from the TI of the OMM region. These features were then used as input data for a machine learning k-Nearest Neighbors (kNN) clustering algorithm [17]. The latter was trained, using radiological imaging results as ground truth, to recognize predominant features in the TI and to make appropriate clustering decisions: presence / absence of pathology. The results showed that the machine learning kNN clustering algorithm can reliably differentiate between pathological and healthy tissues in the OMM region by analyzing eight specifically selected thermal features [18]. However, the successful application of this method requires targeted feature selection and determination of the optimal value of k. Despite these challenges, the use of kNN in TI analysis may offer a rapid, non-invasive, cost-effective, and accessible approach for the early detection of tumors, potentially reducing diagnostic costs and avoiding exposure to ionizing radiation, as seen with CT imaging. In the future, research should focus on the refinement of ML models and the validation of results through clinical studies. This would enhance the accuracy, reliability, and applicability of this technology in oral and maxillofacial oncology.

#### AIM AND OBJECTIVES

#### Aim of the study:

To evaluate the applicability of infrared thermography (IRT) and artificial intelligence (AI) for the detection of pathological conditions (tumorous and inflammatory) in the oral, maxillofacial, and mandibular (OMM) region, and to compare the results with radiological imaging data.

#### Tasks for the study:

- 1. To detect temperature asymmetry in the OMM region using IRT data and to compare the findings with CT and MRI results.
- 2. To apply segmentation techniques to IRT TI for identifying pathological regions and to assess their diagnostic relevance.
- 3. To identify temperature-related features associated with pathology and use them to train a machine learning *k*-nearest neighbors (*k*NN) algorithm for clustering TI as healthy or pathological (neoplastic / inflammatory) cases.
- 4. To evaluate the reliability of the optimized *k*NN clustering model for early detection of OMM pathologies based on CT and MRI validation.

#### Scientific novelty

Early diagnosis and treatment planning for patients with OMM pathologies is often challenging [1, 2].

This study is the first to integrate IRT and AI-based methods for the detection of pathologies in the OMM region, specifically distinguishing thermal images into healthy and pathological cases based on selected thermal features. An optimized kNN clustering algorithm was developed and trained using selected thermal features capable of distinguishing pathological conditions with high accuracy. Importantly, for the first time, the diagnostic performance of the model was validated against objective radiological data from CT and MRI, providing evidence-based verification rather than relying on clinical examination or symptom-based assumptions [14, 18].

A comprehensive review of literature revealed no prior studies combining IRT with optimized Ai-based clustering and concurrently validating results against radiologically confirmed diagnoses, highlighting the methodological uniqueness of this study. Published works to date often emphasize the importance of temperature asymmetry for pathology recognition, and thermograms are interpreted based on clinical symptoms, without objective visual verification [16]. Although AI models often use many features, literature lacks an optimized feature set and objective CT / MRI validation [4].

The research conducted in this dissertation also revealed that, to identify asymmetric temperature variations within symmetrical regions of the OMM area, it is appropriate to use image processing algorithms for the accurate detection of the region of interest (ROI) [14]. We found that large and superficially located tumors in the OMM region can be easily detected in TI without additional image processing. However, in cases of small, deep-seated, or bilaterally located tumors, ROI segmentation is essential to highlight the pathological area, as thermal asymmetry may be subtle or unclear. In the literature, IRT technology has been applied only to studies of the facial region, but not to the oral cavity [4, 19, 20]. This dissertation demonstrates, for the first time, that ROI segmentation in the oral cavity is more informative than in the facial region. This is due to the presence of thinner tissues and mucosa in the oral area, which result in a more sensitive detection of temperature variations.

In this study, TI obtained using IRT and validated with CT data were used to extract eight specific input features characterizing temperature distribution [18]. This enabled the machine learning *k*NN cluster to train and test randomly selected TI [18]. The trained optimized *k*NN algorithm, which evaluates features in a multivariate manner rather than individually, was able to successfully assign input feature vectors to distinct groups, corresponding to the presence or absence of pathology. Statistically significant features were found that differentiate the most between the groups and have the potential to be applied as thermal biomarkers, complementing the *k*NN clustering results and strengthening the early diagnostic capabilities in the OMM region.

We also demonstrated that the binary kNN clustering reliability (healthy vs. pathological cases), based on calculated accuracy, sensitivity, and specificity values, was high. Specifically, for the detection of TI associated with neoplastic pathology, the algorithm achieved 94.1% accuracy, 77.9% sensitivity, and 94.9% specificity (n = 46) [18]. When evaluating all pathological cases (both neoplastic and inflammatory), the respective values were 90.63% accuracy, 98.25% sensitivity, and 92.31% specificity (n = 94). The binary kNN clustering reliably identified pathological cases based on TI data. The optimized kNN clustering algorithm was supported not only by its high accuracy, sensitivity, and specificity, but also by area under the curve (AUC) values, which were close to 0.9, indicating strong discriminative ability.

The pilot study fills the existing gaps – the developed optimized algorithm is not only based on reliable thermographic features, but also objectively validated based on CT / MRI results. This demonstrates clinical reliability and may become a promising additional tool for non-invasive radiological diagnostics in the future.

#### 2. METHODOS

The clinical study of the patients was conducted in accordance with the workflow scheme presented in Fig. 2.1.



Fig. 2.1. Workflow scheme

### 2.1. Protocol for thermographic imaging in the OMM region

As various factors can influence TI data, all subjects were instructed to adhere to specific restrictions prior to the examination. They were advised to avoid mechanical stimulation of the facial region, such as massages, the use of creams, or intense physical exercise. Additionally, the use of medications was discouraged, as well as the consumption of hot, cold, or stimulating foods and beverages that could affect skin temperature and potentially distort the results of the study. To avoid potential temperature fluctuations caused by exposure to X-rays or intravenous contrast agents, all patients were examined under identical conditions prior to the CT scan, following the same thermographic protocol [14, 117, 118]. During this protocol, it was ensured that:

- There was no draft during the examination, and air conditioners were turned off.
- No high-temperature infrared radiation (IR) sources were present near the subject.
- The room maintained a constant temperature (20–22 °C) and humidity, with no direct sunlight exposure.
- A 15-minute acclimatization period was provided for the subject in the examination room.
- The subject had refrained from smoking for at least several hours prior to the examination.
- Relevant information from the subject's medical record was reviewed, including name and surname, sex, age, chief complaint, history of tobacco and alcohol use, sensitivities, past and current illnesses, and medications in use.
- During measurements, all subjects were seated as upright as possible.
- The IRT camera, equipped with imaging and auto-focus functions, was positioned at the subject's head level, at one meter (see [14]).
- Thermographic images were recorded using the IRT camera in a frontal projection of the subject's face, with the mouth open.
- At the end of the sequence, the recorded thermographic data were reviewed for reproducibility, and the images were cross-checked against the CT-detected abnormalities.

A commercially available FLIR E8 infrared thermal camera (FLIR Systems, Inc., Wilsonville, OR USA) was used to obtain thermographic images, with the device positioned approximately one meter from the subject's face. However, any other thermal imaging camera may also be used for this purpose. The images were captured at a resolution of  $320 \times 240$  pixels, with a thermal sensitivity of  $\pm 0.06$  °C and a temperature detection range between -20 °C and +250 °C. All measurements were conducted under standardized environmental conditions, maintaining a room temperature of  $22 \pm 1$  °C and a relative humidity of  $60 \pm 5\%$ . The skin emissivity value was set at 0.98.

Once captured, the thermographic data were transferred to a computer for analysis. Image processing was carried out using Matlab R2014b (The MathWorks, Inc., Natick, MA, USA). To enable data compatibility with Matlab, the thermal images were first converted using ThermaCam Researcher 2.1 software (FLIR Systems, Inc., Wilsonville, OR USA).

#### 2.2. Radiological examination of patients in the OMM region

Following the acquisition of TI, each patient underwent a CT scan using the Toshiba Aquilion ONE system (Canon Medical Systems, Otawara, Japan), with a consistent slice thickness of 1 mm applied across all examinations. A radiologist reviewed and evaluated the CT images. CT imaging served as the reference standard for lesion identification, and based on the CT results, patients were categorized into groups.

To avoid the harmful effects of ionizing radiation on healthy volunteers, and with additional ethical approval, magnetic resonance imaging (MRI) of the head and neck soft tissues was performed without the use of intravenous contrast agents. The MRI examinations were conducted at the Radiology Clinic of the Hospital of Lithuanian University of Healh Sciences Kauno klinikos (Kauno klinikos) using a 1.5 Tesla Siemens Magnetom Avanto scanner (Siemens Medical Systems, Erlangen, Germany). During the procedure, participants were instructed to remain still in a supine position. An 8-channel head coil and a 4-channel neck coil were used for imaging, both positioned over the subject's head and neck regions during the scan. The acquired MRI images were evaluated by a radiologist.

#### 2.3. Inclusion criteria for subject eligibility in IRT examination

A total of 70 individuals who were referred for a CT scan at the Radiology Clinic of Kauno klinikos for confirmation or exclusion of pathology following clinical evaluation were invited to participate in the clinical study. None of them declined participation; however, 5 individuals were excluded from the study due to not meeting the eligibility criteria described below. Subsequently, additional approval was obtained to form a healthy volunteer (SS) group (n = 29). The final study sample consisted of 94 participants, including 39 healthy individuals and 55 patients diagnosed with pathology via CT imaging (Fig. 2.3.1).



Fig. 2.3.1. Schematic distribution of subjects into groups

- 1. Patients included in the study met the following criteria:
  - signed informed consent form,
  - age  $\geq 18$  years,
  - first time CT procedure due to clinical symptoms,
  - no history of surgical interventions in the OMM region,
  - no history of medication prescribed for conditions in the OMM region.
- 2. Patients were excluded from the study if they met any of the following criteria:
  - history of surgical interventions in the OMM region,
  - ongoing or prior medication for conditions in the OMM region,
  - use of physical therapy, ultrasound, or acupuncture within 24 hours prior to the examination,
  - bathing, swimming, or exercising within 1 hour prior to the examination,
  - consumption of coffee, smoking, or alcohol intake within 1 hour before the examination,
  - shaving of the target body area within 4 hours prior to the procedure,
  - elevated body temperature or recent sunburn,
  - presence of acute or chronic fungal sinusitis,
  - diagnosis of diffuse non-Hodgkin's lymphoma,
  - presence of facial scars associated with pathological hypothermic lesions [118].

#### 2.4. Visual analysis and segmentation of TI in the OMM region

Thermographic images of the subjects facial and mouth regions were analyzed in two stages. First, a visual assessment was conducted to evaluate the temperature distribution across the face and mouth, as well as to identify any deviations from normal thermal patterns. In some cases, pathological changes were immediately apparent, as localized areas of elevated temperature, typically associated with inflammatory or neoplastic processes, were clearly visible on the thermograms. However, for other patients, no obvious thermal anomalies were observed during initial inspection. Therefore, to enhance the clarity of the analysis and enable precise identification of regions of interest (ROI), the images were segmented based on absolute temperature values. This segmentation allowed for a more detailed and systematic evaluation of the thermal data. The color map serves as a representative tool for assessing facial pathologies. The number and values of isotherms are automatically determined based on the minimum and maximum temperatures detected in the facial region. Pathological areas typically exhibit distinct (elevated) temperatures and may be highlighted using a different color than the surrounding facial tissues, allowing for clearer differentiation from healthy regions.

Automatic image segmentation was performed using Matlab R2014b software (The MathWorks, Inc., USA) (Appendix 1). The segmentation process included initial image preprocessing, application of threshold analysis, clustering, and morphological operations, all aimed at optimizing the accuracy of the segmentation.

Since the pathology was not always clearly visible in the segmented images, further stages of analysis incorporated parametric methods. Contour detection of the face and mouth was performed to identify anatomical boundaries and enable a detailed analysis of temperature variations. Additionally, a symmetry axis detection method was applied to assess the thermal distribution symmetry between the two sides of the face.

# **2.5.** Contour detection and symmetry axis identification of thermographic images of the face and mouth

## 2.5.1. Detection of human face edges

Following the acquisition and preprocessing of TI, the subsequent step involved the delineation of facial boundaries. To detect edges, a gradientbased method was employed, which identifies image regions exhibiting high gradient values, these correspond to locations where intensity changes most rapidly. In essence, edges are determined by locating the maximum of the images first derivative.

Gradient components of the TI in various directions were computed using a convolution mask, as detailed in [123]. Pixels with high gradient magnitudes were classified as edge pixels. For this purpose, the Prewitt operator was utilized due to its algorithmic simplicity and low computational demand. An example of the original thermographic image and the resulting edge detection output is shown in Fig. 2.5.1.1.



Fig. 2.5.1.1. Original facial TI and gradient image

Note: the presented image shows a subject with no detected OMM pathology. image (A) was acquired using IRT technology, while image (B) displays the computer - calculated facial gradient map.

## 2.5.2. Detection of human face or mouth cavity symmetry axis

To determine the orientation and position of the facial symmetry axis, it is sufficient to use the external edge points of the face. To represent the outer contour of the face, the convex hull algorithm was applied, which identifies the smallest convex polygon that encloses all detected edge points [124]. This convex hull delineates the outermost boundary of the facial region and serves as the structural reference for analyzing thermal distribution. The set of selected edge points forming this polygon defines the contour used for further symmetry axis calculations (Fig. 2.5.2.1, A).


Fig. 2.5.2.1. Detection of the convex polygon of facial and mouth contour points and symmetry axis

The thermographic image of a healthy subject (A). The symmetry axis (black line) corresponds to the major axis of the fitted contour (dashed line) (B, C). The temperature ( $^{\circ}$ C).

An ellipse was fitted to the set of convex hull vertices using the leastsquares method, and its major axis was used to determine the symmetry axis of the face (as illustrated in Fig. 2.5.2.1, B).

Similarly, the boundaries of the mouth were identified from the previously computed convex hull (Fig. 2.5.2.1, C). This symmetry axis served to divide the thermographic image into two distinct regions corresponding to the left and right sides of the mouth for separate analysis [18]. Since the shape of the mouth does not approximate an ellipse, the centroid method was used instead to determine its center. This approach is based on calculating the average coordinates of all contour points rather than fitting an ideal geometric curve, allowing for more accurate representation of the mouth anatomical structure.

### 2.6. Detection of thermal asymmetry in regions of interest (ROI) in facial and mouth thermographic images

To support tumor detection, feature vectors were generated for each subject based on temperature data extracted from specific regions within their thermographic images. These vectors incorporated the temperatures of individual pixels from four defined areas, allowing for the calculation of key features such as  $\Delta T_{f.mean}$ ,  $\Delta T_{m.mean}$ ,  $\Delta T_{f.max}$ ,  $\Delta T_{m.max}$ ,  $n_f$ ,  $n_m$ ,  $\Delta DEV_f$ ,  $\Delta DEV_m$  (see Table 2.6.1)

Features	Definition
$\Delta T_f(^{\circ}\mathrm{C})$	The difference between mean temperatures of R vs. L sides of the face
$\Delta T_m$ (°C)	The difference between mean temperatures of R vs. L sides of the mouth cavity
$\Delta T_{fmax}$ (°C)	The difference between max temperatures of R vs. L sides of the face
$\Delta T_{mmax}$ (°C)	The difference between max temperatures of R vs. L sides of the mouth cavity
<i>n</i> f	The number of pixels in TI of the R (L) side of the face having $\Delta T$ degree higher temperature than the max temperature of opposite face side
Иm	The number of pixels in TI of the R (L) side of the mouth cavity having $\Delta T$ degree higher temperature than the max temperature of opposite mouth cavity side.
$\Delta DEV_f$	The difference of the absolute deviations of the temperature values of all pixels belonging to the R and L face side, respectively
$\Delta DEV_m$	The difference of the absolute deviations of the temperature values of all pixels belonging to the R and L mouth cavity side, respectively

Table 2.6.1. Thermal characteristics of selected features extracted from TI

R and L denotes right and left side, respectively.

It is important to note that many individuals in the control group exhibited non-tumorous pathologies, such as inflammatory conditions. Therefore, following prior research [14], a thermal asymmetry threshold of 0.4 °C between the left and right sides of the face or mouth was adopted as a key inclusion criterion for this group. A temperature difference exceeding 0.4 °C was considered indicative of abnormal thermal behavior and was associated with potential tumor presence. Consequently, this asymmetry threshold was used as a foundational parameter in constructing each patient's feature vector.

To further quantify this asymmetry, the number of thermographic pixels on one side of the face or mouth that exhibited a temperature difference ( $\Delta T$ ) greater than the maximum temperature on the opposite side was determined using histogram analysis for both regions.

#### 2.7. Training procedure and automatic clustering

To train the clustering system, each feature value was calculated as an average of five measurements obtained from the same TI. This approach was adopted to account for minor variations that can occur during the estimation of facial or mouth contours, which occasionally required adjusting the position of a few contour points.

The processed TI data from healthy subjects and patients with various OMM pathologies, whether of neoplastic or inflammatory origin, were stored in the computer memory as feature matrices. These matrices served as the basis for classifying each case into one of two categories: absence (0) or presence (1) of a pathology.

In this study, a k-nearest neighbor (kNN) clustering algorithm [17] was employed, as it is particularly effective for smaller datasets with a limited number of features. The kNN model relies on labeled feature vectors from the training dataset to assign class labels to new, unseen instances based on their proximity to existing data points.

During the clustering stage, the feature vector extracted from a patient's TI is compared against the feature matrix obtained during the training process (Appendix 2). With the number of nearest neighbors set to k = 1, the patient's data are assigned to the cluster of the closest data point. As a result, the sample is grouped into either the pathology cluster (UP / NP) or the healthy subject cluster (ST), depending on which it most closely resembles in feature space.

In this study, feature vectors were extracted for each individual patient [18]. The complete dataset was then randomly partitioned into two subsets: one for training and the other for testing. The training subset included only 24 thermographic images from patients without pathological findings (ST) and 24 images from patients with confirmed tumor or inflammatory pathologies (UP / NP). To ensure the robustness of the proposed method, the traintest split process was repeated 24 times, each time using different combinations of data for training and testing.

In the kNN approach, test samples are classified by analyzing their similarity to labeled instances in the training set. Because the actual labels of the test samples are already known, this comparison allows for an objective assessment of the model's prediction reliability and overall performance.

To evaluate the performance of the proposed method in terms of correct and incorrect clustering, a confusion matrix was constructed. Based on this matrix, key metrics such as accuracy, sensitivity, and specificity were calculated. Clustering accuracy was assessed by comparing the predicted outcomes with the actual class labels derived from CT scan findings. A reference vector containing the ground truth labels for each thermographic image was created to enable this comparison. In addition, the feature vector was compared with the clustering results obtained from the system. Recognition accuracy was defined as the ratio of correctly clustered thermographic images to the total number of cases analyzed. To further evaluate the system's performance, sensitivity was calculated as the proportion of correctly clustered pathological (UP / NP) cases relative to the total number of true UP / NP cases. Specificity, in turn, was determined by the ratio of correctly clustered non-pathological (ST) cases to the total number of actual ST cases.

#### 2.8. Statistical analysis

Each TI contour of the facial and mouth was calculated by repeating the process five times. Statistical data analysis was conducted using Microsoft Excel (Microsoft, USA) and IBM SPSS 22 software (IBM Corp., NY, USA). Numerical data are presented as a means with standard deviations (SD), which reflect the variability of the measurements.

To compare the means between two groups, the Student's *t*-test was used, while comparisons among more than two groups employed one-way analysis of variance (ANOVA) for parametric data or the Kruskal-Wallis test for non-parametric data. Normality of data distribution was assessed using the Shapiro-Wilk test. Differences in means were considered statistically significant when p < 0.05.

Mathematical determination of facial and mouth contours in TI, as well as the development of clustering algorithms, was carried out using MATLAB software (The MathWorks, Inc., USA). For plotting histograms, the statistical software SPSS 22 was used.

#### **3. RESULTS**

The clinical study was conducted at the Department of Radiology, Hospital of the Lithuanian University of Health Sciences Kauno klinikos, with the approval of the Regional Biomedical Research Ethics Committee of Kaunas (June 3, 2014; No. BE-2-31). All participants were thoroughly informed about the study and signed a written informed consent form. The recruitment of participants took place between 2014 and 2016. The scientific study included 94 patients, of whom 55 (58.5%) were assigned to the pathology group, and 39 (41.5%) to the non-pathology group. The demographic, anthropometric, and clinical characteristics of the patients are presented in Table 3.1.

Demographic data	With pathologie (n = 55)	Without pathologie (n = 39)
Age (years)	18–86	20–64
Midle age (years) $\pm$ SEM	$53.3\pm2.53$	$33.5\pm2.03$
Women, n (%)	30 (54.5)	17 (43.6)
Men, n (%)	25 (45.5)	22 (56.4)
In total, n (%)	55 (100)	39 (100)
CT detected pathological side		
Right side, n (%)	20 (36.4)	0 (0)
Left side, n (%)	23 (41.8)	0 (0)
Bilateral, n (%)	12 (21.8)	0 (0)
Men / women pathological side		
Men, right side, n (%)	13 (52)	0 (0)
Men, left side, n (%)	10 (40)	0 (0)
Men, bilateral, n (%)	2 (8)	0 (0)
Women, right side, n (%)	8 (26.7)	0 (0)
Women, left side, n (%)	13 (43.3)	0 (0)
Women, bilateral, n (%)	9 (30)	0 (0)

Table 3.1. Demographic and clinical data of the study participants

In this study, the following patient groups were identified: the healthy subjects (ST) group, which included healthy volunteers (SS) and individuals in whom no structural abnormalities or pathological lesions were detected by CT or MRI. The pathology or mixed group (NP/UP) included patients with changes of neoplastic origin (NP) or inflammatory origin (UP). Neoplastic pathology was identified through CT imaging and subsequently confirmed by histopathological analysis. Inflammatory pathology, such as bacterial or infection-related inflammatory conditions, was diagnosed by CT findings and confirmed by clinical examination data.

# **3.2.** Assessment of the diagnostic potential of IRT for detecting areas of thermal asymmetry in facial and mouth thermographic images (TI)

### 3.2.1. Analysis and evaluation of TI in healthy subjects

In healthy subjects (ST group, n = 39), no statistically significant thermal asymmetries were identified across the four main analyzed regions. This indicates that heat distribution between symmetrical areas of the face and mouth was uniform, with no marked temperature differences suggestive of pathological changes. Fig. 3.2.1.1 presents examples of thermographic maps from a healthy subject: in a facial anterior projection (A), and mouth anterior projection (B).



Fig. 3.2.1.1. Detection of facial and mouth contours and the symmetry axis in a thermal image of a healthy subject

The symmetry axis (solid line) corresponds to the major axis of the ellipse (dashed line). TI of a healthy subject are shown in the frontal plane (A) and with mouth open (B). Note: No thermal asymmetry is present in the facial or mouth TI. The temperature (°C).

The TI were processed in two stages (see Methods and Appendix 1), using algorithmic contour detection procedures to identify the outer facial contour, the ROI in the mouth, and to determine the position of the symmetry axis. In Table 3.2.1.1 is presented an example of calculated temperature features.

**Table 3.2.1.1.** Temperature features in the TI of one healthy subject (Fig. 3.2.1.1), measured in the left and right ROI of the face and mouth

	ROI	T <sub>meanL</sub> (°C)	T <sub>maxL</sub> (°C)	T <sub>meanR</sub> (°C)	T <sub>maxR</sub> (°C)	∆ <i>T<sub>mean</sub></i> (°C)	$\Delta T_{max}$ (°C)	$\Delta DEV$	<b>n</b> f∕m
ST	f	$33.47\pm0.039$	36.17	$33.64\pm0.004$	36.03	0.17	0.14	0.02	0
	m	$34.92\pm0.023$	36.97	$35.03\pm0.013$	36.78	0.11	0.19	0.08	0

ST – healthy subject with no pathology. ROI – region of interest, f – face, m – mouth,  $T_{meanL}$  and  $T_{maxL}$  – mean and maximal temperature on the left side, respectively,  $T_{meanR}$  and  $T_{maxR}$  – mean and maximal temperature on the right side, respectively,  $\Delta T_{mean}$  and  $\Delta T_{max}$  – differences in mean and maximal temperatures between the left and right sides, respectively,  $\Delta DEV$  – difference in temperature deviations between all pixels on the right and left sides of face / mouth, respectively,  $n_{f/m}$  – the number of pixels in the right / left side of the face or mouth in the thermal image, whose temperature is 0.4 °C higher than the maximal temperature on the opposite side of the face or mouth. Values are presented as mean ± standard deviation (SD).

In all subjects from the healthy subjects (ST) group (n = 39), no evident thermal asymmetry was observed in the TI of the four analyzed regions. The mean facial temperatures on the left and right sides were  $33.78 \pm 1.693$  °C and  $33.82 \pm 1.617$  °C, respectively, while the mean mouth temperatures on the left and right sides were  $35.73 \pm 1.613$  °C and  $35.74 \pm 1.642$  °C, respectively. For these subjects, the calculated differences in mean temperature  $(\Delta T_{mean})$  between the left and right sides of the face and mouth were 0.12 ± 0.21 °C and  $0.14 \pm 0.19$  °C, respectively. The differences in maximum temperature ( $\Delta T_{max}$ ) between the left and right sides of the face and mouth were  $0.062 \pm 0.19$  °C and  $0.075 \pm 0.25$  °C, respectively. These differences were not statistically significant (p < 0.05). In addition, the number of pixels in the right (or left) side of the facial and mouth thermographic images, with a temperature at least 0.4 °C higher than the maximum temperature on the opposite side, was  $0.086 \pm 0.07$  and  $0.11 \pm 0.06$ , respectively. Histograms of the distribution of temperature differences in TI of subjects in the healthy subjects (ST) group, compared with the normality curve, are presented in Fig. 3.2.1.2. It was found that all subjects in the ST group and in the SS group (not illustrated), exhibited narrow temperature range, indicating low temperature variability and a uniform distribution. The distribution of histograms in the ST group is symmetric and centered around zero, indicating parameter balance and a low number of extreme values. These results reflect normal thermoregulation, with no pronounced regional temperature differences that could indicate pathological processes. These results reflect normal thermoregulation, with no significant regional temperature differences that could indicate underlying pathological processes. The low variability in temperature distribution also indicates that heat transfer within the tissues occurs

smoothly and without significant fluctuations, which is characteristic of healthy tissue with normal blood circulation.



*Fig. 3.2.1.2. Histograms of temperature difference distributions in the ST group with normality curves* 

The set of histograms is presented using four selected features: the differences in mean and maximum temperatures between the right and left sides of the facial ( $\Delta T_{f.mean}$ , and  $\Delta T_{f.max}$ ) (A, B) and mouth regions ( $\Delta T_{m.mean}$ ,  $\Delta T_{m.max}$ ) (C, D), respectively. The calculation of mean temperatures was based on summing the temperatures of all pixels within the contour-defined region on one side of the face or mouth and dividing the total by the number of pixels in that area. For each variable, a histogram was generated based on 39 cases (n = 39), using an x axis interval ranging from -1.5 to 1.5 with bar width of 0.2. The y-axis represents the number of cases. Note: Each bar represents the number of cases falling within a specific interval. The normality curve (red dashed line) reflects the distribution based on the mean and standard deviation of each variable.

#### 3.2.2. Evaluation of TI in clinical cases with neoplastic pathology

In patients diagnosed with neoplastic pathology (n = 27), including histologically confirmed benign (n = 4) and malignant tumors (n = 23), the TI revealed significant temperature differences when compared to the corresponding parameters in the ST group. In the NP group, the mean temperature difference ( $\Delta T_{mean}$ ) between the left and right sides, calculated in the facial and mouth ROI, was  $0.21 \pm 0.1$  °C and  $0.39 \pm 0.1$  °C, respectively. The maximum temperature difference ( $\Delta T_{max}$ ) in the same regions was  $0.20 \pm 0.14$  °C for the face and  $0.49 \pm 0.18$  °C for the mouth. In the NP group, statistically significant differences were observed in the mouth ROI parameters (p < 0.05) when compared to the corresponding values in the ST group. In these subjects, the calculated number of pixels in the right (or left) side of the facial and mouth TI, with a temperature at least 0.4 °C higher than the maximum temperature on the opposite side, was  $2.48 \pm 1.85$  for the face and  $48.57 \pm 22.6$  for the mouth.

Below are several representative clinical cases in which neoplastic pathology was diagnosed by CT, while IRT revealed varying degrees of thermal asymmetry in the OMM region: clearly visible (Fig. 3.2.2.1), minimally visible (Fig. 3.2.2.2), or not visible (Fig. 3.2.2.3). The thermal characteristics of these cases are detailed in Table 3.2.2.1.

Fig. 3.2.2.1 presents the first clinical case, in which pathology in the mandibular region was suspected following the initial examination. After observing asymmetrical deformation on the left side of the face during clinical evaluation, the patient was referred to a CT scan for more detailed diagnostic assessment. During the CT examination, a heterogeneous expansile lesion was observed in the left side of the mandible, containing multiple areas of "ground-glass" opacity of varying size (Fig. 3.2.2.1, A), remodeling the bone and significantly thinning the cortical layer. No cortical bone defect or infiltration into surrounding soft tissues was observed. In this patient, a benign neoplastic lesion was histologically confirmed (Fig. 3.2.2.1, C), and the diagnosis of mandibular fibrous dysplasia was established. The thermographic images obtained during the IRT examination also revealed thermal asymmetry on the side of the face where the lesion had been identified through clinical evaluation (Fig. 3.2.2.1, D). Moreover, the anatomical location of the pathology determined by IRT corresponded precisely with that identified by CT imaging. The difference in mean temperature ( $\Delta T_{mean}$ ) between the symmetrical facial regions was 0.87 °C. In contrast, the TI of the mouth (Fig. 3.2.2.1, E) showed clearly visible thermal asymmetry. The pathological area appeared as a region of elevated temperature. The maximum temperature in that zone exceeded 38 °C (see Table 3.2.2.1, case NP #1). In this case, thermal asymmetry was visible even without additional image segmentation. However, after applying the segmentation procedure, the pathological area became even more clearly defined (Fig. 3.2.2.1, F).



Fig. 3.2.2.1. Diagnostic images of the first clinical case showing clearly visible thermal asymmetry on IRT

Top: CT scan in bone window, axial plane (A) and MRI (B), showing tumorous masses in the left side of the mandible. Middle: histological section (C), confirming the diagnosis of mandibular fibrous dysplasia. The histological section shows numerous fine trabeculae of immature bone not lined by osteoblasts, embedded in a proliferative fibrous stroma rich in mitotically inactive fibroblasts. Bottom: TI in the frontal plane with the patient's mouth closed (D), and mouth region shown before segmentation (E) and after the segmentation procedure (F) while the patient's mouth is open. Note: The arrow indicates the area of thermal asymmetry before (E) and after (F) segmentation. The temperature scale ( $^{\circ}$ C) on the right.

	ROI	T <sub>meanL</sub>	$\frac{T_{maxL}}{(^{\circ}C)}$	T <sub>meanR</sub>	$T_{maxR}$	$\Delta T_{mean}$	$\Delta T_{max}$	$\Delta DEV$	n <sub>f/m</sub>
NP	f	$34.42 \pm 0.019$	36.45	$33.55 \pm 0.017$	36.23	0.87	0.22	0.0183	0
#1	m	$37.84\pm0.023$	38.97	$37.29\pm0.217$	38.33	0.55	0.64	0.15	35
NP	f	$35.50\pm0.054$	38.14	$35.52\pm0.032$	37.96	0.28	0.18	0.044	0
#2	m	$36.85\pm0.001$	38.15	$36.91\pm0.017$	38.57	-0.06	-0.42	0.093	143
NP	f	$32.83\pm0.015$	35.01	$32.94\pm0.001$	36.12	-0.11	-1.11	0.0312	0
#3	m	$35.84\pm0.085$	37.82	$35.88\pm0.062$	37.88	-0.04	-0.06	0.17	125

*Table 3.2.2.1.* Thermographic temperature features in clinical cases of neoplastic pathology, measured in the left and right facial and mouth ROI

NP – Neoplastic Pathology, ROI – Region of Interest, f – face, m – mouth,  $T_{meanL}$  and  $T_{maxL}$  – mean and maximum temperature on the left side, respectively,  $T_{meanR}$  and  $T_{maxR}$  – mean and maximum temperature on the right side, respectively,  $\Delta T_{mean}$  and  $\Delta T_{max}$  – differences in mean and maximum temperature between the left and right sides, respectively,  $\Delta DEV$  – difference in temperature deviations between all pixels on the right and left sides of the face and mouth, respectively;  $n_{f/m}$  – the number of pixels in the right (left) side of the face or mouth in the thermal image, whose temperature is 0.4 degrees higher than the maximum temperature on the opposite side of the face or mouth. Values are presented as mean ± standard deviation (SD).

Fig. 3.2.2.2 presents the second case of neoplastic pathology, in which the patient was referred to a CT scan following clinical examination due to pain in the right buccal mucosa. In this case, facial deformity was subtle and difficult to assess due to malocclusion, but the axial CT image (Fig. 3.2.2.2, A) revealed a large area of bone destruction in the right side of the mandible. In this patient, a malignant soft tissue tumor, poorly differentiated squamous cell carcinoma (SCC G3), was confirmed by histological analysis (Fig. 3.2.2.2, C). Despite the extensive mandibular bone destruction, the corresponding TI of the same patient showed only a small difference in mean temperature ( $\Delta T_{mean}$ ) and maximum temperature ( $\Delta T_{max}$ ) between the left and right sides of the mouth (Fig. 3.2.2.2, E): 0.06 °C and 0.42 °C, respectively (see Table 3.2.2.1, case NP #2). However, after applying image segmentation in the ROI, an area of elevated temperature became apparent on the affected side (Fig. 3.2.2.2, F). In this case, the pathological zone became visually distinguishable only after the segmentation procedure, with a maximum temperature reaching 39.0 °C.



Fig. 3.2.2.2. Diagnostic images of the second clinical case showing minor thermal asymmetry on IRT

Top: CT scan in bone window, axial plane (A) and MRI (B), pathological masses in the right side of the mandible. Middle: and histological section (C), confirming the diagnosis of poorly differentiated squamous cell carcinoma (SCC G3). The histological section shows solid sheets of highly pleomorphic tumor cells with large, hyperchromatic nuclei and relatively scant cytoplasm. Numerous mitotic figures are present, with no clear keratinization observed. The stroma is abundant, containing occasional lymphocytes. Bottom: TI in the frontal plane with the patient's mouth closed (D), and with the mouth open, showing the mouth region before (E) and after (F) the image segmentation procedure. Note: the arrow indicates the area of thermal asymmetry before (E) and after (F) segmentation. The temperature scale ( $^{\circ}$ C) on the right.

However, in some cases, pathological changes in the OMM region may be very minimal or not visually apparent (Fig. 3.2.2.3).



*Fig. 3.2.2.3. Diagnostic images of the third clinical case showing no visible thermal asymmetry on IRT* 

Top: CT scan in bone window, axial plane (A) and MRI (B), pathological masses in right nasopharyngeal region with localized destructive lesion of the hard palate. Middle: and histological section (C), confirming the diagnosis of moderately differentiated squamous cell carcinoma (SCC G2). The histological section shows solid sheets of mildly pleomorphic tumor cells with large, hyperchromatic nuclei and a moderate amount of cytoplasm. Well-defined keratinization foci ("keratin pearls") are present. The stroma is abundant and contains numerous lymphocytes and plasma cells. Bottom: TI in the frontal plane with the patient's mouth closed (D), and with the mouth open, showing the mouth region before (E) and after (F) the image segmentation procedure. Note: the arrow indicates the area of thermal asymmetry before (E) and after (F) segmentation. The temperature scale (°C) on the right.

An example is the third case of neoplastic pathology, presented in Fig. 3.2.2.3, where the patient reported mild pain deep in the oral cavity during clinical examination and was therefore referred to a CT scan. Clinically, a very subtle deformation of the right lateral wall of the oropharynx was observed. In this patient, CT imaging revealed extensive soft tissue infiltration involving the soft palate and the right parapharyngeal space, along with destruction of the hard palate.

In the presented CT image using bone window settings (Fig. 3.2.2.3, A), a localized destructive lesion of the hard palate is observed. In this patient, the diagnosis of moderately differentiated squamous cell carcinoma was confirmed histologically (Fig. 3.2.2.3, C). In this case, no significant thermal asymmetry was observed in the TI with the patient's mouth closed (Fig. 3.2.2.3, D), and the mean temperature difference between the two sides of the face was only 0.1 °C (see Table 3.2.2.1, case NP #3). Even with the mouth open, the thermographic image showed no clearly visible difference in mean temperature between the right and left sides of the mouth (Fig. 3.2.2.3, E). However, after applying the image segmentation algorithm to the region of interest (ROI) in the pathological area, a localized high-temperature zone became apparent, located deep within the oral cavity (Fig. 3.2.2.3, F).

Fig. 3.2.2.4 presents histograms of the distribution of four selected features in NP group patients TI, reflecting  $\Delta T_{mean}$  and  $\Delta T_{max}$  values calculated between the left and right sides of the facial and mouth ROI.



*Fig. 3.2.2.4. Histograms of temperature difference distributions in the NP group with normality curves* 

The set of histograms is presented using four selected features: the differences in mean and maximum temperatures between the right and left sides of the facial ( $\Delta T_{f.mean}$ , and  $\Delta T_{f.max}$ ) (A, B) and mouth regions ( $\Delta T_{m.mean}$ ,  $\Delta T_{m.max}$ ) (C, D), respectively. The calculation of mean temperatures was based on summing the temperatures of all pixels within the contour-defined region on one side of the face or mouth and dividing the total by the number of pixels in that area. For each variable, a histogram was generated based on 27 cases (n = 27), using an x axis interval ranging from -1.5 to 1.5 with bar width of 0.2. The y-axis represents the number of cases. Note: Each bar represents the number of cases falling within a specific interval. The normality curve (red dashed line) reflects the distribution based on the mean and standard deviation of each variable.

The temperature histograms in the NP group were noticeably wider distributed than those observed in the ST group, indicating greater variability in thermal asymmetry (Fig. 3.2.1.2). This indicates that heat distribution in the affected area is uneven, and temperature values show high variability, which is characteristic of pathological tissue with altered blood flow. In addition, some histograms display bimodality (two peaks) or slight asymmetry.

#### 3.2.3. Evaluation of clinical cases with inflammatory pathology

In a subset of patients, inflammatory pathology was identified by CT imaging (UP group, n = 28) and was also detected in the TI. In these cases, asymmetrical temperature differences were most observed in the facial region, indicating the impact of the inflammatory process on thermal distribution. However, the thermal asymmetry in patients from the UP group was slightly lower compared to cases in the NP group. In the UP group, the  $\Delta T_{mean}$  values, representing mean temperature differences between the left and right sides of the facial and mouth ROI, were  $0.21 \pm 0.1$  °C and  $0.28 \pm 0.1$  °C, respectively. The corresponding  $\Delta T_{max}$  values were  $0.19 \pm 0.14$  °C for the face and  $0.45 \pm 0.18$  °C for the mouth. The differences in mouth ROI parameters were statistically significant (p < 0.05) when compared to the corresponding data in the ST group. However, when compared to the NP group (see Chapter 3.2.5), the observed differences were not statistically significant (p > 0.05). The results confirm that both inflammatory processes and neoplastic pathology (NP) are associated with the greatest variations in thermal asymmetry within the mouth. In the UP group, the calculated number of pixels on the right (or left) side of the facial and mouth TI, with a temperature at least 0.4 °C higher than the maximum temperature on the opposite side, was  $4.42 \pm 1.75$  for the face and  $21.13 \pm 13.4$  for the mouth.

The histograms of the UP group (Fig. 3.2.3.1), similarly to those of the NP group, were broader ranged and, in contrast to the ST group, demonstrated a greater variability of values. Some histograms in the UP group showed irregular, asymmetrical distributions or exhibited multiple peaks, with values spread across a wide range. This indicates that the features in this group vary unevenly, and extreme values are frequently observed.



*Fig. 3.2.3.1. Histograms of temperature difference distributions in the UP group with normality curves* 

The set of histograms is presented using four selected features: the differences in mean and maximum temperatures between the right and left sides of the facial ( $\Delta T_{f.mean}$ , and  $\Delta T_{f.max}$ ) (A, B) and mouth regions ( $\Delta T_{m.mean}$ ,  $\Delta T_{m.max}$ ) (C, D), respectively. The calculation of mean temperatures was based on summing the temperatures of all pixels within the contour-defined region on one side of the face or mouth and dividing the total by the number of pixels in that area. For each variable, a histogram was generated based on 28 cases (n = 28), using an x axis interval ranging from -1.5 to 1.5 with bar width of 0.2. The y-axis represents the number of cases. Note: Each bar represents the number of cases falling within a specific interval. The normality curve (red dashed line) reflects the distribution based on the mean and standard deviation of each variable.

#### 3.2.4. Evaluation of TI in clinical cases with pathological changes

Since the NP and UP groups did not exhibit clear differences, they were combined in this study to evaluate pathological changes in the OMM region, regardless of their origin. This resulted in a combined sample of 55 patients with mixed pathological conditions (NP / UP group). In the NP / UP group, the calculated  $\Delta T_{mean}$  values between the left and right sides of the facial and mouth ROI in TI were  $0.21 \pm 0.1$  °C and  $0.34 \pm 0.1$  °C, respectively. The corresponding  $\Delta T_{max}$  values were  $0.19 \pm 0.14$  °C for the face and  $0.46 \pm 0.18$  °C

for the mouth. These differences in mouth data were statistically significant (p < 0.05) when compared to the corresponding data in the ST group. In the NP / UP group, the calculated number of pixels in the right (or left) side of the facial and mouth TI, with a temperature at least 0.4 °C higher than the maximum temperature on the opposite side, was  $3.17 \pm 1.85$  for the face and  $29.6 \pm 19.3$  for the mouth. The histograms reflecting the distribution of the four selected features in this group (Fig. 3.2.4.1) also demonstrated a wide temperature range and high variability of values.



*Fig. 3.2.4.1. Histograms of temperature difference distributions in the NP / UP group with normality curves* 

The set of histograms is presented using four selected features: the differences in mean and maximum temperatures between the right and left sides of the facial ( $\Delta T_{f:mean}$ , and  $\Delta T_{f:max}$ ) (A, B) and mouth regions ( $\Delta T_{m:mean}$ ,  $\Delta T_{m:max}$ ) (C, D), respectively. The calculation of mean temperatures was based on summing the temperatures of all pixels within the contour-defined region on one side of the face or mouth and dividing the total by the number of pixels in that area. For each variable, a histogram was generated based on 55 cases (n = 55), using an x axis interval ranging from -1.5 to 1.5 with bar width of 0.2. The y-axis represents the number of cases. Note: Each bar represents the number of cases falling within a specific interval. The normality curve (red dashed line) reflects the distribution based on the mean and standard deviation of each variable.

# **3.2.5.** Comparative evaluation of thermographic images across all clinical cases

To assess the differences and distributions of the selected features across various subject groups, statistical data analysis was conducted (Table 3.2.5.1). The data were categorized into five groups: SS, ST, UP, NP, and UP / NP, each representing distinct subject conditions (see Methods, Fig. 2.3.1). Within each group, eight selected thermal features were analyzed:  $\Delta T_{f.max}$ ,  $\Delta T_{m.mean}$ ,  $\Delta T_{m.max}$ ,  $n_f$ ,  $n_m$ ,  $\Delta DEV_f$ , and  $\Delta DEV_m$ . These features reflect the temperature differences between the left and right sides of the face or mouth, based on specific thermal features.

Feature	Mean	Mean S.D. Min. 25% 50%		50%	75%	Max	
SS group	(n = 29)						
$\Delta T_{f.mean}$	-0.06709	0.120268	-0.258	-0.1481	-0.0855	0.0048	0.1504
$\Delta T_{f.max}$	-0.00397	0.041335	-0.1059	-0.0506	0	0	0.0526
$\Delta T_{m.mean}$	-0.00832	0.165093	-0.3971	-0.0981	-0.0309	0.0867	0.283
$\Delta T_{m.max}$	0.011486	0.044931	-0.0592	0	0	0.0522	0.1161
$\Delta DEV_f$	0.035893	0.023952	0.0021	0.0172	0.0328	0.0477	0.087
$\Delta DEV_m$	0.013845	0.021034	0.00037	0.0042	0.0101	0.0157	0.1155
nf	0	0	0	0	0	0	0
nm	0	0	0	0	0	0	0
ST group	(n = 39)						
$\Delta T_{f.mean}$	-0.03522	0.135296	-0.258	-0.1464	-0.0467	0.0747	0.2417
$\Delta T_{f.max}$	-0.00758	0.104813	-0.3792	-0.0516	0	0.0491	0.2964
$\Delta T_{m.mean}$	-0.00811	0.180142	-0.3971	-0.1404	-0.0316	0.11375	0.3818
$\Delta T_{m.max}$	0.019569	0.12395	-0.2596	-0.0255	0	0.0549	0.3896
$\Delta DEV_f$	0.039551	0.027541	0.0021	0.01855	0.0356	0.053	0.1369
$\Delta DEV_m$	$V_m$ 0.027264 0.035208 0.0		0.000367	0.00545	0.0124	0.029	0.1515
nf	0.051282	0.223456	0	0	0	0	1
nm	0	0	0	0	0	0	0

*Table 3.2.5.1. Statistical characteristics of the eight selected features across the SS, ST, UP, NP, and UP / NP subject groups* 

Feature	Mean	S.D.	Min.	25%	50%	75%	Max
UP group	(n = 28)						
$\Delta T_{f.mean}$	0.07933	0.27262	-0.326	-0.10295	0.03745	0.22	0.742
$\Delta T_{f.max}$	-0.0192	0.264428	-0.644	-0.13415	-0.016	0.13285	0.7034
$\Delta T_{m.mean}$	0.03946	0.35519	-0.753	-0.18013	0.05205	0.2255	0.8143
$\Delta T_{m.max}$	0.18399	0.53974	-0.953	-0.11648	0.2028	0.423725	1.3652
$\Delta DEV_f$	0.11901	0.32373	0.0023	0.01975	0.0514	0.092625	1.7508
$\Delta DEV_m$	0.12965	0.10798	0.0105	0.052825	0.10475	0.186675	0.4213
n <sub>f</sub>	4.42857	21.2034	0	0	0	0	112
nm	21.1071	44.1976	0	0	0	26.25	212
NP group	(n = 27)						
$\Delta T_{f.mean}$	0.062107	0.303831	-0.8983	-0.0828	0.0243	0.23075	0.7816
$\Delta T_{f.max}$	0.040811	0.263094	-0.5054	-0.1203	0	0.2025	0.5669
$\Delta T_{m.mean}$	0.065111	0.558457	-0.6759	-0.3433	0.0076	0.30825	1.9834
$\Delta T_{m.max}$	0.024315	0.680047	-1.7773	-0.3011	0.0216	0.4237	1.4516
$\Delta DEV_f$	0.040074	0.03147	0.0066	0.01945	0.0352	0.0437	0.1192
$\Delta DEV_m$	0.123878	0.117843	0.0054	0,0434	0.0878	0.1744	0.4896
<b>n</b> f	2.111111	7.95339	0	0	0	0	41
nm	41.37037	78.01388	0	0	0	27	257
UP / NP g	roup (n = 5	5)					
$\Delta T_{f.mean}$	0.07088	0.285804	-0.8983	-0.0887	0.0252	0.2214	0.7816
$\Delta T_{f.max}$	0.010253	0.26307	-0.6443	-0.1356	-0.0108	0.15145	0.7034
$\Delta T_{m.mean}$	0.052053	0.461965	-0.7533	-0.226	0.0089	0.2255	1.9834
$\Delta T_{m.max}$	0.105607	0.612224	-1.7773	-0.2554	0.1676	0.43055	1.4516
$\Delta DEV_f$	0.08026	0.233375	0.0023	0.01945	0.0371	0.0738	1.7508
$\Delta DEV_m$	0.126816	0.111915	0.0054	0.0473	0.094	0.1817	0.4896
<i>n</i> f	3.290909	16.01929	0	0	0	0	112
nm	31.05455	63.33726	0	0	0	26,5	257

Table 3.2.5.1. Continued

n – sample size, Std – standard deviation, Min – minimum value, 25% – first quartile, 50% – median, 75% – third quartile, Max – maximum value.  $\Delta T_{f.mean}$  and  $\Delta T_{m.mean}$  – difference in mean temperatures between the right and left sides of the face and mouth, respectively,  $\Delta T_{f.max}$ and  $\Delta T_{m.max}$  – difference in maximum temperatures between the right and left sides of the face and mouth, respectively,  $n_f$ ,  $n_m$  – number of pixels on the right (left) side of the thermographic image, for the face and mouth respectively, with temperatures at least 0.4 °C higher than the maximum temperature on the opposite side,  $\Delta DEV_f$ , and  $\Delta DEV_m$  – difference in absolute temperature deviations between all pixels on the right and left sides of the face and mouth, respectively. To evaluate the distribution characteristics of the studied features between the group without pathology (ST) and the group with pathologies (UP / NP), the data were normalized due to the larger sample size in the UP / NP group to ensure result comparability. The comparative analysis revealed that feature values in the ST group are more concentrated around zero, while the distribution in the UP / NP group is wider. Fig. 3.2.5.1 presents normal distribution curves calculated based on the previously normalized data for two selected features:  $\Delta T_{f.mean}$  and  $\Delta T_{m.mean}$ .



Fig. 3.2.5.1. Normal distribution curves of mean facial and mouth temperature features for the ST and UP / NP groups, calculated based on normalized data

The distribution curves are presented for two features:  $\Delta T_{f.mean}$  (A) and  $\Delta T_{m.mean}$  (B). For each feature, the distribution curve was calculated based on normalized data and is presented on the *y*-axis using an *x*-axis interval from -1.5 to 1.5. The ST curve (orange) is narrower and taller, characteristic of a normal distribution. In contrast, the UP / NP curve (blue purple) appears lower and wider, indicating greater data dispersion and potential deviations from normality.

The distribution of these features was approximated using different Gaussian functions based on the assumption of normality. The accuracy of the approximation was assessed using the R<sup>2</sup> coefficient, whose values indicated a very good fit of the applied models to the experimental data. Additionally, approximation was evaluated using RSS (Residual Sum of Squares) and RMSE (Root Mean Square Error), which also demonstrated good agreement between the fitted curves and the experimental data (see Table 3.2.5.2). The table presents the accuracy of data approximation for the subject groups (SS, ST, UP, NP) using three Gaussian function models: single (1G), double (2G), and asymmetric (Asym). The quality of the approximation was assessed using three statistical indicators: RSS, RMSE, and R<sup>2</sup>. Lower RSS and RMSE values and higher R<sup>2</sup> values indicate better model fit. The table allows for an

evaluation of which model provided the most accurate approximation for each group.

		1 <b>G</b>	2G	Asym
RSS	SS	402.2692715	421.9770381	416.9108004
	ST	616.4387768	645.9284031	632.8333431
	UP	179.2161333	181.4993716	179.5937378
	NP	206.7837393	216.4022529	214.1619483
RMSE	SS	0.969189846	0.030656248	0.492400513
	ST	1.186444231	0.0581744	0.791825622
	UP	0.646738136	0.556369592	0.632683301
	NP	0.851217793	0.516328334	0.616246302
<b>R</b> <sup>2</sup>	SS	0,88461168	0,999884553	0,97021613
	ST	0,88202706	0,99971637	0,947453131
	UP	0,844993978	0,885285478	0,851657917
	NP	0,800539243	0,926611503	0,895459462

*Table 3.2.5.2.* Comparison of data approximation accuracy indicators between groups using different Gaussian function models

The subject groups SS, ST, UP, and NP represent different clinical conditions under investigation (see Methods, Fig. 2.3.1). To assess the quality of data approximation, three statistical indicators were used: Residual Sum of Squares (RSS), Root Mean Square Error (RMSE), and the coefficient of determination ( $\mathbb{R}^2$ ). Lower RSS values indicate a better fit of the model to the data, while smaller RMSE values reflect a more accurate approximation. The  $\mathbb{R}^2$  value shows the proportion of variance explained by the model, with values closer to 1 indicating a stronger fit. Three types of Gaussian function models were applied: a single Gaussian function (1G), a sum of two Gaussians (2G), and an asymmetric Gaussian function (Asym). The best-fitting approximation for each group is highlighted in bold.

Table 3.2.5.3 presents a more detailed analysis based on single Gaussian function approximation, outlining the key characteristics of each curve: maximum value (amplitude), its position along the temperature axis (peak location), curve width, and the coefficient of determination ( $\mathbb{R}^2$ ). These indicators provide insights into the shape, dispersion, and symmetry deviation of the distributions across different groups. It was observed that the ST and SS groups exhibited narrower (smaller width) and taller (higher amplitude) curves, along with higher  $\mathbb{R}^2$  values, indicating better conformity to a theoretical normal distribution. In contrast, the UP and NP groups displayed wider, flatter curves with lower  $\mathbb{R}^2$  values, reflecting a weaker fit to the normality assumption. These findings are consistent with the earlier visual analysis and confirm the greater variability and dispersion in the pathological groups.

Gro	ups	Max	Max location	Width	Sample (n)	R <sup>2</sup>
$\Delta T_{f.mean}$	SS	9.700929713	-0.15257323	0.27	29	0.892718748
	ST	10.16807086	-0.10588639	0.38	39	0.892089014
	UP	4.569081033	-0.03944224	0.55	28	0.872162483
	NP	5.478033605	-0.00676673	0.42	27	0.826070724
	UP / NP	9.973242976	-0.01719771	0.48	55	0.89799711
$\Delta T_{m.mean}$	SS	7.870725609	-0.064343501	0.33	29	0.879832094
	ST	9.164497779	-0.06840499	0.39	39	0.892031409
	UP	3.393118493	-0.064175755	0.75	28	0.631175379
	NP	2.321891298	-0.088283489	1.09	27	0.581421505
	UP / NP	5.593478024	-0.070288805	0.89	55	0.79535542
$\Delta T_{f.max}$	SS	9.683404606	-0.051169697	0.15	29	0.994798713
	ST	10.48438935	-0.066147333	0.19	39	0.951725072
	UP	4.739492598	-0.081466123	0.51	28	0.878799456
	NP	4.7954186	-0.065180615	0.42	27	0.728213928
	UP / NP	9.1730118	-0.067855003	0.5	55	0.890344529
$\Delta T_{m.max}$	SS	7.626893455	-0.027573795	0.18	29	0.994362055
	ST	8.893235744	-0.039228143	0.2	39	0.897880563
	UP	3.506930213	0.241537927	0.51	28	0.504624116
	NP	2.210430115	-0.019207612	0.99	27	0.528943467
	UP / NP	4.543646756	0.089238746	1.01	55	0.62589206

*Table 3.2.5.3. Statistical analysis of data approximation using normal distribution curves between groups based on a single Gaussian function* 

The abbreviations SS, ST, UP, NP, and UP / NP represent different subject conditions examined in the study (see Methods, Fig. 2.3.1). The variable  $\Delta T_{f.mean}$  refers to the average temperature difference between the right and left sides of the face, while  $\Delta T_{m.mean}$  indicates the same measurement for the mouth.  $\Delta T_{f.max}$  and  $\Delta T_{m.max}$  represent the maximum temperature differences between the corresponding sides of the face and mouth, respectively. The "Max." value denotes the highest point of the Gaussian function, indicating the curve's amplitude. "Max. location" specifies the temperature at which this peak occurs, and "Width" reflects the dispersion of values around the maximum, describing the spread of the Gaussian curve. "Sample" refers to the number of observations (n) included in each group. Finally, R<sup>2</sup> is the coefficient of determination, used to assess how well the Gaussian model fits the experimental data, with a value of R<sup>2</sup> = 1 indicating a perfect fit.

The intergroup comparison of selected thermal parameters enables the assessment of data dispersion, outliers, and distribution patterns. Notable differences are observed between the groups in terms of both central tendencies and variability. Statistical analysis using one-way analysis of variance (ANOVA) revealed statistically significant differences among the five study groups with respect to the  $\Delta T_{f:mean}$ ,  $n_m$ , and  $\Delta DEV_m$  features (Table 3.2.5.4). No significant differences were found for the remaining five evaluated features (Table 3.2.5.4). These findings are further supported by the boxplot analysis (Fig. 3.2.5.2–3.2.5.4), which shows that higher values of  $\Delta T_{f:mean}$ ,  $n_m$ , and  $\Delta DEV_m$  are characteristic of the pathological patient groups, while lower values are typical of the SS and ST groups. The diagram allows for a visual evaluation of intergroup differences as well as the centralization and dispersion patterns of each indicator. Statistically significant differences between healthy and pathological groups are evident (Table 3.2.5.5 and Appendix 3).

*Table 3.2.5.4. Statistical significance and effect size of thermal features across study groups* 

Feature	p-value	Significance	Effect size (η <sup>2</sup> )	$\eta^2$ interpretation
$\Delta DEV_m$	3.75E-10	+++	0.249444	+++
$n_m$	0.001327	++	0.09745	++
$\Delta T_{f.mean}$	0.031457	+	0.0591	+
$\Delta DEV_f$	0.316213	_	0.026815	+
<b>N</b> f	0.517197	_	0.018495	+
$\Delta T_{m.max}$	0.57266	_	0.016597	+
$\Delta T_{f.max}$	0.854929	-	0.007659	_
$\Delta T_{m.max}$	0.891163	_	0.006413	_

Thermal features assessed from two perspectives: statistical significance (p-value) and effect size ( $\eta^2$ ). Significance notation is as follows: (+++) highly significant difference (p < 0.001), (++) significant (0.001  $\leq$  p < 0.01), (+) weakly significant (0.01  $\leq$  p < 0.05), (-) not significant (p  $\geq$  0.05). Effect size levels are denoted as: (+++) large effect ( $\eta^2 \geq$  0.14), (++) medium effect (0.06  $\leq \eta^2 < 0.14$ ), (+) small effect (0.01  $\leq \eta^2 < 0.06$ ), (-) negligible effect ( $\eta^2 < 0.01$ ).



**Fig. 3.2.5.2.** Boxplots showing the distribution of  $\Delta T_{f.mean}$  differences across all study groups

The vertical axis –  $\Delta T_{f.mean}$  feature value, horizontal axis – the subject groups, diamonds – outlier values, horizontal lines indicate \*p < 0.05, \*\*p ≤ 0.01.



*Fig. 3.2.5.3. Boxplots showing the distribution of n<sub>m</sub> differences across all study groups* 

The vertical axis  $-n_m$  feature value, horizontal axis - the subject groups, diamonds - outlier values, horizontal lines indicate \*\*\*p  $\leq 0.001$ .



Fig. 3.2.5.4. Boxplots showing the distribution of  $\Delta DEV_m$  differences across all study groups

The vertical axis  $-\Delta DEV_m$  feature value, horizontal axis – the subject groups, diamonds – outlier values, horizontal lines indicate \*\*\* $p \le 0.001$ .

*Table 3.2.5.5.* Comparison of thermal features between ST and UP / NP groups: medians, interquartile ranges (IQR), and statistical significance

Feature	ST medians	ST IQR	UP / NP medians	UP / NP IQR	p-value
$\Delta T_{f.mean}$	-0.047	0.221	0.025	0.310	0.024
$\Delta T_{m.mean}$	-0.032	0.254	0.009	0.451	0.830
$\Delta DEV_f$	0.036	0.034	0.037	0.054	0.473
$\Delta DEV_m$	0.012	0.024	0.094	0.134	0.000
<b>n</b> f	0.000	0.000	0.000	0.000	0.191
$n_m$	0.000	0.000	0.000	26.500	0.000
$\Delta T_{f.max}$	0.000	0.101	-0.011	0.287	0.969
$\Delta T_{m.max}$	0.000	0.080	0.168	0.686	0.144

The table presents the medians and interquartile ranges (IQR) of thermal features in the ST and UP / NP groups, along with p-values calculated using the Mann-Whitney U test. Statistically significant differences (p < 0.05) were observed for the features  $\Delta T_{f.mean}$ ,  $\Delta DEV_m$ , and  $n_m$ , indicating their potential diagnostic value.

					ST							UP /	/ NP			]		
		$\Delta T_{f.mean}$	$\Delta T_{f,max}$	$\Delta T_{m.mean}$	$\Delta T_{m,max}$	ΔDEV	$\Delta DEV_m$	'n	$\Delta T_{f.mean}$	$\Delta T_{f,max}$	$\Delta T_{m,mean}$	$\Delta T_{m,max}$	ΔDEV	$\Delta DEV_m$	'n	nm		
	n <sub>m</sub>	-0.13	0.07	0.25	-0.08	0.16	0.05	-0.11	0.29	0.20	0.38	0.06	-0.06	0.79	0.05	1.00	-	-0.6
	n <sub>f</sub>	-0.15	-0.06	0.11	0.05	0.23	-0.03	-0.05	0.19	0.26	-0.14	-0.22	0.09	0.14	1.00	0.05	the second se	-0.4
	$\Delta DEV_m$	-0.12	0.02	0.15	-0.07	0.22	0.11	-0.04	0.33	0.32	0.30	0.12	-0.10	1.00	0.14	0.79	14	0.4
UP / NP	$\Delta DEV_{f}$	-0.11	-0.62	0.09	0.29	0.01	0.20	0.00	-0.05	-0.10	-0.03	0.01	1.00	-0.10	0.09	-0.06	-	-0.2
	ΔT <sub>m.max</sub>	0.20	0.11	-0.16	0.11	-0.14	0.22	-0.08	0.20	-0.04	0.73	1.00	0.01	0.12	-0.22	0.06		
	$\Delta T_{m.mean}$	0.07	0.09	-0.06	-0.05	-0.05	0.03	-0.05	0.20	0.11	1.00	0.73	-0.03	0.30	-0.14	0.38	8	0.0
	$\Delta T_{f.max}$	0.02	0.04	-0.07	-0.05	0.07	-0.10	0.08	0.29	1.00	0.11	-0.04	-0.10	0.32	0.26	0.20		
	$\Delta T_{f.mean}$	0.10	0.02	0.19	0.10	0.07	0.03	0.33	1.00	0.29	0.20	0.20	-0.05	0.33	0.19	0.29	-	0.2
	<b>n</b> r	0.10	-0.01	-0.25	-0.25	0.56	0.02	1.00	0.33	0.08	-0.05	-0.08	0.00	-0.04	-0.05	-0.11		
	$\Delta DEV_m$	0.15	-0.11	0.20	0.34	0.15	1.00	0.02	0.03	-0.10	0.03	0.22	0.20	0.11	-0.03	0.05	-	0.4
	$\Delta DEV_{f}$	-0.02	0.25	0.05	0.07	1.00	0.15	0.56	0.07	0.07	-0.05	-0.14	0.01	0.22	0.23	0.16		
ST	ΔT <sub>m.max</sub>	0.08	0.11	0.64	1.00	0.07	0.34	-0.25	0.10	-0.05	-0.05	0.11	0.29	-0.07	0.05	-0.08	4	0.6
	$\Delta T_{m.mean}$	0.12	0.15	1.00	0.64	0.05	0.20	-0.25	0.19	-0.07	-0.06	-0.16	0.09	0.15	0.11	0.25		010
	$\Delta T_{f.max}$	0.42	1.00	0.15	0.11	0.25	-0.11	-0.01	0.02	0.04	0.09	0.11	-0.62	0.02	-0.06	0.07	-	0.8
	$\Delta T_{f.mean}$	1.00	0.42	0.12	0.08	-0.02	0.15	0.10	0.10	0.02	0.07	0.20	-0.11	-0.12	-0.15	-0.13		1.0
																	_	10

Additionally, a correlation analysis, presented as a heatmap (Fig. 3.2.5.5), revealed the interrelationships between thermal features within the ST and UP / NP groups.



Pearson correlation coefficient (r) heatmap illustrating the interrelationships between thermal features in the ST and UP / NP groups. Each cell intersection displays the r value, indicating the strength and direction of correlation between two features: values close to +1 denote a strong positive correlation, values near -1 indicate a strong negative correlation, and values close to 0 suggest no correlation. The intensity of color represents the correlation magnitude – darker shades indicate stronger correlations. Note: The UP / NP group is characterized by predominantly strong positive correlations, whereas the ST group shows weaker or even negative associations.

In the UP / NP group, strong positive correlations were identified between the features  $\Delta T_{m.mean}$ ,  $\Delta T_{m.max}$ , and  $\Delta DEV_m$  (r > 0.73), as well as between  $n_m$ and  $\Delta DEV_m$  (r  $\approx$  0.79), indicating a close interrelationship among these variables. In contrast, the ST group exhibited weaker or even negative correlations; for example, a significant negative correlation was observed between  $\Delta T_{f.mean}$  and  $\Delta DEV_f$  (r  $\approx -0.62$ ). These findings suggest that in pathological groups, the features are not only elevated in value but also exhibit stronger interdependence, which may be relevant for constructing composite feature sets for diagnostic or predictive modeling. Statistical analysis enabled the identification of thermal features with greater discriminative potential by evaluating their values across different subject groups. The observed trends indicate that certain features consistently differentiate between healthy and pathological cases, and their mutual interactions and distribution patterns support their informativeness. This statistical analysis was conducted to enhance the understanding of the distribution of the eight selected thermal features among groups and to assess their potential informativeness for clustering purposes.

#### 3.3. Clustering of TI using AI

Based on thermal characteristics, feature vectors were constructed from the temperature data and subsequently used to train the selected AI model, with the goal of developing a non-invasive diagnostic method capable of identifying pathological changes from TI data.

To cluster patients into pathological and non-pathological cases, machine learning algorithms were applied using binary kNN clustering. Using the kNN clustering method, each new data point was assigned to a group based on its nearest neighbors in the training dataset, thereby enabling efficient identification of pathological cases. The model was trained to identify pathological cases not based on a single parameter, but rather on a combination of features, making clustering decisions according to the prevalence and distribution of dominant characteristics. For example, an important indicator in the pathological region is the number of altered temperature points, which reflects the extent of the affected area. Altered temperature points are defined as pixels in the right or left side of the facial or mouth TI, whose temperature is at least 0.4 °C higher than the maximum temperature on the opposite side of the face or mouth. Typically, in pathological cases, the number of these points is high (see Table 4.3.1,  $n_f$  and  $n_m$ ), although in some instances, only a few altered points may be present within the pathological area. Isolated high-temperature points, which may represent noise artifacts, can also occur in the healthy subject group. Therefore, by evaluating features in combination, the model is able to make an appropriate clustering decision, ensuring accurate identification of pathological cases despite the presence of potential noise artifacts or isolated anomalies in data from healthy patients. This approach allows for better differentiation between pathological and healthy cases, by taking into account the entire set of features.

The dataset was then randomly divided into two subsets for training and testing, with the training subset containing half of the data. In the first stage of the study, we aimed to evaluate the potential of the *k*NN classifier to detect neoplastic pathologies. Therefore, based on the constructed feature vectors (Table 3.3.1), thermographic data from 46 patients were used to form two groups: a group of healthy subjects or patients without neoplastic pathology (ST group, n = 23), in whom CT imaging revealed no tumor related pathology, and a group of patients with CT confirmed neoplastic pathology in the OMM region (NP group, n = 23) [18].

It is important to note that during this stage of the study, temperature asymmetry greater than 0.4 °C was used as the selection criterion [14, 15]. As a result, the group without neoplastic pathology may have included individual patients with minor inflammation-related changes.

*Table 3.3.1. Features values of constructed feature vectors for subjects in the ST and NP groups* 

Group	Δ <i>T<sub>f.mean</sub></i> (°C)	ΔT <sub>f.max</sub> (°C)	n <sub>f</sub>	$\Delta DEV_f$	ΔT <sub>m.mean</sub> (°C)	$\Delta T_{m.max}$ (°C)	<b>n</b> m	ΔDEV <sub>m</sub>
ST	$\begin{array}{c} 0.14 \pm \\ 0.037 \end{array}$	$\begin{array}{c} 0.15 \pm \\ 0.038 \end{array}$	$\begin{array}{c} 0.086 \pm \\ 0.07 \end{array}$	$\begin{array}{c} 0.117 \pm \\ 0.128 \end{array}$	$\begin{array}{c} 0.16 \pm \\ 0.032 \end{array}$	$\begin{array}{c} 0.22 \pm \\ 0.036 \end{array}$	$\begin{array}{c} 0.304 \pm \\ 0.19 \end{array}$	$0.063 \pm 0.015$
NP	$\begin{array}{c} 0.23 \pm \\ 0.087 * \end{array}$	$\begin{array}{c} 0.22 \pm \\ 0.062 \end{array}$	$\begin{array}{c} 2.48 \pm \\ 21.85 \end{array}$	$\begin{array}{c} 0.041 \pm \\ 0.012 \end{array}$	$\begin{array}{c} 0.46 \pm \\ 0.0143 \end{array}$	$\begin{array}{c} 0.56 \pm \\ 0.169 \end{array}$	48.57 ± 22.6*	$\begin{array}{c} 0.139 \pm \\ 0.043 ^{*} \end{array}$

ST – healthy subjects, NP – subjects with neoplastic pathology,  $\Delta T_{f.mean}$  and  $\Delta T_{m.mean}$  represent the difference in mean temperature between the right and left sides of the face and mouth, respectively.  $\Delta T_{f.max}$  and  $\Delta T_{m.max}$  represent the difference in maximum temperature between the right and left sides of the face and mouth, respectively.  $n_f$  and  $n_m$  indicate the number of pixels on the right (left) side of the thermographic image of the face or mouth with temperatures 0.4 °C higher than the maximum temperature on the opposite side,  $\Delta DEV_f$  and  $\Delta DEV_m$  refer to the difference in absolute temperature deviations between all pixels on the right and left sides of the face and mouth, respectively, values are presented as means  $\pm$ standard deviation (SD), \* p < 0.05.

Based on the 46 analyzed patient TI [18], 24 were randomly selected for training the algorithm: 12 from patients without any diagnosed pathology, and 12 from patients with neoplastic pathology confirmed by CT. The procedure of splitting the data into training and testing sets was repeated 12 times, allowing for the evaluation of the model's ability to adapt to different data samples.

In the second stage of the study, after including healthy volunteers (SS group, n = 29) in the IRT assessments, two new subject groups were formed based on TI data from all 94 examined patients. One group was formed by combining healthy patients with additional healthy volunteers, resulting in the SS/ST group (n = 39), hereafter referred to as the ST group. All individuals in this group had no significant structural or inflammatory changes detected on CT or MRI scans. The other group, the NP / UP group (n = 55), consisted of patients with various pathological changes, including neoplastic and inflammation-related conditions identified in the OMM region. The feature vectors constructed for these groups are presented in Table 3.3.2.

*Table 3.3.2.* Values of constructed feature vectors for subjects in the ST and NP / UP groups

Group	Δ <i>T<sub>f.mean</sub></i> (°C)	Δ <i>T<sub>f.max</sub></i> (°C)	<b>n</b> f	$\Delta DEV_f$	Δ <i>T</i> m.mean (°C)	Δ <i>T<sub>m.max</sub></i> (°C)	<b>n</b> m	$\Delta DEV_m$
ST	$\begin{array}{c} 0.12 \pm \\ 0.037 \end{array}$	$\begin{array}{c} 0.062 \pm \\ 0.038 \end{array}$	$\begin{array}{c} 0.086 \pm \\ 0.07 \end{array}$	$\begin{array}{c} 0.04 \pm \\ 0.012 \end{array}$	$\begin{array}{c} 0.14 \pm \\ 0.032 \end{array}$	$\begin{array}{c} 0.075 \pm \\ 0.036 \end{array}$	0.11 ± 0.06	$\begin{array}{c} 0.027 \pm \\ 0.015 \end{array}$
NP / UP	$0.21 \pm 0.087*$	$0.193 \pm 0.062$	3.17± 1.85	$\begin{array}{c} 0.08 \pm \\ 0.012 \end{array}$	$\begin{array}{c} 0.34 \pm \\ 0.143 \end{array}$	$\begin{array}{r} 0.46 \pm \\ 0.169 \end{array}$	29.6±19.3*	$0.123 \pm 0.043*$

ST – healthy subjects, NP – subjects with neoplastic pathology,  $\Delta T_{f.mean}$  and  $\Delta T_{m.mean}$  represent the difference in mean temperature between the right and left sides of the face and mouth, respectively.  $\Delta T_{f.max}$  and  $\Delta T_{m.max}$  represent the difference in maximum temperature between the right and left sides of the face and mouth, respectively.  $n_f$  and  $n_m$  indicate the number of pixels on the right (left) side of the thermographic image of the face or mouth with temperatures 0.4 °C higher than the maximum temperature on the opposite side,  $\Delta DEV_f$  and  $\Delta DEV_m$  refer to the difference in absolute temperature deviations between all pixels on the right and left sides of the face and mouth, respectively, values are presented as means  $\pm$ standard deviation (SD), \* p < 0.05.

Based on the analysis of thermographic data from 94 patients, 48 OMM region TI were randomly selected for algorithm training: 24 from subjects without any pathology, and 24 from subjects with CT confirmed pathology. The procedure of splitting the data into training and testing sets was repeated 24 times, allowing for the assessment of the model's ability to generalize across different data samples.

## **3.4.** Assessment of the diagnostic reliability of the *k*NN method in the OMM region

To evaluate the performance accuracy of the selected kNN clustering model and the frequency of misclassifications, a confusion matrix was constructed, and values for accuracy, sensitivity, and specificity were calculated. Recognition accuracy was assessed by comparing the number of correctly identified TI to the total number of analyzed cases. To validate the confusion matrices, a receiver operating characteristic (ROC) analysis was performed.

During the first stage [18], evaluating the algorithm's ability to identify TI from patients with neoplastic pathology, the results demonstrated a clustering accuracy of 94.1% (AUC = 0.8769), with a sensitivity of 77.9% and a specificity of 94.9%. Fig. 3.4.1 presents the empirical ROC curve, which integrates information across all thresholds, with sensitivity and specificity calculated non-parametrically at each point. The results indicated that the model demonstrates good diagnostic performance, as the calculated area under the ROC curve (AUC) ranged between 0.8 and 0.9. This suggests that, based on this calculated AUC value, if data from one randomly selected patient with neoplastic pathology and one subject without such pathology were compared, the model would correctly assign a higher risk to the patient with pathology in approximately 88% of cases.

This result demonstrates a reasonably high diagnostic accuracy, particularly considering that the sensitivity was 77.9%, and the specificity reached as high as 94.9%. Thus, the results obtained during the first stage of the study indicate that the adapted kNN clustering algorithm enabled reliable differentiation of patients into groups of healthy individuals and those with neoplastic pathology.



*Fig. 3.4.1. ROC* curve of the performance characteristics analysis for the sample of the study group with neoplastic pathology

The dashed line represents the line of no discrimination (x = y). The calculated area under the ROC curve (AUC) was 0.8769. An AUC value between 0.8 and 0.9 is interpreted as indicating a "very good" classification ability to reliably distinguish patients with pathological changes from healthy individuals [129–131].

In the second stage, when assessing how well the adapted algorithm could identify CT data from patients with all types of pathologies (both neoplastic and inflammatory), the results showed a clustering accuracy of 90.63% (AUC = 0.8927), with a sensitivity of 98.25% and a specificity of 92.31%. Fig. 3.4.2 presents the ROC curve for the analysis of characteristic metrics in the mixed pathological group (NP / UP group) sample. The calculated area under the ROC curve (AUC) of 0.8927 indicates a very good diagnostic accuracy of the model. In this case, when randomly selecting one positive and one negative instance, the model correctly identifies their class in more than 89% of cases. The exceptionally high sensitivity (98.25%) indicates that the model correctly detects patients with pathology in nearly all cases, while the high specificity (92.31%) suggests that healthy individuals are also correctly classified in the majority of cases.



*Fig. 3.4.2. ROC curve of the characteristic metrics analysis for the sample of the study group with different pathologies* 

The calculated area under the ROC curve (AUC) was 0.8927. An AUC value between 0.8 and 0.9 is interpreted as indicating a "very good" classification ability to reliably distinguish patients with pathological changes from healthy individuals [129–131].

#### CONCLUSIONS

- 1. The AI-based IRST method can reliably detect pathological lesions in the OMM region, and the obtained results showed good concordance with CT/MRI findings.
- 2. Large and superficial tumors in the OMM region can be detected in IRST images without segmentation, however, for small, deeply located, or bilaterally distributed lesions, segmentation is essential due to weak thermal asymmetry. Segmentation of the mouth ROI is more informative, as thermal changes are more sensitively detected in the oral mucosa due to its physiological properties.

- 3. The selected eight thermal distribution features  $(\Delta T_{f:mean}, \Delta T_{m.mean}, \Delta T_{f:max}, \Delta T_{m.max}, n_f, n_m, \Delta DEV_f, \Delta DEV_m)$  formed the basis for the successful application of the kNN clustering algorithm. Among them,  $\Delta T_{f:mean}, n_m$  and  $\Delta DEV_m$  stood out as statistically significant and the most discriminative between groups. These features can serve as thermal biomarkers that complement the kNN clustering results and enhance early diagnostic capabilities in the maxillofacial region.
- 4. The optimized binary kNN clustering model reliably identified and accurately classified patients' thermal images into healthy and pathological groups, achieving high levels of accuracy, sensitivity, and specificity (90–98%), as well as an AUC value of approximately 0.9.

### LITERATŪROS SĄRAŠAS

- 1. Al-Essa HS, Hafth HA, Fadil AG. The challenge for the detection of orally potentially malignant lesions. J Oral Med, Oral Surg, Oral Pathol, Oral Radiol 2023;9:118–25.
- 2. Abdul NS, Shivakumar GC, Sangappa SB, Di Blasio M, Crimi S, Cicciu M et al. Applications of artificial intelligence in the field of oral and maxillofacial pathology: a systematic review and meta-analysis. BMC Oral Health 2024;24:122.
- 3. Sujir N, Ahmed J, Pai K, Denny C, Shenoy N. Challenges in early diagnosis of oral cancer: Cases series. Acta Stomatol Croat Int J Oral Sci Dent Med 2019;53:174–80.
- 4. De Lima ED, Paulino JAS, Freitas APLF, Ferreira JEV, Barbosa JS, Silva DFB et al. Artificial intelligence and infrared thermography as auxiliary tools in the diagnosis of temporomandibular disorder. Dentomaxillofac Radiol 2022;51:1–11.
- 5. Bullitt E, Lin NU, Smith JK, Zeng D, Winer EP, Carey LA, et al. Blood vessel morphological changes as visualized by MRA during treatment of brain metastases. Radiology 2007;245:824–30.
- 6. Liu, Q., Li, M., Wang, W. et al. Infrared thermography in clinical practice: a literature review. Eur J Med Res 2025;30:33.
- 7. Sulochana, C.; Sumathi, M. A Systematic Review on oral cancer diagnosis and prognosis using machine learning techniques. J Algebraic Stat 2022;13:3542–50.
- 8. Adeoye J, Tan JY, Choi S-W, Thomson P. Prediction models applying machine learning to oral cavity cancer outcomes: A systematic review. Int J Med Inform 2021;154: 104557.
- 9. Dixit S, Kumar A, Srinivasan. A current review of machine learning and deep learning models in oral cancer diagnosis: recent technologies, open challenges, and future research directions. Diagnostics 2023;13:1353.
- 10. Wang W, Liu Yi, Wu J. Early diagnosis of oral cancer using a hybrid arrangement of deep belief networkand combined group teaching algorithm. Sci Rep 2023;13:22073.
- 11. Avanzo M, Stancanello J, Pirrone G, Drigo A, Refito A. The evolution of artificial intelligence in medical imaging: from computer science to machine and deep learning. Cancers 2024;16:3702.
- 12. Najar R. Redefining radiology: a review of artificial intelligence integration in medical imaging. Diagnostics 2023;13:2760.
- 13. Zhang B, Shi H, Wang H. Machine learning and AI in cancer prognosis, prediction, and treatment selection: a critical approach. J Multidiscip Healthc 2023;16:1779–91.
- 14. Mačianskytė D, Monastyreckienė E, Basevičius A, Adaškevičius R. Comparison of segmented thermal images versus a CT scanning for detection of maxillofacial pathology. Dentomaxillofac Radiol 2019;48:1–9.
- 15. Durnovo EA, Potekhina YUP, Marochkina MS, Khomutinnikova NE, Yanova NA. Features of infrared thermography in the diagnosis of complex diseases of maxillofacial region. Mod Probl Sci Educ 2012;30 psl.
- 16. Barbosa JS, Amorim A, Arruda M, Medeiros G, Freitas A, Vieira L, et al. Infrared thermography assessment of patients with temporomandibular disorders. Dentomaxillofac Radiol 2020;49:1–8.
- Uddin S, Haque I, Lu H, Moni MA Gide E. Comparative performance analysis of k-Nearest Neighbour (kNN) algorithm and its different variants for disease prediction. Sci Rep 2022;12:6256.

- 18. Mačianskytė D, Adaškevičius R. Automatic detection of human maxillofacial tumors by using thermal imaging: a preliminary study. Sensors 2022;22:1985.
- 19. Umapathy S, Palani Thanaraj Krishnan. Automated detection of orofacial pain from thermograms. Expert Syst 2021;e12747:1–14.
- 20. Thukral R, Aggarwal AK, Arora AS, Dora T, Sancheti S. optimal temperature thresholding in passive thermography for head and neck diagnosis. Afr J Bio Sc 2024; 6:4214–24.
- Kamiński B, Błochowiak K, Kołomański K, Sikora M, Karwan S, Chlubek D. Oral and maxillofacial infections - a bacterial and clinical cross-section. J Clin Med 2022; 11:2731.
- 22. Jevon P, Abdelrahman A, Pigadas N. Management of odontogenic infections and sepsis: an update. Br Dent J 2020;229:363–70.
- Oral cavity & oropharyngeal cancer key statistics 2021 (n.d.). Oral cavity & oropharyngeal cancer key statistics. Available online: https://www.cancer.org/cancer/oral-cavity-and-oropharyngeal-cancer/about/key-statistics.html (accessed on 29 January 2023)
- 24. Bala M, Braimah RO, Taiwo AO, Alyami B, Aliyu BM, Kanmodi KK et al. Squamous cell carcinoma in the oral and maxillofacial region: a 12-year analysis at a tertiary healthcare facility from North-Western Nigeria. J Cancer Tumor Int 2023;13:19–27.
- 25. Berberi AN, Aoun GT, Aad GP, Khalaf EN. Benign mesenchymal odontogenic tumors of the maxillofacial bones: a report of 3 cases with 3 years follow-up. J Oral Maxillofac Pathol 2022;26:S46–S50.
- 26. Bashir A, Khan ZA, Maqsood A, Prabhu N, Saleem MM, Alzarea BK et al. The evaluation of clinical signs and symptoms of malignant tumors involving the maxillary sinus: recommendation of an examination sieve and risk alarm score. Healthcare 2023;11:194.
- 27. Fatima J, Fatima E, Mehmood F, Ishtiaq I, Khan MA, Khurshid HMS et al. Comprehensive analysis of oral squamous cell carcinomas: clinical, epidemiological, and histopathological insights with a focus on prognostic factors and survival time. Cureus 2024;16:e54394.
- 28. Neville BW, Damm DD, Allen CM, Chi AC, editors. Oral and maxillofacial pathology. 4th ed. Missouri, USA: WB Saunders, Elsevier; 2016. p. 604–5.
- 29. Lewis-Jones H, Colley S, Gibson D. Imaging in head and neck cancer: United Kingdom National Multidisciplinary Guidelines. J Laryngol Otol 2016;130:S28.
- Mogen JL, Block KT, Bansal NK, Patrie JT, Mukherjee S, Zan E, et al. Dynamic contrast-enhanced MRI to differentiate parotid neoplasms using golden-angle radial sparse parallel imaging. AJNR Am J Neuroradiol 2019;40:1029–36.
- King AD, Yu K-H, Mo FKF, Law BKH, Yuen TWC, Bhatia KS, et al. Cervical nodal metastases from head and neck squamous cell carcinoma: MRI criteria for treatment assessment. Head Neck 2016;38:E1598–604.
- Connolly M, Srinivasan A. Diffusion-weighted imaging in head and neck cancer: technique, limitations, and applications. Magn Reson Imaging Clin N Am 2018; 26:121–33.
- 33. Kessler AT, Bhatt AA. Review of the major and minor salivary glands, Part 2: neoplasms and tumor-like lesions. J Clin Imaging Sci 2018;8:48–57.
- Gaddipati R. Fascial space infections. In: Bonanthaya K, Panneerselvam E, Manuel S, Kumar VV, Rai A, editors. Oral and maxillofacial surgery for the clinician. Singapore: Springer; 2021. p. 441–59.
- 35. Wakeel AMAl, Monem MFAEl, Abdullah MS. Magnetic resonance imaging of temporomandibular joint disorders. Menoufia Med J 2020;33:956–61.
- 36. Nazerani T, Kalmar P, Aigner RM. Emerging role of nuclear medicine in oral and maxillofacial surgery. In: Sridharan G, editor. Oral and Maxillofacial Surgery. 2021 eBook (PDF) (accessed on 16 may 2024).
- 37. Nakamoto Y, Tamai K, Saga T, Higachi T, Hara T, Suga T, et al. Clinical value of image fusion from MR and PET in patients with head and neck cancer. Mol Imaging Biol 2009;11:46–53.
- 38. Fonti R, Conson M, Del Vecchio S. PET/CT in radiation oncology. Semin Oncol 2019;46:202-9.
- 39. Bertagna F, Nicolai P, Maroldi R, Mattavelli M, Bertoli R, Giubbini R, et al. Diagnostic role of (18)F-FDG-PET or PET/CT in salivary gland tumors: A systematic review. Rev Esp Med Nucl Imagen Mol 2015;34:295–302.
- 40. Van den Wyngaert T, Huizing MT, Vermorken JB. Osteonecrosis of the jaw related to the use of bisphosphonates. Curr Opin Oncol 2007;19:315–22.
- 41. Abdelhafez Y, Raychaudhuri SP, Mazza D, Sarkar S, Hunt HL, McBride K, et al. Totalbody 18F-FDG PET/CT in autoimmune inflammatory arthritis at ultra-low dose: initial observations. J Nucl Med 2022;63:1579–85.
- 42. Lee H, Lee KSA, Lee WWO. 18F-NaF PET/CT findings in fibrous dysplasia. Clin Nucl Med 2015;40:912–14.
- 43. Liu Q, Li M, Wang W, Jin S, Piao H, Jiang Y, et al. Infrared thermography in clinical practice: a literature review. Eur J Med Res 2025;30:33.
- 44. Kesztyüs D, Brucher S, Wilson C, Kesztyüs T. Use of infrared thermography in medicinal diagnosis, screening, and disease monitoring: a scoping review. Medicina 2023;59:1–32.
- 45. Schroeder DV, editor. An introduction to thermal physics. Oxford University Press; 2021. p. 1–435.
- 46. Planck M. On the law of distribution of energy in the normal spectrum. Ann Phys 1901;4:553.
- 47. Guo X, Xie X. Planck formula for black-body radiation: derivation and applications. Highl Sci Eng Technol 2023;64:200–4.
- 48. Abdulkareem AF, Hashim AQ. Infrared medical thermography, medical applications, and its basic principles: a review. BIO Web Conf 97, 2024;00140:1–35.
- 49. Malik A, Zakwandi R, Nurfalah S, Nurhayati N, Rochman C, Nasrudin D. Measuring the coefficient of emissivity using thermal radiation equipment SNR V-1.4 SL (IOP Conf. Series: Mater Sci Eng 2018;434:012017.
- 50. Coben R, Myers TE. Sensitivity and specificity of long wave infrared imaging for attention-deficit/hyperactivity disorder. J Attention Disord. 2009;13:56-65.
- 51. Ring EFJ, Ammer K. Infrared thermal imaging in medicine. Physiol Meas 2012; 33:R33-R46.
- 52. Lahiri B, Bagavathiappan S, Jayakumar T, Philip J. Medical applications of infrared thermography: a review. Infrared Phys Technol 2012;55:221–35.
- 53. Ioannou S, Gallese V, Merla A. Thermal infrared imaging in psychophysiology: potentialities and limits. Psychophysiology 2014;51:951–63.
- 54. Mackowiak PA, Wasserman SS, Levine MM. A critical appraisal of 98.6 degrees F, the upper limit of the normal body temperature, and other legacies of Carl Reinhold August Wunderlich. JAMA 1992;268:1578–80.

- 55. Mostovoy A. Thermography and oral pathology. In EAT2012 Book of proceedingsappendix 1 of thermology international; Thermography Clinic Inc.: Toronto, Canada, 2012;22:159–61.
- 56. Kaushik R, Sivaselvan B, Kamakoti V. Clinical thermography for breast cancer screening: a systematic review on image acquisition, segmentation, and classification. IETE Technical Review 2023;41:238–60.
- 57. Neves EB, Vilaça-Alves J, Rosa C, Reis VM. Thermography in neurologic practice. Open Neurol J 2015;9:24–7.
- Balbinot LF, Canani LH, Robinson CC, Achaval M, Zaro MA. Plantar thermography is useful in the early diagnosis of diabetic neuropathy. Clinics (Sao Paulo) 2012;67:1419– 25.
- 59. Kumar P, Gaurav A, Rajnish RK, Sharma S, Kumar V, Aggarwal S, et al. Applications of thermal imaging with infrared thermography in Orthopaedics. J Clin Orthop Trauma 2021;24:101722.
- 60. Liu Q, Li M, Wang W, Jin S, Piao H, Jiang Y, et al. Infrared thermography in clinical practice: a literature review, Eur J Med Res 2025;30:33.
- 61. Gurjarpadhye AA, Parekh MB, Dubnika A, Rajadas J, Inayathullah M. Infrared imaging tools for diagnostic applications in dermatology. SM J Clin Med Imaging 2015;1:1–5.
- 62. Lubkowska A, Chudecka M. Thermal characteristics of breast surface temperature in healthy women. Int J Environ Res Public Health 2021;18:1097.
- 63. Tavakol ME, Lucas C, Sadri S, Ng EYK. Analysis of breast thermography using fractal dimension to establish possible difference between malignant and benign patterns. J Healthc Eng 2010;1:27–44.
- 64. Jafari Z, Karami E. Breast cancer detection in mammography images: a CNN-based approach with feature selection. Information 2023;14:410.
- 65. Munguía-Siu A, Vergara I, Espinoza-Rodríguez JH. The use of hybrid CNN-RNN deep learning models to discriminate tumor tissue in dynamic breast thermography. J Imaging 2024;10:329.
- Rahman A, Debnath T, Kundu D, Khan SI, Aishi AA, Sazzad S, Sayduzzaman M, Band SS. Machine learning and deep learning-based approach in smart healthcare: Recent advances, applications, challenges and opportunities. AIMS Public Health 2024;11: 58– 109.
- Pannala R, Krishnan K, Melson J, Parsi MA, Schulman AR, Sullivan, et al. Artificial intelligence in gastrointestinal endoscopy. ASGE society document VideoGIE 2020; 5:598–613.
- 68. Tang A, Tam R, Cadrin-Chenevert A, Guest W, Chong J, Barfett J, et al. Canadian association of radiologists white paper on artificial intelligence in radiology. Can Assoc Radiol J 2018;69:120–35.
- 69. Fujima N, Andreu-Arasa VC, Meibom SK, Mercier GA, Salama AR, Truong MT, et al. Prediction of the treatment outcome using machine learning with FDG-PET imagebased multiparametric approach in patients with oral cavity squamous cell carcinoma. Clin Radiol 2021;76:711.e1-711.e7
- 70. Creff G, Devillers A, Depeursinge A, Palard-Novello X, Acosta O, Jegoux F, et al. Evaluation of the prognostic value of FDG PET/CT parameters for patients with surgically treated head and neck cancer: A systematic review. JAMA Otolaryngol Head Neck Surg 2020;146:471–9.
- 71. Heo MS, Kim JE, Hwang JJ, Han SS, Kim JS, Yi WJ, et al. Artificial intelligence in oral and maxillofacial radiology: What is currently possible? Dentomaxillofac Radiol 2021;50:20200375.

- 72. Choi RY, Coyner AS, Kalpathy-Cramer J, Chiang MF, Campbell JP. Introduction to machine learning, neural networks, and deep learning. Transl Vis Sci Technol 2020; 9:14.
- 73. Seyyed-Kalantari L, Zhang H, McDermott MBA, Chen IY, Ghassemi M. Underdiagnosis bias of artificial intelligence algorithms applied to chest radiographs in under-served patient populations. Nat Med 2021;27:2176–82.
- 74. Mak KK, Lee K, Park C. Applications of machine learning in addiction studies: a systematic review. Psychiatry Res 2019;275:53–60.
- 75. Erickson BJ, Korfiatis P, Akkus Z, Kline TL. Machine learning for medical imaging. Radiographics 2017;37:505–15.
- 76. Siddalingappa R, Kanagaraj S. K-nearest-neighbor algorithm to predict the survival time and classification of various stages of oral cancer: a machine learning approach. F1000Research 2022;11:70.
- 77. Zhang H, Shao L. Research on K-nearest neighbor identification of hand-drawn circuit diagram. J Phys: Conf Ser 2019;1325:012233.
- 78. Tahir A, Pervaiz A. Hand written character recognition using SVM. Pacific Int J 2020;3:59-62.
- 79. Tang W, Fei L. Handwritten digit recognition based on SVM. CFIMA24 Proc Conf 2024. p. 324–31.
- Kourou K, Exarchos T, Exartos K, Karamouzis MV, Fotiadis DI. Machine learning applications in cancer prognosis and prediction. Comput Struct Biotechnol J 2015; 13:8–17.
- Kourou K, Exarchos KP, Papaloukas C, Sakaloglou P, Exarchos T, Fotiadis DI. Applied machine learning in cancer research: a systematic review for patient diagnosis, classification and prognosis. Comput Struct Biotechnol J 2021;19:5546–55.
- 82. James BL, Sunny SP, Heidari AE, Ramanjinappa RD, Lam T, Tran AV, et al. Validation of a point-of-care optical coherence tomography device with machine learning algorithm for detection of oral potentially malignant and malignant lesions. Cancers 2021; 13:3583.
- 83. Chu CS, Lee NP, Ho JW, Choi SW, Thomson PJ. Deep learning for clinical image analyses in oral squa-mous cell carcinoma: a review. JAMA Otolaryngol Head Neck Surg 2021;147:893–900.
- Alabi RO, Elmusrati M, Sawazaki-Calone I, Kowalski LP, Haglund C, Coletta RD, et al. Comparison of supervised machine learning classification techniques in prediction of locoregional recurrences in early oral tongue cancer. Int J Med Inform 2020;136: 104068.
- 85. Kumar KS, Adimoolam M. Handwritten character recognition using k-nearest neighbour algorithm and compare with feature extraction precision naive bayes algorithm. AIP Conf Proc 2023;2821:070005.
- 86. Kumar NV, Kumar PV, Pramodh K, Karuna Y. Classification of skin diseases using image processing and SVM. In: Abstracts of the international conference on vision towards emerging trends in communication and networking. IEEE Xplore 2019:1–5.
- 87. Dharani R, Revathy S. DEEPORCD: detection of oral cancer using deep learning. J Phys Conf Ser 2021;1911:012006.
- 88. Romeo V, Cuocolo R, Ricciardi C, Ugga L, Cocozza S, Verde F, et al. Prediction of tumor grade and nodal status in oropharyngeal and oral cavity squamous-cell carcinoma using a radiomic approach. Anticancer Res 2019;40:271–80.

- 89. Thomas SM, Lefevre JG, Baxter G, Hamilton NA. Interpretable deep learning systems for multi-class segmentation and classification of nonmelanoma skin cancer. Med Image Anal. 2021;68:101915.
- 90. Harnale S, Maktedar DD. Oral cancer detection: Hybrid method of KFCM clustering. Int J Recent Technol Eng 2020;8:2287–92.
- 91. Ran X, Xi Y, Lu Y, Wang X, Lu Z. Comprehensive survey on hierarchical clustering algorithms and the recent developments. Artif Intell Rev 2023;56:8219–63.
- 92. Peng Y. Digital recognition methods based on deep learning. Sci Program 2022; 2022:1–12.
- 93. Men K, Chen X, Zhang Y, Zhang T, Dai J, Yi J, et al. Deep deconvolutional neural network for target segmentation of nasopharyngeal cancer in planning computed tomography images. Front Oncol 2017;7:315.
- 94. Nanditha BR, MP GKAS. Oral cancer detection using machine learning and deep learning techniques. Int J Cur Res Rev 2022;14:64.
- 95. Alhazmi A, Alhazmi Y, Makrami A, Masmali A, Salawi N, Masmali K, et al. Application of artificial intelligence and machine learning for prediction of oral cancer risk. J Oral Pathol Med 2021;50:444–50.
- 96. Diwakar M, Kumar M. A review on CT image noise and its denoising. Biomed Signal Process Control 2018;42:73–88.
- 97. Hussain Z, Gimenez F, Yi D, Rubin D. Differential data augmentation techniques for medical imaging classification tasks. AMIA Annu Symp Proc 2017; 2017:979–84.
- Chu CS, Lee NP, Ho JWK, Choi SW, Thomson PJ. Deep learning for clinical image analyses in oral squamous cell carcinoma: a review. JAMA Otolaryngol Head Neck Surg 2021;147:893–900.
- Mobadersany P, Yousefi S, Amgad M, Gutman DA, Barnholtz-Sloan JS, Velázquez Vega JE, Brat DJ, Cooper LAD. Predicting cancer outcomes from histology and genomics using convolutional networks. Proc Natl Acad Sci U S A 2018;115: E2970-E2979.
- 100. Shi JY, Wang X, Ding GY, Dong Z, Han J, Guan Z, et al. Exploring prognostic indicators in the pathological images of hepatocellular carcinoma based on deep learning. Gut 2021;70:951–61.
- Akkus Z, Galimzianova A, Hoogi A, Rubin DL, Erickson BJ. Deep learning for brain MRI segmentation: state of the art and future directions. J Digit Imaging 2017;30:449– 59.
- 102. Reyes M, Meier R, Pereira S, Silva CA, Dahlweid F-M, von Tengg-Kobligk H. On the interpretability of artificial intelligence in radiology: challenges and opportunities. Radiology: Artificial Intelligence 2020;2:e190043.
- 103. Shuai Z, Xiaolin D, Jing Y, Yanni H, Meng C, Yuxin W, Wei Z. Comparison of different feature extraction methods for applicable automated ICD coding. BMC Med Inform Decis Mak 2022;22:11.
- 104. Li J, Zhu Q, Wu Q. A self-training method based on density peaks and an extended parameter-free local noise filter for k nearest neighbor. Knowledge-Based Systems 2019;184:104895.
- 105. Daulay RSA, Efendi S, Suherma. Review of literature on improving the kNN algorithm. TECS 2023;11:63–72.
- 106. Zao S, Li J. A semi-supervised self-training method based on density peaks and natural neighbors. J Ambient Intell Humaniz Comput 2021;12:2939–53.

- 107. Halder RK, Uddin MN, Uddin A, Aryal S, Khraisat A. Enhancing K-nearest neighbor algorithm: a comprehensive review and performance analysis of modifications. J Big Data 2024;11:113.
- 108. Hu LY, Huang MW, Ke SW, Tsai CF. The distance function effect on k-nearest neighbor classification for medical datasets. SpringerPlus 2016;5:1–9.
- 109. Lopez-Bernal D, Balderas D, Ponce P, Molina A. Education 4.0: teaching the basics of KNN, LDA and simple perceptron algorithms for binary classification problems. Future Internet 2021;13:193–206.
- 110. Feng G, Wu J. Research progress of kNN classification algorithm improvement. Library and Information Service. 2012;56:97–100.
- 111. Drahani R, Revathy S. DEEPORCD: Detection of oral cancer using deep learning. J Phys Conf Ser 2021;1911:01006.
- 112. Chu CS, Lee NP, Adeoye J, Thomson P, Choi S. Machine learning and treatment outcome prediction for oral cancer. J Oral Pathol Med 2020;49:977–85.
- 113. Chen L, Wang C, Chen J, Xiang Z, Hu X. Voice disorder identification by using Hilbert-Huang transform (HHT) and K Nearest Neighbors (KNN). J Voice 2021; 35:932.
- 114. Yang H, Jo E, Kim HJ, Cha I-H, Jung Y-S, Nam W, et al. Deep learning for automated detection of cyst and tumors of the jaw in panoramic radiographs. J Clin Med 2020;9:1936.
- 115. Shamin MZM, Syed S, Shiblee M, Usman M, Ali, SJ; Hussein HS, et al. Automated detection of oral pre-cancerous tongue lesions using deep learning for early diagnosis of oral cavity cancer. Comput J 2020;65:91–104.
- 116. Al-Rawi N, Sultan A, Rajai B, Shuaeeb H, Alnajjar M, Alketbi M, et al. The effectiveness of artificial intelligence in detection of oral cancer. Int Dent J 2022;72:436–47.
- 117. Sauvaget E, Salvan D, Faucon B, Borsik M, Lecrec N, Bisdorff A. Head and neck venous malformation: interest of the diode laser treatment. Sang Thrombose Vaiss 2017;29:69–74.
- 118. Zanoni M, Fontana FA, Stella F. On applying machine learning techniques for design pattern detection. J Syst Soft 2015;103:102–17.
- 119. Akalin A, Mu X, Kon MA, Ergin A, Remiszewski SH,Thompson CM, et al. Classification of malignant and being tumors of the lung by infrared spectral histopathology (SHP). Lab Invest 2015;95:406–21.
- 120. Ng EYA. Review of thermography as promising non-invasive detection modality for breast tumor. Int J Therm Sci 2009;48:840–59.
- 121. Komoriyama M, Nomoto R, Tanaka R, Hosoya N, Gomi K, Iino F, et al. Application of thermography in dentistry – visualization of temperature distribution on oral tissues. Dent Mater J 2003;22:436–43.
- 122. Otsu N. A threshold selection algorithm from gray-level histograms. IEEE Trans Syst Man Cybern 1979;SMC-9:62–66.
- 123. Prewitt JMS. Object enhancement and extraction. In: Lipkin B, Rosenfeld A., eds. Picture processing and psychopictorics. New York: Academic Press; 1970. p. 75-149.
- 124. Rosenfeld A, Thurston M. Edge and curve detection for visual scene analysis. IEEE Trans. Comp 1971;20:562–9.
- 125. Barber BC, Dobkin DP, Huhdanpaa H. The quickhull algorithm for convex hulls. ACM Trans Math Softw 1995;22:469–83.
- 126. Fitzgibbon A, Pilu M, Fisher RB. Direct least square fitting of ellipses. IEEE Trans Pattern Anal Mach Intell 1999;21:476–80.
- 127. Anandaroop R, Deepak CS. Non-linear least squares ellipse fitting using the genetic algorithm with applications to strain analysis. J Struct Geol 2008;30:1593–602.

- 128. Cunningham P, Delany SJ. k-Nearest Neighbour Classifiers. Technical Report, UCD-CSI-2007-4. 2007. Prieiga per internetą: https://www.researchgate.net/profile/Sarah\_ Delany/publication/228686398\_kNearest\_neighbour\_classifiers/links/0fcfd50d0c1d1f 41ad000000/k-Nearest-neighbour-classifiers.pdf (accessed on 24 February 2022)
- 129. Kumar R, Indrayan A. Receiver operating characteristics (ROC) curve for medical researchers. Perspective 2011:48:227–87.
- 130. Nahm FS. Receiver operating characteristic curve: Overview and practical use for clinicians. Korean J Anesthesiol 2022;75:25–36.
- 131. Çorbacıoğlu ŞK, Aksel G. Receiver operating characteristic curve analysis in diagnostic accuracy studies: a guide to interpreting the area under the curve value. Turk J Emerg Med 2023;23:195–8.
- 132. Strimbu K, Tavel JA. What are biomarkers? Curr Opin HIV AIDS 2010;6:463-6.
- 133. Mayeux R. Biomarkers: potential uses and limitations. NeuroRx 2004;1:182-8.
- Pepe MS, Etzioni R, Feng Z, Potter JD, Thompson ML, Thornquist M, et al. Phases of biomarker development for early detection of cancer. J Natl Cancer Inst 2001;93:1054– 61.
- 135. Pallavi G, Vidhya K. Brain tumor detection with high accuracy using k-nearest neighbor comparing with thresholding method. AIP Conf Proc 2023;2822:020183.
- 136. Mustafa Qays Hatem. Skin lesion classification system using a k-nearest neighbor algorithm. Vis Comput Ind Biomed Art 2022;5:1–10.
- 137. Yan KX, Liu L, Li H. Application of machine learning in oral and maxillofacial surgery. Artif Intell Med Imaging 2021;2:104–14.
- 138. Dong C, Tao J, Wu Y, Su Y, Wang Y, Wang C, et al. Detection of cervical lymph node metastasis from oral cavity cancer using a non-radiating, noninvasive digital infrared thermal imaging system. Sci Rep 2018:8:1–9.
- 139. Chakraborty M, Raman SK, Mukhopadhyay S, Patsa S, Anjum N, Ray JG. High precision automated face localization in thermal images: oral cancer dataset as test case. SPIE Proc 2017;10133:1013326.
- 140. Conway DI, Petticrew M, Marlborough H, Berthiller J, Hashibe M, Macpherson LM. Socioeconomic inequalities and oral cancer risk: a systematic rewiev and meta-analysis of case control studies. Int J Cancer 2008;29:515–24.
- 141. Etehadtavakol M, Emrani Z, Ng EYK. Rapid extraction of the hottest or coldest regions of medical thermographic images. Med Biol Eng Comput 2019;57:379–88.
- 142. Abdel-Nasser M, Moreno A, Puig D. Breast cancer detection in thermal infrared images using representation learning and texture analysis methods. Electronics 2019;8:100.
- 143. Al Husaini MAS, Hadi H, Gunawan TS, Islam MR. Self-detection of early breast cancer application with infrared camera and deep learning. Electronics 2021;10:2538.
- 144. Tello-Mijares S, Woo F, Flores F. Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network. J Healthc Eng 2019;2019:9807619.
- 145. Brioschi M, Usuki H, Jan Crawford BS, Steed P, Ammer K, Serbu G. Guidelines for dental-oral and systemic health infrared thermography. Pan Am J Med Thermol 2015; 2:44–53.
- 146. UnitedHealthcare West. Medical Management Guideline. No: MMG126. Thermography 2021. p. 1–11. Prieiga per internetą: https://www.uhcprovider.com/content/dam/ provider/docs/public/policies/signaturevalue-mmg/thermography-sv.pdf (accessed on 30 April 2025)

- 147. U.S. Food and Drug Administration. Breast cancer screening: Thermogram no substitute for mammogram 2023. Prieiga per internetą: https://www.fda.gov/consumers/ consumer-updates/breast-cancer-screening-thermogram-no-substitute-mammogram
- 148. Van Natta M, Chen P, Herbek S, Jain R, Kastelic N, Katz E, et.all. The rise and regulation of thermal facial recognition technology during the COVID-19 pandemic. J Law Biosci 2020;1–17.
- 149. Brzezinski RY, Rabin N, Lewis N, Peled R, Kerpel A, Tsur AM et.all. Automated processing of thermal imaging to detect COVID-19. Sci Rep 2021:11:17489.
- 150. Bioły A, Marcjasz P, Dryja P, Boczar A, Buliszak A, Babczyńska M. The diagnostic value of thermography in oncology: current evidence and future perspectives. Qual Sport 2025;41:59830.

# **MOKSLINĖS PUBLIKACIJOS**

## Web of Science DB referuojamuose leidiniuose su citavimo rodikliu:

- 1. **Mačianskytė D**, Adaškevičius R. Automatic Detection of Human Maxillofacial Tumors by Using Thermal Imaging: A Preliminary Study. Sensors (Basel), the section "Sensing and Imaging". 2022 Mar 3;22(5):1985. doi: 10.3390/s22051985. (IF=3.9; Q2)
- Macianskyte D, Monastyreckiene E, Basevicius A, Adaskevicius R. Comparison of segmented thermal images versus a CT scanning for detection of maxillofacial pathology. Dentomaxillofac Radiol. 2019 May;48(4):20180075. doi: 10.1259/dmfr.20180075. Epub 2019 Feb 19. (IF=2.545; Q2)
- Adaškevičius R, Krasnickaitė V. Mačianskytė D. Application of thermal imaging for early diagnostic of maxillofacial pathology. *Proceedings* "Biomedical Engineering". Kaunas: Technologija, 2014 p. 144–7. ISSN: 2029–3380.

## Kitos publikacijos:

- 1. **Mačianskytė D**, Basevičius, R. Adaškevičius. Infrared thermography in the detection of oral and maxillofacial pathology. Tarptautinės konferencijos "Baltic Congress of Radiology" medžiaga, Latvija, Liepoja, 2016 m.
- 2. **Mačianskyte D**, Adaškevičius R. Termografijos ir termovizijos pritaikymas žandikaulių srities navikinių pakitimų ankstyvai diagnostikai. VII nacionalinės doktorantų mokslinės konferencijos medžiaga leidinyje "Mokslas-sveikatai", LSMU, Kaunas, 2014 p. 68–9.
- 3. Adaškevičius R, Krasnickaitė V. **Mačianskytė D**. Application of thermal imaging for early diagnostic of maxillofacial pathology. Tarptautinės mokslinės konferencijos "Biomedical Engineering" medžiaga, KTU, Kaunas, KTU, 2015 m. kovo 9 d.

Kitos publikacijos duomenų bazėje Web of Science DB referuojamuose leidiniuose su citavimo rodikliu:

- 1. **Mačianskytė D**, Janužis G, Kubilius R, Adomaitienė V, Sčiupokas A. Association between chronic pain and depressive symptoms in patients with trigeminal neuralgia. Medicina (Kaunas) 2011;47(7):386–92. PMID: 22112988. (SJR IF=0.543; Q3)
- Adaskevicius R, Macianskyte D, Monastyreckiene E. Experimental determination of computed tomography settings for jaw scanning. Electronics and electrical engineering (Elektronika ir elektrotechnika), Kaunas University of technology 2011;5(111):129–32. ISSN 1392–1215. (SJR IF=0.27; Q3)
- 3. Verkauskas G, **Macianskyte D**, Janciauskas D, Preiksa RT, Verkauskiene R, Jaubert F. Diagnosis and management of 46,XY mixed gonadal dysgenesis and disorder of sexual differentiation. Medicina (Kaunas) 2009; 45(5):357–64. PMID: 19535881. (SJR IF=0,506; Q3)

## MOKSLINIŲ PUBLIKACIJŲ KOPIJOS

No special permission is required to reuse all or part of the article published in Biomedical Engineering 2014: Proceedings of the 18<sup>th</sup> International Conference (Kaunas University of Technology Institute of Biomedical Engineering), including tables and figures. Furthermore, no special permission is required for authors to deposit their work in external repositories, in accordance with the publisher's open access policy.

Conference "Biomedical Engineering"

## Application of Thermal Imaging for Early Diagnostic of Maxillofacial Pathology R. Adaškevičius<sup>1\*</sup>, V. Krasnickaitė<sup>1</sup>, D.Mačianskytė<sup>2</sup>

<sup>1</sup>Kaunas University of Technology, Lithuania <sup>2</sup>Lithuanian University of Health Sciences, Lithuania \*E-mail: rimas.adaskevicius@ktu.lt

**Introduction.** Thermal imaging is a technique of detecting the objects' infrared radiation and creating an image based on that information, but it is not widely used in routine medical diagnostics. The first utilizations of thermal imaging were made with large and noise scanners in 1956. In ours days thermography is broadly used for diagnostics of breast cancer, skin melanom and other areas of pathology.

Thermal imaging captures the natural thermal radiation generated by an object at a temperature above absolute zero. It is non-invasive, non-contact, passive and radiation – free technique. Clinical application of thermography is based on the ability to image natural heat emissions of the human body. It is based on the principle that the temperature of the area surrounding the damaged, prie-cancerous and cancerous tissue is higher than that of a normal tissue. For a normal person, the thermogram shows uniform and symmetric temperature variations. In case of abnormality, pathological regions show aprupt variations in temperature [1, 4].

The objectives of the study is to evaluate the potential of thermography in diagnosis of the disease of human jaw.

**Materials and methods.** Thermal imaging is a technique for temperature measurements based on the infrared radiation from objects. The radiance from human skin is an exponential function of the surface temperature, which is influenced by the level of blood perfusion in the skin. Unlike images created by x-rays or proton activation through magnetic resonance, thermal imaging is not based on morphological analysis. The technique provides only a map of the distribution of temperatures on the surface of the subject imaged. So, to determine whether a local abnormality in tissue temperature is present or not the special image processing approaches for extraction of the features of thermal images must be used.

The proposed method for thermal imaging analysis for early diagnostic of maxillofacial pathology comprises the following steps:

1) The acquisition of thermal data;

2) Pre-processing of thermal images;

3) Examination of paired (right and left) areas of face surface and paired intraoral areas;

4) Segmentation of thermal image;

5) Evaluation of diagnostic accuracy by comparing results from thermal imaging with computer tomography findings.

Conference "Biomedical Engineering"

Before the measurements, the subjects were thermo-equilibrated in the laboratory space for 15 minutes [2]. The room temperature was maintained by a wall mounted air conditioning unit and was in range between 20 °C and 22 °C. The air conditioning was switched off during measurements and there was no direct sunlight. The subjects were instructed to sit up as straight as possible.

The face region being investigated by an infrared thermal camera was positioned one meter away from subject. Thermal imaging was carried out using a thermal camera FLIR E8 (thermal sensitivity -0.06 °C, resolution  $-320 \times 240$ , the maximum temperature range from -20 °C to +250 °C). For each of subjects facial thermal images were taken using frontal projection, right and left lateral projections, and mouth's cavity. Each surface temperature profiles of the patients were recorded and later analyzed using image processing software in Matlab.

Thermal images transformed into Matlab readable data files by ThermaCam Researcher 2.1. Each image must carry the information about temperature range, emissivity of body, atmospheric temperature and relative humidity, distance from human to camera.

The pre-processing of thermal image starts from checking of thermal data structure: the parameters representing environment conditions, the distance from patient to camera, emissivity of body must be in the correct range. The next step after checking of integrity of thermal image is to detect edges of human face. For edge detection the gradient image was created from the original thermal image. Each pixel of a gradient image measures the change in intensity of that same point in the original image, in a given direction. After gradient images have been computed, pixels with large gradient values become possible edge pixels. The Prewitt method was used to find edges using the Prewitt approximation [3]. It returns edges at those points where the gradient values are maximal. The Prewitt method was selected for its simplicity and its low computational load.

For presentation of human face external contour as smallest convex polygon that contains all the points of edge, the convex hull was calculated. The convex hull of an edge image is the set of pixels included in the smallest convex polygon that surround all edge pixels and was used to describe the external boundary of field, which temperature changes were analysed.

Thermal imaging is hence well suited to pick up changes in blood perfusion that might occur due to inflammation or other causes. Asymmetrical temperature distributions as well as the presence of hot and cold spots are known to be strong indicators of an underlying dysfunction [4]. Thermal symmetry in the face is a normal finding in healthy subjects. The best fitting for an ellipse from set of convex hull vertices was used for identification of axis of face symmetry. The Least-Squares criterion for estimation of the best fit to an ellipse from a given set of points was used. So, the major semi axis of ellipse represents an axis of symmetry of human face. It was used for splitting the field of analysis into two independent areas. The average temperatures of left and right sides of human face were calculated and compared. The temperature asymmetry higher than 0.4 °C

145

[1] was associated with the presence of abnormality and additional investigation for identification of abnormal regions is necessary. In the same order the mouth cavity was investigated and temperature asymmetry evaluated.

For representation of pathological region additional right or left side thermal images were used. The appropriate side image was used for calculation of isolines along which the temperature has a constant value. The number of isolines and the values of the isolines are chosen automatically based on the minimum and maximum temperature values of face area. A filled contour plot for displaying of isolines and filling the areas between the isolines using constant colors corresponding to the current temperature color map is representative tool for evaluation of abnormality of face region. The abnormal region has different temperature and it can be highlighted in different color from the rest of the face. The location of abnormality, identified using thermal imaging was compared with results of computerized tomography (CT).

**Results.** The thermograms were collected from 6 patients (3 patients with a tumor, one patient with an inflammatory origin of jaw and 2 healthy persons) using non-contact thermography at the Clinic of Radiology, Lithuanian University of Health Sciences. All patients additionally were investigated with CT Toshiba "ONE Aquilion". The average and standard deviation of temperature measurements taken using frontal face and mouth's cavity projections were calculated from 5 measurements in each image and the results are shown in Table 1.

		Patient 1	Patient 2	Patient 3	Patient 4	Patient 5	Patient 6
	Face	33,51 ±	$33,77 \pm$	$32,93 \pm$	$31,884 \pm$	$34,49 \pm$	33,68 ±
Righ	mean $\pm$ SD	0,017	0,032	0,01	0,015	0,038	0,039
Side,	Mouth's cavity	$37,44 \pm$	$38,67 \pm$	$35,85 \pm$	$33,445 \pm$	$36,412 \pm$	$35,07 \pm$
T °C	mean ± SD,	0,0217	0,017	0,0618	0,0243	0,0192	0,013
	Highest temperature	38,34	39,23	36,13	34,23	37,13	36,18
Left	Face	$34,37 \pm$	$33,93 \pm$	$32,85 \pm$	$31,35 \pm$	$34,32 \pm$	33,59 ±
Side,	mean $\pm$ SD	0,019	0,054	0,015	0,018	0,013	0,04
T °C	Mouth's cavity	$38,08 \pm$	$38,23 \pm$	$35,85 \pm$	$32,95 \pm$	$36,252 \pm$	$34,894 \pm$
	mean $\pm$ SD	0,0234	0,01	0,085	0,0221	0,0286	0,023
	Highest temperature	38,98	38,85	35,03	34,53	36,91	36,05

Table 1. Thermographic analysis of frontal regions face and mouth's cavity

In case of tumor in maxillofacial region (Patient 1) in pathological field of face thermal image the higher temperature area due to hyper vascularity of tumor tissue was detected. The asymmetry of average face temperature was 0.76 °C. In case of tumor in maxillofacial region (Patient 2), the asymmetry of average face temperature can be small and the location of tumor was evaluated by calculating temperature asymmetry mouth's (asymmetry of cavity is 0.44 °C). The pathological area is highlighted in different color (Fig. 1). In case when the tumor was localized deep in mouth's cavity, in oropharyngeal region, the average temperatures between left side and right side of face or mouth's cavity do not differ (Patient 3). So, the highest temperatures of different sides must be compared. In case of inflammatory (Patient 4), the abnormal area was

146

## Conference "Biomedical Engineering"

successfully identified, but the temperature in this area was lower than in other fields of face. The significant difference in thermal symmetry of the face or mouth's cavity images was not found for healthy persons (Patient 5, Patient 6).



Fig. 1. Thermo graphic image of patient face with tumour (abnormal area highlighted in dark red in mouth cavity) and CT image of tumor

**Conclusions.** The proposed method can be used for medical diagnostic of maxillofacial pathology. Temperature gradients are observed in the affected regions of patients, indicating abnormal blood flow in the affected region, which is well correlated with the CT findings. The temperature in the affected regions was about 0.45-1.1 °C above the normal regions. Results of this work indicate that detection of maxillofacial pathology using thermal images shows a great promise in helping to develop an objective screening tool in the near future.

## References

1. Durnovo E.A., Potekhina YU.P., Marochkina M.S., Khomutinnikova N.E., Yanova N.A. Features of Infrared Thermography in the Diagnosis of Complex Diseases of Maxillofacial Region // Modern Problems of Science and Education, No 4, 2012.

2. Rajendra Acharya U., Ng E.Y.K., Vinitha Sree S., Chua Kuang Chua, Subhagata Chattopadhyay. Higher order spectra analysis of breast thermograms for the automated identification of breast cancer //Expert Systems, February 2014, Vol. 31, No.1. –P. 37 - 47.

3. Shrivakshan G.T. A Comparison of various Edge Detection Techniques used in Image Processing // IJCSI International Journal of Computer Science Issues, Vol. 9, Issue 5, No 1, September 2012. –P. 272 - 276.

4. Mostovoy A. Thermography and Oral Pathology // EAT2012 Book of Proceedings – Appendix 1 of Thermology international 22/3, 2012. –P. 159 - 161.

## Application of Thermal Imaging for Early Diagnostic of Maxillofacial Pathology R. Adaškevičius<sup>1</sup>, V. Krasnickaite<sup>1</sup>, D.Mačianskytė<sup>2</sup>

<sup>1</sup>Kaunas University of Technology, Lithuania <sup>2</sup>Lithuanian University of Health Sciences, Lithuania

We present a method for diagnostic of maxillofacial pathology using thermal imaging. It is based on the principle that the temperature of the area surrounding the damaged, prie-cancerous and cancerous tissue is higher than that of a normal tissue. It was found, that face surface temperature asymmetry higher than  $0.4^{\circ}$ C was associated with the presence of abnormality.

147

No special permission is required to reuse all or part of the article published by Dentomaxillofacial Radiology, a journal of The British Journal of Radiology (BJR), including tables and figures. Furthermore, no special permission is required for authors to deposit their work in external repositories, in accordance with the journal's open access policy.

> Dentomaxillofacial Radiology (2019) 48, 20180075 © 2019 The Authors. Published by the British Institute of Radiology birruphlications org/dmfr

## **RESEARCH ARTICLE Comparison of segmented thermal images versus a CT scanning for detection of maxillofacial pathology**

<sup>1</sup>Diana Macianskyte, <sup>1</sup>Egle Monastyreckiene, <sup>1</sup>Algidas Basevicius and <sup>2</sup>Rimas Adaskevicius

<sup>1</sup>The Clinic of Radiology, Lithuanian University of Health Sciences, Kaunas, Lithuania; <sup>2</sup>Department of Electrical Power Systems, Kaunas University of Technology, Kaunas, Lithuania

**Objectives:** To evaluate thermal images (TIs) by using an algorithm for optimized region of interest (ROI) and image segmentation, in order to find zones of the facial skin surface with asymmetrical temperature, and to test consistency with CT findings, to detect maxillofacial pathologies (*i.e.* tumours).

**Methods:** The following steps for the TI evaluation were applied: data acquisition/pre-processing of frontal face and mouth projection, detection of face and mouth external contour, finding face and mouth symmetry axis, calculation of differences in average and maximal temperatures between left and right face and mouth sides, image segmentation of the selected ROI, and evaluation of diagnostic accuracy by comparing the TI results with CT findings.

**Results:** In healthy subjects, the average temperature difference between left/right sides of facial and mouth ROI was negligible  $(0.02 \pm 0.21 \, ^{\circ}\text{C} \text{ and } 0.05 \pm 0.19 \, ^{\circ}\text{C}$ , respectively; n = 23). In the presence of tumour, the average temperature difference was higher in corresponding TIs  $(0.47 \pm 0.1 \, ^{\circ}\text{C} \text{ and } 0.66 \pm 0.1 \, ^{\circ}\text{C}$  facial and mouth ROI, respectively; n = 19, p < 0.05). For large tumours, thermal asymmetry in the corresponding TI is easily detected, and image segmentation is optional for finding the affected zone. For small or deeply localized tumours, segmentation of the mouth cavity of the ROI was required for the detection of hot and cold spots.

**Conclusions:** Asymmetrical temperature zones and their location as detected from thermal images coincide well with the presence and localization of maxillofacial pathologies (*i.e.* tumours) established by CT. However, accurate information could often be obtained only after application of image segmentation algorithm to the selected ROI.

Dentomaxillofacial Radiology (2019) 48, 20180075. doi: 10.1259/dmfr.20180075

Cite this article as: Macianskyte D, Monastyreckiene E, Basevicius A, Adaskevicius R. Comparison of segmented thermal images versus a CT scanning for detection of maxillofacial pathology. *Dentomaxillofac Radiol* 2019; **48**: 20180075.

Keywords: Infrared; thermal imaging; CT; segmentation algorithm; maxillofacial pathology

## Introduction

Infrared thermography (IRT) is a non-invasive, non-contact as well as inexpensive diagnostic method. Because of its possibly high availability to large populations, its meets the essential requirements for a screening modality for pathology ( $e_g$  tumour) detection.<sup>1,2</sup> Nevertheless, it is still not used for routine clinical diagnosis, largely because the desired information cannot be easily extracted.

The first attempt to measure human facial temperature has been made as early as in 1996.<sup>3</sup> However, possibilities to use IRT for detecting the presence of local lesions in the orofacial region in humans have been poorly explored, because the analysis of thermal images (TIs) in the maxillofacial part is complicated due to its elaborate anatomical structure. Therefore, for reliable IRT analysis it is important to use the computational algorithms. Development and application of adequate

Correspondence to: Mrs Diana Macianskyte, E-mail: diana.macianskyte@lsmuni.lt

Received 21 February 2018; revised 18 January 2019; accepted 25 January 2019

algorithms might help detect changed skin temperature distribution in the affected zones, and automatically processed evaluation of the images could possibly avoid overdiagnosis when interpreting TI data. It has been shown that accurate detection of the TI of the region of interest (ROI) and use of image segmentation are critical steps in the analysis,<sup>4</sup> to help revealing lesions more precisely.

In this study, we applied a new algorithm and demonstrate that image segmentation of optimized ROI allow detection of asymmetrical changes of skin temperature in the maxillofacial region. We also aimed to examine any relationship between the IRT and CT results, when comparing the asymmetrical temperature zones and their location in the TI with the lesions revealed during CT.

#### Methods and materials

The study was carried out in accordance with the European Community guiding principles outlined in the Declaration of Helsinki, and was approved by the Ethics Committee of Biomedical Research of Kaunas Region, Lithuania (No.BE-2-31). We investigated 42 human subjects (23 males and 19 females) with an age range of 15-86 years. They included patients (n = 19)who after clinical evaluation were directed to a CT procedure (in 2016) for suspected diagnosis of tumour in the orofacial/maxillofacial region [16 males and 3 females; mean ( $\pm$  standard deviation) age of 61.1  $\pm$  4.5 and 71.0 ± 11.0 years, respectively] and healthy volunteers (n = 23; 7 males and 16 females; mean age 40.4  $\pm$ 6.0 and 51.3  $\pm$  4.0 years, respectively), who were directed for CT evaluation before the planning of tooth implantation. The inclusion criteria was that the subject underwent a CT procedure for a first time, and had no prior surgical or drug treatment in the maxillofacial region. The exclusion criteria were a history of surgical procedures and/or traumatic injuries in maxillofacial region, a drug treatment, or the presence of other, non-cancerous pathologies. The procedures were explained to each of the subjects, and written informed consent was obtained.

#### Data acquisition

Because there are various factors which might affect the TI data, all patients were asked to avoid using medications, massage, physical exercise, facial cosmetics, shaving, smoking, alcohol drinking, intake of tea or coffee and large meals at least 1 h prior to the start of IRT measurements.<sup>5</sup>

At a first step, prior to the CT scanning procedure, the standardized thermograms were recorded for everyone subject. This was done in order to avoid the subsequent influence of X-rays and contrast agent on the temperature profiles of the face. All subjects underwent the same thermographic protocol adjusted for

Dentomaxillofac Radiol, 48, 20180075

birpublications.org/dmfr

clinical application. Before starting IRT measurements, all patients were thermo-equilibrated for 15 min in the laboratory space (*i.e.* with a constant temperature, humidity, no direct sunlight etc.).<sup>6</sup> During the measurements each patient was instructed to sit up straight, and the head was positioned in front of an infrared thermal camera. Under the conditions of this study, the camera was placed 1 m from the patient's face. The camera's lens was manipulated to bring the subject's face into focus. The TIs of the face were taken in both the frontal closed and open mouth projections. The TIs were coded and stored on computer, to be later analyzed by an experienced thermographer.

At the next step, each patient was scanned with a multislice CT (Toshiba *Aquilion ONE*, Canon Medical Systems, Japan), using identical scanning parameters (contiguous 1 mm thick axial slices). All CT images were analyzed by an experienced radiologist, and the diagnosis of the maxillofacial pathology was determined.

Finally, based on CT findings the diagnostic accuracy of a new algorithm for TI analysis was evaluated. To be able of comparing these data, the special procedures were followed: pre-processing of the TI, detection of the face/mouth edges, finding of the face/mouth symmetry axis, calculation of temperatures (averaged and peak) of the ROI, and image segmentation of the selected ROI. The schematic experimental set-up and the sequence of algorithmic calculations is presented in Figure 1.

#### Face contour detection

The pre-processing of TIs starts with checking the thermal data structure (Table 1): the environment conditions, the distance to camera, the emissivity of the body etc. Then the edges of human face were determined (Figure 1b). The proper detection of facial edge in a TI is an important process which allows preserving its important structural characteristics, while reducing the unwanted data from an image. In order to extract such information, the image gradients created from the original TI were used by looking for the maximum and minimum in the first derivative of the temperature. Hence, each pixel of a gradient image  $(\nabla f)$  measures the change in temperature  $(\partial I)$  of that same point in the original image in a given direction. To get the full range of direction, the gradient images in the x and y directions were computed as first order derivatives of thermal image *I* in *x* and *y* direction:

$$\nabla f_x = \frac{\partial I}{\partial x},$$
  
$$\nabla f_y = \frac{\partial I}{\partial y}.$$
 (1)

At each point in the image, the resulting gradient magnitude was calculated using<sup>7</sup>:

$$\nabla f = \sqrt{\nabla f_x^2 + \nabla f_y^2}.$$
 (2)



Use of IRT vs CT for maxillofacial pathology detection

Figure 1 Schematic experimental system and principal steps of usage an algorithm for the analysis of thermal images. An infrared camera was mounted on an upright frame and located 1.0 m from the face of the subject to be examined (a). The following main steps for TI evaluation were applied: (a) acquisition/pre-processing and storage of raw thermal data, (b) detection of human face edges by creating image gradients ( $G_x$  and  $G_z$ - the convolution mask along x-axis and y-axis, respectively), (c) finding of orientation and position of the symmetry axis (Note: the larger axis of an ellipse matches with the symmetry axis of the human face), (d) calculation of average and peak temperatures of both left/right facial ROI, (e) evaluation of temperature differences (averaged and peak), and (f) image segmentation (if necessary) of selected facial ROI. The same steps were used for analysis of the mouth cavity ROI. IRT, infrared thermography; ROI, region of interest; TI, thermal image.

A Prewitt approximation was used, due to its simplicity and low computational load, to find edges at points<sup>8</sup> where the gradient values are maximal. An original human face contour detection is presented in Figure 1b. For the presentation of human face external contour as the smallest convex polygon that contains all points of the edge, the convex hull was calculated using the Quick Hull method.<sup>9</sup> This convex hull was used to describe the external boundary of the field in which temperature changes were analyzed.

## Finding the position and orientation of the symmetry axis

Asymmetrical temperature distribution is an indicator of lesion (*i.e.* pathology).<sup>10</sup> Finding of facial symmetry axis allows to separate left and right sides of the face and to calculate skin temperature difference ( $\Delta t$ ) between both sides by subtracting the right side-value from the left.

The best fitting of human face edges to an ellipse, formed from set of convex hull vertices, was used for the identification of the facial axis symmetry (Figure 1c). The least-squares criterion was used for the best fit estimation. Hence, the major semi-axis of the ellipse represents the facial symmetry axis, which was used for splitting the field of analysis into two independent (left and right side) areas. Then, the average ( $\Delta r_{mex}$ ) and the maximal ( $\Delta t_{max}$ ) temperatures were calculated and compared for both sides of the human face (Figure 1d-e). Temperature

asymmetry higher than 0.4 °C was taken as indication of the presence of a pathology.<sup>11</sup> The mouth cavity was investigated using a similar approach and temperature asymmetry evaluated.

Image segmentation of the leftlright region of interest The appropriate side-of the ROI image was used for determining isolines along which the temperature has a constant value. The thresholding method for image segmentation (Figure 1f) was used. This method is based on threshold value to turn the region of TI into a binary image. Using two neighbouring temperature thresholds  $t_i + \Delta t/2$  and  $t_i - \Delta t/2$ , a range of temperatures related to the region:

$$t_i + \Delta t/2 > t_i > t_i - \Delta t/2 \tag{3}$$

can be defined as binary area g(x, y) having  $t_i$  temperature.  $\Delta t$  is the temperature range of segment or temperature difference between neighbouring isolines. A filled contour plot for displaying isolines and filling the areas g(x, y) between the isolines using constant colours, corresponding to the current temperature  $t_i$  colour map, can be defined as:

$$g(x, y) = \begin{cases} t_{i+1}, & \text{if } T(x, y) > t_i \\ t_i, & \text{if } t_i + \Delta t/2 > T(x, y) \ge t_i - \Delta t/2 \\ t_{i-1}, & \text{if } T(x, y) \le t_i \end{cases}$$
(4)

Table 1	Measurement	conditions	for	the TI	session
---------	-------------	------------	-----	--------	---------

Input quantity	Setting the emissivity as object surface property	Room temperature (°C)	Relative humidity (%)	Subject rest time before test (min)	Camera-to-object distance (m)
Estimate values	0.98	$22 \pm 0.1$	60 ± 5	$15 \pm 0.2$	1

Of note: there was no direct sunlight in the room, and air conditioning was switched off during the measurements. Values measured with an infrared camera were stored in a computer file.

birpublications.org/dmfr

Dentomaxillofac Radiol, 48, 20180075

where T(x, y) is the temperature of TI pixel at particular location x, y.

The colour map is a representative tool for the evaluation of facial pathology. The number and values of the isolines are chosen automatically based on the minimum and maximum values of face area. TIs were analyzed in respect of the skin and mouths mucosal lining (epithelium) temperature differences between the affected side and the opposite normal side. The pathological region has different temperature range and it can be highlighted in different colour from the rest of the face. The place and side of facial/mouth asymmetrical temperature identified in the TI was compared with the findings of CT.

## Evaluation of diagnostic accuracy

Patients with suspected diagnosis of maxillofacial tumour were involved in this study. In general, CT was used detect the presence of a tumour in the orofacial/ maxillofacial region. As mentioned above, the CT images were analyzed by a radiologist. The CT-generated information on the absence/presence of lesion and of its location was compared with the TI results for the same patient (*i.e.* we checked whether the appearance of asymmetrical temperature zone in the TI of selected ROI as well as its location coincided with a CT data).

## IRT imaging equipment

TIs were acquired using a commercially available infrared thermal camera *FLIR E8* (*FLIR Systems, Inc.*, USA). The camera's thermal sensitivity is 0.06 °C, resolution is  $320 \times 240$  pixels, and maximum temperature range is -20 °C up to +250 °C. All surface temperature profiles were analyzed using an image processing software developed in *Matlab R2014b* (*The MathWorks, Inc.*, USA). The images were transformed into *Matlab* readable data files by using special software *ThermaCam Researcher 2.1* (*FLIR Systems, Inc.*, USA). It is to be noted that each TI must carry tinformation such as temperature range with colour temperature, relative humidity, and patient-to-camera distance (Table 1).

#### Data analysis and statistics

The maximal and average temperatures of four human face areas (two facial sides: left and right; and two mouth cavity sides: left and right) were computed five times in each image for normal and pathological cases. All measurements were expressed as *mean*  $\pm$  *standard deviation* (*SD*). The *t*-test was used to evaluate whether the means of left and right sides are statistically different from each other. The significance level was set at *p* < 0.05. The *t*-test may performed in *Mallab*.

### Results

Representative examples of TI maps from the frontal projection of human face (a) and of mouth cavity (b)

Dentomaxillofac Radiol, 48, 20180075

birpublications.org/dmfr



Figure 2 Thermographic images of young a 24-year-old male without any health problems. No lesion detected during a CT evaluation (not shown). Symmetrical temperature distribution of thermal images obtained in a healthy subject: in the frontal closed (a) and open-mouth projections (b) after finding the external contour of the ROI (*dot-dashed curve*) and the symmetry axis (*vertical line*). Note: no evident temperature changes in left/right sides. The corresponding scale bar is given on the right side of the image in °C. ROI, region of interest.

of a healthy subject (Case 1) are shown in Figure 2. The TIs were processed in two steps, through the algorithmic procedures for detecting the external contour of the ROI and finding position of the symmetry axis. Calculated temperatures for left/right sides of the selected ROI are presented in Table 2 (see Case 1). Importantly, in all healthy subjects (n = 23) there was no evident thermal asymmetry in the TIs of the four areas examined: 35.85  $\pm$  1.31 °C vs 35.82  $\pm$  1.33 °C for left and right side of the face, respectively, and 36.72  $\pm$  1.55 °C vs 36.77  $\pm$ 1.58 °C for left and right side of the mouth cavity. In these subjects, calculated  $\Delta t_{mean}$  (difference in mean temperature) between the left/right sides of both facial and mouth ROIs was negligible ( $0.02 \pm 0.21$  °C and 0.05 $\pm$  0.19 °C, respectively). In addition,  $\Delta t_{max}$  (difference in maximum temperature) values also were not significant (0.02  $\pm$  0.19°C and 0.03  $\pm$  0.25 °C, respectively; p >0.05). It should be noted that these patients underwent a CT to evaluate the mandibular canal position before the planning of tooth implantation.

In contrast, in case of pathology such as benign (n = 4) or malignant (n = 15) tumour, as detected by CT, the TI of the same patients displayed a higher temperature difference profile. Representative cases are presented below.

Figure 3 shows a case of maxillofacial tumour. After clinical examination, the patient was directed to a CT procedure, because of visible deformity on the left side of the face. As illustrated in Figure 3a, an axial section of the CT scan image showed evident expansion on the left side of the mandible, with apparent ground-glass opacities and intact overlying bone and soft tissue. This patient had histologically proven benign tumour, namely fibrous dysplasia of the mandible. TI evaluation revealed thermal asymmetry at the corresponding facial side where lesion was present (Figure 3b), and the  $\Delta t_{mean}$ was of 0.87 °C. In addition, obvious thermal asymmetry was seen in the TI of mouth cavity, as presented in Figure 3c, where the pathological area is highlighted as higher colour intensity. The highest temperature in that area was > 38 °C (see Case 2 in Table 2). Of note, in this

4 of 9

Table 2         Calculated temperatures for left/right sides of the ROIs from the TIs presented in Figures 2–5									
Presented Cases	ROI	$t_{meanL}$ (°C)	$t_{maxL} (°C)$	$t_{meanR}$ (°C)	$t_{maxR} (°C)$	$\begin{array}{c} \varDelta t_{mean} \ (^{\circ}C) \end{array}$	$\Delta t_{max}$ (°C)	IRT (0/1)	CT view
Case 1, a healthy subject	f	33,93 ±0,039	36,17	33,77 ±0,04	36,03	0,16	0,14	0	No lesion detected
	m	35,08 ±0,013	36,97	34,92 ±0,023	36,78	0,16	0,19	0	
Case 2, the patient with benign tumour	f	34,42 ±0,019	36,45	33,55 ±0,017	36,23	0,87	0,22	1	Evident bone lesion on the left side-of the mandible
	m	37,84 ±0,023	38,97	37,29 ±0,217	38,33	0,55	0,64	1	
Case 3, the patient with malignant soft tissue tumour	f	35,50 ±0,054	38,14	35,52 ±0,032	37,96	0,28	0,18	1	A wide bone destruction zone on the right side-of the
	m	36,85 ±0,01	38,15	36,91 ±0,017	38,57	-0,06	-0,42	1	mandible
Case 4, the patient with malignant tumour (deeply	f	32,83 ±0,015	35,01	32,94 ±0,01	36,12	-0,11	-1,11	1	A hard palate bone destruction zone
located)	m	35,84	37,82	35,88	37,88	-0,04	-0,06	1	

Use of IRT vs CT for maxillofacial pathology detection

Macianskyte et al

IRT, infrared thermography; ROI, region of interest; TI, thermal image; f, facial; m, mouth.

IR1, infrared thermography, KOI, region or interest, 11, unrular image, 1, ractar, in, involta,  $t_{meat}$ , and  $t_{meat}$ , is a dual to the ROIs;  $t_{max}$  and the ROIs; the computer generated information on the absence (0) or presence (1) of temperatures asymmetry the temperatures are the ROIs; the computer generated information of the absence (0) or presence (1) of temperatures asymmetry temperatures asymmetry to the temperatures asymmetry temperatures asymmetry temperatures are the temperatures asymmetry temperatures tempera detected by IRT; CT (view) : the CT-generated diagnosis on the absence/presence of lesion and of its location; Detected values presented as mean +SD

case thermal asymmetry was visible without additional image segmentation. Nevertheless, after segmentation the pathological zone became even more segregated and visible (Figure 3d).

Figure 4 shows another case of tumour, where the patient, after clinical examination, was directed for a CT procedure, because of a painful buccal mucosa on the right side. In this case facial deformity was negligible but in an axial CT image, as presented in Figure 4a, a wide bone destruction zone on the right side of the mandible was seen. The patient had histologically proven malignant soft tissue tumour, namely squamous cell carcinoma (SCC). Despite the huge bone lesion in the mandible, in the corresponding TI of the same patient only slight  $\Delta t_{mean}$  and  $\Delta t_{max}$  between left/right sides of the mouth cavity were detected (Figure 4c): 0.06 and 0.42 °C, respectively (see Case 3 in Table 2). However, after application of image segmentation ( $\Delta t = 0.5$  °C) for the ROI, a higher temperature zone became visible in the affected side. Figure 4d shows highlighting of the pathological area with more intensive colouring. The highest temperature spot reached 39.0 °C.

In some pathological cases, deformity due to maxillofacial pathology can be negligible or even not visible. Figure 5 shows a case in which the patient complained of a weak pain deep in the mouth cavity during clinical examination and, therefore, was directed for a CT procedure. There was just very slight deformity of the right oropharyngeal wall. The CT image of the patient, presented in Figure 5a, displayed soft tissue infiltration of the velum and the right parapharyngeal region, with spread and local destruction of hard palate. Histopathological diagnosis was SCC. In this case, there was no visible thermal asymmetry in the TI of closed-mouth (Figure 5b). The average temperature difference between both sides of the face was just 0.1 °C (see Case 4 in Table 2). Even in the open-mouth position there was no clear temperature difference between right and left sides.



Figure 3 CT vs IRT images obtained in a 15-year-old male patient with fibrous dysplasia on the left side and with visible deformity of the mandible in axial CT image of affected jaw (a) vs TIs in frontal closed-mouth (b) and in open-mouth projections (c). Note: in CT image (a) expansion on the left side of the mandible with ground-glass opacities (marked by arrows) is evident. Accordingly, in the TIs there are evident asymmetrical temperature changes on the left side of the face (b) and of the mouth cavity before and after segmentation (c, d, respectively). Segmentation highlighted the lesion in dark (marked by arrow). Other notations are the same as in Figure 2. IRT, infrared thermography.

birpublications.org/dmfr

Dentomaxillofac Radiol. 48, 20180075



Figure 4 CT vs IRT images obtained in a 64-year-old male patient with obvious pathological changes of malignant soft tissue tumour (SCC) on the right side: in axial CT image of affected jaw (a) vs TIs in frontal closed-mouth (b) and in open-mouth projections (c). Note: in the CT image (a) of affected jaw there is a wide bone destruction zone of the body of the mandible on the right (marked by oval). In the TI of the mouth cavity, before and after segmentation (c, d, respectively), there is asymmetrical temperature on the right side, which the lesion region highlighted in dark (marked by arrow). Other notations are same as in Figure 2. IRT, infrared thermography; TI, thermal image; SCC, squamous cell carcinoma.

However, after application of the image segmentation algorithm ( $\Delta t = 1$  °C) for the selected ROI, a local high temperature zone, positioned deeply in mouth cavity, appeared (Figure 5c).

A quantitative evaluation of all thermal images collected from patients with tumours (n = 19) showed higher temperature profiles in the affected region with respect to the surrounding normal tissues. Figure 6 illustrates histograms representing the distribution of the results of  $\Delta t_{max}$  and  $\Delta t_{mean}$ , calculated between left and right sides of the ROIs of human face and mouth, for both groups of all subjects of the current study. Of note, there was much wider distribution of temperature differences between left/right side of the selected ROIs in patients with maxillofacial tumours, when compared with the healthy subjects (Figure 6, e-h vs Figure 6 a-d) (see Discussion for possible reasons). In patients with tumour, the mean values obtained for the facial and mouth cavity ROIs were 0.47  $\pm$  0.1 °C and 0.66  $\pm$  0.1 °C, respectively, for the  $\Delta t_{\text{mean}}$  between left/right sides, and  $0.33 \pm 0.14$  °C and  $0.74 \pm 0.18$  °C, respectively, for the  $\Delta t_{max}$  between both sides. The differences between parameters for mouth cavity ROI obtained in patients with tumours were statistically significant in comparison with those obtained on healthy volunteers (p < 0.05).

#### Discussions

The overall aim of this study was to evaluate the use of improved TIs of the maxillofacial area in the diagnosis of tumours. Improved TIs were obtained using an image processing algorithm based on the optimized ROI and image segmentation, when searching of zones with asymmetrical temperature. We wanted to look for possible correspondence between IRT and CT results. The comparison revealed that the new algorithm, which automatically processes analysis of the thermal images, allows to detect lesions in the maxillofacial area and to clearly display its location in the left or right facial/ mouth side, in consistence with CT evaluation for the same patient. However, in some cases, segmentation of the selected ROI was necessary for IRT for accurate detection of asymmetrical temperature.

Since diagnosis accuracy depends on how well the segmentation of the ROI was performed, we used an algorithm allowing to obtain optimized selected ROI. In our study, was calculated human facial/mouth external contour as smallest convex polygon that contains all points of the edge for both facial/mouth ROIs (see Methods and materials). This allowed to get very precise contouring of the selected ROI and overcome



Figure 5 CT vs IRT images obtained in a 65-year-old male patient without visible facial deformity due to malignant tumour (SCC): on the axial CT image (a) vs frontal face TI (b) and open-mouth TIs before (c), and after segmentation (d), with the lesion region highlighted in dark colour (marked by arrow). Note: on the CT image (a) there is a hard palate bone destruction zone (marked by an ellipse). In the thermal image there is poor mouth's temperature asymmetry (c), but after segmentation (d) a clear zone with higher temperature is seen on the right side, with the lesion region highlighted in dark (marked by arrow). Other notations are same as in Figure 2. IRT, infrared thermography; TI, thermal image; SCC, squamous cell carcinoma.

Dentomaxillofac Radiol, 48, 20180075

birpublications.org/dmfr



Use of IRT vs CT for maxillofacial pathology detection

Figure 6 The distribution of temperature difference values for healthy subjects (a-d) vs patients with clinically confirmed maxillofacial tumours (e-h).  $f\Delta t_{max}$  and  $f\Delta t_{max}$ : differences in mean temperatures ( $f\Delta t_{max}$ ) and in peak temperatures ( $f\Delta t_{max}$ ) between left and right sides of the face.  $m\Delta t_{max}$  and  $m\Delta t_{max}$ : differences in mean temperature ( $m\Delta t_{max}$ ) and in peak temperature ( $m\Delta t_{max}$ ) between left and right side-of the mouth.

the inclusion of irrelevant data in evaluating of the TI, in contrast to previous studies,<sup>12-14</sup> in which geometric shapes were used to define the ROIs. In most applications, IRT images obtained using non-optimized software for the ROI detection contain information not only within the area to be characterized, but also from the surroundings. Consequently, this might not allow to detect modest asymmetry in TIs of small or deeply located lesion, especially when the lesion is close to the mandibular joint that only emits limited heat. Furthermore, small and/or modest asymmetry of the  $\Delta t$  may not be revealed due to eventual fat tissue, which is an effective insulator. Therefore, limited heat could be difficult to detect without algorithmic calculations. The algorithm used in the present study allows to overcome this limitation.

Besides, we tried to detect symmetrical/asymmetrical temperature distribution not in separate anatomical regions as was done in previous studies,3,11 but between both (left/right) sides of the frontal face and mouth TIs. A critical step was the determination of a symmetry axis (see Methods and materials), which allowed to compare the  $\Delta t_{mean}$  and  $\Delta t_{max}$  values calculated from left versus the right sides of facial and mouth cavity images. When pathology was not detected upon CT evaluation, as in the case of the healthy subjects, then there was no temperature asymmetry between the sides of the selected ROI. In contrast, when CT delineated a tumour structure, later confirmed with histopathology (in most cases SCC), then the left-vs-right asymmetry in temperature was also obtainable in the TI. The  $\Delta t$  location corresponded to the location of tumour detected on maxillofacial CT. The temperature difference between lesion and normal zones was of 0.4 °C or higher. Of note, when the tumour was large, then thermal asymmetry in the corresponding TI was easily detected, and image segmentation was not necessary but optional for

finding the lesion zone. However, if the tumour was small in size and/or deeply located, then a segmentation of the selected ROI was required for accurate detection of asymmetrical temperature distribution.

As in the case presented in Figure 4, despite CT images showing obvious bone destruction zone, the IRT image can show only slight  $\Delta t_{mean}$  and no clear asymmetry in the TI. Without additional segmentation such small temperature distribution would be undetectable. Image segmentation was helpful or required when the tumour was deeply localized in the oropharyngeal region (Figure 5). In this case, without image segmentation the  $\Delta t_{mean}$  was only of ~0.1 °C and hardly visible, possibly, because of marginal changes of distance from the IRT camera to the patient face. However, after the segmentation of the mouth ROI, the TI appeared asymmetrical the location coincided with the zone revealed during CT evaluation. Quantitative evaluation of segmented mouth ROIs revealed significantly higher values of the  $\Delta t_{\text{mean}}$  (0.66 ± 0.1 °C vs 0.05 ± 0.19 °C) and  $\Delta t_{\text{max}}$  (0.74 ± 0.1 °C vs 0.03 ± 0.25 °C) for patients with maxillofacial tumour vs the healthy subjects, respectively. This possibly suggests that image segmentation of the ROI of mouth is of particular importance in searching for thermal asymmetry in tumour affected zones, which might be overlooked without such procedures.

In our study, as presented in Figure 6, the  $\Delta t$  values of facial/mouth temperature detected in the healthy volunteers were much smaller in comparison with those of the patients with tumours. Nevertheless, they were variable as well. It is important to note that there was no thermal asymmetry in the TIs of the healthy volunteers even after segmentation of the selected ROI. In a study by others, where young males (age range 18–30 years) without any health problems were investigated, it has been documented that facial  $\Delta t$  values might be variable even in quite homogeneous group.<sup>15</sup>

birpublications.org/dmfr

Dentomaxillofac Radiol, 48, 20180075

Use of IRT vs CT for maxillofacial pathology detection Macianskyte *et al* 

Variable  $\Delta t$  values could be explained the fact that each group in our study were mixed and included subjects with a different gender, age, ethnicity, and socioeconomic status. In the current study the impact of these factors was not evaluated, but it is known that they have marked impact on the TI data. It is documented that orofacial cancer most often arise in older subjects and in users of tobacco and alcohol, with poor diet and lower socioeconomic status,<sup>16</sup> who usually are irregular dental patients. However, in this study we do not provide a comparison of such data.

On the other hand, physiological factors such as local blood flow, sweating etc. are almost uncontrolled factors that might change the  $\Delta t$  values. Besides, a 15 min equilibration time at the room temperature might be not sufficient after exposure to severe cold, we cannot exclude that  $\Delta t$  values calculated for some patients were influenced of the environmental temperature, since part of IRT data were collected in cold season.

Undoubtedly, many factors could influence the distribution of data obtained from the thermal images of both groups (healthy volunteers or patients with tumours) but this does not change the essence of the IRT diagnostic efficiency, *i.e.* capability to detect  $\Delta t$  asymmetry in the zone of lesion. Maxillofacial cancerous lesions generate more heat, possibly because of an increased blood supply, compared to the surrounding healthy tissue. These differences, as shown in the current study, can be detected by IRT, when using an image processing algorithm with optimized ROI and image segmentation. In addition, our data indicate that in patients with tumours, thermal information obtained after image segmentation of the ROI of mouth cavity is more informative, when compared with the corresponding  $\Delta t$ calculated from the facial skin (Figure 6, g-h vs Figure 6 e-f). These data possibly indicate that tumour in facial area should provide heat for larger volume of tissues in order to be visible in the TI, in contrast to the mouth, formed mostly of the mucous membrane.

In the IRT literature,<sup>17,18</sup> it has been proposed that in malignant conditions there were no temperature changes seen until the tumours were large enough to cause necrosis, and this resulted in associated cold spots. However, at present, no detailed analysis has been presented about the rise of temperature depending on tumour stage and/or size. Note that in cases presented here no necrosis zones were obtained in CT images, but we managed to detect clearly the zones of asymmetrical temperature in the TI, when segmentation for the selected ROI was applied. This is in accordance with the opinion that infrared imaging gives a reflection on metabolic activity that allows for detection of tumour induced angiogenesis leading to the development of vascularization much before any other changes appeared.

Summarizing, the detailed comparison of TIs and CT images obtained from the same patient, IRT revealed the presence of temperature asymmetry as well as its

birpublications.org/dmfr

location side (*i.e.* coincide with CT results) in all cases. However, image segmentation should be used for accurate unravelling of the affected zones, especially when the tumour is small or deeply located. Importantly, previous studies stated that the average temperature difference between separate anatomical regions should be about 0.4 °C,<sup>3,11</sup> in order to confirm the presence of pathology. The results of the current study suggest that such criterion may not always be valid. We showed that even very small the temperature asymmetry (~0.1 °C) in the TI could be detected with IRT, but image segmentation was needed for this.

#### Limitations

The segmentation of TIs enables us to highlight a local higher temperature zone from the rest of the face/ mouth. Despite our algorithm for automatic processing of thermal images the investigator should check the computer-generated diagnosis, which is based on the detection of zones with asymmetrical temperature. To be able visualizing tumours at their early growth stages, accurate calculations must be done. For this, application of artificial intelligence algorithm should be applied, and this will be explored in our future work.

#### Conclusions

The results of this study show that the presence of asymmetrical temperature zones and their location, as detected from thermal images, coincide well with the presence and localization of maxillofacial pathologies established by CT. However, accurate information could be obtained only after application of image segmentation algorithm to the selected ROI. Our study demonstrates that image segmentation could help in identifying affected zones when pathology is small or deeply located, and not seen from the TI.

#### Clinical relevance:

Contemporary gold-standard methods for maxillofacial cancer detection and confirmation are CT scanning and biopsy report. Unfortunately, both of them are not safe. More importantly, they are most efficient for the diagnosis of late stages of the maxillofacial lesions, *i.e.* when the anatomical changes are present. Therefore, cancer detection, especially in its early stage, could benefit from the use of thermal images.

 In our study, the applicability of IRT (a physiological test) for the detection of maxillofacial lesion is based on the correlation with results obtained using CT evaluation (an anatomical test), and confirmation with a histologically proven diagnosis of tumour. Cancerous maxillofacial lesions generate more heat, possibly, because of an increased blood supply, compared to the surrounding healthy skin, and these Δt

8 of 9

differences can be measured by IRT.

- A new IRT algorithm, that optimizes the chosen region (ROI), allows detecting the exact place where the asymmetrical temperature in the maxillofacial region originates. TI data validation by CT and histopathology is an important step toward the clinical application of IRT for the evaluation of maxillofacial lesions.
- In the study, both techniques (CT and IRT) yielded

#### References

- Ring EF, Ammer K. Infrared thermal imaging in medicine. *Physiol Meas* 2012; 33: R33–R46. doi: https://doi.org/10.1088/ 0967-3334/33/3/R33
- Lahiri BB, Bagavathiappan S, Jayakumar T, Philip J. Medical applications of infrared thermography: a review. *Infrared Phys Technol* 2012; 55: 221–35. doi: https://doi.org/10.1016/j.infrared. 2012.03.007
- Gratt BM, Graff-Radford SB, Shetty V, Solberg WK, Sickles EA. A 6-year clinical assessment of electronic facial thermography. *Dentomaxillofac Radiol* 1996; 25: 247–55. doi: https://doi.org/10. 1259/dmfr.25.5.9161178
- Duarte A, Carrão L, Espanha M, Viana T, Freitas D, Bártolo P, et al. Segmentation algorithms for thermal images. *Procedia Technology* 2014; 16: 1560–9. doi: https://doi.org/10.1016/j.protcy. 2014.10.178
- Ring EFJ, Ammer K. The technique of infra red imaging in medicine. *Thermol Int* 2000; 10: 7–14.
- Acharya UR, Ng EYK, Sree SV, Chua CK, Chattopadhyay S, EYK N. Higher order spectra analysis of breast thermograms for the automated identification of breast cancer. *Expert Systems* 2014; **31**: 37-47. doi: https://doi.org/10.1111/j.1468-0394.2012. 00654.x
- Shrivakshan GT. A comparison of various edge detection techniques used in image processing. *IJCSI International Journal of Computer Science* 2012; 9(Iss5, No1): 272–6.
- Prewitt JMS. Object enhancement and extraction. In: Lipkin B, Rosenfeld A, eds. *Picture processing and Psychopictorics*. New York: Academic Press; 1970. pp. 75–149.
- 198 Barber CB, Dobkin DP, Huhdanpaa H. The quickhull algorithm for convex hulls. ACM Transactions on Mathematical Software 1996; 22: 469–83. doi: https://doi.org/10.1145/235815.235821
- Mostovoy A. Thermography and oral pathology. EAT2012 Book of Proceedings – Appendix 1 of Thermology international 2012; 22: 159–61.

the same results for revealing the presence (or not) of a tumour lesion and its anatomical localization. Nevertheless IRT is not a replacement for CT. IRT, due to its non-invasiveness, may be used during clinical evaluation of patient as an additional screening tool in searching the lesions and continuation of its progression in the maxillofacial region. For this, artificial intelligence algorithm with an automatic recognition of lesions must be used.

- Durnovo EA, Potekhina YUP, Marochkina MS, Khomutinnikova NE, Yanova NA. Features of infrared thermography in the diagnosis of complex diseases of maxillofacial region. *Modern Problems of Science and Education* 2012.
- Christensen J, Vaeth M, Wenzel A. Thermographic imaging of facial skin-gender differences and temperature changes over time in healthy subjects. *Dentomaxillofac Radiol* 2012; 41: 662–7. doi: https://doi.org/10.1259/dmfr/55922484
- Christensen J, Matzen LH, Vaeth M, Schou S, Wenzel A. Thermography as a quantitative imaging method for assessing postoperative inflammation. *Dentomaxillofac Radiol* 2012; **41**: 494–9. doi: https://doi.org/10.1259/dmf/r98447974
- Rodrigues-Bigaton D, Dibai-Filho AV, Packer AC, Costa AC, de Castro EM. Accuracy of two forms of infrared image analysis of the masticatory muscles in the diagnosis of myogenous temporomandibular disorder. J Bodyw Mov Ther 2014; 18: 49–55. doi: https://doi.org/10.1016/j.jbmt.2013.05.005
- 15. Zaproudina N, Varmavuo V, Airaksinen O, Närhi M. Reproducibility of infrared thermography measurements in healthy individuals. *Physiol Meas* 2008; 29: 515–24. doi: https://doi.org/10.1088/ 0967-3334/29/4/007
- Conway DI, Petticrew M, Marlborough H, Berthiller J, Hashibe M, Macpherson LM. Socioeconomic inequalities and oral cancer risk: a systematic review and meta-analysis of case-control studies. Int J Cancer 2008; 122: 2811–9. doi: https://doi.org/10. 1002/jjc.23430
- Hayase Y, Wakasa T, Uemura M, Adachi K, Ochi S, Kishi K. Clinical evaluation of thermography in the diagnosis of malignant tumors in the oral and maxillo-facial region. *Oral Radiol.* 1992; 8: 11–17. doi: https://doi.org/10.1007/BF02347273
   Pogrel MA, Yen C-K, Taylor RC. Infrared thermography in oral
- Pogrel MA, Yen C-K, Taylor RC. Infrared thermography in oral and maxillocatial surgery. Oral Surgery, Oral Medicine, Oral Pathology 1989; 67: 126–31. doi: https://doi.org/10.1016/0030-4220(89)90315-0

birpublications.org/dmfr

Dentomaxillofac Radiol, 48, 20180075

No special permission is required to reuse all or part of article published by MDPI, including table and figures. Furthermore, no special permission is required for authors to submit their work to external repositories (MDPI | Open Access Information)



Article



## Automatic Detection of Human Maxillofacial Tumors by Using Thermal Imaging: A Preliminary Study

Diana Mačianskytė<sup>1,\*</sup> and Rimas Adaškevičius<sup>2</sup>

- <sup>1</sup> The Clinic of Radiology, Lithuanian University of Health Sciences, LT-50009 Kaunas, Lithuania
- <sup>2</sup> Department of Electrical Power Systems, Kaunas University of Technology, LT-51368 Kaunas, Lithuania; rimas.adaskevicius@ktu.lt
- Correspondence: diana.macianskyte@lsmuni.lt

Abstract: Traditional computed tomography (CT) delivers a relatively high dose of radiation to the patient and cannot be used as a method for screening of pathologies. Instead, infrared thermography (IRT) might help in the detection of pathologies, but interpreting thermal imaging (TI) is difficult even for the expert. The main objective of this work is to present a new, automated IRT method capable to discern the absence or presence of tumor in the orofacial/maxillofacial region of patients. We evaluated the use of a special feature vector extracted from face and mouth cavity thermograms in classifying TIs against the absence/presence of tumor (n = 23 patients per group). Eight statistical features extracted from TI were used in a k-nearest neighbor (kNN) classifier. Classification accuracy of kNN was evaluated by CT, and by creating a vector with the true class labels for TIs. The presented algorithm, constructed from a training data set, gives good results of classification accuracy of kNN: sensitivity of 77.9%, specificity of 94.9%, and accuracy of 94.1%. The new algorithm exhibited almost the same accuracy in detecting the absence/presence of tumor as CT, and is a proof-of-principle that IRT could be useful as an additional reliable screening tool for detecting orofacial/maxillofacial tumors.



Citation: Mačianskytė, D.; Adaškevičius, R. Automatic Detection of Human Maxillofacial Tumors by Using Thermal Imaging: A Preliminary Study. *Sensors* 2022, 22, 1985. https://doi.org/10.3390/ s22051985

Academic Editors: Constantin Vertan and Valeriu Vrabie

Received: 28 December 2021 Accepted: 25 February 2022 Published: 3 March 2022

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2022 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (https:// creativecommons.org/licenses/by/ 4.0/). Keywords: infrared thermal image; CT; machine learning algorithm; kNN classifier; orofacial/maxillofacial tumor

## 1. Introduction

Infrared radiation from human skin can be described by an exponential function of the surface temperature, which is influenced by the level of blood perfusion in the skin [1]. Unlike images created by X-rays or proton activation through magnetic resonance, thermal imaging (TI) is not based on morphological analysis. The technique provides only a map of the distribution of temperatures on the surface of the object imaged.

Infrared thermography (IRT), due to its apparent simplicity, is a feasible diagnostic tool in medicine and has been used in various fields for analyzing physiological and/or pathophysiological functions causing skin temperature changes for over 30 years [2] (for review see [3–7]). It is a non-invasive, contactless, passive, and noxious radiation-free technique that does not cause patient discomfort. However, it is still not widely used in routine clinical diagnosis, largely because of the lack of clinically approved medical devices, standardized protocols for IRT in medicine and, importantly, because the desired information cannot be extracted easily.

Nowadays, the development of new generation IRT techniques using high-resolution cameras has allowed the wide use of TI for better diagnostic capabilities. TI obtained with modern technology may contain several thousands of temperature points and enables accurate thermal mapping of very subtle changes in skin surface temperature that are clinically significant.

Local skin temperature can be influenced by many diseases and/or pathologies (e.g., tumors, inflammation, infection, fever, chronic pain diseases, changes in nervous system

Sensors 2022, 22, 1985. https://doi.org/10.3390/s22051985

https://www.mdpi.com/journal/sensors

function, etc.) as well as by psychophysiological events (for review see [5–7]). The skin surface temperature is always the sum of all thermal processes taking place under the skin, and an awareness of the underlying physiology must be considered when making clinical decisions. So, the tissue temperature of the area surrounding a pathological zone can be different from that of normal tissue, but various conditions can have opposite effects on the temperature (e.g., low in necrosis or ischemia, high in inflammation). For a healthy person, the thermogram shows uniform and symmetric variations in skin temperature, and differences in selected areas from side to side are very small (~0.2 °C). In contrast, pathological regions show abrupt variations in temperature [8,9]. Thermal symmetry in the face is a normal finding in healthy subjects. Asymmetrical distributions of temperature as well as the presence of hot or cold spots are known to be strong indicators of an underlying dysfunction [9].

At present, IRT is most often used for the diagnosis and treatment monitoring of breast cancer, skin melanoma, and other pathologies [1,10,11]. However, it is also of potential importance for evaluating the development of pathologies in the early stages. Early detection can facilitate the subsequent clinical management of patients. In order to be practically relevant, systems of automated and computer-assisted IRT interpretation have to be developed and trained. Therefore, the application of machine learning (ML) tools to detect key features from complex datasets might be helpful [12] (for review see [13]).

The use of automated image analysis techniques is of particular importance in the orofacial and maxillofacial regions [2]; because their elaborate anatomical structure, it is very difficult to detect pathology (e.g., tumor) in the early stages. Usually, the patients are directed to other diagnostic methods, often in late stages, when the orofacial/maxillofacial tumor is already advanced in size and causes specific symptoms. To detect the tumor timely, potential patients should be examined before they have any complaints. This would imply that all healthy subjects undergoing preventive medical examination should be directed to CT. However, due to the high risk of radiation and its high costs, CT cannot be used as a screening method. Instead, ML IRT can be used as a non-invasive and radiation-free routine diagnostic method, which by detecting early temperature changes in the affected area, could enable to find the presence of possible tumors, and to timely direct the patient to further investigation. However, there are currently no screening ML IRT tools for automatic classification of human face and mouth cavity thermograms.

Considering the information presented above, the aim of this study was to develop a new automated ML TI method capable to discern the presence or absence of physiological abnormalities, due to tumors, by using skin surfaces temperature distribution in the orofacial/maxillofacial region. Our recent study showed that accurate detection of the facial TI, using an image processing algorithm based on the optimized region of interest (ROI) and image segmentation when searching for zones with asymmetrical temperature distribution, is a critical step for revealing maxillofacial tumors precisely [14]. In this paper, we present a new efficient algorithm, which is supplemented with the *k*NN classification scheme constructed from a training data set for TI features extraction and allows automatic recognition of tumors. The new algorithm exhibited almost the same accuracy in detecting tumor regions as CT and can be a fast method for efficiently classifying facial and mouth cavity TI of patients into non-tumor vs. tumor cases. Therefore, we provide proof of principle that IRT might be a complementary tool for doctors/radiologists to help in the screening of tumors, especially at the earlier stages.

#### 2. Materials and Methods

## 2.1. Patients

Forty-six patients, who underwent a CT procedure in the orofacial/maxillofacial region during the years 2014 to 2016 at the Clinic of Radiology of the Hospital of the Lithuanian University of Health Sciences (LUHS), were enrolled in this study. Written informed consent was obtained before procedures. The inclusion criteria were: patients who had no orofacial/maxillofacial history, but who after clinical evaluation by different

physicians (e.g., maxillofacial-oral surgery, otolaryngologists, etc.) were directed to a CT procedure for suspected pathology, and those who were evaluated before planning of tooth implantation. The overall characteristics of the patients are summarized in Table 1, which groups them depending on whether CT scan showed they had orofacial/maxillofacial tumor (T-group) or not (i.e., control patients, relative to the presence of tumor; NT-group).

Table 1. Clinical characteristics of the patients.

Patient Data	NT-Group	T-Group	
Age range (years)	18–78	18-86	
Mean age (years) $\pm$ SEM	$49.5 \pm 3.5$	$57.1 \pm 2.8$	
Female, $n$ (%)	17 (73.9)	8 (34.8)	
Male, n (%)	6 (26.1)	15 (65.2)	
Total, n (%)	23 (100)	23 (100)	
Anatomical regions			
Detected by CT			
Right-sided, $n$ (%)	0 (0)	10 (43.5)	
Left-sided, n (%)	0 (0)	12 (52.2)	
Both-sided, n (%)	0 (0)	1 (4.3)	

NT—non-tumor group, which includes patients with inflammatory diseases and with lymphatic nodes diseases of the maxillofacial area, and having no tumor lesions on CT evaluation; T—tumor group, which includes patients with different orofacial/maxillofacial tumors detected by CT and confirmed histopathologically.

The study was performed with the European Community guiding principles and with the approval of the Ethics Committee of Biomedical Research of Kaunas Region, Lithuania (no. BE-2-31, 3 June 2014).

### 2.2. Pre-Processing and Thermal Image Acquisition

The methods used for the TI data acquisition in patients have been described before [14]. In short, at the first step, a standardized TI was recorded for every patient prior to the CT scanning procedure, in order to avoid the subsequent influence of X-rays and/or contrast agents on the temperature profiles. All patients underwent the same thermographic protocol adjusted for clinical application, trying to minimize factors that might affect the TI data (medications, facial cosmetics, intake of tea/coffee, smoking, physical exercise, etc.). Before undertaking the measurements, all patients were thermo-equilibrated in the laboratory for 15 min [10,14]. During IRT measurements, all of them were instructed to sit as straight as possible. TI was taken from each patient's face and mouth cavity (in frontal closed and open mouth projections). Surface temperature profiles of each patient were recorded and later analyzed.

The TI was captured using a commercially available FLIR E8 infrared thermal camera (FLIR Systems, Inc., Wilsonville, OR, USA), which was positioned one meter away from the patient's face. TI was acquired using a resolution of 320 × 240 pixels, thermal sensitivity of  $\pm 0.06$  °C, and a temperature range from -20 °C to +250 °C. The thermography measurements were performed in controlled environments: relative humidity of  $60 \pm 5\%$ , and temperature of  $22 \pm 1$  °C. Emissivity was set for the skin thickness value of 0.98 [14].

The TI captured by the IRT camera was subsequently transferred to a computer and analyzed using image processing software in Matlab R2014b (The MathWorks, Inc., Natick, MA, USA). The images were transformed into Matlab readable data files by ThermaCam Researcher 2.1 (FLIR Systems, Inc., Wilsonville, OR, USA).

#### 2.3. CT Scanning Procedure

After TI acquisition, every patient was CT scanned (Toshiba Aquilion ONE, Canon Medical Systems, Otawara, Japan) using the same scanning parameters (thickness step of 1 mm), and CT-scan images were analyzed by a radiologist. CT was used as a gold standard exam with regard to identifying lesions, and according to CT-scan findings, the patients were divided into non-tumor (NT) and tumor (T) groups (Table 1).

## 2.4. Experimental Protocol for TI Exploration

The proposed method comprises several steps, as presented in Figure 1.



Figure 1. Flowchart showing the major steps of the study. Note: based on CT-scan findings, the TIs were classified as NT (0) and T (1) cases, i.e., the absence/presence of tumor lesions, respectively.

As we have documented before [14], the algorithm includes: finding of orientation and position of the symmetry axis of the human face or of the mouth cavity, which helped calculate thermal features (see Table 2).

Features	Definition
$\Delta T_f$ (°C)	The difference between mean temperatures of R vs. L sides of the face.
$\Delta T_m$ (°C)	The difference between mean temperatures of R vs. L sides of the mouth cavity.
$\Delta T_{fmax}$ (°C)	The difference between max temperatures of R vs. L sides of the face.
$\Delta T_{mmax}$ (°C)	The difference between max temperatures of R vs. L sides of the mouth cavity.
$n_f$	The number of pixels in TI of the R (L) side of the face having $\Delta T$ degree higher temperature than the max temperature of opposite face side.
n <sub>m</sub>	The number of pixels in TI of the R (L) side of the mouth cavity having $\Delta T$ degree higher temperature than the max temperature of opposite mouth cavity side.
$\Delta DEV_f$	The difference of the absolute deviations of the temperature values of all pixels belonging to the R and L face side, respectively.
$\Delta DEV_m$	The difference of the absolute deviations of the temperature values of all pixels belonging to the R and L mouth cavity side, respectively.

Table 2. Terminology of statistical features extracted from TI.

R and L denote right and left side, respectively.

## 2.5. Detection of Human Face Edges

After acquisition and pre-processing of TI, the next step was the identification of human face image boundaries. For edge detection, the gradient-based approach was used. This approach is based on searching image points with a high gradient which corresponds to the points where the gradient magnitude is maximal. The edge is detected by looking for the maximum in the first derivative of the image.

TI gradient components in any direction were calculated using a convolution mask and the equations given in Appendix A.1, and pixels with the large gradient magnitude values were considered as edge pixels. The Prewitt method [15] was selected for its simplicity and its low computational load. An original human face's TI and the detected edges are presented in Figure 2.



Figure 2. Original thermal image (a) and obtained human face edges (b).

2.6. Detection of Human Face or Mouth Cavity Symmetry Axis

In order to find the orientation and position of a human face's symmetry axis, only external face edge points are necessary. For the presentation of a human face's external contour, the smallest convex polygons that contain all the edge points were determined using the convex hull algorithm [16] (see Appendices A and A.2). The convex hull of the edge image is a set of pixels included in the smallest convex polygon that surrounds all edge pixels and was used to describe the external boundary of the field, where temperature changes were analyzed. The selected points formed the convex hull (Figure 3a).



**Figure 3.** Estimated convex hull contour points (**a**) and symmetry axis (**b**) of a human face. The symmetry axis (continuous black line) is the major axis of the ellipse (dot line). Note: Normal color and thermal properties without abnormalities are presented. The corresponding scale bar is given on the right side in °C.

The ellipse best fitting the set of convex hull vertices, using least-squares criterion, was used for the identification of axis symmetry of the face (Figure 3b).

In the same way, the edges of the mouth cavity were extracted from the calculated convex hull. This symmetry axis was used for splitting the field of analysis into two independent mouth cavity regions of the TI (Figure 4) (see Appendices A and A.3).



Figure 4. Estimated convex hull of mouth cavity contour points. Note: normal color and thermal properties without abnormalities are presented.

#### 2.7. Recognition of Tumor Region

For detecting tumors, using extracted areas of TI, the feature vector for each patient was created. The temperatures of individual pixels of four areas were used to calculate the features ( $\Delta T_f$ ,  $\Delta T_m$ ,  $\Delta T_{fmax}$ ,  $\Delta T_{mmax}$ ,  $n_f$ ,  $n_m$ ,  $\Delta DEV_f$ , and  $\Delta DEV_m$ ) (Table 2) for each patient (see Appendices A and A.4).

Of note: since in the study the majority of patients in the control group also had pathologies (e.g., inflammation) but no tumor; therefore, as was suggested before [9], the major inclusion criterion in the control group was to have thermal asymmetry ( $\Delta T$ ) between both facial/mouth cavity sides not higher than 0.4 °C. Accordingly, when comparing the difference between temperatures of the left and right side of the NT class versus the T class, a temperature asymmetry higher than 0.4 °C was taken as being associated with the presence of abnormality [9]. Therefore, such a temperature difference can be used as a basis to form feature vector for a single patient.

The number of TI pixels of one given side of the face or mouth cavity having  $\Delta T$  degree higher temperature than the maximal temperature of opposite side was calculated using histograms of both sides.

#### 2.8. Training Procedure and Automatic Classification

For training of the system, each feature value has been calculated as average from five estimates of the same TI. This is done because the calculation of feature vector values requires estimating the contour of the face or the mouth cavity, which sometimes involved changing the positions of a few points. Feature vectors of NT-group patients (i.e., with-out tumors) and of T-group patients (i.e., with different orofacial/maxillofacial tumors) were stored as feature matrices in computer memory for the classification into classes, i.e., absence (0) or presence (1) of tumor, respectively.

In this study, the *k*-nearest neighbor (kNN) classification scheme [17] was used for the TIs, because the kNN has a tendency to work best on smaller data sets that do not have many features. The model of the kNN classifier is based on feature vectors and class labels from the training data set.

The *k*NN classifier is commonly based on the Euclidean distance between a test sample and the specified training samples:

$$d = \sum_{n=1}^{p} \left( x_n^{test} - x_n^{train} \right) , \qquad (1)$$

where *p* is the size of the feature vector,  $x_n^{lest}$  is the value of the sample vector representing features of test TI,  $x_n^{lrain}$  is the values of the vector representing features extracted from TI, used for training.

During the classification stage, the vector values representing features extracted from TI of one patient are compared with the values in the feature matrix created during the training. Because the number of nearest neighbors has been selected as k = 1, then the patient data are simply assigned to the class of single nearest neighbor, representing the corresponding group of patients (NT or T).

In the study, such feature vectors were calculated for all patients. Thereafter, the dataset were randomly divided into two subsets for training and testing. The training subset involves only half of the data: 12 NT-images of patients without tumor lesions and 12 T-images of patients with tumor changes. The trained-test split procedure was repeated 12 times and different datasets were used for training and testing of the presented method.

The *k*NN algorithm assigns a category to observations in the test dataset by comparing them with the observations in the training dataset. Because we know the actual category of observations in the test dataset, the performance of the *k*NN model can be evaluated.

For estimating the correctness of classification/misclassification of the method presented here a confusion matrix was formed and the accuracy, sensitivity, and specificity values were calculated. Classification accuracy was evaluated by CT, and by creating a vector with the true class labels for obtained TI. Furthermore, the comparison of this vector with the results of classification obtained using was performed. The rate of correct solutions was selected as recognition accuracy parameter. It can be calculated as a ratio between the correctly classified TI to all the obtained data. The sensitivity of kNN classifier was calculated as the ratio between the number of correctly classified T-cases and the number of true T-cases. The specificity of the classifier was calculated as the ratio between the number of correctly classified NT-cases and the number of true NT-cases.

## 2.9. Statistical Analysis

All diagnostic data of the patients obtained by CT were classified either into NT-group (without tumors) or T-group (with tumors). The *t*-test was used to evaluate whether the values of a particular feature for NT-group are significantly different from values of the same feature for the T-group. If this holds, then the feature can be used to differentiate all data. This analysis is used for the analysis of a two-group experimental design. We used a significance level of p < 0.05 for statistical tests. The average temperatures of individual pixels of four human face areas and the independent samples *t*-tests of features were computed for each study group. All features were expressed as mean  $\pm$  standard deviation (SD). The two-sample *t*-test analysis (ROC) was used for the comparison of diagnostic efficiency.

#### 3. Results

#### 3.1. Experimental Verification of the Method

For each of the 46 patients, two frontal images of the face and of the mouth cavity were investigated. The mean temperature within each ROI was calculated and the difference between the affected region vs. the unaffected region in the opposite facial/mouth side was evaluated. As expected, temperature distribution between left and right parts of the human face as well as of the mouth cavity was symmetrical for TI of the NT-group ( $\Delta T \leq 0.4$  °C) (see Figures 3b and 4, respectively) and matched well with the CT-scan findings (not illustrated), where no visible tumors in the orofacial/maxillofacial region were obtained. In contrast, in the T-group the size and location of tumor as revealed by CT coincided well with the higher temperature zones ( $\Delta T > 0.4$  °C) obtained in the corresponding TI. Figure 5 shows a comparison of the images between the tumor area, detected with a CT (Figure 5a), and the presence of a changed thermal area, obtained with IRT (Figure 5b,c), for the same patient. Note that when the tumor is large in size, the affected zone could be identified easily from the TI without any additional processing [14].



Figure 5. Mapping of a CT-scan image with TI without preprocessing and after segmentation. A CT-scan image (a) is presented in the axial plane and shows large infiltrative pathologic masses on the left side (marked by an oval ellipse). The TI of the same patient is presented in an open mouth position, and the area with higher temperature could be seen on the left side of the mouth cavity before (b) and after the segmentation (c) of images. The corresponding temperature scale bar is given on the right side in °C.

Segmentation, as presented in Figure 5c, is used to represent the area of the tumor in a more meaningful and easy-to-analyze way. The filled contours are used to assign a color to each pixel in the image so that pixels of the same color have a temperature within a specified narrow range.

#### 3.2. Evaluation of Diagnostic Accuracy

Table 3 provides the mean values of these features for the two classification classes, NT and T, representing data in the absence/presence of tumors.

Table 3. Feature vectors formed for the TI of both NT (n = 23) and T (n = 23) groups.

Group	$\Delta t_{f}$ , °C	$\Delta t_{fmax}$ , °C	n <sub>f</sub>	$\Delta DEV_f$	$\Delta t_m$ , °C	$\Delta t_{mmax}$ , °C	n <sub>m</sub>	$\Delta DEV_m$
NT	$0.14\pm0.037$	$0.15\pm0.038$	$0.086\pm0.07$	$0.117\pm0.128$	$0.16\pm0.032$	$0.22\pm0.036$	$0.304\pm0.19$	$0.063\pm0.015$
Т	$0.23\pm0.087$	$0.22\pm0.062$	$2.48 \pm 1.85$	$0.041\pm0.012$	$0.46\pm0.143$	$0.56\pm0.169$	$48.57\pm22.6$	$0.139\pm0.043$
		NT- and T-	natients withou	it orofacial tum	ors and natient	s with obvious	orofacial tumo	ors respectively

N1- and 1-patients without orotacial tumors and patients with obvious orotacial tumors, respectively; for definition of features ( $\Delta T_f$ ,  $\Delta T_m$ ,  $\Delta T_{max}$ ,  $n_f$ ,  $m_a$ ,  $\Delta DEV_f$ , and  $\Delta DEV_m$ ) see Table 2. The significance of the difference between NT vs. T data was evaluated using confidence intervals. Note: only the mouth cavity data have statistical significance (not illustrated).

After classification of all TI into two classes, the following performance values with the presented method were obtained using equations described previously [18]: sensitivity of 77.9%, specificity of 94.9%, and accuracy of 94.1%.

In addition, for the verification of the formed confusion matrix, the associated receiver operating characteristic curve (ROC), as presented in Figure 6, was built. The area under the ROC curve indicates the overall performance of a diagnostic test in terms of its accuracy at various diagnostic thresholds used to discriminate cases and non-cases of a disease [19].



**Figure 6.** The ROC curve of the statistical test built. The true positive rate is plotted as a function of the false-positive rate. The area under the ROC curve (AUC) combines measures of sensitivity and specificity. The larger the AUC, the better the performance of the diagnostic test to correctly pick up cases with and without pathologies. AUC is 0.8769.

## 4. Discussion

This paper aimed to provide a proof-of-principle that a new automated ML TI algorithm is capable to help discern the presence and absence of tumors using skin surfaces temperature distribution in the human face. Since in medicine, careful interpretation of results is essential, we performed the comparison between CT findings and TI obtained with IRT, to identify tumors in the selected orofacial/maxillofacial region. Our study rests on the selected threshold for  $\Delta T$  values when describing the level of pathology, i.e., lower or

higher than 0.4 °C, corresponding to the absence or presence of the pathology, respectively. Calculations performed in our study confirmed such threshold conditions as was suggested before [9]. In our study, if we used a threshold lower than 0.4 °C (e.g., 0.35 °C), some of the "control" patients were ascribed to pathology (more false-positive cases). In contrast, when the threshold was higher than 0.4 °C, then some of tumor patients were ascribed to "control" patients (more false-positive cases). Accordingly, this confirmed that the optimal threshold under our experimental conditions is similar to the one used previously by others [9].

The proposed algorithm revealed that the presence of tumors defined by CT perfectly corresponded with the higher temperature zones defined by the IRT. Here, the employed automated image analysis technique provided highly reproducible findings, and no patients with orofacial/maxillofacial tumors were misdiagnosed. This suggests that ML IRT imaging examination is efficacious and, possibly, could be used as a non-invasive routine diagnostic method to detect early temperature changes in the affected region of the human face.

IRT as well as the asymmetry technique, by measuring regional temperature, which is a natural index of physiological function, can provide crucial information on the presence, location, and severity of alterations due to tumor. Therefore, on the one hand, due to its safety and exact recognition of tumor zones, the IRT method could be a useful supplement to the conventional method and may help in the medical as well as in the healthcare fields for the initial examination of patients. On the other hand, IRT still is not applied in the routine diagnosis of patients in the clinic, due to lack of certified thermal tools available to physicians, absence of standards for setting an appropriate ROI, of unified protocols, and overall requirements for the qualification of medical thermologists for clear interpretation of obtained TI. In addition, there are a lot of other reasons why thermal imaging is not applied in clinical routines, especially due to artefacts caused by facial hair, skin conditions, scars, "blushing" effect, asymmetrical distribution of adipose tissues, facial paralysis, veins near the superficial layer of the skin, etc. To date, IRT has been adopted extensively in the early detection of breast cancer [20-23], but for orofacial tumor detection, the available evidence is limited and weak [24,25]. It should also be underlined that according to the newest healthcare guidelines [26,27], current evidence does not support the routine use of thermography as a screening procedure in either field of clinical diagnosis. This is because there is insufficient evidence to conclude that IRT (including magnetic resonance thermography and temperature gradient studies) benefits tumor evaluation and because all technical findings require to complete the final interpretation, which would prevent overdiagnosis and misinterpretation of the TI findings.

In this respect, ML IRT can serve as a versatile screening method for giving the correct answers in the diagnosis of absence or presence of tumors, avoiding very subjective interpretation of the images. Major ML technical advances have been accomplished in recent years with the development of appropriate algorithms for the automatic detection of abnormalities [28–30] (for review see [12]), which help in interpreting imaging findings as well as minimizing errors or misinterpretation of images. Nevertheless, to our knowledge, nowadays there are no appropriate ML IRT algorithms for the screening of tumors in the facial region, especially for the detection of tumors in early stages. Our automated analysis algorithm could possibly be used for this early detection of both orofacial and maxillofacial tumors, but more extensive studies will be needed to test this. The algorithm has been successfully designed to recognize both trained and untrained data. The presented algorithm for extracting features of TI gives good results of the *k*-nearest neighbor classification scheme. The classification accuracy is 94.1%. The presented method is simple, exhibits quite good performance, and does not require significant computational resources, allowing data collection for long time periods using a small battery as a power source.

In summary, the predictive power of ML IRT has not been fully exploited. Beyond obtaining a good classification accuracy, for more accurate recognition the artificial neural network or support vector machine (SVM) classification algorithms can be used. A primary limitation of the study might be related to the small input data amount. The larger the training complex, the more accurate the existence of the tumor can be predicted. Another

limitation can be linked with the absence of a real control group, including human subjects without inflammation, infection or immune reactions, as would be expected for healthy volunteers. One more limitation can be linked to a late stage of the pathology because in most of the patients the abnormal structures were already advanced in size and caused specific symptoms. To detect the pathology in the early stages, patients should be examined before they accomplaints. Unfortunately, at the moment only a form they are patients to be a structure to the pathology in the early stages.

specific symptoms. To detect the pathology in the early stages, patients should be examined before they have any complaints. Unfortunately, at the moment only a few patients passed this criterion. Therefore, data from larger groups of patients are needed before the algorithm could be used as a non-invasive routine diagnostic method, especially for the early detection of tumors. As future work, more cases will be added to the classification states, and more experimental tests with more persons, including healthy volunteers, will be carried out.

#### 5. Conclusions

We present a novel approach to the problem of recognition of orofacial/maxillofacial tumors using TI. The approach reveals that the new algorithm exhibited nearly the same accuracy in detecting tumor-affected regions as CT. Therefore, this is a proof-of-principle that the presented algorithm could be a fast method for efficiently classifying facial and mouth cavity images into non-tumor and/or tumor cases. The proposed algorithm is promising as a useful and reliable screening tool and, possibly, for the early detection of tumors in the orofacial/maxillofacial region. In addition, it may assist in providing a clearer interpretation of TI, avoiding reliance on subjective criteria.

Author Contributions: Conceptualization, D.M. and R.A.; methodology, D.M. and R.A.; software, R.A.; validation, D.M. and R.A.; formal analysis, D.M. and R.A.; investigation, D.M. and R.A.; writing—review and editing, D.M. and R.A. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: The study was conducted in accordance with the Declaration of Helsinki, and approved by the Ethics Committee of Biomedical Research of Kaunas Region, Lithuania (No. BE-2-31, 3 June 2014).

Informed Consent Statement: Informed consent was obtained from all subjects involved in the study.

Data Availability Statement: Not applicable.

Conflicts of Interest: The authors declare no conflict of interest.

#### Appendix A

Appendix A.1. Calculation of TI Gradient Components

Each gradient component of the TI can be calculated using a convolution, and gives the value of the gradient in any direction as shown in the following relationships (Equations (A1) and (A2)), respectively [15]:

$$\nabla_x = I(x, y) * G_x,\tag{A1}$$

$$\nabla_{y} = I(x, y) * G_{y},\tag{A2}$$

where I(x,y) is the temperature value of (x,y) pixel of the TI; \* denotes the two-dimensional convolution operation,  $G_x$  is the convolution mask along x axis; and  $G_y$  is the convolution mask along y-axis, which can be described using Equations (A3) and (A4), respectively:

$$G_{\rm x} = \begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix},\tag{A3}$$

$$G_y = \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix},$$
 (A4)

The kernels were applied separately to the input image. This allowed producing separate measurements of the gradient component in each orientation. In this case, the gradient magnitude of each orientation was calculated using the Equation (A5):

$$\nabla(x,y)| = \sqrt{\nabla_x^2 + \nabla_y^2},\tag{A5}$$

After the gradient magnitude image had been computed, pixels with the large gradient magnitude values were considered as edge pixels.

### Appendix A.2. Determining the Facial Symmetry Axis

The convex hull of the edge image is a set of pixels included in the smallest convex polygon that surround all edge pixels and was used to describe the external boundary of the field, where temperature changes were analyzed.

The convex hull of a finite set of points in a plane was computed using the Quick Hull method [16]. First, points with minimum and maximum x coordinates were found. These two points were used to form the line dividing the set into two subsets of points, to be processed recursively. In a next step, on one side of the line, the point with the maximum distance from the line was determined. The two points found in the first step along with this new one forms a triangle. Points lying inside of this triangle are not a part of the convex hull and were ignored. This recursive processing was repeated. All points right of the triangle were used as a new subset and everything to the left of it was used as another subset. If the subset only contains the start and end points of the dividing line, then this line must be a segment of the searched hull polygon and the recursion can come to an end. The same operation of forming lines and triangles was repeated until no more points were left: the recursion had come to the end, and the selected points formed the convex hull (see Figure 3).

In the case where the temperature of the chin region is close to the neck temperature, then the final contour of the lower part of the face cannot accurately represent the actual contour. In such a case, the interactive change of a few point coordinates is necessary.

Because the points of the contour do not lie exactly on the ellipse, then we would have m equations of the following general form [31]:

$$ax_{i}^{2} + bx_{i}y_{i} + cy_{i}^{2} + dx_{i} + ey_{i} + f = r_{i},$$
(A6)

where *a*, *b*, *c*, *d*, *e*, and *f* are constants of the ellipse polynomial equation,  $r_i$  is residual. The system of *m* equations can be written in matrix form as:

$$\begin{pmatrix} x_1^2 & x_1y_1 & y_1^2 & x_1 & y_1 & 1\\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots\\ x_i^2 & x_iy_i & y_i^2 & x_i & y_i & 1\\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots\\ x_m^2 & x_my_m & y_m^2 & x_m & y_m & 1 \end{pmatrix} \begin{pmatrix} a \\ b \\ c \\ d \\ e \\ f \end{pmatrix} = \begin{pmatrix} r_1 \\ \vdots \\ r_2 \\ \vdots \\ r_m \end{pmatrix},$$
(A7)

The problem then is to estimate the model parameters a, b, c, d, e, and f such that the least-squares criterion of residuals r is minimized. The criterion is the sum, S, of squared residuals, which was calculated as:

$$S = \sum_{i=1}^{m} r_i^2 \to min,\tag{A8}$$

The larger diameter or major axis matches with the symmetry axis of the human face and divides the face TI into left and right sides, as is shown in Figure 3. The center

coordinates ( $x_c,y_c$ ) and clockwise angle  $\Theta$  between the *x*-axis, and the major-axis of an ellipse was calculated [32]:

$$x_c = \frac{cd - bf}{b^2 - ac},\tag{A9}$$

$$y_c = \frac{af - bd}{b^2 - ac},\tag{A10}$$

$$\theta = \begin{cases} 0 & \text{for } b = 0, a < c \\ \frac{1}{2}\pi & \text{for } b = 0, a > c \\ \frac{1}{2}c \tan^{-1}(\frac{a-c}{2b}) & \text{for } b \neq 0, a < c \\ \frac{\pi}{2} + \frac{1}{2}c \tan^{-1}(\frac{a-c}{2b}) & \text{for } b \neq 0, a > c \end{cases}$$
(A11)

### Appendix A.3. Detection of Orientation and Position of Mouth Cavity's Symmetry Axis

The edges of the mouth cavity were also extracted using the convex hull method. It is difficult to fit an ellipse to the mouth cavity contour. So, the *x* position of the symmetry axis was estimated as the centroid of a finite set of contour points using the following equation:

$$x_c = \frac{x_1 + x_2 + \dots + x_k}{k},\tag{A12}$$

where  $x_1$ ,  $x_2$ , ...,  $x_k$  are x coordinates of contour points; k—number of contour points. The axis of symmetry is the line that is perpendicular to the x-axis that passes through the point  $x_c$ , and was used for splitting the mouth cavity into two independent TI regions (see Figure 4).

#### Appendix A.4. Calculation of Temperature Differences and of Number of Pixels

The difference between average temperatures of right and left sides of the face or mouth cavity can be expressed as:

$$\Delta t = \left| \frac{1}{N_L} \sum_{i=1}^{N_L} t_{Li} - \frac{1}{N_R} \sum_{i=1}^{N_R} t_{Ri} \right|,$$
(A13)

where  $t_{Li}$  and  $t_{Ri}$  is the temperature of *i* pixel in left and right side area, respectively;  $N_L$  and  $N_R$ —the number of pixels in left and right side area, respectively.

The number of pixels in the TI of the right (left) side of the face or mouth cavity having  $\Delta T$  degree higher temperature than the maximal temperature of opposite side was calculated using histograms of both sides:

$$n = \begin{cases} \sum_{i=i_{T_{kmax}}}^{N_{HL}} n_{Li}, \text{ for } T_{Lmax} > T_{Rmax} + \Delta T \\ \sum_{i=i_{T_{Rmax}}}^{N_{HR}} n_{Ri}, \text{ for } T_{Rmax} > T_{Lmax} + \Delta T \\ 0, \text{ for } |T_{Rmax} - T_{Lmax}| < \Delta T \end{cases}$$
(A14)

where  $T_{Rmax}$ ,  $T_{Lmax}$ —maximal temperature of right and left side, respectively,  $i_{T_{Lmax}}$ —index of bin having  $T_{Lmax}$  temperature,  $N_H$ —number of bins in histogram, and  $n_i$ —number of pixels in *i* bin. The number of bins  $N_H$  can be calculated from a suggested bin width  $\partial T$  as :

$$N_H = \frac{T_{max} - T_{min}}{\partial T},\tag{A15}$$

The brackets indicate the ceiling function. In this way, a feature vector has been constructed for each patient.

#### References

- Schaefer, G.; Nakashima, T.; Zavisek, M.; Yokota, Y.; Drastich, A.; Ishibuchi, H. Breast cancer classification using statistical features and fuzzy classification of thermograms. In Proceedings of the IEEE International Fuzzy Systems Conference, London, UK, 23–26 July 2007. [CrossRef]
- Singh, J.; Arora, A.S. An automated approach to enhance the thermographic evaluation on orofacial regions in lateral facial thermograms. J. Therm. Biol. 2018, 71, 91–98. [CrossRef] [PubMed]
- Thevenot, J.; López, M.B.; Hadid, A. A survey on computer vision for assistive medical diagnosis from faces. *IEEE J. Biomed. Health Inform.* 2018, 22, 1497–1511. [CrossRef] [PubMed]
- De Melo, D.P.; Bento, P.M.; Peixoto, L.R.; Martins, S.K.L.D.; Martins, C.C. Is infrared thermography effective in the diagnosis of temporomandibular disorders? A systematic review. Oral Surg. Oral Med. Oral Pathol. Oral Radiol. 2019, 127, 185–192. [CrossRef]
- 5. Ring, E.F.J.; Ammer, K. Infrared thermal imaging in medicine. Physiol. Meas. 2012, 33, R33–R46. [CrossRef]
- Lahiri, B.B.; Bagavathiappan, S.; Yayakumar, T.; Philip, J. Medical applications of infrared thermography: A review. Infrared Phys. Technol. 2012, 55, 221–235. [CrossRef]
- Ioannou, S.; Gallese, V.; Merla, A. Thermal infrared imaging in psychophysiology: Potentialities and limits. *Psychophysiology* 2014, 51, 951–963. [CrossRef] [PubMed]
- Mostovoy, A. Thermography and oral pathology. In EAT2012 Book of Proceedings—Appendix 1 of Thermology International; Thermography Clinic Inc.: Toronto, Canada, 2012; Volume 22, pp. 159–161. Available online: http://www.uhlen.at/thermologyinternational/data/pdf/22A159.pdf (accessed on 24 February 2022).
- Durnovo, E.A.; Potekhina, Y.U.P.; Marochkina, M.S.; Khomutinnikova, N.E.; Yanova, N.A. Features of infrared thermography in the diagnosis of complex diseases of maxillofacial region. *Mod. Probl. Sci. Educ.* 2012, 30. Available online: https://www.scienceeducation.ru/en/article/view?id=6657 (accessed on 24 February 2022).
- Ng, E.Y. A Review of thermography as promising non-invasive detection modality for breast tumor. Int. J. Therm. Sci. 2009, 48, 840–859. [CrossRef]
- Shada, A.L.; Dengel, L.T.; Petroni, G.R.; Smolkin, M.E.; Acton, S.; Slingluff, C.L. Infrared thermography of cutaneous melanoma metastases. J. Surg. Res. 2013, 182, e9–e14. [CrossRef]
- Zanoni, M.; Fontana, F.A.; Stella, F. On applying machine learning techniques for design patern detection. J. Syst. Softw. 2015, 103, 102–117. [CrossRef]
- Kourou, K.; Exarchos, T.P.; Exarchos, K.P.; Karamouzis, M.V.; Fotiadis, D.I. Machine learning applications in cancer prognosis and prediction. *Comput. Struct. Biotechnol. J.* 2015, 13, 8–17. [CrossRef] [PubMed]
- Macianskyte, D.; Monastyreckiene, E.; Basevicius, A.; Adaskevicius, R. Comparison of segmented thermal images versus a CT scanning for detection of maxillofacial pathology. *Dentomaxillofac. Radiol.* 2019, 48, 20180075. [CrossRef] [PubMed]
- 15. Rosenfeld, A.; Thurston, M. Edge and curve detection for visual scene analysis. IEEE Trans. Comp. 1971, 20, 562–569. [CrossRef]
- Barber, B.C.; Dobkin, D.P.; Huhdanpaa, H. The quickhull algorithm for convex hulls. ACM Trans. Math. Softw. 1995, 22, 469–483. [CrossRef]
- Cunningham, P.; Delany, S.J. k-Nearest Neighbour Classifiers. Technical Report, UCD-CSI-2007-4. 27 March 2007. Available online: https://www.researchgate.net/profile/Sarah\_Delany/publication/228686398\_k-Nearest\_neighbour\_classifiers/links/ 0fcfd50d0c1d1f41ad000000/k-Nearest-neighbour-classifiers.pdf (accessed on 24 February 2022).
- Zhu, W.; Zeng, N.; Wang, N. Sensitivity, specifity, accuracy, associated confidence interval and ROC analysis with practical SAS implementations. In Proceedings of the NESUG Proceedings: Health Care and life Sciences, Baltimore, MD, USA, 14–17 November 2010. Available online: https://www.lexjansen.com/nesug/nesug10/hl/hl07.pdf (accessed on 24 February 2022).
- 19. Shapiro, D.E. The interpretation of diagnostic tests. *Stat. Methods Med. Res.* **1999**, *8*, 113–134. [CrossRef]
- Abdel-Nasser, M.; Moreno, A.; Puig, D. Breast cancer detection in thermal infrared images using representation learning and texture analysis methods. *Electronics* 2019, 8, 100. [CrossRef]
- Al Husaini, M.A.S.; Hadi Habaebi, M.; Gunawan, T.S.; Islam, M.R. Self-detection of early breast cancer application with infrared camera and deep learning. *Electronics* 2021, 10, 2538. [CrossRef]
- Etehadtavakol, M.; Emrani, Z.; Ng, E.Y.K. Rapid extraction of the hottest or coldest regions of medical thermographic images. Med. Biol. Eng. Comput. 2019, 57, 379–388. [CrossRef]
- Tello-Mijares, S.; Woo, F.; Flores, F. Breast cancer identification via thermography image segmentation with a gradient vector flow and a convolutional neural network. J. Healthc. Eng. 2019, 2019, 9807619. [CrossRef]
- Chakraborty, M.; Raman, S.K.; Mukhopadhyay, S.; Patsa, S.; Anjum, N.; Ray, J.G. High precision automated face localization in thermal images: Oral cancer dataset as test case. In *Medical Imaging 2017: Image Processing*; International Society for Optics and Photonics: Bellingham, WA, USA, 2017; p. 1013326. [CrossRef]
- Hyase, Y.; Wakasa, T.; Uemura, M.; Adachi, K.; Ochi, S.; Kishi, K. Clinical evaluation of thermography in the diagnosis of malignant tumors in the oral and maxillofacial region. Oral Radiol. 1992, 8, 11–17. [CrossRef]
- Brioschi, M.; Usuki, H.; Jan Crawford, B.S.; Steed, P.; Ammer, K.; Serbu, G. Guidelines for dental-oral and systemic health infrared thermography. Pan Am. J. Med. Thermol. 2015, 2, 44–53.
- UnitedHealthcare West. Medical Management Guideline. Guideline Number: MMG126. K. Effective Date: 1 May 2021. Thermography. 2021. pp. 1–11. Available online: https://www.uhcprovider.com/content/dam/provider/docs/public/policies/ signaturevalue-mmg/thermography-sv.pdf (accessed on 24 February 2022).
- Exarchos, K.P.; Goletsis, Y.; Fotiadis, D.I. Multiparametric decision support system for the prediction of oral cancer reoccurrence. IEEE Trans. Inf. Technol. Biomed. 2012, 16, 1127–1134. [CrossRef] [PubMed]
- Jin, C.; Yang, Y.; Xue, Z.J.; Liu, K.M.; Liu, J. Automated analysis method for screening knee osteoarthritis using medical infrared thermography. J. Med. Biol. Eng. 2013, 33, 471–477. [CrossRef]
- Duarte, A.; Carrao, L.; Espanha, M.; Viana, T.; Freitas, D.; Barloto, P.; Faria, P.; Almeida, H.A. Segmentation algorithms for thermal images. Proc. Technol. 2016, 16, 1560–1569. [CrossRef]
- Fitzgibbon, A.; Pilu, M.; Fisher, R.B. Direct least square fitting of ellipses. IEEE Trans. Pattern Anal. Mach. Intell. 1999, 21, 476–480. [CrossRef]
- Anandaroop, R.; Deepak, C.S. Non-linear least squares ellipse fitting using the genetic algorithm with applications to strain analysis. J. Struct. Geol. 2008, 30, 1593–1602. [CrossRef]

## PRIEDAI

1 priedas / Appendix 1

```
1 clear all
 2 close all
 3
 4 %fprintf(1,'\n');
 5
 6 patient = input('Paciento pavarde:', 's');
7 cd(patient)
8
9 % Nuskaitom profili
10 fprintf(1, '\n');
11 format_image2 = 'MAT';
12 image_name = 'M1';
13 ima_name = [image_name '.' format_image2];
14 Structura = load(ima_name);
15 f = fieldnames(Structura);
16 ima_names = ['Structura.' f{1}];
17 Iprad = eval(ima names);
18 Iprad = Iprad - 273.15;
19 [hI, wI] = size(Iprad);
20 imagesc(Iprad)
21 colormap(jet)
22 hd2 = imrect(gca, [0.1*wI, 0.01*hI, 0.8*wI, 0.7*hI]); % Pataisyta 0.8*hI i 0.8*wI
23 poposition = wait(hd2);
24 xyv2 = getPosition(hd2);
25 I = imcrop(Iprad, xyv2);
26
27 [junk, threshold] = edge(I, 'prewitt');
28 cv = edge(I, 'prewitt', threshold, 'vertical'); % Pataisyta 1*threshold i threshold
29 cv = bwareaopen(cv, 20, 8);
30 [h, w] = size(cv);
31 k = 0;
32 x = []; % Inicijuoti x ir y tuščiais masyvais
33 y = [];
34 for i = 1:w
35
       for j = 2:h-1
36
            if cv(j, i) > 0
37
               k = k + 1;
38
               x(k) = i;
30
               y(k) = j;
40
           end
41
       end
42 end
43 [KD, AA] = convhull(x, y);
44
45 xvd = x(KD(:));
46 yvd = y(KD(:));
47 polin = [xvd' yvd'];
48
49 scrsz = get(0, 'ScreenSize');
50 figure('Position', [1 scrsz(4) scrsz(3)/1.5 scrsz(4)])
51
52 imagesc(I)
53 colormap(jet)
54
55 hh = impoly(gca, polin);
56 xlabel('Ar priimtini veido konturai? Jei ne, redaguokite juos?')
57 position = wait(hh);
58 % Formuojam apdorojamu duomenu masyva
59 MaskeD = createMask(hh); % Pakeista hh.createMask i createMask(hh)
60 nPadetisD = getPosition(hh); % Pakeista hh.getPosition i getPosition(hh)
61 Analize = I .* MaskeD;
```

```
62
 63 % Apskaiciuojam veido simetrijos asi
 64 [Xc, Yc, A, B, Phi, P] = ellipsefit(nPadetisD(:, 1), nPadetisD(:, 2));
 65 [virsus, indx] = min(nPadetisD(:, 2));
 66 virsus = min(nPadetisD(:, 2));
 67 apacia = max(nPadetisD(:, 2));
 68 kaire = min(nPadetisD(:, 1));
 69 desine = max(nPadetisD(:, 1));
 70
 71 Xa = Xc + (apacia - Yc) * tan(pi/2 - Phi);
 72 Xv = Xc + (Yc - virsus) * tan(Phi - pi/2);
 73
 74 kvidurys = Xc;
 75 line([Xa Xv], [apacia virsus]);
 76 slope = (apacia - virsus) / (Xv - Xa);
 77
 78 [aukstis, plotis] = size(Analize);
 79
 80 % Skaiciuojam viduriniu sriciu vidutines temperaturas
 81 S1 = 0;
 82 k = 0;
 83 PriekisK = zeros(aukstis, plotis); % Inicijuoti PriekisK masyva
 84 for i = 1:apacia
 85
        galas = plotis;
 86
        pradzia = round(((Yc - i) / slope) + Xc);
 87
         for j = pradzia:galas
 88
             PriekisK(i, j) = Analize(i, j);
             if Analize(i, j) > 0
 89
 90
                 S1 = S1 + Analize(i, j);
 91
                 k = k + 1;
 92
             end
 93
        end
 94
         Tmk1(i) = max(Analize(i, pradzia:galas));
 95 end
 96 Tk1 = S1 / k;
 97 Tk1max = max(Tmk1);
 98 Tk1min = min(min(PriekisK(PriekisK > 0)));
 99
100 S2 = 0;
101 \ 1 = 0;
102 PriekisD = zeros(aukstis, plotis); % Inicijuoti PriekisD masyvą
103
    for i = 1:apacia
104
        pradzia = 1;
105
        galas = round(((Yc - i) / slope) + Xc);
106
         for j = pradzia:galas
107
             PriekisD(i, j) = Analize(i, j);
108
             if Analize(i, j) > 0
                S2 = S2 + Analize(i, j);
109
110
                 1 = 1 + 1;
111
             end
112
         end
113
         Tmd1(i) = max(Analize(i, pradzia:galas));
114 end
115 Td1 = S2 / 1;
116 Td1max = max(Tmd1);
117 Td1min = min(min(PriekisD(PriekisD > 0)));
118
119 kiekisd = (Td1max - Td1min) / 0.01; % histogramos tikslumas (ilgis)
120 kiekisk = (Tk1max - Tk1min) / 0.01;
121
122 [histD, td] = hist(PriekisD(PriekisD > 0), kiekisd);
```

```
123 [histK, tk] = hist(PriekisK(PriekisK > 0), kiekisk);
124 [rr, rkK] = size(histK); % histogramos masyvo reiksmiu skaicius
125 [rr, rkD] = size(histD);
126
127 tikrasmaxD = td(rkD - fix(rkD * 0.001));
128 tikrasmaxK = tk(rkK - fix(rkK * 0.001));
129
130 nd = 0;
131 nk = 0;
132 if (tikrasmaxD - tikrasmaxK) > 0
         for i = fix(kiekisd):-1:1
133
             if (td(i) - tikrasmaxK) > 0.4
134
135
                 nd = nd + histD(i);
136
             end
137
         end
138 elseif (tikrasmaxK - tikrasmaxD) > 0
139
         for i = fix(kiekisk):-1:1
140
             if (tk(i) - tikrasmaxD) > 0.4
141
                nk = nk + histK(i);
142
             end
143
         end
144 else
145
         nk = 0;
146
         nd = 0;
147 end
148
149 % Nuskaitom burnos ertmes vaizda
150 fprintf(1, '\n');
151 format_image2 = 'MAT';
152 image_name = 'M2';
153 ima_name = [image_name '.' format_image2];
154 Structura = load(ima name);
155 f = fieldnames(Structura);
156 ima_names = ['Structura.' f{1}];
157 Iprad4 = eval(ima names);
158 Iprad4 = Iprad4 - 273.15;
159 [hI, wI] = size(Iprad4);
160
161 scrsz = get(0, 'ScreenSize');
162 figure('Position', [1 scrsz(4) scrsz(3)/1.5 scrsz(4)])
163 imagesc(Iprad4)
164 colormap(jet)
165
166 hd4 = imrect(gca, [0.1*wI, 0.01*hI, 0.8*wI, 0.7*hI]); % Pataisyta 0.8*hI i 0.8*wI
167 poposition = wait(hd4);
168 xyv4 = getPosition(hd4);
169 I4 = imcrop(Iprad4, xyv4);
170
171 [junk, threshold] = edge(I4, 'prewitt');
172 cv4 = edge(I4, 'prewitt', threshold, 'vertical'); % Pataisyta 1*threshold i threshold
173 %cv4 = bwareaopen(cv4, 20, 8);
174 [h, w] = size(cv4);
175 k = 0;
176 x4 = []; % Inicijuoti x4 ir y4 tuščiais masyvais
177 y4 = [];
178 for i = 1:w
179
         for j = 2:h-1
180
             if cv4(j, i) > 0
181
                 k = k + 1;
182
                 x4(k) = i;
183
                 y4(k) = j;
```

```
184
            end
185
        end
186 end
187 [KD4, AA4] = convhull(x4, y4);
188
189 xvd4 = x4(KD4(:));
190 yvd4 = y4(KD4(:));
191 polin = [xvd4' yvd4'];
192
193 scrsz = get(0, 'ScreenSize');
194 figure('Position', [1 scrsz(4) scrsz(3)/1.5 scrsz(4)])
195
196 imagesc(I4)
197 colormap(jet)
198
199 hh = impoly(gca, polin);
200 xlabel('Ar priimtini burnos konturai? Jei ne, redaguokite juos?')
201 position = wait(hh);
202 % Formuojam apdorojamu duomenu masyva
203 MaskeB = createMask(hh); % Pakeista hh.createMask i createMask(hh)
204 nPadetisB = getPosition(hh); % Pakeista hh.getPosition i getPosition(hh)
205 Analize4 = I4 .* MaskeB;
206 [aukstis, plotis] = size(Analize4);
207
208 % Apskaiciuojam burnos simetrijos asi
209 [Xc, Yc, A, B, Phi, P] = ellipsefit(nPadetisB(:, 1), nPadetisB(:, 2));
210 [virsus, indx] = min(nPadetisB(:, 2));
211 virsus = min(nPadetisB(:, 2));
212 apacia = max(nPadetisB(:, 2));
213 kaire = min(nPadetisB(:, 1));
214 desine = max(nPadetisB(:, 1));
215
216 Xba = Xc + (apacia - Yc) * tan(pi/2 - Phi);
217 Xbv = Xc + (Yc - virsus) * tan(Phi - pi/2);
218
219 line([Xc Xc], [1 aukstis]);
220 slopeb = (apacia - virsus) / (Xbv - Xba);
221 % Skaiciuojam burnos sriciu vidutines temperaturas
222 \quad S5 = 0;
223 k = 0;
224 BurnaD = zeros(aukstis, plotis); % Inicijuoti BurnaD masyvą
225
    for i = 1:aukstis
226
        galas = fix(Xc);
227
        pradzia = 1;
228
         for j = pradzia:galas
229
             BurnaD(i, j) = Analize4(i, j);
             if Analize4(i, j) > 0
230
231
                S5 = S5 + Analize4(i, j);
232
                 k = k + 1;
233
            end
234
         end
235
         Tmbd(i) = max(Analize4(i, pradzia:galas));
236 end
237 Tbd = S5 / k;
238 Tbdmax = max(Tmbd);
239 Tbdmin = min(min(BurnaD(BurnaD > 0)));
240
241 S6 = 0;
242 1 = 0;
243 BurnaK = zeros(aukstis, plotis); % Inicijuoti BurnaK masyvą
244 for i = 1:aukstis
```

```
245
        galas = fix(plotis);
        pradzia = fix(Xc);
246
247
         for j = pradzia:galas
248
            BurnaK(i, j) = Analize4(i, j);
249
             if Analize4(i, j) > 0
250
                 S6 = S6 + Analize4(i, j);
251
                 1 = 1 + 1:
252
             end
253
        end
254
         Tmbk(i) = max(Analize4(i, pradzia:galas));
255 end
256 Tbk = S6 / 1;
257 Tbkmax = max(Tmbk);
258 Tbkmin = min(min(BurnaK(BurnaK > 0)));
259
260 kiekisdB = (Tbdmax - Tbdmin) / 0.01; % histogramos tikslumas (ilgis)
261 kiekiskB = (Tbkmax - Tbkmin) / 0.01;
262
263
    [histDB, td] = hist(BurnaD(BurnaD > 0), kiekisdB);
264 [histKB, tk] = hist(BurnaK(BurnaK > 0), kiekiskB);
265 [rr, rkK] = size(histKB); % histogramos masyvo reiksmiu skaicius
266 [rr, rkD] = size(histDB);
267
268 tikrasmaxDB = td(rkD - fix(rkD * 0.001));
269 tikrasmaxKB = tk(rkK - fix(rkK * 0.001));
270 ndB = 0;
271 nkB = 0;
272
273 if (tikrasmaxDB - tikrasmaxKB) > 0
274
        for i = fix(kiekisdB):-1:1
275
            if (td(i) - tikrasmaxKB) > 0.4
276
                 ndB = ndB + histDB(i);
277
            end
278
        end
279 elseif (tikrasmaxKB - tikrasmaxDB) > 0
280
        for i = fix(kiekiskB):-1:1
281
            if (tk(i) - tikrasmaxDB) > 0.4
282
                 nkB = nkB + histKB(i);
283
            end
284
         end
285 else
286
        nkB = 0;
287
        ndB = 0;
288 end
289
290 entropijaBD = entropy(BurnaD(:));
291 entropijaBK = entropy(BurnaK(:));
292
293 if Td1 < Tk1
294
        DeviacijaDv = std2(PriekisD(PriekisD > Td1));
295
        DeviacijaKv = std2(PriekisK(PriekisK > Td1));
296
    else
297
        DeviacijaDv = std2(PriekisD(PriekisD > Tk1));
298
        DeviacijaKv = std2(PriekisK(PriekisK > Tk1));
299 end
300 Diaviaciju_skirtV = abs(DeviacijaDv - DeviacijaKv);
301
302 if Tbd < Tbk
303
        DeviacijaD = std2(BurnaD(BurnaD > Tbd));
        DeviacijaK = std2(BurnaK(BurnaK > Tbd));
304
305 else
```

```
306 DeviacijaD = std2(BurnaD(BurnaD > Tbk));
307 DeviacijaK = std2(BurnaK(BurnaK > Tbk));
308 end
309 Diaviaciju_skirtB = abs(DeviacijaD - DeviacijaK);
310
311 Taskai_burnos_kaireje = nkB;
312 Taskai_burnos_desineje = ndB;
313 Taskai_veide_desineje = nd;
314 Taskai_veide_kaireje = nk;
315
316 cd ..
317
```

```
1 clear all
 2 load dataN2.mat
 3
 4 tikras(1:39)=0;
 5 tikras(40:96)=1;
 6 resp = (1:24)' > 12;
 7 meas=meas(1:96,:);
 8
 9
10 species(1:24)=0;
11 species(25:48)=1;
12 for k=1:20
13
        mokymas(1:24,:)=meas(k:(k+23),:);
14
        mokymas(25:48,:)=meas((53+k):(k+76),:);
15
        mdl = fitcknn(mokymas,species,'NumNeighbors',1,'Distance', 'euclidean');
16
        [label,score,cost]=predict(mdl,meas);
17
        Labels(:,k)=label;
18
        C(:,:,k) = confusionmat(tikras,label);
19
        rocObj = rocmetrics(tikras,score,mdl.ClassNames);
20
        Area(:,k)=rocObj.AUC(1);
        rocurve(:,:,k)=table2array(rocObj.Metrics);
21
22
        R=statsOfMeasure(C(:,:,k),0);
23
        R=table2array(R);
24
        for i=1:9
25
        Results(i,k)=str2num(R(i,3));
26
        end
27
        [X(:,k),Y(:,k),T(:,k),AUC(:,k)] = perfcurve(Labels(:,k),tikras,'1','xvals','all');
28 end
29 for i=1:20
30 confmat=C(:,:,i);
31 TP = confmat(2, 2);
32 TN = confmat(1, 1);
33 FP = confmat(1, 2);
34 FN = confmat(2, 1);
35 Accuracy(i) = (TP + TN) / (TP + TN + FP + FN);
36 Sensitivity(i) = TP / (FN + TP);
37 specificity(i) = TN / (TN + FP);
38 end
39 [y,I]=sort(Y(2,:));
40 YY(1)=0;
41 YY(2:21)=y;
42 YY(21)=1;
43 XX(1)=0;
44 [x,I]=sort(X(2,:));
45 for j=1:20
46 XX(j+1)=X(2,I(j));
47 end
48 XX(2:21)=x;
49 XX(21)=1;
50
51 for i=1:20
52 rrocx(3*(i-1)+1:3*i)=rocurve(4:6,3,i);
53 rrocy(3*(i-1)+1:3*i)=rocurve(4:6,4,i);
54 end
55 a=sort(rrocx);
56 b=sort(rrocy);
57 plot(a,b)
58 title('ROC curve')
59 xlabel('False Positive Rate')
60 ylabel('True Positive Rate')
61
```

AUC=max(Area)
 ACUR=max(Accuracy)
 SENS=max(Sensitivity)
 SPEC=max(specificity)

## 3 priedas / Appendix 3

Požvmis	Grunė 1	Grunė 2	U-stat	n	I	Požvmis	Grunė 1	Grunė 2	U-stat	n
1 02,1115	Grupe 1	Grupe 2	U Stat	reikšmė			Grupe 1	Grupe L	e stat	reikšmė
V- vid	SS	ST	489,5	0,349022		V-Dev	ST	UP	429	0,138603
V- vid	SS	UP	264	0,023903		V-Dev	ST	NP	549,5	0,769182
V- vid	SS	NP	234	0,010042		V-Dev	ST	UP/NP	978,5	0,473056
V- vid	SS	UP/NP	498	0,004908		V-Dev	UP	NP	460	0,170025
V- vid	ST	UP	409	0,0827		V-Dev	UP	UP/NP	852	0,432409
V- vid	ST	NP	369	0,040602		V-Dev	NP	UP/NP	660,5	0,421233
V- vid	ST	UP/NP	778	0,024063		B-Dev	SS	ST	444,5	0,135004
V- vid	UP	NP	365	0,833318		B-Dev	SS	UP	63	4,57E-08
V- vid	UP	UP/NP	757	0,904158		B-Dev	SS	NP	52,5	2,85E-08
V- vid	NP	UP/NP	755,5	0,901825		B-Dev	SS	UP/NP	115,5	1,44E-10
V- max	SS	ST	577,5	0,882393		B-Dev	ST	UP	157	7,86E-07
V- max	SS	UP	438	0,611815		B-Dev	ST	NP	153,5	1,18E-06
V- max	SS	NP	378	0,82957		B-Dev	ST	UP/NP	310,5	5,11E-09
V- max	SS	UP/NP	816	0,865061		B-Dev	UP	NP	399	0,729993
V- max	ST	UP	579	0,677776		B-Dev	UP	UP/NP	791	0,843457
V- max	ST	NP	499	0,72317		B-Dev	NP	UP/NP	721,5	0,839679
V- max	ST	UP/NP	1078	0,969317		nV	SS	ST	536,5	0,227232
V- max	UP	NP	325,5	0,381312		nV	SS	UP	377	0,153579
V- max	UP	UP/NP	717,5	0,61643		nV	SS	NP	319	0,017004
V- max	NP	UP/NP	795	0,607831		nV	SS	UP/NP	696	0,047441
B- vid	SS	ST	573 <i>,</i> 5	0,925881		nV	ST	UP	533	0,698784
B- vid	SS	UP	384	0,731454		nV	ST	NP	452	0,070928
B- vid	SS	NP	394	0,973838		nV	ST	UP/NP	985	0,190935
B- vid	SS	UP/NP	778	0,858131		nV	UP	NP	339	0,263014
B- vid	ST	UP	517	0,717127		nV	UP	UP/NP	731	0,492064
B- vid	ST	NP	527	1		nV	NP	UP/NP	781,5	0,536597
B- vid	ST	UP/NP	1044	0,82987		nB	SS	ST	565,5	1
B- vid	UP	NP	399	0,729993		nB	SS	UP	217,5	4,44E-05
B- vid	UP	UP/NP	791	0,843457		nB	SS	NP	217,5	7,37E-05
B- vid	NP	UP/NP	721,5	0,839679		nB	SS	UP/NP	435	2,52E-05
B- max	SS	ST	574,5	0,912201		nB	ST	UP	292,5	3,17E-06
B- max	SS	UP	261	0,019921		nB	ST	NP	292,5	5,96E-06
B- max	SS	NP	372	0,753081		nB	ST	UP/NP	585	1,53E-06
B- max	SS	UP/NP	633	0,121785		nB	UP	NP	367,5	0,854065
B- max	ST	UP	372	0,026552		nB	UP	UP/NP	759,5	0,91633
B- max	ST	NP	510	0,833744		nB	NP	UP/NP	753	0,913993
B- max	ST	UP/NP	882	0,144015						
B- max	UP	NP	438	0,316472						
B- max	UP	UP/NP	830	0,56654						
B- max	NP	UP/NP	682,5	0,557085						
V-Dev	SS	ST	527,5	0,641829						
V-Dev	SS	UP	299	0,089121						
V-Dev	SS	NP	379.5	0.850428						

678,5 0,264904

V-Dev

SS

UP/NP

## **CURRICULUM VITAE**

Vardas, Pavardė: Adresas: El. paštas:	<b>Diana Mačianskytė, MD</b> Lietuvos sveikatos mokslų universitetas, A. Mickevičiaus g. 9, LT-44307 Kaunas, Lithuania diana.macianskyte@lsmuni.lt					
Išsilavinimas:						
2002–2008	Medicinos gydytoja, Kauno medicinos universitetas, Magistro laispnis					
2009–2013	Radiologijos rezidentūra, Lietuvos sveikatos mokslų universiteto ligoninė Kauno klinikos					
2013–2025	Doktorantė, Lietuvos sveikatos mokslų universitetas, Kaunas, Lietuva					
Darbo patirtis:						
2010-present	Lektorė, Lietuvos sveikatos mokslų universiteto Medicinos akademijos Radiologijos klinika					
2013-present	Gydytoja radiologė, Lietuvos sveikatos mokslų universiteto ligoninės Kauno klinikų Radiologijos klinika					
Name, Surname: Address: E-mail:	<b>Diana Mačianskytė, MD</b> Lithuanian University of Health Sciences, A. Mickevičiaus 9, LT-44307 Kaunas, Lithuania diana.macianskyte@lsmuni.lt					
Education:						
2002–2008	Studies at Lithuanian University of Health Sciences, Medical Doctor diploma at Lithuanian University of Health Sciences, Kaunas, Lithuania					
2009–2013	Resident of Radiology, Lithuanian University of Health Sciences, Kaunas, Lithuania					
2013–2025	PhD student, Department of Radiology, Hospital of Lithuanian University of Health Sciences Kauno klinikos, Kaunas, Lithuania					
Work experience:						
2010-present	Lecturer, Department of Radiology, Medical Academy, Lithuanian University of Health Sciences					

2013-present	Radiologist, Department of Radiology, Hospital of Lithuanian
	University of Health Sciences Kauno klinikos, Kaunas, Lithuania

## PADĖKA

Išreiškiu nuoširdžią padėką savo disertacinio darbo vadovui prof. dr. Algidui Basevičiui už reikšmingą metodologinį indėlį, konstruktyvią kritiką, akademinę įžvalgą ir nuoseklų palaikymą viso darbo rengimo metu.

Taip pat esu dėkinga konsultantui prof. dr. Rimui Adaškevičiui už vertingas pastabas, konceptualinę paramą ir dalijimąsi patirtimi, kurios reikšmingai prisidėjo prie darbo turinio gilinimo ir rezultato išbaigtumo. Jo profesionalumas, griežtumas ir skatinimas kelti aukštus mokslinius reikalavimus buvo itin svarbūs formuojant tyrimo kryptį ir siekiant kokybiško rezultato.

Nuoširdi padėka pirmiesiems mano intelektualinio kelio skatintojams – prof. dr. Eglei Monastyreckienei ir prof. dr. Ričardui Kubiliui – už įkvėpimą, kurį gavau dar studijų pradžioje. Jūsų mentorystė, pasitikėjimas ir žmogiška parama tapo esminiu pagrindu tolimesniam akademiniam tobulėjimui.

Dėkoju visiems, kurie vienaip ar kitaip prisidėjo prie šio darbo įgyvendinimo: tyrimo dalyviams, kolegoms ir bendradarbiams. Kiekvienas jūsų indėlis buvo reikšmingas ir prisidėjo prie šio tyrimo turinio kokybės bei išsamumo.

I sincerely thank Prof. Dr. Kanigula Mubagwa for believing that this work is meaningful, original, and promising. Your encouragement to persevere and complete the dissertation was invaluable.

Ypatingą padėką reiškiu savo tėvams ir šeimai – už neišsenkantį palaikymą, moralinę paramą ir kantrybę. Jūsų besąlygiška parama ir tikėjimas šio kelio prasme buvo kertinis motyvuojantis veiksnys, leidęs atkakliai siekti tikslo ir užbaigti šį mokslinį darbą.