

lek. dent. Michał Kielczykowski

Ocena tkanek miękkich profilu twarzy w zależności od morfologii twarzowej części czaszki

Rozprawa na stopień doktora nauk medycznych i nauk o zdrowiu w dyscyplinie nauki
medyczne

Promotor: prof. dr hab. n. med. Ewa Czochrowska

Promotor pomocniczy: dr n. med. Konrad Perkowski

Zakład Ortodoncji Warszawskiego Uniwersytetu Medycznego



Obrona rozprawy doktorskiej przed Radą Dyscyplin Nauk Medycznych Warszawskiego
Uniwersytetu Medycznego

Warszawa 2024

Słowa kluczowe w języku polskim:

Analiza cefalometryczna

Analiza profilu

Analiza tkanek miękkich

Leczenie kamuflażowe

Szkieletowa wada zgryzu

Słowa kluczowe w języku angielskim:

Camouflage treatment

Cephalometric analysis

Profile analysis

Skeletal malocclusion

Soft tissue analysis

Składam serdecznie podziękowania Promotor prof. dr hab. n.med. Ewie Czochrowskiej za wszechstronną pomoc oraz zaangażowanie na wszystkich etapach mojej pracy. Chciałabym dodatkowo podziękować dr n. med. Konradowi Perkowskiem za ogromną inspirację w powstanie tej rozprawy, prof. dr hab. Małgorzacie Zadurskiej za życzliwość i wsparcie. Szczególne podziękowania dla mojej żony i syna za wiarę we mnie, motywację i wsparcie.

Wykaz publikacji stanowiących pracę doktorską:

1. **Kielczykowski M**, Zadurska M, Czochrowska E, Perkowski K. Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa. Forum Ortodontyczne 2022;18(4):230-236. MEiN: **40** pkt.
2. **Kielczykowski M**, Kamiński K, Perkowski K, Zadurska M, Czochrowska E. Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review. Diagnostics (Basel). 2023 Aug 10;13(16):2640. IF: **3,000**; MEiN: **70** pkt.
3. **Kielczykowski M**, Perkowski K, Kamiński K, Zadurska M, Czochrowska E. Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age. BMC Oral Health. 2024 Jun 20;24(1):711. IF: **2,600**; MEiN: **100** pkt.

Łączna punktacja MEiN: 210 pkt.

Łączny Impact Factor: 5,600

Spis treści:

Słowa kluczowe w języku polskim.....	2
Słowa kluczowe w języku angielskim.....	2
Dedykacje.....	3
Wykaz publikacji stanowiących pracę doktorską.....	4
Spis treści.....	5
Wykaz stosowanych skrótów.....	6
Streszczenie w języku polskim.....	7
Streszczenie w języku angielskim.....	14
Wstęp uzasadniający połączenie wskazanych publikacji w jeden cykl, jak i komentujący osiągnięcie kandydata na tle dotychczasowego stanu wiedzy.....	18
Założenia i cel pracy.....	21
Kopie opublikowanych prac.....	22
Podsumowanie i wnioski.....	54
Opinia komisji Bioetycznej.....	55
Oświadczenia współautorów cyklu publikacji stanowiących rozprawę doktorską.....	56

Wykaz stosowanych skrótów (w kolejności alfabetycznej)

AI Sztuczna Inteligencja (*Artificial Intelligence*)

CNN Konwolucyjne sieci neuronowe (*Convolutional Neural Networks*)

SSD *Single Shot Multibox Detector*

TMPT Tkanki miękkie profilu twarzy

YOLOv3 *You-Only Look-Once version 3*

STRESZCZENIE W JĘZYKU POLSKIM

Ocena tkanek miękkich profilu twarzy w zależności od morfologii twarzowej części czaszki

WSTĘP

Ocena profilu twarzy pacjenta ma istotne znaczenie w diagnostyce oraz planowaniu leczenia ortodontycznego. Tkanki miękkie mogą się znacznie różnić grubością, a przez to maskować występowanie istotnych zaburzeń szkieletowo-zębowych. W ostatnich latach obserwuje się wzrost zainteresowania morfologią tkanek miękkich profilu twarzy (TMPT) u pacjentów diagnozowanych przed rozpoczęciem leczenia ortodontycznego. W celu oceny charakterystyki tkanek miękkich profilu wykorzystuje się najczęściej analizę cefalometryczną teleradiogramu boczego głowy. W piśmiennictwie są opisywane sprzeczne doniesienia dotyczące grubości TMPT w odniesieniu do istniejącej wady szkieletowej u dorosłych. Także jest niewiele badań oceniających grubość u pacjentów w wieku rozwojowym i zmian zachodzących z wiekiem. Obecnie coraz powszechniej ortodonci wykorzystują algorytmy sztucznej inteligencji (AI) do przeprowadzania analizy cefalometrycznej. Mimo dynamicznego rozwoju AI w wielu dziedzinach medycyny w ostatnich latach, klinicyści wciąż mają obawy odnośnie do wiarygodności pomiarów uzyskiwanych drogą zautomatyzowanego oznaczania punktów cefalometrycznych przez AI. Ponadto algorytmy sztucznej inteligencji zawierają ograniczoną liczbę pomiarów tkanek miękkich, chociaż ich morfologia może w istotny sposób wpływać na wybór metody leczenia ortodontycznego.

CEL

Celami pracy było:

1. podsumowanie danych z aktualnego piśmiennictwa dotyczących zależności między czynnikami takimi jak klasa szkieletowa lub płeć pacjenta a grubością TMPT,
2. ocena możliwości wykorzystania algorytmów sztucznej inteligencji i jej skuteczności w diagnostyce ortodontycznej w oparciu o badania wykorzystujące różne typy algorytmów AI,
3. ocena zależności między grubością TMPT a klasą szkieletową wady zgryzu pacjenta,
4. porównanie grubości TMPT u osób w różnych grupach wiekowych,
5. porównanie grubości TMPT u mężczyzn i kobiet.

MATERIAŁ I METODY

W pierwszej publikacji przeprowadzono przegląd piśmiennictwa z lat 2002-2020, z wykorzystaniem bazy danych PubMed i podsumowano informacje na temat istniejących zależności między morfologią TMPT a rodzajem szkieletowej wady zgryzu oraz płcią badanych. Ze względu na istniejące rozbieżności w wynikach opublikowanych dotychczas badań, niewielką ilość doniesień naukowych dotyczących grubości tkanek miękkich w grupie dzieci oraz brak przeprowadzonego podobnego badania w populacji polskiej podjęto decyzję o przeprowadzeniu badania własnego.

W drugiej publikacji przeprowadzono przegląd piśmiennictwa w celu podsumowania informacji dotyczących dokładności algorytmów sztucznej inteligencji w diagnostyce ortodontycznej na podstawie analizy cefalometrycznej teleradiogramów bocznych głowy. W tym celu przeszukano bazy danych PubMed, Medline, Scopus and Dentistry & Oral Sciences Source z lat 2009-2023.

Trzecia praca była badaniem retrospektywnym, w którym oceniano zależności między grubością tkanek miękkich profilu twarzy a szkieletową wadą zgryzu, wiekiem i płcią badanych. Do badania zostali włączeni pacjenci rasy kaukaskiej w wieku od 7 do 35 lat, którzy zgłosili się w celu leczenia ortodontycznego do Zakładu Ortodontji Warszawskiego Uniwersytetu Medycznego w latach 2019-22. Zakwalifikowani do badania pacjenci mieli wykonane teleradiogramy boczne głowy przed rozpoczęciem leczenia ortodontycznego. Kryteriami wyłączenia z badania byli pacjenci z wadami wrodzonymi i urazami w obrębie twarzoczaszki, wcześniej przeprowadzone leczenie protetyczne lub chirurgiczne, jak również zabiegi augmentacji tkanek miękkich, niekompetencja warg oraz zła jakość zdjęć rentgenowskich. U wszystkich włączonych do badania przeprowadzono analizę cefalometryczną z uwzględnieniem analizy tkanek miękkich profilu twarzy. Pacjenci zostali przydzieleni do jednej z sześciu grup badawczych na podstawie wieku i występujących relacji szkieletowych (kąt ANB). Zakładana minimalna liczba pacjentów w każdej grupie miała wynosić 60 z równomiernym podziałem płci. Przeprowadzona analiza tkanek miękkich profilu twarzy obejmowała dziesięć pomiarów liniowych.

Analiza statystyczna

W badaniu retrospektywnym porównywano pomiędzy grupami grubość TMPT w różnych miejscach pomiarowych. Ze względu na brak znajomości wartości średniej i odchylenia standardowego ocenianych parametrów dla populacji, z których pochodziły oceniane próby, do analizy normalności rozkładu wykorzystano test Lillieforsa. Analiza wykazała brak

zgodności z rozkładem normalnym większości ocenianych parametrów, stąd w dalszych analizach wykorzystywano testy nieparametryczne: test U Manna-Whitneya oraz test ANOVA Kruskala-Wallisa. Analizę statystyczną przeprowadzono przy użyciu oprogramowania PQStat v. 1.6.8. Za próg istotności statystycznej przyjęto wartość $p < 0,05$.

Dwadzieścia losowo wybranych radiogramów zostało ponownie zanalizowanych w odstępie czterech tygodni. Uzyskane wyniki zostały następnie porównane z wynikami wcześniejszej analizy cefalometrycznej. Współczynnik korelacji wewnątrzklasowej (ICC) został użyty do określenia korelacji między pierwszymi a drugimi pomiarami. Stwierdzono wysoką powtarzalność pomiarów ($p < 0,001$), z wartościami ICC $> 0,90$ dla większości parametrów, z wyjątkiem (U1-St i B-Lms), gdzie wartości wynosiły odpowiednio 0,89 i 0,87.

WYNIKI

Przegląd piśmiennictwa dotyczący różnic w grubości TMPT wykazał występowanie dymorfizmu płciowego. U mężczyzn wartości pomiarów grubości warg, tkanek miękkich okolicy podnosowej, bruzdy wargowo-bródkowej oraz okolicy bródki były istotnie wyższe niż u kobiet. Ponadto stwierdzono tendencję do kompensacji przez TMPT okolic niedorozwoju szczęki lub żuchwy lub ich dotylnej pozycji.

Przegląd baz danych na temat skuteczności algorytmów AI wykorzystywanych do analizy cefalometrycznej potwierdził, że większość algorytmów AI stosowanych do automatycznego pozycjonowania punktów na radiogramach cefalometrycznych charakteryzowała się stosunkowo wysoką dokładnością. Jednocześnie skuteczność stosowania AI w cefalometrii różni się w zależności od algorytmu lub rodzaju aplikacji, co należy uwzględnić w interpretacji wyników.

W badaniu retrospektywnym uczestniczyło 300 pacjentów, którzy zostali przydzieleni do pięciu grup. Grupa 6 (pacjenci w fazie wzrostu z III klasą szkieletową) nie została uwzględniona w badaniu, ponieważ nie osiągnięto założonej liczebności grupy. Stwierdzono występowanie istotnych różnic w grubości TMPT w odniesieniu do typu szkieletowej wady zgryzu. U dorosłych z III klasą szkieletową grubość tkanek podnosowych była istotnie zwiększona w porównaniu z pacjentami z I i II klasą szkieletową. Grubość dolnej wargi u pacjentów z II klasą szkieletową była istotnie zwiększona w porównaniu z innymi grupami. Dzieci i młodzież z II klasą szkieletową miały grubsze dolne wargi w porównaniu z grupą z I klasą szkieletową. Większość pomiarów TMPT była znacząco mniejsza u dzieci i młodzieży w porównaniu z dorosłymi. Grubość TMPT u mężczyzn była istotnie większa we wszystkich grupach wiekowych w porównaniu z kobietami.

WNIOSKI

1. Stwierdzono istnienie zależności między grubością TMPT a występowaniem szkieletowej wady zgryzu oraz płcią, co ma znaczenie w planowaniu leczenia ortodontycznego u pacjentów z wadami szkieletowymi.
2. Algorytmy AI mogą być z powodzeniem wykorzystywane w diagnostyce ortodontycznej, ale ich skuteczność zależy od jakości danych wprowadzonych do analizy, liczby i jakości radiogramów oraz zastosowanego algorytmu lub aplikacji.
3. Stwierdzono występowanie zależności między grubością TMPT a klasą szkieletową wady zgryzu i wykazano obecność kompensacji w rejonie niewystarczającego wzrostu doprzedniego szczęk lub żuchwy.
4. Grubość TMPT różni się w zależności od wieku pacjentów i jest zwiększona u pacjentów dorosłych.
5. Stwierdzono obecność dymorfizmu płciowego w odniesieniu do grubości TMPT oraz zwiększenie ich grubości u badanych płci męskiej w porównaniu z płcią żeńską, zarówno u dorosłych jak i u dzieci i młodzieży.

Publikacja nr 1 wchodząca w skład cyklu rozprawy doktorskiej

Kielczykowski M, Zadurska M, Czochorowska E, Perkowski K. Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa. Forum Ortodontyczne 2022;18(4):230-236

W pierwszej publikacji przeprowadzono przegląd piśmiennictwa i podsumowano informacje na temat istniejących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią badanych. W tym celu przeszukano bazę danych PubMed z wykorzystaniem słów kluczowych: facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth. Do analizy zakwalifikowano 21 publikacji z lat 2002-2020 w języku angielskim. W badaniach stwierdzono występowanie dymorfizmu płciowego w zakresie grubości tkanek miękkich profilu twarzy u dorosłych, zgodnie z którym mężczyźni cechują się grubszymi tkankami miękkimi. W piśmiennictwie brak jest jednoznacznych wniosków dotyczących różnic w grubości TMPT u pacjentów w wieku rozwojowym. Stwierdzono również występowanie różnic w grubości TMPT w zależności od klasy szkieletowej wady zgryzu. Zależności widoczne były głównie w rejonie okolicy podnosowej oraz w okolicy wargi górnej i dolnej. U pacjentów z III klasą szkieletową okolica podnosowa i warga górna cechowały się większą grubością w porównaniu z pacjentami z II klasą szkieletową. Natomiast u pacjentów z II klasą szkieletową grubość okolicy wargi dolnej była istotnie większa niż u pacjentów z III klasą szkieletową. Te zależności mogą świadczyć o istnieniu kompensacji w zakresie tkanek miękkich w rejonach, w których szczęka lub żuchwa jest niedostatecznie rozwinięta lub położona bardziej dystalnie. Może to wpływać na profil twarzy pacjenta maskując występowanie gnatyecznej wady zgryzu. Nie stwierdzono jednoznacznych wyników dotyczących różnic w grubości tkanek miękkich w górnym piętrze twarzy oraz w rejonie bródki w zależności od występującej klasy szkieletowej.

Publikacja nr 2 wchodząca w skład cyklu rozprawy doktorskiej

Kielczykowski M, Kamiński K, Perkowski K, Zadurska M, Czochorowska E. Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review. Diagnostics (Basel). 2023 Aug 10;13(16):2640.

W pracy dokonano przeglądu piśmiennictwa dotyczącego skuteczności zastosowania algorytmów sztucznej inteligencji w analizie cefalometrycznej teloradiogramów bocznych głowy. Przeszukano bazy danych takich jak PubMed, Medline, Scopus oraz Dentistry & Oral

Sciences Source z lat 2009-2023 wykorzystując słowa kluczowe artificial intelligence i cephalometric analysis. Do analizy zakwalifikowano 23 publikacji z lat 2009-2023 roku w języku angielskim. Stwierdzono, że w ostatnich latach znacznie zwiększyło się zainteresowanie zastosowaniem algorytmów AI w diagnostyce ortodontycznej opierającej się na analizie cefalometrycznej. Wykazano, że dokładność różnych typów algorytmów AI jest zróżnicowana. Algorytmy oparte na konwolucyjnych sieciach neuronowych (CNN), opracowanych indywidualnie przez autorów prac do celów ich badań lub algorytmy takie jak YOLOv3 czy SSD, które nie są dostępne dla lekarzy w codziennej praktyce klinicznej, są bardziej efektywne i dokładniejsze niż dostępne programy komercyjne. W większości badań przeprowadzonych przy zastosowaniu AI przedział ufności wynosił do 2 mm, zaś średni procent wykrytych punktów orientacyjnych w tym przedziale wynosił powyżej 80%. Jednocześnie, średnia różnica w lokalizacji punktów cefalometrycznych pomiędzy dwoma doświadczonymi klinicystami może wynosić nawet do 1,5 mm. Autorzy publikacji wykorzystywali różną liczbę teleradiogramów do testowania i walidacji baz danych, które wahały się od kilkunastu do tysiąca. Wykazano, że wraz ze wzrostem liczebności bazy danych służącej do nauki algorytmu AI wzrasta jego skuteczność. Badania wykazały również, że czas potrzebny na analizę cefalometryczną przy pomocy większości popularnych algorytmów AI wynosi kilka sekund, co jest znacznie krótsze niż manualne wyznaczanie punktów orientacyjnych. Dodatkową zaletą stosowania zautomatyzowanego systemu do identyfikacji punktów cefalometrycznych w porównaniu z oznaczaniem manualnym jest fakt, że zawsze uzyskuje się ten sam wynik dla tego samego obrazu, podczas gdy w przypadku manualnego oznaczania istnieją duże różnice zależne od doświadczenia klinicznego lekarza. Większość badań oceniających dokładność automatycznego wyznaczania punktów cefalometrycznych opierało się na ocenie punktów antropometrycznych zlokalizowanych na kościach oraz zębach pacjenta. Biorąc pod uwagę znaczenie grubości i morfologii tkanek miękkich profilu twarzy w diagnostyce i planowaniu leczenia ortodontycznego celowe jest przeprowadzenie dalszych badań dokładności algorytmów AI w analizie cefalometrycznej tkanek miękkich profilu twarzy.

Publikacja nr 3 wchodząca w skład cyklu rozprawy doktorskiej

Kielczykowski M, Perkowski K, Kamiński K, Zadurska M, Czochorowska E. Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age. BMC Oral Health. 2024 Jun 20;24(1):711. IF: 2,600; MEiN: 100 pkt.

Trzecia praca jest badaniem klinicznym retrospektywnym, w którym oceniano zależności między grubością tkanek miękkich profilu twarzy a występowaniem szkieletowej wady zgryzu, wiekiem i płcią badanych. Do badania zakwalifikowano łącznie 300 pacjentów w wieku 7-35 lat, którzy zgłosili się w celu leczenia ortodontycznego w Zakładzie Ortodontji WUM w latach 2019-22. U wszystkich badanych były wykonane teleradiogramy boczne głowy przed rozpoczęciem leczenia ortodontycznego. Kryteriami wyłączenia z badania były wady wrodzone twarzoczaszki, urazy w obrębie twarzoczaszki, wcześniejsze leczenie protetyczne lub chirurgiczne, jak również zabiegi augmentacji tkanek miękkich, niekompetencja warg oraz niska jakość zdjęć rentgenowskich. Badanych podzielono na 6 grup w zależności od wieku oraz klasy szkieletowej wady zgryzu. Na każdym zdjęciu telerentgenowskim bocznym głowy przeprowadzono cyfrową analizę cefalometryczną w programie DDP-Ortho 2.10.2022 (Polorto, Częstochowa, Polska) z uwzględnieniem analizy tkanek miękkich i porównano grubości tkanek miękkich profilu twarzy pomiędzy grupami na podstawie 10 pomiarów liniowych. Wyniki poddano analizie statystycznej z zastosowaniem oprogramowania PQStat v. 1.6.8. Wykazano różnice w grubości tkanek miękkich w zależności od klasy szkieletowej. U dorosłych z III klasą szkieletową wykazano istotnie zwiększoną grubość tkanek miękkich okolicy podnosowej oraz wargi górnej w porównaniu do pacjentów z I i II klasą szkieletową, zaś grubość wargi dolnej była istotnie większa w II klasy szkieletowej w porównaniu do pozostałych grup. Dzieci z II klasą szkieletową miały grubszą wargę dolną niż dzieci z I klasą szkieletową. Wykazano również, że tkanki miękkie profilu twarzy mężczyzn we wszystkich grupach wiekowych są istotnie grubsze w porównaniu do kobiet. Większość pomiarów grubości tkanek miękkich u dzieci była istotnie mniejsza niż u dorosłych.

STRESZCZENIE W JĘZYKU ANGIELSKIM

The assessment of the soft tissue facial profile in relation to the facial morphology

INTRODUCTION

The assessment of a patient's facial profile is important in the diagnosis and planning of orthodontic treatment. Soft tissues can vary significantly in thickness, potentially masking the presence of significant dentofacial defects. In recent years, there has been an increasing interest in the morphology of the soft tissues facial profile (STFP) in the diagnosis of orthodontic patients. The analysis of the cephalometric radiographs head's is commonly used to evaluate the characteristics of the STFP. The literature reports conflicting findings regarding the STFP thickness in relation to the existing skeletal malocclusion in adults. However, there is limited evidence on the STFP in growing patients and age-related changes. Currently, orthodontists increasingly use artificial intelligence (AI) algorithms in cephalometric analysis. Despite a rapid development in AI's in different medical fields in recent years, clinicians still have concerns about the reliability of measurements obtained through automated cephalometric point marking by AI. Additionally, AI algorithms have a limited number of soft tissue measurements, although STFP morphology can significantly influence the planning of orthodontic treatment.

AIM

The aims of the study were:

1. to summarize the data from current literature regarding the influence of factors such as skeletal class or patient gender on the thickness of the STFP,
2. to assess the use and effectiveness of AI algorithms in orthodontic diagnostics based on studies assessing different types of AI algorithms,
3. to evaluate the relationship between STFP thickness and the skeletal malocclusion,
4. to compare the STFP thickness in different age groups,
5. to compare the STFP thickness in males and females.

MATERIAL AND METHODS

In the first publication, a literature review from 2002-2020 was conducted using the PubMed database, summarizing information on existing relationships between STFP morphology and the type of skeletal malocclusion and gender of the subjects. Due to existing discrepancies in the literature, the scarce evidence regarding the assessment of the STFP in children, and the lack of a similar study in the Polish population, a decision was made to conduct an own study.

In the second publication, a literature review was conducted to summarize information on the accuracy of AI algorithms in orthodontic diagnostics based on the cephalometric analysis. The PubMed, Medline, Scopus, and Dentistry & Oral Sciences Source databases from 2009-2023 were searched.

The third paper was a retrospective study evaluating the relationships between the thickness of the STFP and skeletal malocclusion, age, and gender. The study included Caucasian patients aged 7-35 who presented for orthodontic treatment at the Department of Orthodontics of the Medical University of Warsaw from 2019-22. The patients had cephalometric radiographs taken before starting orthodontic treatment. Exclusion criteria included patients with dentofacial deformities and facial traumas, previous prosthetic or surgical treatment, soft tissue augmentation procedures, lip incompetence, and poor-quality radiographs. The cephalometric analysis was performed in all enrolled patients which included the analysis of the STFP. Patients were assigned to one of the six study groups based on age and existing skeletal relationships (ANB angle). The minimum number of patients in each group was set at 60 with an equal gender distribution. The STFP analysis included ten linear measurements.

Statistical Analysis

In the retrospective study, the STFP thickness at different measurement sites was compared between groups. Due to the unknown mean and standard deviation of the assessed parameters for the population from which the evaluated samples were derived, the Lilliefors test was used for normality analysis. The analysis showed a lack of conformity with the normal distribution for most assessed parameters; therefore, non-parametric tests were used: the Mann-Whitney U test and the Kruskal-Wallis ANOVA test. Statistical analysis was performed using PQStat v. 1.6.8 software. A significance threshold of $p < 0.05$ was assumed. Twenty randomly selected radiographs were re-analyzed at four-week intervals. The results were then compared with the

results of the previous cephalometric analysis. The intraclass correlation coefficient (ICC) was used to determine the correlation between the first and second measurements. High repeatability of measurements was found ($p < 0.001$), with ICC values > 0.90 for most parameters, except for (U1-St and B-Lms), where values were 0.89 and 0.87, respectively.

RESULTS

The literature review on the differences in STFP thickness showed the presence of sexual dimorphism. In men, the thickness of the lips, soft tissues in the subnasal area, labiomental fold, and chin were significantly higher than in women. Additionally, there was a tendency for STFP to compensate for the underdevelopment of the maxilla or mandible or their retrusive position.

The database review on the effectiveness of AI algorithms used for cephalometric analysis confirmed that most AI algorithms used for automatic detection of cephalometric points were relatively accurate. However, the effectiveness of using AI in cephalometry varies depending on the algorithm or application, which should be considered when interpreting the results.

The retrospective study involved 300 patients who were assigned to five groups. Group 6 (growing patients with skeletal Class III) was not included in the study as the assumed group size was not achieved. Significant differences in the thickness of the STFP were found depending on the type of skeletal malocclusion. In adults with skeletal Class III, the thickness of the subnasal tissues was significantly increased compared to patients with skeletal Class I and Class. The thickness of the lower lip in patients with skeletal Class II was significantly increased compared to other groups. Children and adolescents with skeletal Class II had thicker lower lips compared to the group with skeletal Class I. Most measurements of the STFP were significantly smaller in children and adolescents compared to adults. The thickness of the STFP in males was significantly greater in all age groups compared to females.

CONCLUSIONS

1. There is a relationship between the thickness of the STFP and the presence of skeletal malocclusion and gender, which is important in planning orthodontic treatment in patients with skeletal abnormalities.
2. AI algorithms can be successfully used in orthodontic diagnostics, but their effectiveness depends on the quality of the data entered the analysis, the number and quality of cephalometric radiographs, and the type of AI algorithms or applications.
3. There is a relationship between the thickness of the STFP and the skeletal malocclusion, with compensation present in the area of insufficient anterior growth of the maxilla or mandible.
4. The thickness of the STFP varies depending on the age of the patients and is increased in adults.
5. Sexual dimorphism in the thickness of the STFP was found, with greater thickness in male subjects compared to females, both in adults and children and adolescents

Wstęp uzasadniający połączenie wskazanych publikacji w jeden cykl, jak i komentujący osiągnięcie naukowe kandydata na tle dotychczasowego stanu wiedzy.

Tkanki miękkie profilu twarzy (TMPT) stanowią obiekt zainteresowania specjalistów z wielu dziedzin medycyny. Mają one znaczenie w diagnostyce i planowaniu leczenia w zakresie ortodoncji oraz chirurgii plastycznej. Różnice w ich grubości wykorzystywane są również w antropologii oraz medycynie sądowej.

Estetyka twarzy pacjentów leczonych ortodontycznie zależy nie tylko od wielkości i wzajemnej pozycji szczęki i żuchwy lub pozycji i nachylenia zębów siecznych siekaczy. Istotny wpływ na nią mogą mieć również tkanki miękkie pokrywające struktury twarde twarzoczaszki, w tym ich harmonia, proporcje oraz grubość.

Analiza cefalometryczna teleradiogramów bocznych głowy jest powszechnie używana do celów diagnostyki i planowania leczenia ortodontycznego. Umożliwia ona analizę morfologii twarzoczaszki w płaszczyźnie strzałkowej oraz pionowej, oceniając wzajemne stosunki pomiędzy kośćmi twarzoczaszki oraz zębami. Na teleradiogramach widoczny jest także zarys TMPT pacjenta, który umożliwia uwzględnienie ich pomiarów w przeprowadzanej analizie cefalometrycznej.

Obecnie coraz powszechniej ortodenci wykorzystują algorytmy sztucznej inteligencji (*AI, Artificial Intelligence*) do przeprowadzania analizy cefalometrycznej. Opracowano różne metody zastosowania AI do wykonania analizy cefalometrycznej, które mają na celu zmniejszenie obciążenia klinicysty i oszczędność jego czasu. Także algorytmy AI mogą być pomocne dla mniej doświadczonych ortodontów w oznaczaniu punktów cefalometrycznych. Dokładność automatycznej identyfikacji punktów przez AI podczas analizy cefalometrycznej różni się w zależności od typu zastosowanego algorytmu, jednak większość z nich wykazuje stosunkowo wysoką dokładność. Można oczekiwać, że w przyszłości automatyczne lokalizowanie punktów wykorzystywanych w analizie cefalometrycznej będzie bardziej dokładne niż analiza manualna, a zwiększona dostępność algorytmów AI dla lekarzy oraz możliwości personalizacji wykonywanych pomiarów umożliwi w większym zakresie badanie grubości oraz relacji TMPT w diagnostyce ortodontycznej.

Wyniki opublikowanych badań dotyczących analizy tkanek miękkich twarzoczaszki prezentują rozbieżne wyniki, jeżeli chodzi o zależność grubości TMPT a obecnością kostnej wady zgryzu w płaszczyźnie strzałkowej u pacjentów dorosłych. Istnieją doniesienia potwierdzające obecność kompensacji szkieletowych wad zgryzu przez tkanki miękkie,

zgodnie z czym u pacjentów z gnatyczną wadą doprzednią tkanki miękkie okolicy podnosowej i wargi górnej miały większą grubość, natomiast u pacjentów z wadą dotylną warga dolna cechowała się większą grubością. W grupie dzieci niewiele uwagi poświęcano temu zagadnieniu. Wyniki aktualnie dostępnych badań wskazują również na obecność dymorfizmu płciowego w zakresie grubości TMPT u osób dorosłych, jednakże ilość przeprowadzonych badań na ten temat dotyczących pacjentów roznących jest ograniczona. Także nie opublikowano dotychczas badań porównujących różnice w grubości TMPT między dziećmi a dorosłymi.

Ze względu na rozbieżności w wynikach opublikowanych badań, niewielką liczbę doniesień naukowych dotyczących grubości TMPT w grupie pacjentów w wieku rozwojowym oraz brak badań oceniających grubość TMPT w populacji polskiej zdecydowałem się przeprowadzić badanie własne którego celem była ocena i porównanie grubości TMPT w zależności od klasy szkieletowej wady zgryzu, wieku i płci pacjentów ortodontycznych.

W pierwszej pracy cyklu rozprawy doktorskiej pt. **„Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa”** przeprowadzono przegląd piśmiennictwa i podsumowano informacje na temat istniejących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią badanych. Przeszukano w tym celu bazę danych PubMed z wykorzystaniem słów kluczowych facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth z lat 2002-2020 roku w języku angielskim.

W drugiej pracy cyklu rozprawy doktorskiej pt. **„Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review”** dokonano przeglądu piśmiennictwa dotyczącego skuteczności różnych rodzajów algorytmów AI w analizie cefalometrycznej radiogramów bocznych głowy. Przeszukano bazy danych PubMed, Medline, Scopus oraz Dentistry & Oral Sciences Source z lat 2009-2023 wykorzystując słowa kluczowe takie jak: artificial intelligence i cephalometric analysis.

Trzecia praca cyklu rozprawy doktorskiej pt. **„Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age”** jest pracą oryginalną o charakterze badania retrospektywnego. Kryteria włączenia do badania obejmowały wszystkich pacjentów ortodontycznych którzy zgłosili się w celu leczenia ortodontycznego w Zakładzie Ortodoncji WUM w latach 2019-22 u których zostały wykonane teleradiogramy boczne głowy. Kryteriami wyłączenia był wiek powyżej 7 lat i poniżej 35 lat, obecność wad wrodzonych i urazów w obrębie twarzoczaszki, wcześniejsze leczenie protetyczne lub chirurgiczne, jak

również zabiegi augmentacji tkanek miękkich, niekompetencja warg oraz niska jakość zdjęć rentgenowskich. U wszystkich pacjentów przeprowadzono cyfrową analizę cefalometryczną teleradiogramów bocznych głowy w programie DDP-Ortho 2.10.2022 (Polorto, Częstochowa, Polska). Pacjenci zostali podzieleni na 6 grup w zależności od wieku oraz szkieletowej klasy wady zgryzu, w oparciu o wartość kąta ANB. Analiza cefalometryczna obejmowała 10 pomiarów liniowych grubości TMPT. Uzyskane wyniki porównano pomiędzy grupami oraz poddano analizie statystycznej z zastosowaniem oprogramowania PQStat v. 1.6.8. Wykazano różnice w grubości tkanek miękkich w zależności od klasy szkieletowej. U dorosłych z III klasą szkieletową wykazano istotnie zwiększoną grubość tkanek miękkich okolicy podnosowej oraz wargi górnej w porównaniu do pacjentów z I i II klasą szkieletową, zaś grubość wargi dolnej była istotnie większa w II klasy szkieletowej w porównaniu do pozostałych grup. Dzieci z II klasą szkieletową miały grubszą wargę dolną niż dzieci z I klasą szkieletową. Wykazano również, że tkanki miękkie profilu twarzy mężczyzn we wszystkich grupach wiekowych są istotnie grubsze w porównaniu do kobiet. Większość pomiarów grubości tkanek miękkich u dzieci była istotnie mniejsza niż u dorosłych.

Założenia i cele pracy

Celami pracy było:

1. podsumowanie danych z aktualnego piśmiennictwa dotyczących zależności między czynnikami takimi jak klasa szkieletowa lub płeć pacjenta a grubością TMPT,
2. ocena możliwości wykorzystania algorytmów sztucznej inteligencji i jej skuteczności w diagnostyce ortodontycznej w oparciu o badania wykorzystujące różne typy algorytmów AI,
3. ocena zależności między grubością TMPT a klasą szkieletową wady zgryzu pacjenta,
4. porównanie grubości TMPT u osób w różnych grupach wiekowych,
5. porównanie grubości TMPT u mężczyzn i kobiet.

KOPIE OPUBLIKOWANYCH PRAC

Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci Przegląd piśmiennictwa

Differences in the facial soft tissue thickness depending on the skeletal class and sex Literature review

Michał Kielczykowski ^{ABD} (ORCID ID: 0000-0003-1965-4584)

Małgorzata Zadurska ^{EF} (ORCID ID: 0000-0002-2303-4102)

Ewa Czochrowska ^{EF} (ORCID ID: 0000-0003-1009-6483)

Konrad Perkowski ^{AEEF} (ORCID ID: 0000-0002-6188-9670)

Wkład autorów: ^A Plan badań ^B Zbieranie danych ^C Analiza statystyczna ^D Interpretacja danych
^E Redagowanie pracy ^F Wyszukiwanie piśmiennictwa

Authors' Contribution: ^A Study design ^B Data Collection ^C Statistical Analysis ^D Data Interpretation
^E Manuscript Preparation ^F Literature Search

Zakład Ortodontji, Warszawski Uniwersytet Medyczny
Department of Orthodontics, Medical University of Warsaw

Streszczenie

Ocena profilu twarzy pacjenta ma istotne znaczenie w diagnostyce oraz planowaniu leczenia ortodontycznego. Tkanki miękkie mogą się znacznie różnić grubością, a przez to maskować występowanie istotnych zaburzeń szkieletowo-zębowych. **Cel.** Celem pracy było przedstawienie danych z aktualnego piśmiennictwa dotyczących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią pacjenta. **Materiał i metody.** Wykorzystując bazę danych PubMed, wyszukano artykuły na temat istniejących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią badanych z lat 2002–2020, z użyciem słów kluczowych: facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth. **Wyniki.**

Abstract

The assessment of the patient's facial profile is an essential factor in diagnosing and planning orthodontic treatment. Soft tissues can vary considerably in thickness, thus masking the presence of significant skeletal and dental abnormalities. **Aim.** The purpose of this paper was to present data from the current literature on the relationship between the facial soft tissue thickness and skeletal class and patient's sex. **Material and methods.** Using the PubMed database, we reviewed the literature from 2002–2020 regarding existing correlations between facial soft tissue thickness and skeletal class and sex of subjects using the following key words: facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth. **Results.** There is sexual

Adres do korespondencji/Correspondence address:

Michał Kielczykowski
Zakład Ortodontji, Warszawski Uniwersytet Medyczny
ul. Binieckiego 6, 02-097 Warszawa
e-mail: kielczykowski.michal@gmail.com



Copyright: © 2005 Polish Orthodontic Society. This is an Open Access journal, all articles are distributed under the terms of the Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International (CC BY-NC-SA 4.0) License (<http://creativecommons.org/licenses/by-nc-sa/4.0/>), allowing third parties to copy and redistribute the material in any medium or format and to remix, transform, and build upon the material, provided the original work is properly cited and states its license.

W zakresie grubości tkanek miękkich profilu twarzy występuje dymorfizm płciowy. U mężczyzn wartości pomiarów grubości warg, tkanek miękkich okolicy podnosowej, bruzdy wargowo-bródkowej oraz okolicy bródki są statystycznie wyższe niż u kobiet. Istnieje tendencja do kompensacji przez tkanki miękkie miejsc niedorozwoju lub dotylnej pozycji kości szczęki lub żuchwy. U pacjentów z III klasą szkieletową, na skutek niedorozwoju szczęki bądź nadmiernego poziomego wzrostu żuchwy, tkanki miękkie pokrywające okolice podnosową oraz wargę górną mają większą grubość niż u osób z II klasą szkieletową. Analogicznie, w przypadku pacjentów z II klasą szkieletową, u których profil wypukły wynika z dotylnego położenia lub niedorozwoju żuchwy, grubość wargi dolnej jest odpowiednio większa niż w przypadku pacjentów z III klasą szkieletową. **Wnioski.** Biorąc pod uwagę obowiązujący paradygmat tkanek miękkich, kompensacja w zakresie tkanek miękkich szkieletowej wady zgryzu może mieć istotne znaczenie w planowaniu leczenia ortodontycznego. **(Kiełczykowski M, Zadurska M, Czochrowska E, Perkowski K. Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa. Forum Ortod 2022; 18 (4): 230-6).**

Nadesłano: 17.11.2022

Przyjęto do druku: 16.01.2023

<https://doi.org/10.5114/for.2022.126062>

Słowa kluczowe: wady zgryzu, analiza cefalometryczna, analiza profilu twarzy, analiza tkanek miękkich, klasy szkieletowe

Wstęp

Pomiary grubości tkanek miękkich twarzowej części czaszki wykorzystywane są przede wszystkim w ortodontji, chirurgii plastycznej, archeologii oraz w medycynie sądowej w celu identyfikacji osób zmarłych. W przeszłości, w kryminalistyce i medycynie sądowej, do rekonstrukcji wyglądu twarzy człowieka wykorzystywano metodę Gierasimowa (1). Obecnie w tym celu wykorzystuje się głównie techniki komputerowe.

Profil twarzy pacjenta i grubość tkanek miękkich mają istotne znaczenie w diagnostyce oraz w planowaniu leczenia ortodontycznego. Ackerman i wsp. zaproponowali paradygmat, w którym tkanki miękkie profilu twarzy stanowią zarówno cel, jak i największe ograniczenie leczenia (2). Ich prawidłowe relacje, na równi z warunkami zwarciovymi, stanowią zarówno o optymalnej stabilności leczenia, jak i o idealnej estetyce twarzy. Zmiany zębowe i szkieletowe konieczne w planowanym leczeniu ortodontycznym muszą brać pod uwagę dostępne granice adaptacji tkanek miękkich. Holdaway wykazał, że osiągnięcie harmonijnych rysów twarzy pacjenta wymaga wiedzy, jak profil twarzy zmienia się wraz z ruchem zębów (3). Uważał, że w każdym przypadku planowanie leczenia

dimorphism in the facial soft tissue thickness. In men, the values for thickness measurements of the lips, the soft tissues of the subnasal area, the mentolabial sulcus, and the chin area are statistically higher than in women. There is a tendency of soft tissue compensation in the areas of underdevelopment or a posterior position of the maxillary or mandibular bone. In patients with skeletal class III, due to maxillary hypoplasia or excessive horizontal mandibular growth, the soft tissues covering the subnasal region and upper lip are thicker than those in skeletal class II patients. Similarly, for patients with skeletal class II, whose convex profile is due to the posterior position or mandibular hypoplasia, the lower lip thickness is respectively more significant than that of patients with skeletal class III. **Conclusions.** Considering the current soft-tissue paradigm, the soft tissue compensation of a skeletal malocclusion may have essential implications for orthodontic treatment planning. **(Kiełczykowski M, Zadurska M, Czochrowska E, Perkowski K Differences in the facial soft tissue thickness depending on the skeletal class and sex. Literature review. Orthod Forum 2022; 18 (4): 230-6).**

Received: 17.11.2022

Accepted: 16.01.2023

<https://doi.org/10.5114/for.2022.126062>

Key words: malocclusion, cephalometric analysis, facial profile analysis, soft tissue analysis, skeletal classes

Introduction

Facial soft tissue thickness measurements are used primarily in orthodontics, plastic surgery, archaeology, and forensics to identify deceased persons. In the past, the Gierasimov method (1) was used in criminology and forensic medicine to reconstruct the appearance of a person's face. Today, computer techniques are mainly used for this purpose.

The patient's facial profile and soft tissue thickness are essential factors in diagnosing and planning orthodontic treatment. Ackerman et al. proposed a paradigm in which the facial soft tissues represent both the target and the most significant limitation of treatment (2). Their correct relationships, on a par with occlusal conditions, account for both optimal treatment stability and ideal facial aesthetics. The dental and skeletal changes necessary in planned orthodontic treatment must consider the available limits of soft tissue adaptation. Holdaway showed that achieving harmonious facial features in a patient required knowledge of how the facial profile changed with tooth movement (3). He believed that treatment planning should include an analysis of the

powinno obejmować analizę profilu twarzy pacjenta. W roku 1983 opracował własną analizę cefalometryczną w oparciu o analizę profilu twarzy. Arnett i wsp. zwrócili uwagę na fakt, że leczenie ortodontyczne, mimo poprawy warunków zgryzowych, nie zawsze prowadzi do polepszenia czy wręcz zachowania estetyki twarzy przed rozpoczęciem leczenia (4). Planowanie terapii oparte głównie na wynikach pomiarów analizy cefalometrycznej tkanek twardych może prowadzić do zaburzeń estetyki. Zaprezentowana w roku 1999 Soft Tissue Cephalometric Diagnosis (STCD) obejmowała kompleksową analizę struktur twarzy. Tkanki miękkie twarzy, które sąsiadują z zębami i kośćmi szczęk, mogą znacznie różnić się swoją grubością i w efekcie ukrywać lub maskować występowanie istotnych zaburzeń szkieletowo-zębowych (5).

Cel

Celem pracy było przedstawienie danych z aktualnego piśmiennictwa dotyczących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią pacjenta.

Materiał i metody

Korzystając z bazy danych PubMed, dokonano przeglądu piśmiennictwa z lat 2002–2020 i podsumowano informacje na temat istniejących zależności między grubością tkanek miękkich profilu twarzy a klasą szkieletową oraz płcią badanych. Użyto następujących haseł wyszukiwania: facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth. Po usunięciu duplikatów na podstawie przyjętych kryteriów wybrano 21 prac pełnotekstowych.

Wyniki

Różnice w odniesieniu do płci

Grubość tkanek miękkich profilu twarzy badano na wiele sposobów, wykorzystując teloradiogramy boczne głowy, tomografię komputerową wiązki stożkowej (CBCT), tomografię komputerową (CT), rezonans magnetyczny (MR) oraz punkcję igłową wykonywaną na zmarłych (6–25). Metodą najczęściej stosowaną jest analiza cefalometryczna teloradiogramów bocznych głowy. Zdjęcia są wykonywane rutynowo w diagnostyce ortodontycznej i wymagają niewielkiej dawki promieniowania jonizującego.

W większości analizowanych badań wykazano istnienie dymorfizmu płciowego w obrębie grubości tkanek miękkich profilu twarzy (6–10,13, 16). Większe wartości pomiarów tkanek miękkich profilu twarzy (TMPT) uzyskano u mężczyzn we wszystkich bądź prawie wszystkich miejscach pomiarowych, w porównaniu do kobiet. W badaniu Sarilita i wsp. najbardziej istotne różnice uzyskano w obrębie punktów pomiarowych N-N', Rhi-Rhi', A-Sn, Pr-Ls, U1-St oraz Id-Li (8). Gungor i wsp. wykazali statystycznie istotne

patient's facial profile in every case. In 1983, he developed his own cephalometric analysis based on facial profile analysis. Arnett et al. pointed out that despite improving occlusal conditions, orthodontic treatment did not always lead to improvement or even preservation of facial aesthetics before treatment (4). Treatment planning based mainly on the results of cephalometric analysis of hard tissues can lead to aesthetic disorders. Presented in 1999, Soft Tissue Cephalometric Diagnosis (STCD) included a comprehensive analysis of facial structures. The facial soft tissues adjacent to the teeth and jawbones can vary significantly in their thickness and, as a result, hide or mask the presence of significant skeletal and dental abnormalities (5).

Aim

The purpose of this paper was to present data from the current literature on the relationship between the facial soft tissue thickness and skeletal class and patient's sex.

Material and methods

Using the PubMed database, we reviewed the literature from 2002–2020 and summarised information on existing relationships between the facial soft tissue thickness and skeletal class, as well as the sex of the subjects. The following search terms were used: facial soft tissue thickness, malocclusion, skeletal class, facial soft tissue depth. After removing duplicates, 21 full-text papers were selected based on the pre-selected criteria.

Results

Sex differences

Facial soft tissue thickness has been studied in several ways, using lateral cephalograms, cone beam computed tomography (CBCT), computed tomography (CT), magnetic resonance (MR), and needle puncture performed on the deceased (6–25). Cephalometric analysis of lateral cephalograms is the most common method. The images are routinely taken for orthodontic diagnosis and require a low dose of ionizing radiation.

Most of the studies analysed showed sexual dimorphism within the facial soft tissue thickness (6–10,13, 16). Larger facial soft tissue thickness (FSTT) values were obtained in men at all or almost all measurement sites compared to women. In the Sarilita et al. study, the most significant differences were obtained for the N-N', Rhi-Rhi', A-Sn, Pr-Ls, U1-St, and Id-Li measurement points (8). Gungor et al. showed statistically significant differences in the thickness between men and women in each of the points analysed, except Pg-Pg' (9). According to Kamak et al., sexual dimorphism in terms of FSTT is marked particularly significantly in terms of thickness measurements in the subnasal region, upper lip, and lower lip (13).

Differences in the facial soft tissue thickness depending on the skeletal class and sex. Literature review

różnice grubości między kobietami i mężczyznami w każdym z badanych punktów z wyjątkiem Pg-Pg' (9). Według Kamak i wsp. dymorfizm płciowy w zakresie TMPT jest zaznaczony szczególnie istotnie w zakresie pomiarów grubości okolicy podnosowej, wargi górnej oraz wargi dolnej (13).

Do podobnych wniosków doszli inni badacze stosujący analizę Arnetta (14, 15). Różnice były wyraźnie zaznaczone w obrębie wargi górnej, dolnej oraz w obrębie pomiarów Pg-Pg', Me-Me'.

Dymorfizm płciowy wykazano również w analizie wyników badań CBCT prowadzonych przez Hwang i wsp. oraz Gomes i wsp., gdzie pomiary górnej i dolnej wargi, jak również w zakresie N-N' oraz bruzdy wargowo-bródkowej osiągały większe wartości u mężczyzn (20, 22). Różnice w grubości tkanek miękkich profilu twarzy wykazano również w badaniu na dokumentacji MR, gdzie mężczyźni mieli grubsze TMPT w zakresie wargi górnej, dolnej oraz okolicy podnosowej (24). W badaniu prowadzonym jednocześnie na zdjęciach CT oraz MR wykazano istotnie statystycznie grubsze tkanki miękkie twarzy u mężczyzn w porównaniu do kobiet w większości miejsc pomiarowych w płaszczyźnie strzałkowej (23). Badania prowadzone przez Celikoglu i wsp. na grupie osób z I klasą szkieletową dały podobne wnioski, potwierdzając istnienie dymorfizmu płciowego, gdzie w zakresie pomiarów obejmujących wargę górną, dolną oraz okolice bródki mężczyźni wykazywali grubsze TKPT (21). Badania Perović i wsp. pokazują, że tkanki miękkie okolicy podnosowej oraz warg u mężczyzn były istotnie grubsze w I oraz II/2 klasie szkieletowej, natomiast w II/1 większe wartości pomiarów G-G', B-SLI oraz Pg-Pg' zauważono u kobiet (17). Wang i wsp. wykazali, że TMPT u mężczyzn są istotnie grubsze niż u kobiet w obrębie Pr-Ls, U1-St oraz Id-Li w grupach z I klasą szkieletową, G-G' i Rhi-Rhi' w grupach z II klasą szkieletową oraz Rhi-Rhi' i Pr-Ls w grupach z III klasą szkieletową (26).

W analizie grubości tkanek miękkich profilu twarzy u chłopców i dziewcząt pochodzących z Brazylii, poza Rhi-Rhi', Sn-A, oraz Pr-Ls, nie stwierdzono istotnie statystycznych różnic (11). Wyniki te mogą nie odzwierciedlać różnic płciowych, które mogłyby uwidocznić się wraz z osiągnięciem dojrzałości, ponieważ badanie prowadzono wśród dzieci w wieku od 8–12 lat, a więc w czasie, w którym wzrost i rozwój kości oraz tkanek miękkich nie jest jeszcze zakończony. To założenie jest zgodne z wynikami badań prowadzonych na dzieciach i młodzieży populacji japońskiej przez Utsuno i wsp., z którego wynika, że nie ma różnic w grubości TMPT pomiędzy chłopcami i dziewczętami poniżej 11 roku życia, a dymorfizm płciowy zaczyna być widoczny u dzieci dopiero od 12 roku życia (12). Statystycznie istotne różnice zauważono dopiero w grupie od 16 do 18 roku życia, gdzie u osób płci męskiej wartości pomiarów wargi górnej, dolnej oraz okolicy podnosowej były większe niż u osób płci żeńskiej.

Badanie Domaracki i wsp., prowadzone na ciałach zmarłych za pomocą punkcji igłowej, nie wykazało żadnych różnic istotnych statystycznie między grubością TMPT u kobiet oraz u mężczyzn (25).

Other researchers using Arnett's analysis have reached similar conclusions (14, 15). Differences were clearly marked within the upper lip, lower lip, and within the Pg-Pg', Me-Me' measurements.

Sexual dimorphism was also shown in the analysis of CBCT results by Hwang et al. and Gomes et al. where measurements of the upper and lower lip, as well as in the N-N' and mentolabial sulcus, reached higher values in men (20, 22). Differences in facial soft tissue thickness were also shown in a study using MR documentation, where men had larger values of FSTT in the upper lip, lower lip, and in the subnasal region (24). A study conducted simultaneously on CT and MR images showed statistically significantly thicker facial soft tissues in men compared to women at most measurement sites in the sagittal plane (23). Research conducted by Celikoglu et al. on a group of skeletal class I subjects yielded similar conclusions, confirming the existence of sexual dimorphism, where, in terms of measurements including the upper lip, lower lip, and chin area, men showed thicker FSTT (21). Research by Perović et al. shows that the soft tissues of the subnasal region and lips in men were significantly thicker in skeletal class I and II/2, while in II/1 larger values of G-G', B-SLI and Pg-Pg' measurements were noted in women (17). Wang et al. showed that FSTT values in men are significantly higher than in women within Pr-Ls, U1-St and Id-Li in skeletal class I groups, G-G' and Rhi-Rhi' in skeletal class II groups, and Rhi-Rhi' and Pr-Ls in skeletal class III groups (26).

No significant statistical differences were found in the analysis of facial soft tissue thickness in boys and girls of Brazilian origin, except for Rhi-Rhi', Sn-A, and Pr-Ls (11). These results may not reflect sex differences that could become apparent with maturity, as the study was conducted among children between the ages of 8 and 12, namely when bone and soft tissue growth and development are not yet complete. This assumption is consistent with the results of research conducted on children and adolescents of the Japanese population by Utsuno et al., which shows that there are no differences in the FSTT between boys and girls under the age of 11 years, and that sexual dimorphism does not begin to become apparent in children until the age of 12 years (12). Statistically significant differences were noted only in the group from 16 to 18 years of age, where the male subjects had higher values of measurements of the upper lip, lower lip, and the subnasal region than the female subjects.

A study by Domaracki et al. conducted on deceased bodies by needle puncture found no statistically significant differences between FSTT in women and men (25).

Differences in relation to the skeletal class

The results of most studies indicate that there is no correlation between FSTT and skeletal class (G-G', N-N' and Rhi-Rhi' measurements) in the upper face (8, 13, 16, 18, 19, 22).

Różnice w odniesieniu do klasy szkieletowej

Wyniki większości badań wskazują, że nie istnieje korelacja między grubością TMPT a klasą szkieletową (pomiaru G-G', N-N' oraz Rhi-Rhi') w górnym odcinku twarzy, (8, 13, 16, 18, 19, 22). Odmienne wyniki grubości TMPT w zakresie pomiaru N-N' uzyskano w badaniach Kurcuoglu i wsp., gdzie wykazano, że u mężczyzn z III klasą szkieletową pomiar N-N' był najmniejszy spośród pozostałych grup (10). W badaniach Hamid i wsp. ten pomiar był największy w grupie mężczyzn z I klasą szkieletową (6). Wyniki Gungor i wsp. wskazywały na najcieńsze TMPT w rejonie N-N' u kobiet z I klasą szkieletową, w porównaniu do klasy II i III (9).

Wielu badaczy wykazało istotnie większą grubość tkanek miękkich okolicy podnosowej wyrażonej pomiarem A-Sn u kobiet z III klasą szkieletową, w porównaniu z grupą kobiet z II klasą szkieletową (8, 16, 18, 19). Hamid i wsp. w swoich badaniach wykazali tą samą zależność zarówno u kobiet, jak i u mężczyzn (6). Większą grubość wargi górnej, tj. pomiar Pr-Ls, miały kobiety z klasą III, w porównaniu do kobiet z II klasą szkieletową (8, 10, 18, 19). Taką samą zależność w grupie mężczyzn wykazali inni badacze (6, 9, 16). W badaniach Kamak i wsp. warga górna była istotnie grubsza w III niż w II klasie szkieletowej zarówno u kobiet, jak i mężczyzn (13). Większe wartości pomiaru U1-St wyrażającego grubość TMPT wykazano w grupie III klasy szkieletowej, w porównaniu z II klasą zarówno u kobiet, jak u mężczyzn (6, 13). Podobne wnioski wyciągnęli inni badacze w grupie mężczyzn oraz w grupie kobiet (8, 10, 16, 19). W licznych badaniach wykazano również, że grubość wargi dolnej wyrażona pomiarem Id-Li jest znacząco większa u osób z II klasą szkieletową niż z III klasą szkieletową, zarówno u kobiet jak i u mężczyzn (6, 8, 9, 10, 13). W badaniach Chu i wsp. na populacji kobiet wykazano identyczną zależność (19).

W wielu badaniach nie stwierdzono istotnych różnic w grubości TMPT w zakresie pomiaru B-Lms zarówno u kobiet, jak i u mężczyzn (9, 10, 13, 16). Odmienne wyniki uzyskano w badaniach Sarlita i wsp. oraz Hajime i wsp., w których tkanki miękkie w okolicy bruzdy wargowo-bródkowej, wyrażone pomiarem B-Lms, przyjmowały najwyższe wartości u kobiet z II klasą szkieletową (8, 18). Grubość tkanek miękkich profilu twarzy pokrywających bródkę w wymiarze przednio-tylnym (Pg-Pg') jak i pionowym (Me-Me') nie wykazywały różnic pomiędzy klasami szkieletowymi zarówno u kobiet, jak i mężczyzn (8, 9, 13, 16).

Dyskusja

Badania przytoczone w tej pracy były prowadzone na różnych populacjach, tj. sudańskiej, japońskiej, indonezyjskiej, tureckiej, brazylijskiej, hinduskiej, koreańskiej, irackiej, chińskiej, kaukaskiej oraz australijskiej (6–26). Mimo zróżnicowania etnicznego osób stanowiących grupy badawcze wyniki większości z nich są zgodne odnośnie istnienia zależności między grubością tkanek miękkich profilu twarzy a płcią oraz klasą szkieletową pacjenta.

Different results of FSTT in terms of the N-N' measurement were obtained in research by Kurcuoglu et al. where it was shown that men with skeletal class III had the lowest N-N' measurement among the other groups (10). In the studies by Hamid et al., this measurement was the greatest in a group of men with skeletal class I (6). The results of Gungor et al. indicated the lowest values of FSTT in the N-N' region in women with skeletal class I, compared to class II and III (9).

Many researchers have shown significantly greater soft tissue thickness of the subnasal region expressed by the A-Sn measurement in women with skeletal class III, compared to a group of women with skeletal class II (8, 16, 18, 19). In their research, Hamid et al. showed the same relationship in both women and men (6). Greater upper lip thickness, i.e. Pr-Ls measurement, was found in women with skeletal class III, compared to women with skeletal class II (8, 10, 18, 19). The same relationship in the male group has been shown by other researchers (6, 9, 16). In the studies by Kamak et al., the upper lip was significantly thicker in skeletal class III than in skeletal class II in both women and men (13). Larger values of the U1-St measurement expressing corresponding to FSTT were shown in the skeletal class III group, compared to class II in both women and men (6, 13). Other researchers have reached similar conclusions for the male and female groups (8, 10, 16, 19). Numerous studies have also shown that lower lip thickness expressed by the Id-Li measurement is significantly greater in patients with skeletal class II than skeletal class III, in both men and women (6, 8, 9, 10, 13). The research by Chu et al. on a female population showed an identical relationship (19).

Many studies have found no significant differences in FSTT in relation to the B-Lms measurement in both women and men (9, 10, 13, 16). Different results were obtained in the studies by Sarlit et al. and Hajime et al. in which the soft tissues in the region of the mentolabial sulcus expressed by the B-Lms measurement, showed the highest values in women with skeletal class II (8, 18). The thickness of facial soft tissues covering the chin in both the anteroposterior (Pg-Pg') and vertical (Me-Me') dimensions showed no differences between skeletal classes in both men and women (8, 9, 13, 16).

Discussion

The research cited in this paper was conducted on different populations, i.e. Sudanese, Japanese, Indonesian, Turkish, Brazilian, Indian, Korean, Iraqi, Chinese, Caucasian, and Australian (6–26). Despite the ethnic diversity of individuals in the study groups, the results of most of them are consistent in that there is a relationship between the facial soft tissue thickness and the sex and skeletal class of patients.

The results of the studies presented suggest that there is a correlation between the patient's skeletal class and the facial soft tissues thickness in terms of the thickness of the

Wyniki opisanych badań sugerują istnienie zależności między klasą szkieletową pacjenta a tkankami miękkimi profilu twarzy w zakresie grubości wargi górnej i dolnej oraz okolicy podnosowej. Może to wynikać z tendencji do kompensacji tkanek miękkich w miejscach niedorozwoju lub dotylnej pozycji kości szczęki lub żuchwy. U pacjentów z III klasą szkieletową o wklęsłym profilu twarzy na skutek niedorozwoju szczęki lub nadmiernego poziomego wzrostu żuchwy, tkanki miękkie pokrywające okolice podnosową oraz wargę górną, wyrażone pomiarami: A-Sn, Pr-Ls, U1-St, mają większą grubość niż u osób z II klasą szkieletową. Analogicznie w przypadku pacjentów z II klasą szkieletową, u których profil wypukły wynika z dotylnego położenia lub niedorozwoju żuchwy, grubość wargi dolnej wyrażona pomiarem Id-Li jest odpowiednio większa niż w przypadku pacjentów z III klasą szkieletową.

Innym wytłumaczeniem wymienionych zależności może być fakt istnienia kompensacji zębowo-wyrostkowej towarzyszącej wadom szkieletowym oraz ich wpływ na podparcie okolicy wargi górnej i dolnej. W wadach szkieletowych klasy III obejmuje ona wychylenie górnych zębów przednich oraz przechylenie dolnych siekaczy. To wychylenie górnych zębów siecznych może wpływać na pozycję górnej wargi. Podobnie w przypadku pacjentów z II klasą szkieletową wychylone dolne zęby sieczne mogą mieć wpływ na podparcie oraz grubość wargi dolnej.

Ograniczeniem opisywanych badań jest brak informacji o BMI lub masie ciała pacjentów, których zdjęcia cefalometryczne poddano analizie. Wykazano, że wskaźnik BMI może mieć wpływ na grubość tkanek miękkich twarzy pacjenta i dlatego powinien być również brany pod uwagę (27, 28). W badaniu Dong i wsp. u osób otyłych tkanki miękkie pokrywające profil twarzy pacjenta były grubsze we wszystkich badanych miejscach pomiarowych, w porównaniu do osób o szczupłej budowie ciała (27). Natomiast w badaniach De Greef i wsp. istotne zależności między wzrostem BMI a zwiększeniem grubości tkanek miękkich profilu twarzy wykazano w obrębie tkanek miękkich pokrywających okolice bródki i okolice podbródkową (28). Pozostałe pomiary w obrębie górnego i środkowego piętra twarzy nie wykazywały podobnych zależności.

W populacji polskiej nie przeprowadzono dotychczas badań nad zależnościami między grubością TMPT a klasą szkieletową oraz płcią. Ze względu na rosnące wymagania estetyczne pacjentów oczekujących leczenia ortodontycznego konieczne jest przeprowadzenie takich badań wśród rodzimej populacji.

Wnioski

Na podstawie przedstawionego piśmiennictwa należy stwierdzić obecność dymorfizmu płciowego w zakresie grubości tkanek miękkich profilu twarzy. Zauważona kompensacja w zakresie tkanek miękkich szkieletowej wady zgryzu może mieć istotne znaczenie w planowaniu leczenia ortodontycznego, co ma szczególne znaczenie w świetle paradygmatu tkanek miękkich obowiązującego w ortodoncji. W populacji polskiej nie zostały dotychczas przeprowadzone badania, które pozwoliłyby na odniesienie do wyników omawianego piśmiennictwa.

upper and lower lips and the subnasal region. This may be due to a tendency of soft tissue compensation in the areas of underdevelopment or a posterior position of the maxillary or mandibular bone in patients with skeletal class III with a concave facial profile due to maxillary hypoplasia or excessive horizontal mandibular growth. As a result, the soft tissues covering the subnasal region and upper lip, expressed by the A-Sn, Pr-Ls, U1-St measurements, are thicker than those in skeletal class II patients. Similarly, for patients with skeletal class II, whose convex profile is due to the posterior position or mandibular hypoplasia, the lower lip thickness expressed by the Id-Li measurement is respectively greater than that of patients with skeletal class III.

Another explanation for the correlations mentioned above may be dentoalveolar compensation accompanying skeletal defects and their effects on the support of the upper and lower lip region. In class III skeletal defects, it consists of inclination of the upper anterior teeth and tilting of the lower incisors. This inclination of the upper incisors can affect the position of the upper lip. Similarly, for patients with skeletal class II, tilting of lower incisors can affect the support and thickness of the lower lip.

A limitation of the described research is the lack of information on the BMI or body weight of the patients whose cephalometric images were analysed. It has been shown that BMI can affect the patient's facial soft tissue thickness and should, therefore, also be taken into account (27, 28). In a study by Dong et al. in obese patients, the patient's facial soft tissues were thicker at all the measurement points analysed, compared to patients with a slim body posture (27). On the other hand, in the research by De Greef et al., significant correlations between an increase in BMI and an increase in the facial soft tissue thickness were shown for the soft tissues covering the chin and submental area (28). Other measurements in the upper and middle facial regions did not show similar relationships.

In the Polish population, no studies have yet been conducted on the relationship between FSTT and skeletal class or sex. However, due to the increasing aesthetic demands of patients awaiting orthodontic treatment, it is necessary to conduct such studies among the Polish population.

Conclusions

Based on the literature presented, it is necessary to conclude the presence of sexual dimorphism in the facial soft tissue thickness. The soft tissue compensation of a skeletal malocclusion that has been observed may have important implications for orthodontic treatment planning, which is particularly relevant in light of the soft-tissue paradigm prevailing in orthodontics. In the Polish population, no studies have been conducted to date that would allow reference to the results of the literature discussed above.

Piśmiennictwo / References

- Kempińska-Podhorodecka A, Knap O, Parafiniuk M. Criminal methods in archaeology-collaboration between Forensic Medicine Department, Pomeranian Medical University and the Archaeological Museum in Gdańsk. *Ann Acad Med Stetin* 2007; 53: 113-21.
- Ackerman JL, Proffit WR, Sarver DM. The emerging soft tissue paradigm in orthodontic diagnosis and treatment planning. *Clin Orthod Res* 1999; 2: 49-52.
- Holdaway RA. A soft-tissue cephalometric analysis and its use in orthodontic treatment planning. Part II. *Am J Orthod* 1984; 85: 279-93.
- Arnett GW, Jelic JS, Kim J, Cummings DR, Beress A, Worley CM Jr, Chung B, Bergman R. Soft tissue cephalometric analysis: diagnosis and treatment planning of dentofacial deformity. *Am J Orthod Dentofacial Orthop* 1999; 116: 239-53.
- Arnett GW, Bergman RT. Facial keys to orthodontic diagnosis and treatment planning. Part I. *Am J Orthod Dentofacial Orthop* 1993; 103: 299-312.
- Hamid S, Abuaffan AH. Facial soft tissue thickness in a sample of Sudanese adults with different occlusions. *Forensic Sci Int* 2016; 266: 209-14.
- Utsuno H, Kageyama T, Uchida K, Kibayashi K. Facial soft tissue thickness differences among three skeletal classes in Japanese population. *Forensic Sci Int* 2014; 236: 175-80.
- Sarilita E, Rynn C, Mossey PA, Black S, Oscandar F. Facial average soft tissue depth variation based on skeletal classes in Indonesian adult population: A retrospective lateral cephalometric study. *Leg Med* 2020; 43: 101665.
- Gungor K, Bulut O, Hizliol I, Hekimoglu B, Gurcan S. Variations of midline facial soft tissue thicknesses among three skeletal classes in Central Anatolian adults. *Leg Med* 2015; 17: 459-66.
- Kurkcuoglu A, Pelin C, Ozener B, Zagyapan R, Sahinoglu Z, Yazici AC. Facial soft tissue thickness in individuals with different occlusion patterns in adult Turkish subjects. *Homo* 2011; 62: 288-97.
- Pithon MM, Rodrigues Ribeiro DL, Lacerda dos Santos R, Leite de Santana C, Pedrosa Cruz JP. Soft tissue thickness in young north eastern Brazilian individuals with different skeletal classes. *J Forensic Leg Med* 2014; 22: 115-20.
- Utsuno H, Kageyama T, Deguchi T, Umemura Y, Yoshino M, Nakamura H, Miyazawa H, Inoue K. Facial soft tissue thickness in skeletal type I Japanese children. *Forensic Sci Int* 2007; 172: 137-43.
- Kamak H, Celikoglu M. Facial soft tissue thickness among skeletal malocclusions: is there a difference? *Korean J Orthod* 2012; 42: 23-31.
- Uysal T, Yagci A, Basciftci FA, Sisman Y. Standards of soft tissue Arnett analysis for surgical planning in Turkish adults. *Eur J Orthod* 2009; 31: 449-56.
- Kalha AS, Latif A, Govardhan SN. Soft-tissue cephalometric norms in a South Indian ethnic population. *Am J Orthod Dentofacial Orthop* 2008; 133: 876-81.
- Hussein HM. The variation of facial soft tissue thickness in Iraqi adult subjects with different skeletal classes. *J. Baghdad Coll Dent* 2012; 24: 143-49.
- Perović T, Blažej Z. Male and Female Characteristics of Facial Soft Tissue Thickness in Different Orthodontic Malocclusions Evaluated by Cephalometric Radiography. *Med Sci Monit* 2018; 24: 3415-24.
- Utsuno H, Kageyama T, Uchida K, Yoshino M, Oohigashi S, Miyazawa H, Inoue K. Pilot study of facial soft tissue thickness differences among three skeletal classes in Japanese females. *Forensic Sci Int* 2010; 195: 165.e1-5.
- Chu G, Han MQ, Ji LL, Li MJ, Zhou H, Chen T, Guo YC. Will different sagittal and vertical skeletal types relate the soft tissue thickness: A study in Chinese female adults. *Leg Med* 2020; 42: 101633.
- Hwang HS, Park MK, Lee WJ, Cho JH, Kim BK, Wilkinson CM. Facial soft tissue thickness database for craniofacial reconstruction in Korean adults. *J Forensic Sci* 2012; 57: 1442-7.
- Celikoglu M, Buyuk SK, Ekizer A. Assessment of the soft tissue thickness at the lower anterior face in adult patients with different skeletal vertical patterns using cone-beam computed tomography. *Angle Orthod* 2015; 85: 211-7.
- Farias Gomes A, Moreira DD, Zanon MF, Groppo FC, Haiter-Neto F, Freitas DQ. Soft tissue thickness in Brazilian adults of different skeletal classes and facial types: A cone beam CT - Study. *Leg Med* 2020; 47: 101743.
- Kaur K, Sehrawat JS, Bahadur R. Sex dependent variations in craniofacial soft-tissue thickness estimated from MRI and CT scans: A pilot study based on Northwest Indian subjects. *Int J Diagn Imaging* 2017; 4: 47-56.
- Chen F, Chen Y, Yu Y, Qiang Y, Liu M, Fulton D, Chen T. Age and sex related measurement of craniofacial soft tissue thickness and nasal profile in the Chinese population. *Forensic Sci Int* 2011; 212: 272.e1-6.
- Domaracki M, Stephan CN. Facial soft tissue thicknesses in Australian adult cadavers. *J Forensic Sci* 2006; 51: 5-10.
- Wang J, Zhao X, Mi C, Raza I. The study on facial soft tissue thickness using Han population in Xinjiang. *Forensic Sci Int* 2016; 266: 585.e1-5.
- Dong Y, Huang L, Feng Z, Bai S, Wu G, Zhao Y. Influence of sex and body mass index on facial soft tissue thickness measurements of the northern Chinese adult population. *Forensic Sci Int* 2012; 222: 396.e1-7.
- De Greef S, Vandermeulen D, Claes P, Suetens P, Willems G. The influence of sex, age and body mass index on facial soft tissue depths. *Forensic Sci Med Pathol* 2009; 5: 60-5.

Review

Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review

Michał Kielczykowski, Konrad Kamiński, Konrad Perkowski, Małgorzata Zadurska and Ewa Czochrowska * 

Department of Orthodontics, Medical University in Warsaw, 02-097 Warsaw, Poland; kielczykowski.michal@gmail.com (M.K.); konradkaminski90@hotmail.com (K.K.); konrad.perkowski@wum.edu.pl (K.P.); malgorzata.zadurska@wum.edu.pl (M.Z.)

* Correspondence: ewa.czochrowska@wum.edu.pl

Abstract: In recent years, the application of artificial intelligence (AI) has become more and more widespread in medicine and dentistry. It may contribute to improved quality of health care as diagnostic methods are getting more accurate and diagnostic errors are rarer in daily medical practice. The aim of this paper was to present data from the literature on the effectiveness of AI in orthodontic diagnostics based on the analysis of lateral cephalometric radiographs. A review of the literature from 2009 to 2023 has been performed using PubMed, Medline, Scopus and Dentistry & Oral Sciences Source databases. The accuracy of determining cephalometric landmarks using widely available commercial AI-based software and advanced AI algorithms was presented and discussed. Most AI algorithms used for the automated positioning of landmarks on cephalometric radiographs had relatively high accuracy. At the same time, the effectiveness of using AI in cephalometry varies depending on the algorithm or the application type, which has to be accounted for during the interpretation of the results. In conclusion, artificial intelligence is a promising tool that facilitates the identification of cephalometric landmarks in everyday clinical practice, may support orthodontic treatment planning for less experienced clinicians and shorten radiological examination in orthodontics. In the future, AI algorithms used for the automated localisation of cephalometric landmarks may be more accurate than manual analysis.

Keywords: artificial intelligence; cephalometric analysis; convolutional neural networks; orthodontics



Citation: Kielczykowski, M.; Kamiński, K.; Perkowski, K.; Zadurska, M.; Czochrowska, E. Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review. *Diagnostics* **2023**, *13*, 2640. <https://doi.org/10.3390/diagnostics13162640>

Academic Editor: Francesco Inchingolo

Received: 26 June 2023

Revised: 4 August 2023

Accepted: 8 August 2023

Published: 10 August 2023



Copyright: © 2023 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/>).

1. Introduction

Artificial intelligence (AI) is the ability of a machine to imitate logical human behaviour, including complex activities [1]. For the first time, this term was introduced by John McCarthy during a conference at Dartmouth College in 1956 [2]. There are many forms of AI, most notably machine learning (ML), artificial neural networks (ANNs), convolutional neural networks (CNN) and deep learning (DL) [3]. Artificial intelligence is used on a daily basis in the internet search engines (Google) and online private intelligent assistants (Siri), also rapidly evolving in other areas, including medicine. It may contribute to the improved quality of health care due to the increased quality of diagnostic methods and the elimination of diagnostic errors in daily medical practice [4]. In medicine, it is primarily used in radiological diagnosis of neoplastic lesions and in assessing histological specimens regarding the advancement of pathological processes. In gastroenterology, it may assist in detecting and monitoring colon polyps and preventing intestinal cancers; in cardiology, it may assist in the interpretation of ECG results [5]. Medical radiology offers a wide range of AI applications as it relies on digitally coded images that can be easily converted into a computer language [6]. Also, in many areas of dentistry, interest in the use of artificial intelligence has considerably increased in recent years [7]. AI algorithms can be useful in the diagnosis of dental caries, periapical or periodontal diseases, classification of maxillofacial cysts or tumours and localisation of cephalometric landmarks [8].

Analysis of lateral cephalometric radiographs is a method widely used in orthodontic diagnosis and treatment planning. It allows for assessing skeletal relations of the maxilla, mandible and cranial base in the sagittal and vertical dimensions as well as dental relations of the upper and lower teeth to the skeletal bases. It is also used to predict the growth direction in children and adolescents and to evaluate the results of orthodontic treatment. Cephalometric analysis is valuable when planning orthognathic surgery to correct skeletal malocclusions in adults [9]. At present, it is used to identify cephalometric points via their digitalisation on the computer screen utilising software for digital cephalometric analysis. In recent years, AI was employed to perform cephalometric analysis, which is supposed to relieve clinicians' work and save time. Applications that use AI-based image analysis are becoming more common and available to clinicians.

"Deep learning" utilises convolutional neural networks (CNNs) and is the most frequently used algorithm for AI image analysis. The concept of deep learning is based on the following: the algorithm is subjected to pairs of data and corresponding data labels, which in the case of computer vision, will correspond to the images and definitions of the described parameters. In the learning phase, pairs of data and data labels are repeatedly shown to the algorithm, so it becomes optimised to minimise errors in the predicted models. A well-trained algorithm is able to evaluate the structure of the data input and its association with a given label and ultimately is able to predict data labelling on new data/images [10]. A major limitation in training and testing DL models for cephalometric analysis of radiographs is the complexity of data labelling. There is not one true localisation of a specific anthropometric point which would serve as a gold standard. Usually, many specialists manually mark a specific point, and the unification of measurements serves to determine the right label for DL algorithm learning.

The aim of this paper was to present data from the literature on the effectiveness of AI in orthodontic diagnostics based on the analysis of lateral cephalometric radiographs.

2. Methodology

PubMed, Medline, Scopus and Dentistry & Oral Sciences Source databases were searched for publications from years 2009 to 2023 to review information on the accuracy of AI in orthodontic diagnostics based on analysis of lateral cephalometric radiographs. The following terms were used: artificial intelligence and cephalometric analysis. After removing duplicates, twenty-three articles were selected based on inclusion criteria.

3. Results

Several authors have studied the accuracy of detecting key landmarks using artificial intelligence in cephalometric analysis. Table 1 presents the summarised studies on the application of AI in cephalometric analysis. In total, 23 articles were included based on both AI algorithms designed by their authors for the purpose of a specific study [11–25] and web-based software available on search engines and mobile applications [26–33]. The studies focused on comparing the reliability of AI algorithms in localising cephalometric landmarks on lateral cephalometric radiographs with the manual tracing of these points; differences between various algorithms were also examined [11–33].

Table 1. Studies on the effectiveness of AI in the analysis of lateral cephalometric radiographs.

No	Study	No. of Cephalograms	Patients' Age (in Years)	Type of Algorithm	No. of Examiners	No. of Landmarks/Mean SDR	No. of Measurements /Mean Error	Time for Analysis (in Seconds)
1	Leonardi et al., 2009 [11]	41	10–17	Authors' algorithm/CNN, Borland C++	5	10/ n.s.	n.s.	257 for 10 landmarks
2	Tanikawa et al., 2010 [12]	859 (400: permanent dentition; 459: mixed dentition)	5–60; mean age: 23.6 (permanent dentition); 8.9 (mixed dentition)	Authors' algorithm /PPED system	2	18/ n.s.	n.s.	n.s.
3	Lindner et al., 2016 [13]	400	7–76	Authors' algorithm /FALA system, RPRV-CLM	2	19/ 84.7% in the range of 2 mm	8/ 78.4 ± 2.61%	<3
4	Park et al., 2019 [14]	1311 (1028: training set; 283: testing set)	n.s.	Authors' algorithm /YOLOv3 and SSD	1	80/ YOLOv3: 80.4% in the range of 2 mm	n.s.	0.05 for YOLOv3; 2.89 for SSD
5	Hwang et al., 2020 [15]	1311 (1028: training set; 283: testing set)	n.s.	Authors' algorithm /YOLOv3 and manual analysis	2	80/ mean detection error: 1.46 ± 2.97 mm	n.s.	n.s.
6	Moon et al., 2020 [16]	2400 (2200: training set; 200 test set)	n.s.	Authors' algorithm /YOLO v3	2	80/ n.s.	n.s.	n.s.
7	Lee et al., 2020 [17]	400	n.s.	Authors' algorithm /Bayesian CNN	2	19/ 82.11% in the range of 2 mm	n.s.	512/38 for 19 landmarks (1 GPU/4 GPU)
8	Kunz et al., 2020 [18]	1792 (96.6%: training set; 3.4%: validation set)	n.s.	Authors' algorithm/CNN, Keras and Google Tensorflow	12	18/ n.s.	12/ <0.37° (angular measurements); <0.20 mm (metric measurements); <0.25% (proportional measurements)	n.s.
9	Kim et al., 2020 [19]	2075	n.s.	Authors' algorithm/DL, SHG, Tensorflow, Python	2	23/ 84.7% in the range of 2 mm	n.s.	0.4 for 23 landmarks
10	Kim et al., 2021 [20]	950 (800: training set; 100: validation set; 50: testing set)	n.s.	Authors' algorithm/CNN	2	13/ 64.3% in the range of 2 mm	n.s.	n.s.
11	Tanikawa et al., [21]	1785	5.4–56.5; mean age: 12.2	Authors' algorithm /CNN-PC & CNN-PE, Adam	2	26/ success rates from 85% to 91%	n.s.	n.s.
12	Tanikawa et al., 2021 [22]	2385	5.8–77.9	Authors' algorithm/ CNN-PC&PE, Adam	2	26/ success rates from 85% to 90%	n.s.	n.s.
13	Yao et al., 2022 [23]	512 (312: training set; 100: validation set; 100: testing set)	9–40	Authors' algorithm/CNN, PyTorch	2	37/ 45.95% in the range of 1 mm; 97.3% in the range of 2 mm	n.s.	3 for 37 landmarks

Table 1. Cont.

No	Study	No. of Cephalograms	Patients' Age (in Years)	Type of Algorithm	No. of Examiners	Landmarks/Mean SDR	No. of Measurements /Mean Error	Time for Analysis (in Seconds)
14	Uğurlu, 2022 [24]	1620 (1360: training set; 140: validation set; 180: testing set)	9–20	Authors' algorithm/CNN/PyTorch, Python	1	76.2% in the range of 2 mm 21/	n.s.	n.s.
15	Popova et al., 2023 [25]	890 (387: training set; 43: validation set; 460: testing set)	All ages	Authors' algorithm/CNN/(Keras and TensorFlow, Python)	3	84.73% in the range of 2 mm 16/	n.s.	n.s.
16	Jeon et al., 2021 [26]	35	Mean age: 23.8	Commercial analysis/CephX	1	16 26/	0.1–0.3° (angular measurements); 0.1–0.3% (linear measurements)	n.s.
17	Bulatova et al., 2021 [27]	110	n.s.	Commercial analysis/Ceppo	2	16/ ±0.13 mm in the range of 2 mm for 75% of landmarks; mean difference 2.0 ± 3.0 in X plane and 2.1 ± 3.0 in Y plane	n.s.	n.s.
18	Ristau et al., 2022 [28]	60	Patients with a full complement of teeth	Commercial analysis/AudaxCeph	2	13/max. mean error: <2.6 mm in X plane; <2.3 mm in Y plane	n.s.	n.s.
19	Klinç et al., 2022 [29]	110	10–24, mean age: 15.88 ± 2.85	Commercial analysis/WebCeph and CephNinja	1	n.s.	11/ ICC from 0.170 to 0.884	n.s.
20	Çoban et al., 2022 [30]	105	>15, mean age: 17.25 ± 2.85	Commercial analyser/WebCeph	1	n.s.	22/ ICC from 0.418 to 0.959	n.s.
21	Mahto et al., 2022 [31]	30	Mean age: 20.17 ± 6.72	Commercial analyser/WebCeph	1	n.s.	12/ ICCC from 0.795 to 0.966	n.s.
22	Tsolakis et al., 2022 [32]	100	Mean age: 15.9 ± 4.8	Commercial analyser/CS imaging V8	1	16	18/ ICC from 0.70 to 0.92	n.s.
23	Jiang et al., 2023 [33]	9870 (8611: training set; 1000: validation set; 259: testing set)	6–50	Commercial analyser/CNN/CephNet	5/100	28/ 66.15% in the range of 1 mm; 91.73% in the range of 2 mm	11/ 89.33%	n.s.

CNN: Convolutional Neural Network; CNN-PE: Convolutional Neural Network for Point Estimation; CNN-PC: Convolutional Neural Network for Patch Classification; DL: Deep Learning; GPU: Graphic Processing Unit; ICC: Inter-Method Correlation Coefficient; n.s.: Not stated; PPED: Projected Principal Edge Distribution; RFRV-CLM: Random Forest Regression Voting-Constrained Local Model; SHG: Stacked Hourglass Network.

3.1. Developing Automatic Localisation of Cephalometric Landmarks

In 2009, Leonardi et al. verified the algorithm's reliability for the automated identification of cephalometric landmarks designed by the authors [11]. A total of 41 digital lateral cephalometric radiographs of patients aged 10–17 years were used; the patients had undergone orthodontic treatment, and different types of malocclusion were included. Ten hard tissue cephalometric landmarks were marked by five experienced clinicians in the horizontal and vertical planes. Their measurements were averaged to obtain arbitral localisation of each point. Then, the localisation of the cephalometric points was performed using the AI algorithm. The differences in the localisation of points determined using AI as opposed to the localisation of experienced clinicians, which was deemed "true", were assessed. It was demonstrated that the differences between algorithm-located points and the mean localisation of points by the orthodontists were very small and did not exceed 0.59 mm. Statistically significant differences were shown in the horizontal plane for the following landmarks: Nasion (0.217 mm), A point (0.596 mm), B point (0.161 mm), Upper Incisor Edge (0.172 mm) and Lower Incisor Edge (0.226 mm). In the vertical plane, statistically significant differences in localisation included the following points: Nasion (0.483 mm) and Porion (0.538 mm). Tanikawa et al. in 2010 confirmed that automatic recognition of anatomic features on cephalograms is accurate and reliable also in preadolescent children with mixed dentition [12].

A fully automatic landmark annotation system (FALA), which follows a machine learning approach using Random Forest regression-voting and Constrained Local Model framework was developed by Lindner et al. [13]. The system was trained and validated using 19 landmarks located in 400 cephalograms from patients aged 7–76 years. Two experienced orthodontists independently traced manually all radiographs to obtain the "ground truth" annotations, and eight measurements were used, such as SNA, SNB, ANB and others, to evaluate skeletal malformations. The FALA system located, on average, 84.7%/96.3% of all landmarks within a 2 mm/4 mm precision range, while the manual inter-observer precision range was 62.1%/85.0%, respectively. The authors concluded that the system is very promising for conducting a fully automatic cephalometric analysis.

Park et al. compared the accuracy of the automated tracing of cephalometric points via two algorithms: You-Only Look-Once version 3 (YOLOv3) and Single Shot Multibox Detector (SSD) [14]. The accuracy of both algorithms was verified by comparing the localisation of anthropometric points against arbitrarily determined manual localisation of points by an experienced orthodontist. The study was based on 1311 cephalometric radiographs obtained from the medical dataset of radiographs (INFINITT Healthcare Co., Ltd., Seoul, Korea). Both tested algorithms were supposed to automatically determine the position of 80 landmarks. YOLOv3 surpassed SSD in accuracy for 38 out of 80 landmarks, while the remaining 42 did not show statistically significant differences between the two methods. There was no single landmark which the SSD algorithm would identify with higher accuracy, and YOLOv3 showed approximately 5% higher SDR in all ranges. The successful detection rate for the YOLOv3 algorithm was 80.4% for 2 mm ranges. The analysis of one cephalogram via the YOLOv3 algorithm lasted 0.05 s, while the SSD algorithm needed 2.89 s to perform the same analysis.

The following study was based on the same set of cephalometric radiographs and compared YOLOv3 with human examiners [15]. AI showed better accuracy in 14 out of 46 skeletal landmarks, the human examiner performed better in 14 out of 46 landmarks, and the remaining 18 out of 46 did not show statistically significant differences. For the soft tissue landmarks, the YOLOv3 showed better accuracy in 5 out of 32 landmarks, while the human examiner performed better in 7 out of 32, and the remaining 20 out of 32 did not show statistically significant differences. Interestingly, the mean difference between AI and human examiners was similar to the mean difference between human examiners (1.46 ± 2.97 millimetres versus 1.50 ± 1.48 mm, respectively). Gender, skeletal classification, image quality and the presence of metallic artefacts did not affect the AI's accuracy in the localisation of landmarks. The YOLOv3 system was also used in a study by Moon et al.

(2020) for the examination of 80 landmarks in 2400 cephalograms [16]. Their results proved that the accuracy of AI increased linearly with the increasing number of learning data sets on a logarithmic scale.

Lee et al. obtained 400 cephalometric radiographs from the ISBI 2015 Challenge dataset and assessed them using an automated framework for the detection of cephalometric points using Bayesian BCNN [17]. The characteristics of the patients included was not given. The authors compared results obtained by two junior and senior orthodontists, who had traced manually cephalometric points, with those obtained using AI. The successful detection rate was 82.11% for the 2 mm confidence interval value. The biggest discrepancy was seen for the point Soft Tissue Pogonion, while the point Sella was the easiest to identify. In conclusion, the authors stated that there was a high accuracy of the applied automated framework with the averaged values obtained manually.

The study of Kunz et al. presented the assessment of the accuracy of automated tracing of cephalometric landmarks using an AI algorithm created by the authors [18]. A total of 1792 cephalometric radiographs from a private dental office were evaluated. However, no information was given regarding the characteristics of the included patients. Twelve linear and angular measurements were assessed using 18 cephalometric points. To assess “true” values of measurements, the analysis was carried out by twelve orthodontists, and the obtained results were averaged. It was demonstrated that there was a very high correlation between AI predictions and the “gold standard” of manual localisation of points. Absolute mean differences between the two analyses were less than 0.37° for angular measurements, less than 0.20 mm for all the metric parameters and less than 0.25% for the proportional parameter of the facial height. These values did not show statistically significant differences between AI predictions and the human “gold standard”, except for the angle SN-MeGo with a *p*-value equal to 0.043, which was the only parameter with a 0.31-degree deviation.

Kim et al. examined the reliability of their own DL-based algorithm using 2075 lateral cephalometric radiographs that were taken for orthodontic purposes in two medical centres [19]. Medical records of patients, regardless of age, gender or type of malocclusion, were included in this study. A total of twenty-three points were marked on radiographs by two experienced orthodontists, and the localisation of these points was used as a reference during AI reliability verification. The landmarks included both hard tissue (facial bones and teeth) and soft tissue landmarks. Successful detection rates (SDR) of the anthropometric points were 84.3% with a 2 mm margin of error against arbitrarily marked landmark positions. The algorithm took 0.4 sec on average to recognise the localisation of all the points on a given radiograph. The mean time of manual determination of all the points by the orthodontists was not presented, nor was the interexaminer reliability of the two clinicians provided.

Kim et al. created their own programme using artificial intelligence, which was supposed to identify points on cephalometric radiographs automatically [20]. A total of 950 lateral cephalometric radiographs, taken at the Maxillofacial Surgery Clinic of the University Hospital in Yonsei in South Korea, were used to trace thirteen hard tissue points. In this study, the clinically accepted margin of error was the difference in the measurements taken by two experienced orthodontists and not the standard 2 mm margin of error adopted by other researchers. Both clinicians identified thirteen landmarks. The accuracy detection index between the two orthodontists, as assessed using AI, was 36.2% on average, and for the points Orbitale and Porion, it was 7.3% and 3.3%, respectively. Higher accuracy was observed when AI detected the following points, Nasion, A point, Menton, Upper Incisor Border, Lower Incisor Border and Anterior Nasal Spine, for which the accuracy index for the inter-examiner difference exceeded 50%. This study has shown that the deep learning model can achieve better results for some landmarks than experienced clinicians, and the inter-examiner variability is very important for assessing the effectiveness of AI detection of cephalometric landmarks.

Tanikawa et al. evaluated the clinical applicability of an automated system for the identification of cephalometric landmarks with the aim to identify errors related to patients'

factors and a minimum number of images required for the re-learning [21,22]. The authors confirmed the effectiveness of AI in various patient groups. Approximately 5–10% of the original data set of cephalograms is required for system re-training.

Yao et al. examined the reliability of their own algorithm in evaluating lateral cephalometric radiographs [23]. The study material consisted of 512 radiographs of patients from the Maxillofacial Surgery Clinic in Sichuan, China. Patients who qualified for the study aged 9–40 years, and the number of women and men was similar. Two experienced orthodontists manually traced 37 points. The inter-examiner reliability was not assessed. However, the averaged values of their measurements were treated as “true values” for the AI analysis. It was demonstrated that the accuracy of their algorithm was 97.30% for the 2 mm margin of error, and the duration of localisation of 37 anthropometric points was 3 s. The pronasale point had the highest accuracy value (SDR for 2 mm = 99%), while the Pogonion point had the smallest accuracy, for which SDR was 76% for the 2 mm margin of error.

Another study by Uğurlu assessed the accuracy of the automated detection of cephalometric points via the authors-designed AI algorithm [24]. The study material consisted of 1620 radiographs of patients aged 9–20 years treated at the Orthodontic Clinic of the Eskisehir Osmangazi University in Turkey. An experienced orthodontist manually identified 21 hard and soft tissue cephalometric points, which constituted reference localisations for testing the accuracy of the automated determination of points via the AI algorithm. The value of the SDR index was, on average, 76.2% for the 2 mm error value. The algorithm’s accuracy for the Sella, Nasion, Orbitale, A point and B point was 98.3%, 77.8%, 66.1%, 76.1% and 66.1%, respectively, for the 2 mm measurement error. The lowest accuracy was for the point Gonion, with 48.3% for the 2 mm error. Recently, Popova et al. confirmed that the presence of orthodontic appliances did not significantly influence the performance of CNN-based open-source models, such as the Python programming language [25].

3.2. Commercial Software/Applications

Jeon et al. compared the outcomes of the conventional cephalometric analysis with the commercially available software CephX based on lateral head radiographs from 35 adult individuals [26]. Significant differences were found in the localisation of saddle angle, linear measurements of maxillary incisors to the NA line and mandibular incisors to the NB line. There were no significant differences in the localisation of the two soft tissue landmarks. The authors stated that the widths of limits of agreement were wider for the dental measurements compared to the skeletal measurements and concluded that automatic cephalometric analyses based on CNN might offer clinically acceptable clinical performance.

An automated cephalometric analyser Ceppro was tested on 110 cephalometric radiographs for the detection of 16 cephalometric landmarks (Bulatova et al., 2021) [27]. The software was initially trained on 15,000 cephalograms with a 1:1 scale obtained from one cephalometric machine at the Seoul National University Dental Hospital (Seoul, Korea).

AI errors were marked in 38 images out of 110. The authors concluded that the tested system facilitates cephalometric analysis in daily clinical practice and the assessment of bigger databases for research purposes. However, different artefacts may affect its effectiveness.

Ristau et al. examined the accuracy of automated detection of landmarks on lateral cephalometric radiographs using the AudaxCeph commercial software that utilises AI [28]. The study was based on 60 archived radiographs of patients presenting for orthodontic treatment at the University of Louisiana, USA. The inclusion criteria included the presence of all permanent teeth except third molars. On each radiograph, two experienced orthodontists independently marked 13 anthropometric points. The same points were later automatically marked using AudaxCeph. The inter-examiner reliability between the two orthodontists and between each orthodontist and the AI software was assessed. It was demonstrated that the differences in the mean positions of the points marked by both orthodontists did not exceed 2 mm, which is the clinically accepted margin of error during cephalometric analysis. Likewise, the positions marked using AudaxCeph did not differ from the measurements obtained by any of the two practitioners by more than 2 mm, except

for the points Porion and Lower Incisor Apex, where the algorithm deviated more than 2 mm in the horizontal or vertical planes.

Kılınç et al. assessed differences between values from the cephalometric analysis obtained in three different ways [29]. Hand-tracing cephalometric analysis performed by the orthodontist was compared with AI (WebCeph software) and the CephNinja (version 4.2) smartphone application, which involves the manual identification of landmarks by an orthodontist on the screen of their phone. Magnifying and decreasing the size of the picture was applied to pinpoint the areas. The study material consisted of 110 cephalometric radiographs from the archives of the orthodontic clinic of Aydin University in Istanbul, Turkey. The patients were in the age range of 10–24 years. Each of the three methods was used to perform cephalometric analysis and to obtain values for 11 linear and angular measurements. SNA, SNB, SN-MP angle, U1-SN angle, L1-NB (mm) and E Line-Upper Lip values differed considerably for each method, and these differences were clinically significant. The authors demonstrated that the accuracies of WebCeph and CephNinja software were markedly worse than the hand tracing of landmarks, thus restricting their clinical applicability.

Çoban et al. examined 105 cephalometric radiographs of patients who presented at the Department of Orthodontics at Erciyes University in Turkey to undergo orthodontic treatment [30]. The inclusion criteria included patients older than 15 years. The radiographs were subjected to cephalometric analysis, including 23 measurements obtained with two methods: manual tracing of cephalometric points by an orthodontist and automated detection using AI-based software. It was shown that the results obtained with the WebCeph software were statistically significantly different in comparison with the standard cephalometric method in which the orthodontist was responsible for the tracing. Major differences were detected for the SNA, ANB, NA, Y-axis and SN. GoGn, SN.PP, ANS-Me, CoA, CoGn, U1.PP, U1-NA, IMPA, L1-NB, L1.NB, NLA and ULE measurements. It was also demonstrated that 17 out of 23 comparable measurements showed discrepancies between the two applied methods of cephalometric analysis.

Also, Mahto et al. compared the values from the cephalometric analysis performed manually with the AI-based, WebCeph software [31]. A total of 18 landmarks and 12 angular and linear measurements were analysed on 30 cephalometric radiographs obtained from the Department of Orthodontics of the Dhulikhel Hospital in Nepal before orthodontic treatment. The mean age of patients was 20.17 years \pm 6.72. Manual cephalometric analysis was performed by one clinician, and the results were compared with the values provided by the WebCeph. The intraclass correlation coefficient (ICC) indicated a high correlation between the values obtained using both methods, which was demonstrated in 7 out of 12 examined measurements. They included ANB, FMA, IMPA, LL to E-line, L1 to NB (mm), L1 to NB ($^{\circ}$) and S-N to Go-Gn. For the remaining five measurements, the ICC was between 0.75 and 0.9. The small number of examined cephalometric radiographs was a major limitation of this study.

Tsolakis et al. performed the cephalometric analysis of 100 radiographs of patients who presented for orthodontic treatment at a private dental office [32]. The medical records of patients included in the study did not account for gender or age. The accuracy of automated detection of points and measurements taken using CS imaging V8 was compared with manual tracing conducted by an experienced orthodontist. Mean values of the SNA, SNB, ANB, SN-MP, U1-SN, L1-NB, SNPg, ANPg, SN/ANS-PNS, SN/GoGn, U1/ANS-PNS, L1-APg, U1-NA and L1-GoGn measurements did not reveal statistically significant differences between the two methods. Some measurements, however, did demonstrate larger discrepancies between the automated and manual determinations of points. Significant differences were observed for FMA measurements (2.1 degrees), IMPA (4 degrees), ANS-PNS/GoGn (3 degrees) and U1-L1 (3.3 degrees).

Recently, Jiang et al. developed a novel and accurate system for automatic cephalometric landmark location and analysis based on a two-stage cascade CephNet system [33]. The system consisted of two-stage neural networks, from which the first aimed to de-

tect 10 regions of interest (ROI), each containing 1–9 landmarks, and in the second stage, the landmarks were accurately located in the ROIs. The system was not dependent on the cephalography machine or anatomical variability of patients, and 9870 cephalograms from 20 medical institutions in China were included for evaluation and training. Five orthodontists manually annotated 30 skeletal, dental and soft tissue cephalometric landmarks to establish the standard data for comparison and training of AI, and in the next stage, 100 orthodontists adjusted the landmark location using web browsers (SaaS system). The accuracy of automatic landmark localisation reached, on average, 66.15% within 1 mm SDR and 91.73% within 2 mm. The least accurate landmark location was seen for the point Gonion (Go), and landmarks surrounding stable and clear anatomical structures exhibited higher SDR than landmarks interfered with by overlapping anatomical structures. The landmarks defined as the “most front” or “most convex”, for example, Pog) have also shown larger detection errors. The accuracy of cephalometric analysis based on 11 cephalometric measurements was, on average, 89.33% for CephNet.

3.3. Successful Detection Rates (SDR)

Hwang et al. compared the accuracy of the YOLOv3 algorithm with the accuracy of manual identification of anthropometric points by two orthodontists: the first had 28 years of clinical experience, while the other was a 3rd-year orthodontic resident [15]. Both were employed at the same institution. The study material was the same as in part 1 of their research [14]. It was demonstrated that the YOLOv3 algorithm detected the same position for each landmark, while the human inter-examiner variability of manual detections demonstrated a detection error of 0.97 ± 1.03 mm. The mean difference between human examiners was 1.50 ± 1.48 mm. Comparisons in the detection errors between AI and human examiners for the identification of all cephalometric points were less than 0.9 mm, except for one landmark at the apex of the lower incisor, where measurement showed an error of 1.2 mm. The authors concluded that the differences between AI algorithms and human examiners did not seem to be clinically significant.

A similar study was conducted by Bulatova et al. in which the accuracy of the automated determination of points via the YOLOv3 algorithm was compared with manual tracing performed by one orthodontist [27]. Cephalometric analysis was conducted on 110 cephalographs obtained from the AAOF Legacy Denver medical database. Sixteen points were identified with both methods. The successful detection rate of AI with an accuracy of up to 2 mm when manual detection and AI were compared was 75% and 93% with an accuracy of up to 4 mm, which the authors believe to be clinically acceptable. The points for which the localisation difference was greater than 2 mm were L1 apex, U1 apex, Basion, Gonion and Orbitale.

3.4. Size of the Dataset and Patients' Characteristics

Tanikawa et al. were the first to evaluate the effectiveness of the automatic system for recognition of cephalometric landmarks in patients with full permanent dentition (400 patients, mean age: 23.6 years) and patients with mixed dentition (459 patients, mean age: 8.9 years) [12]. The authors concluded that the system successfully recognised all the anatomic structures surrounding all the landmarks. The mean success rate was 84%, with a range from 60% (N landmark) to 100% (Ptm landmark).

Moon et al. determined the size of the dataset for AI algorithm training to make it as reliable as a human hand that manually performs cephalometric analysis [16]. It was estimated that the mean difference in a manual tracing of cephalometric landmarks by different orthodontists was 1.5 mm. The study assessed the accuracy of AI cephalometric analysis by changing the number of cephalograms available for the AI training from 50 to 2000 radiographs and the number of marked points in one picture from 19 to 80. It was shown that the accuracy of AI increased linearly in proportion to the increasing number of learning data sets (cephalometric radiographs) on a logarithmic scale. It decreased with the increasing number of detection targets (points needed for a specific cephalometric

analysis). It was calculated that at least 2300 sets of learning data were necessary to make the algorithm as accurate as human examiners are.

Tenikawa et al. examined the accuracy of an AI algorithm, which was used for the automated detection of cephalometric landmarks depending on patients' characteristics such as dental age, the use of orthodontic devices, presence of clefts lip and/or palate and overjet [21]. For training and testing the algorithm, a total of 1785 cephalometric radiographs of patients who presented for orthodontic treatment at the University Dental Hospital in Osaka, Japan, were used. The patient's age ranged from 5.4 to 56.5 years. It was demonstrated that the successful detection rates (SDR) differed in subgroups from 85% to 91%. It was also observed that cleft of the lip and/or palate was a factor responsible for higher identification errors, while the dentition type, orthodontic devices and the extent of overjet were not significant factors.

Artificial intelligence is used for copying previous solutions in trained samples. Therefore, it cannot guarantee exact solutions if the image has new input data (picture quality) or if the picture considerably differs from the samples used for training. In order to overcome this problem, AI should re-learn additional samples that are similar to the new data input. For example, a system that was trained to be used in adult patients and has shown 88% accuracy in adults may still drop to 69% when used in children, even if the radiation dose was maintained. After the system was re-trained using 400 additional cephalograms of children, the success rate increased to 82% [12]. In comparison, to obtain high accuracy of landmark identification for cephalometric analysis of radiographs taken with a different cephalograph (with a different quality), the AI algorithm has to be additionally trained with 85–170 radiographs having a specific desired quality, which amounts to approximately 5–10% increase in the initial data set [22].

Recently, Popova et al. assessed the influence of growth structures such as tooth buds and the presence of fixed orthodontic appliances on the accuracy of a customised CNN model for the automatic detection of cephalometric landmarks [25]. Sixteen skeletal and dental cephalometric landmarks were included in the analysis. Two last year orthodontic residents and an orthodontic specialist created a verified dataset, which was used as a reference for the training, testing and validation of the CNN model. In total, 890 cephalograms were used, from which the training dataset consisted of 430 cephalograms with both mixed and permanent dentition and orthodontic appliances. The performance of the developed CNN was tested using 460 cephalograms with various radiographic features, such as fixed orthodontic appliances and anatomical structures in patients at different growth stages. Significant differences were observed in the recognition of the Ap-Inferior point and the Is-Superior points between patients with mixed and permanent dentition. Fixed orthodontic appliances, such as brackets, bands, and other fixed orthodontic appliances, had no significant effect on the performance of the CNN model. The growth structures, such as tooth germs in mixed dentition, play a role in the performance of the AI model.

4. Discussion

The majority of the studies included in this review have been published in the last three years, which shows a rapid increase in interest in the application of AI in cephalometric analysis and orthodontic diagnostics of malocclusions. The accuracy of different types of AI algorithms varies, as demonstrated by the results published in the included studies (Table 1). The authors used different numbers of cephalograms for the testing and validation of the database, which varied from dozen to a thousand. Also, the number of clinicians performing the manual annotation of landmarks varied in number and in clinical experience in cephalometric tracing. Moon et al. (2020) concluded that the more data that were implemented during the training procedure of AI, the smaller the detection errors observed [16]. The development of reliable "gold standards" in the identification of cephalometric landmarks is important to reduce bias in the dataset used for AI training. Also, the time of the AI analysis varied between studies.

Today, CNN-based algorithms derived by many authors for the purpose of their studies, or YOLOv3 or SSD algorithms, not available to doctors in their daily clinical practice, are more effective and accurate than the widely available web-based software such as WebCeph, AudaxCeph or CS Imaging.

Most AI algorithms used for the automated tracing of landmarks on lateral cephalographic radiographs are characterised by relatively high accuracy. In most studies, the confidence interval was within 2 mm, and the mean percentage of detected landmarks within this margin was above 80%. However, from the clinical point of view, the localisation error up to 2 mm can be acceptable for some, but not all points traced in cephalometric analysis. The localisation of cephalometric points A and B in the horizontal plane is crucial for the determination of maxillary/mandibular relations in the sagittal plane. An inaccurate localisation of these points in the range of 1.5–2 mm would result in a considerable inaccuracy of many angular and linear measurements, especially if errors are duplicated using the same landmark in several measurements. It also has to be stressed that cephalometric analysis of lateral head radiographs performed manually is a subjective examination, and the localisation of specific anthropometric points may differ between orthodontists. It has been demonstrated that the mean discrepancies between two experienced clinicians could be up to 1.5 mm as well. Moreover, a repeated tracing of landmarks on the same radiograph by one orthodontist may entail an error of approximately 1 mm between two measurements. Unlike manual tracing of cephalometric landmarks, the AI algorithm always marks identical localisation of the landmarks, which can be an additional asset for its use [15].

The studies confirmed that the time needed for analysing a cephalometric radiograph using most of the popular AI algorithms takes a few seconds. This is considerably shorter than the manual tracing of landmarks by clinicians. The most recent algorithms evolve rapidly, and their calculating capacity increases, which will probably result in their increased efficiency and reliability. It can be expected that in the future, AI algorithms that are used for the automated localisation of landmarks may be more accurate than manual tracing. At the same time, the interpretation of cephalometric analysis via artificial intelligence may be inferior to the interpretation performed by experienced orthodontists but can still be useful to less experienced specialists or even non-specialists. It is necessary to conduct further studies to assess the reliability of AI-performed cephalometric analysis in planning, monitoring and analysing orthodontic treatment. There is no doubt that the ease and short duration of cephalometric analysis via AI may be a significant factor in facilitating orthodontic treatment in clinical practice.

The use of AI algorithms in radiological diagnostics in the area of orthodontics is not restricted to the automated detection of landmarks in cephalometric analysis. AI provides high accuracy in the assessment of cervical vertebral maturation on radiographs [34,35]. Another AI algorithm that is described in the literature is supposed to predict the need for tooth extractions due to orthodontic reasons [36].

The identification of cephalometric landmarks is challenging, as a skull is a 3D object projected onto a 2D plane on a lateral head cephalogram. Overlapping structures increase the difficulty in precise landmark identification, especially in patients with facial asymmetry. Moreover, improper head position during image acquisition and radiographic distortions may lead to errors in landmark identification by orthodontic professionals. The quality of cephalograms used for landmark identification, the level of orthodontic training and experience in landmark identification as well as inter-observer variability between clinicians who participate in the training and validation of the AI model are important factors and limitations of this diagnostic tool. Another source of AI inaccuracy might be due to the operator's mistake while calibrating images for the AI cephalometric analysis, like in the Ceppro software (Bulatova et al., 2021) [27]. Even a small error in using a digital ruler alters the number of pixels in 1 mm and can influence the coordinates for all points.

The advantage when using an automated system for the identification of cephalometric landmarks in comparison with the manual annotation is the fact that it would always give the same result for the same image, while there are large variations in the accuracy of

manual annotation related to the levels of training and experience [13]. Improving the training and validation of AI algorithms may completely replace manual cephalometric tracing in the future.

Threats and challenges of the future use and development of AI in the analysis of patients' medical records are related to the data protection and application of the principles of medical ethics whenever computer software that simulates human brain activity is used. It is possible that new legal regulations concerning the application of AI in the diagnostics and monitoring of orthodontic treatment will have to be proposed and implemented. Pre- and postgraduate curricula and clinical practice must be adjusted for technological advancements, so they can contribute to the optimisation of orthodontic treatment without adversely affecting its effectiveness.

5. Conclusions

In recent years, artificial intelligence has been more and more frequently used in the orthodontic diagnostic process. It is a promising tool that facilitates the tracing of cephalometric landmarks in daily clinical practice, which can assist less experienced clinicians in orthodontic treatment planning and shortens the time devoted to performing radiological diagnoses of patients. At the same time, the reliability of AI in cephalometry differs depending on the accuracy of manual landmark identification related to the operator's clinical training and experience, the number and quality of radiographs, the type of algorithm or application, which have to be accounted for during interpretation of results. It is predicted that AI will continue to be implemented and further developed for its application in orthodontics.

Author Contributions: Conceptualisation, M.K. and E.C.; methodology, M.K. and K.K.; validation, E.C. and K.P.; writing—original draft preparation, M.K., K.K. and E.C.; writing—review and editing, M.K.; E.C., K.P. and M.Z.; supervision, E.C. and M.Z. All authors have read and agreed to the published version of the manuscript.

Funding: This research received no external funding.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: The data presented in this study are available upon request from the corresponding author.

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

References

1. Wong, S.H.; Al-Hasani, H.; Alam, Z.; Alam, A. Artificial intelligence in radiology: How will we be affected? *Eur Radiol.* **2019**, *29*, 141–143. [[CrossRef](#)]
2. Obermeyer, Z.; Emanuel, E.J. Predicting the Future—Big Data, Machine Learning, and Clinical Medicine. *N. Engl. J. Med.* **2016**, *375*, 1216–1219. [[CrossRef](#)]
3. Subramanian, A.K.; Chen, Y.; Almalki, A.; Sivamurthy, G.; Kafle, D. Cephalometric Analysis in Orthodontics Using Artificial Intelligence—A Comprehensive Review. *Biomed Res. Int.* **2022**, *2022*, 1880113. [[CrossRef](#)] [[PubMed](#)]
4. Jiang, F.; Jiang, Y.; Zhi, H.; Dong, Y.; Li, H.; Ma, S.; Wang, Y.; Dong, Q.; Shen, H.; Wang, Y. Artificial intelligence in healthcare: Past, present and future. *Stroke Vasc. Neurol.* **2017**, *2*, 230–243. [[CrossRef](#)] [[PubMed](#)]
5. Amann, J.; Blasimme, A.; Vayena, E.; Frey, D.; Madai, V.I. Explainability for artificial intelligence in healthcare: A multidisciplinary perspective. *BMC Med. Inform. Decis. Mak.* **2020**, *20*, 310. [[CrossRef](#)] [[PubMed](#)]
6. Thrall, J.H.; Li, X.; Li, Q.; Cruz, C.; Do, S.; Dreyer, K.; Brink, J. Artificial Intelligence and Machine Learning in Radiology: Opportunities, Challenges, Pitfalls, and Criteria for Success. *J. Am. Coll. Radiol.* **2018**, *15*, 504–508. [[CrossRef](#)] [[PubMed](#)]
7. Khanagar, S.B.; Al-Ehaideb, A.; Vishwanathaiah, S.; Maganur, P.C.; Patil, S.; Naik, S.; Baeshen, H.A.; Sarode, S.S. Scope and performance of artificial intelligence technology in orthodontic diagnosis, treatment planning, and clinical decision-making—A systematic review. *J. Dent. Sci.* **2021**, *16*, 482–492. [[CrossRef](#)]
8. Hung, K.; Montalvao, C.; Tanaka, R.; Kawai, T.; Bornstein, M.M. The use and performance of artificial intelligence applications in dental and maxillofacial radiology: A systematic review. *Dentomaxillofac. Radiol.* **2020**, *49*, 20190107. [[CrossRef](#)] [[PubMed](#)]

9. Devereux, L.; Moles, D.; Cunningham, S.J.; McKnight, M. How important are lateral cephalometric radiographs in orthodontic treatment planning? *Am. J. Orthod. Dentofacial. Orthop.* **2011**, *139*, e175–e181. [[CrossRef](#)]
10. Talaat, S.; Kaboudan, A.; Talaat, W.; Kusnoto, B.; Sanchez, F.; Elnagar, M.H.; Ghoneima, A.; Bourauel, C. Improving the accuracy of publicly available search engines in recognizing and classifying dental visual assets using convolutional neural networks. *Int. J. Comput. Dent.* **2020**, *23*, 211–218. [[PubMed](#)]
11. Leonardi, R.; Giordano, D.; Maiorana, F. An evaluation of cellular neural networks for the automatic identification of cephalometric landmarks on digital images. *J. Biomed Biotechnol.* **2009**, *2009*, 717102. [[CrossRef](#)] [[PubMed](#)]
12. Tanikawa, C.; Yamamoto, T.; Yagi, M.; Takada, K. Automatic recognition of anatomic features on cephalograms of preadolescent children. *Angle Orthod.* **2010**, *80*, 812–820. [[CrossRef](#)] [[PubMed](#)]
13. Lindner, C.; Wang, C.W.; Huang, C.T.; Li, C.H.; Chang, S.W.; Cootes, T.F. Fully Automatic System for Accurate Localisation and Analysis of Cephalometric Landmarks in Lateral Cephalograms. *Sci. Rep.* **2016**, *6*, 33581. [[CrossRef](#)] [[PubMed](#)]
14. Park, J.-H.; Hwang, H.-W.; Moon, J.-H.; Yu, Y.; Kim, H.; Her, S.-B.; Srinivasan, G.; Aljanabi, M.N.A.; Donatelli, R.E.; Lee, S.-J. Automated identification of cephalometric landmarks: Part 1-Comparisons between the latest deep-learning methods YOLOV3 and SSD. *Angle Orthod.* **2019**, *89*, 903–909. [[CrossRef](#)] [[PubMed](#)]
15. Hwang, H.-W.; Park, J.-H.; Moon, J.-H.; Yu, Y.; Kim, H.; Her, S.-B.; Srinivasan, G.; Aljanabi, M.N.A.; Donatelli, R.E.; Lee, S.-J. Automated identification of cephalometric landmarks: Part 2-Might it be better than human? *Angle Orthod.* **2020**, *90*, 69–76. [[CrossRef](#)]
16. Moon, J.H.; Hwang, H.W.; Yu, Y.; Kim, M.G.; Donatelli, R.E.; Lee, S.J. How much deep learning is enough for automatic identification to be reliable? *Angle Orthod.* **2020**, *90*, 823–830. [[CrossRef](#)]
17. Lee, J.H.; Yu, H.J.; Kim, M.J.; Kim, J.W.; Choi, J. Automated cephalometric landmark detection with confidence regions using Bayesian convolutional neural networks. *BMC Oral Health* **2020**, *20*, 270. [[CrossRef](#)]
18. Kunz, F.; Stellzig-Eisenhauer, A.; Zeman, F.; Boldt, J. Artificial intelligence in orthodontics: Evaluation of a fully automated cephalometric analysis using a customized convolutional neural network. *J. Orofac. Orthop.* **2020**, *81*, 52–68. [[CrossRef](#)]
19. Kim, H.; Shim, E.; Park, J.; Kim, Y.J.; Lee, U.; Kim, Y. Web-based fully automated cephalometric analysis by deep learning. *Comput. Methods Programs Biomed.* **2020**, *194*, 105513. [[CrossRef](#)]
20. Kim, Y.H.; Lee, C.; Ha, E.G.; Choi, Y.J.; Han, S.S. A fully deep learning model for the automatic identification of cephalometric landmarks. *Imaging Sci. Dent.* **2021**, *51*, 299–306. [[CrossRef](#)]
21. Tanikawa, C.; Lee, C.; Lim, J.; Oka, A.; Yamashiro, T. Clinical applicability of automated cephalometric landmark identification: Part I-Patient-related identification errors. *Orthod. Craniofac. Res.* **2021**, *24* (Suppl. S2), 43–52. [[CrossRef](#)] [[PubMed](#)]
22. Tanikawa, C.; Oka, A.; Lim, J.; Lee, C.; Yamashiro, T. Clinical applicability of automated cephalometric landmark identification: Part II—Number of images needed to re-learn various quality of images. *Orthod. Craniofac Res.* **2021**, *24* (Suppl. S2), 53–58. [[CrossRef](#)] [[PubMed](#)]
23. Yao, J.; Zeng, W.; He, T.; Zhou, S.; Zhang, Y.; Guo, J.; Tang, W. Automatic localization of cephalometric landmarks based on convolutional neural network. *Am. J. Orthod. Dentofacial. Orthop.* **2022**, *161*, e250–e259. [[CrossRef](#)] [[PubMed](#)]
24. Uğurlu, M. Performance of a Convolutional Neural Network-Based Artificial Intelligence Algorithm for Automatic Cephalometric Landmark Detection. *Turk. J. Orthod.* **2022**, *35*, 94–100. [[CrossRef](#)] [[PubMed](#)]
25. Popova, T.; Stocker, T.; Khazaei, Y.; Malenova, Y.; Wichelhaus, A.; Sabbagh, H. Influence of growth structures and fixed appliances on automated cephalometric landmark recognition with a customized convolutional neural network. *BMC Oral Health* **2023**, *23*, 274. [[CrossRef](#)] [[PubMed](#)]
26. Jeon, S.; Lee, K.C. Comparison of cephalometric measurements between conventional and automatic cephalometric analysis using convolutional neural network. *Prog. Orthod.* **2021**, *22*, 14. [[CrossRef](#)] [[PubMed](#)]
27. Bulatova, G.; Kusnoto, B.; Grace, V.; Tsay, T.P.; Avenetti, D.M.; Sanchez, F.J.C. Assessment of automatic cephalometric landmark identification using artificial intelligence. *Orthod. Craniofac Res.* **2021**, *24* (Suppl. 2), 37–42. [[CrossRef](#)]
28. Ristau, B.; Coreil, M.; Chapple, A.; Armbruster, P.; Ballard, R. Comparison of AudaxCeph[®]'s fully automated cephalometric tracing technology to a semi-automated approach by human examiners. *Int. Orthod.* **2022**, *20*, 100691. [[CrossRef](#)]
29. Kılınc, D.D.; Kırçelli, B.H.; Sadry, S.; Karaman, A. Evaluation and comparison of smartphone application tracing, web based artificial intelligence tracing and conventional hand tracing methods. *J. Stomatol. Oral Maxillofac Surg.* **2022**, *123*, e906–e915. [[CrossRef](#)]
30. Çoban, G.; Öztürk, T.; Hashimli, N.; Yağci, A. Comparison between cephalometric measurements using digital manual and web-based artificial intelligence cephalometric tracing software. *Dent. Press J. Orthod.* **2022**, *27*, e222112. [[CrossRef](#)]
31. Mahto, R.K.; Kafle, D.; Giri, A.; Luintel, S.; Karki, A. Evaluation of fully automated cephalometric measurements obtained from web-based artificial intelligence driven platform. *BMC Oral Health* **2022**, *22*, 132. [[CrossRef](#)]
32. Tsolakis, I.A.; Tsolakis, A.I.; Elshebiny, T.; Matthaios, S.; Palomo, J.M. Comparing a Fully Automated Cephalometric Tracing Method to a Manual Tracing Method for Orthodontic Diagnosis. *J. Clin. Med.* **2022**, *11*, 6854. [[CrossRef](#)] [[PubMed](#)]
33. Jiang, F.; Guo, Y.; Yang, C.; Zhou, Y.; Lin, Y.; Cheng, F.; Quan, S.; Feng, Q.; Li, J. Artificial intelligence system for automated landmark localization and analysis of cephalometry. *Dentomaxillofac. Radiol.* **2023**, *52*, 20220081. [[CrossRef](#)] [[PubMed](#)]
34. Kök, H.; Acilar, A.M.; İzgi, M.S. Usage and comparison of artificial intelligence algorithms for determination of growth and development by cervical vertebrae stages in orthodontics. *Prog. Orthod.* **2019**, *20*, 41. [[CrossRef](#)] [[PubMed](#)]

35. Amasya, H.; Yildirim, D.; Aydogan, T.; Kemalglu, N.; Orhan, K. Cervical vertebral maturation assessment on lateral cephalometric radiographs using artificial intelligence: Comparison of machine learning classifier models. *Dentomaxillofac. Radiol.* **2020**, *49*, 20190441. [[CrossRef](#)]
36. Real, A.D.; Real, O.D.; Sardina, S.; Oyonarte, R. Use of automated artificial intelligence to predict the need for orthodontic extractions. *Korean J. Orthod.* **2022**, *52*, 102–111. [[CrossRef](#)] [[PubMed](#)]

Disclaimer/Publisher’s Note: The statements, opinions and data contained in all publications are solely those of the individual author(s) and contributor(s) and not of MDPI and/or the editor(s). MDPI and/or the editor(s) disclaim responsibility for any injury to people or property resulting from any ideas, methods, instructions or products referred to in the content.

RESEARCH

Open Access



Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age

Michał Kielczykowski¹, Konrad Perkowski¹, Konrad Kamiński¹, Małgorzata Zadurska¹ and Ewa Czochrowska^{1*}

Abstract

Background The aim of the study was to assess the thickness of the soft tissue facial profile (STFP) in relation to the skeletal malocclusion, age and gender.

Methods All patients, aged 7–35 years, who were seeking orthodontic treatment at the Department of Orthodontics, Medical University of Warsaw between 2019 and 22 were included in the study. All patients had lateral head radiographs taken before the treatment. The cephalometric analysis was performed including the STFP analysis. The patients were allocated to one of six groups based on age and skeletal relations (ANB angle). The minimum number of patients in each group was 60 with equal gender distribution. The STFP analysis included ten linear measurements.

Results A total of 300 patients were included in the study and allocated to five groups. Group 6 (growing patients with skeletal Class III malocclusion) was not included in the study as it failed to achieve the assumed group size. There were significant differences in the thickness of the STFP in relation to the skeletal malocclusions. Adults with skeletal Class III malocclusion had significantly thicker subnasal soft tissues compared to patients with skeletal Class I and Class II malocclusions. The thickness of the lower lip in patients with Class II skeletal malocclusion was significantly bigger compared to the other groups. Children and adolescents with Class II malocclusions had thicker lower lip in comparison to the group with Class I malocclusion. The majority of the STFP measurements were significantly smaller in children and adolescents compared to adults. The thickness of the STFP in males was significantly bigger in all age groups compared to females.

Conclusions The thickness of facial soft tissues depends on the patient's age and gender. The degree of compensation of the skeletal malocclusion in the STFP may be a decisive factor during orthodontic treatment planning regarding a surgical approach or a camouflage treatment of skeletal defects.

Keywords Camouflage treatment, Cephalometric analysis, Profile analysis, Skeletal malocclusion, Soft tissue analysis

*Correspondence:

Ewa Czochrowska
ewa.czochrowska@wum.edu.pl

¹Department of Orthodontics, Medical University in Warsaw,
Warsaw 02-097, Poland



© The Author(s) 2024. **Open Access** This article is licensed under a Creative Commons Attribution 4.0 International License, which permits use, sharing, adaptation, distribution and reproduction in any medium or format, as long as you give appropriate credit to the original author(s) and the source, provide a link to the Creative Commons licence, and indicate if changes were made. The images or other third party material in this article are included in the article's Creative Commons licence, unless indicated otherwise in a credit line to the material. If material is not included in the article's Creative Commons licence and your intended use is not permitted by statutory regulation or exceeds the permitted use, you will need to obtain permission directly from the copyright holder. To view a copy of this licence, visit <http://creativecommons.org/licenses/by/4.0/>. The Creative Commons Public Domain Dedication waiver (<http://creativecommons.org/publicdomain/zero/1.0/>) applies to the data made available in this article, unless otherwise stated in a credit line to the data.

Introduction

Soft tissue facial profile (STFP) is the subject of interest for many specialists from different medical fields. In orthodontics and plastic surgery STFP is important regarding diagnosis and treatment planning [1]. The differences in thickness are used in anthropology to determine the facial appearance of ancient populations and in forensic medicine to identify the deceased on the basis of skeletal traits [2].

Maxillary and mandibular morphology and position as well as incisor position and inclination play an important role regarding facial aesthetics. Also, the thickness of overlying soft tissues, their harmony and proportions in the face, is very important, hence its recent application to different treatments, including plastic surgery, to enhance fullness of the profile, or to camouflage underlying skeletal malocclusions.

Ackerman et al. [3] have proposed a paradigm that now prevails in orthodontics: proper STFP relations constitute the most important objective in orthodontic treatment and their proper proportion in relation to the underlying hard tissues determines optimal aesthetics and treatment stability. Holdaway [4] and later Arnett et al. [5] introduced STFP analysis in orthodontic diagnostics and orthognathic surgery. Awareness of how soft tissue thickness changes relative to age, gender or skeletal malocclusion may provide valuable information during orthodontic treatment of patients with gnathic defects. The existence of compensation regarding the thickness of patient's soft tissue profile in the insufficient growth zone may to a lesser or greater extent conceal the existence of bone disproportion, in this way improving the harmony of the face in a patient who is affected by malocclusion. The higher the compensation, the less visible the gnathic malocclusion in the patient's profile. Such a situation may motivate both the patient and the doctor to consider more conservative treatment methods including orthodontic camouflage.

Cephalometric analysis is commonly used in orthodontic diagnosis and treatment planning to analyse the sagittal and vertical skeletal and dental relations. At present, clinicians more and more frequently apply Artificial Intelligence algorithms to conduct cephalometric analysis, which may facilitate their work and save time [6]. Because the outline of the patient's soft tissue profile is visible on telerradiographs it will be accounted for during cephalometric analysis of hard tissues of the jaws and teeth, without unnecessary exposure of the patient to radiation or additional costs. It matters when the orthodontic treatment is planned since STFP thickness influences the patient's profile after therapy in view of the intended alterations of tooth positions.

In the literature, there are contradictory results concerning soft tissue thickness in relation to the existing

skeletal sagittal malocclusion in adult patients. Several of them seem to confirm compensation of skeletal malocclusion by soft tissues, which means that in patients with Class III skeletal malocclusion the soft tissues of the subnasal and the upper lip areas are thicker, while in patients with skeletal Class II malocclusion the lower lip is thicker [7–11]. In growing patients only one study was conducted, which supported the presence of the soft tissue compensation in this age group [12]. The majority of published studies indicate the presence of sexual dimorphism related to soft tissue thickness in adults, manifested by thicker tissues in adult males than in females [13–16]. In the literature, the same observation relates to children although the number of studies on this subject is limited [17–19]. There have been reports concerning changes in the thickness of facial soft tissues at subsequent stages of growth, increasing with age [20–22]. Few published studies dwell on the same subject in adults, with the available reports indicating a positive correlation between soft tissue thickness and age [23–25]. So far, comparative studies concerning STFP thickness differences between children and adults have not been published.

Due to the discrepancies in the published results and the limited number of scientific reports analysing STFP in growing patients the aim of the present study was to assess and to compare the STFP thickness in relation to the skeletal malocclusion, age and gender.

Materials and methods

All Caucasian patients aged 7–35 years who were orthodontically treated in the Department of Orthodontics, Medical University in Warsaw between 2019 and 2022 were included in the study. The exclusion criteria were: presence of dentofacial deformities, history of craniofacial trauma, previous orthodontic treatment, previous prosthodontic or surgical treatment including any soft tissue augmentation procedures, incompetent lip closure and poor quality of radiographs.

All the patients had a cephalometric analysis based on the lateral head radiographs taken before the orthodontic treatment. All radiographs were taken with 4-in-1 Dental X-ray Imaging system PAPAYA 3D PLUS. Each radiograph had been calibrated with a millimetre scale before the cephalometric analysis. The cephalometric analysis was performed using the DDP-Ortho 2.10.2022 software (Polorto, Czestochowa, Poland), which was preadjusted for STFP analysis including ten measurements in accordance with the methodology proposed by Utsuno et al., Kamak et al. and Hamid et al. (Table 1; Fig. 1) [7, 8, 17]. The cephalometric analysis was performed by the researcher, who was blinded to the patient's clinical records and treatment (M.K.).

Based on the value of the ANB angle, the patients were allocated to one of the six groups in relation to age

Table 1 Cephalometric analysis of the thickness of the soft tissues facial profile. The ANB angle is in degrees, other measurements in mm

Measurement	Definition
ANB	The angle formed between the Nasion point (the most anterior point on the frontonasal suture in the midline), Point A (the deepest point on the curved profile of the maxilla between the Anterior Nasal Spine and the alveolar crest) and Point B (the deepest point on the curved profile of the mandible between the chin and alveolar crest). Used to determine the skeletal class.
G-G'	Linear distance from the most prominent point on the frontal bone to the soft tissue prominence on the forehead.
N-N'	Linear distance from the skeletal Nasion to the soft tissue Nasion.
Rh	Perpendicular distance from the intersection of the nasal bone and cartilage to the nasal soft tissue.
Sn-A	Linear distance between the point Subnasale and the A point.
Ls-Pr	Linear distance between the most prominent point of the upper lip and the point Prosthion.
St-U1	Linear distance between the most prominent point of the upper incisor and the point Stomion.
Li-Id	Linear distance between the most prominent point of the lower lip and the point Infradentale.
B-Lm	Linear distance from the point B to the Labiomental sulcus.
Pg-Pg'	Linear distance between the skeletal Pogonion and the soft tissue Pogonion.
Me-Me'	Linear distance between the skeletal Menton and the soft tissue Menton.

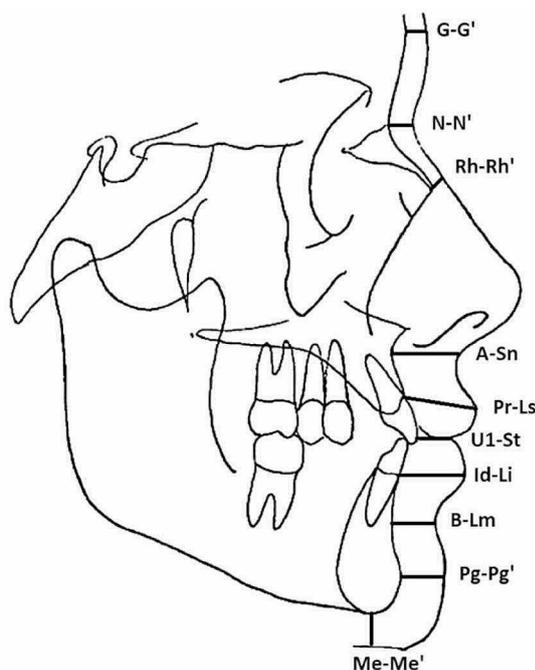


Fig. 1 Thickness of the soft tissue profile at landmarks

Table 2 Allocation of patients to groups

	Age	ANB value/ skeletal class
Group 1	17–35	0–4° / skeletal Class I
Group 2	17–35	> 4° / skeletal Class II
Group 3	17–35	< 0° / skeletal Class III
Group 4	7–16	0–4° / skeletal Class I
Group 5	7–16	> 4° / skeletal Class II
Group 6	7–16	< 0° / skeletal Class III

(Table 2). The value of the ANB angle > 4 degrees was defined as skeletal Class II malocclusion, while 0 < as Class III malocclusion. Class I malocclusion was diagnosed for the values between 0 and 4 degrees.

The inclusion criteria for the minimum sample size was 60 participants with equal gender distribution in each of the groups based on the study by Kamak & Celikoglou [8]. The study was approved by the Bioethics Committee of the Medical University of Warsaw (AKBE/86/2022).

Statistical analysis

The statistical analysis was performed using PQStat software version 1.6.8. A level of significance was set at p < 0.05. Due to the lack of knowledge about the mean and standard deviation values of the evaluated parameters for the assessed populations, the Lilliefors test was used to analyze the normality of the distribution. The analysis revealed a lack of conformity to a normal distribution for most of the assessed parameters (age in the adult group, age in the children and adolescents’ group, G-G’; N-N’; Rh-Rh’; A-Sn, Pr-Ls, U1-St, Pg-Pg’, Me-Me’, and ANB), the non-parametric tests were utilized in further analyses (U Mann-Whitney and ANOVA Kruskal-Wallis).

Reliability of the measurements

Twenty randomly chosen cephalometric radiographs were re-traced by the same researcher (M.K.) at four-weeks interval. The obtained results were then compared with the previous cephalometric analysis. The Interclass Correlation Coefficient was used to determine the correlation between the first and the second measurements.

Results

The characteristics of the study groups including age differences is presented in Table 3. Group 6 was not included in the study as it failed to achieve the assumed group size. No statistically significant differences were demonstrated for age in children and adolescents; for adults, patients in Group 3 (Class III) were younger than patients in Group 1 (Class I) and Group 2 (Class II), and the difference was statistically significant (Table 4).

STFP thickness in relation to the skeletal class

Table 4 presents the mean thickness of STFP and standard deviation for each skeletal class in groups comprising

Table 3 Characteristics of patients in groups. The group 6 was not included as it failed to achieve the assumed group size

	Group size	Male	Female	Age range	Mean age + SD	Age comparison	
						Kruskal-Wallis ANOVA	post-hoc analysis
Group 1	60	30 (50%)	30 (50%)	Min: 17 Max: 35	25.5 ± 5.2	p=0.017	Gr. 3 vs. Gr. 1 (p=0.045)
Group 2	60	30 (50%)	30 (50%)	Min: 17 Max: 35	25.6 ± 5.7		
Group 3	60	30 (50%)	30 (50%)	Min: 17 Max: 34	23.0 ± 5.4		
Group 4	60	30 (50%)	30 (50%)	Min: 7 Max: 16	12.5 ± 2.4	p=0.987	Gr. 3 vs. Gr. 2 (p=0.035)
Group 5	60	30 (50%)	30 (50%)	Min: 8 Max: 16	12.5 ± 1.8		

Table 4 Comparisons of the STFP thickness relative to skeletal class in adult males and females (ANOVA Kruskal-Wallis test, post-hoc analysis acc. to Dunn with Bonferroni modification)

	Landmark	Class I vs. Class II	Class I vs. Class III	Class II vs. Class III	Mean thickness (mm)		
					I	II	III
Males	G-G'	N.s.	N.s.	N.s.	6.1	5.7	6.4
	N-N'	N.s.	N.s.	N.s.	6.5	6.2	6.9
	Rh-Rh'	N.s.	N.s.	N.s.	2.8	2.7	2.6
	A-Sn	0.036	N.s.	0.001	17.0	15.9	17.4
	Pr-Ls	N.s.	0.001	0.001	15.0	15.0	17.1
	U1-St	N.s.	0.001	0.001	7.2	6.7	9.5
	Id-Li	N.s.	N.s.	0.026	15.5	16.3	15.2
	B-Lms	N.s.	N.s.	N.s.	11.7	12.1	11.7
	Pg-Pg'	N.s.	N.s.	N.s.	12.2	12.6	11.7
	Me-Me'	N.s.	N.s.	N.s.	8.1	8.5	8.2
Females	G-G'	N.s.	N.s.	N.s.	5.7	5.7	5.9
	N-N'	N.s.	N.s.	N.s.	5.6	5.4	5.7
	Rh-Rh'	N.s.	N.s.	N.s.	2.5	2.2	2.2
	A-Sn	N.s.	0.001	0.001	14.0	13.8	15.7
	Pr-Ls	N.s.	0.004	0.023	12.3	12.3	13.9
	U1-St	N.s.	N.s.	0.001	5.4	4.7	6.3
	Id-Li	0.001	N.s.	0.001	13.1	14.8	13.2
	B-Lms	N.s.	N.s.	N.s.	10.7	11.3	10.8
	Pg-Pg'	N.s.	0.049	N.s.	11.2	11.2	10.2
	Me-Me'	N.s.	N.s.	N.s.	6.8	7.0	6.7

adult males and females. In both analyzed groups, the significant differences were observed in measurements of the chin area and both lips ($p < 0.05$); furthermore, in the female group, significant differences were also observed for the chin. Characteristically for males with Class II, the soft tissue thickness was the smallest in the subnasal area (A-Sn) in comparison with other areas. By analogy, males with Class III had the thickest soft tissues at the upper lip (Pr-Ls) and lip contact (U1-St) areas. Soft tissues of the lower lip (Id-Li) were thicker in males with Class II in comparison with Class III patients. In females, the measurement at the subnasal area (A-Sn) and the upper lip (Pr-Ls) revealed the higher thickness in patients with Class III, while the thickness of the lower lip (Id-Li) was the highest in the Class II malocclusion. Females with Class III had thicker soft tissues at the lip contact area (U1-St) than those with Class II malocclusion. The chin thickness (Pg-Pg) was higher in patients with Class I than in Class III malocclusion.

Table 5 presents mean STFP thickness and standard deviation in relation to the skeletal class in boys and girls. The boys with Class I malocclusion had significantly ($p < 0.05$) higher measurements at the Glabella (G-G'), Subnasale (A-Sn) and the chin (Me-Me'), in contrary to the thickness of the lower lip (Id-Li) where higher values were found for the boys with Class II malocclusion. In girls with Class I malocclusion higher soft tissue thickness was present at the subnasale (A-Sn), upper lip (Pr-Ls) and lip contact (U1-St) areas. Girls with Class II malocclusion had thicker soft tissues at the lower lip (Id-Li) and the chin (Pg-Pg') areas.

STFP thickness in relation to age

Table 6 presents differences in the mean thickness of STFP and standard deviation for males and females in both age groups in relation to the skeletal malocclusion. As for males, adults with Class I malocclusion had significantly thicker soft tissues in 9 out of 10 measurements, while in Class II malocclusion significantly thicker

Table 5 Comparisons of STFP thickness in relation to skeletal classes in boys and girls (U Mann-Whitney test)

	Landmark	Class I vs. Class II	Mean thickness (mm)	
			Class I	Class II
Boys	G-G'	0.026	6.1	5.5
	N-N'	N.s.	5.9	5.5
	Rh-Rh'	N.s.	2.3	2.4
	A-Sn	0.006	14.9	13.8
	Pr-Ls	N.s.	13.9	13.6
	U1-St	N.s.	5.7	4.9
	Id-Li	0.001	13.7	15.6
	B-Lms	N.s.	10.9	11.1
	Pg-Pg'	N.s.	10.8	10.1
	Me-Me'	0.021	6.8	6.2
Girls	G-G'	N.s.	5.8	5.4
	N-N'	N.s.	5.2	5.3
	Rh-Rh'	N.s.	2.2	2.2
	A-Sn	0.031	13.8	13.0
	Pr-Ls	0.044	12.8	11.8
	U1-St	0.009	5.0	4.2
	Id-Li	0.006	12.5	13.7
	B-Lms	N.s.	9.8	10.0
	Pg-Pg'	0.040	9.6	10.6
	Me-Me'	N.s.	6.0	6.5

soft tissues were present in 7 out of 10 measurements ($p < 0.05$).

Significantly thicker soft tissues in adult females in comparison with girls were present for 3 measurements in patients with Class I malocclusion (B-Lms, Pg-Pg', Me-Me') and Class II malocclusions (A-Sn, Id-Li, B-Lms).

STFP thickness in relation to gender

The differences in the STFP thickness between adult females and males are presented in Table 7. Males had significantly thicker STFP than females in all measurements except G-G' measurement. In growing patients, the same tendency towards increased STFP thickness was observed in boys, however, there were more measurements for which the difference between boys and girls was not statistically significant (Table 8). In patients with Class I malocclusion boys had significantly thicker STFP in seven out of ten landmarks; by analogy, in patients with Class II malocclusion higher STFP thickness was demonstrated in five out of ten measurements in boys.

High repeatability of the measurements was found ($p < 0.001$), with ICC values > 0.90 for most of the parameters, with the exception of (U1-St and B-Lms) where the values were 0.89 and 0.87, respectively (Table 9).

Table 6 Age-related comparisons of STFP thickness (considering gender and skeletal classes). The U Mann-Whitney test

	Landmarks	Adults vs. children and adolescents	Mean thickness (mm)		
			Children and adolescents	Adults	
Males	Class I	G-G'	N.s.	6.1	6.1
		N-N'	0.030	5.9	6.5
		Rh-Rh'	0.005	2.3	2.8
		A-Sn	0.001	14.9	17.0
		Pr-Ls	0.006	13.9	15.0
		U1-St	0.001	5.7	7.2
		Id-Li	0.001	13.7	15.5
		B-Lms	0.026	10.9	11.7
		Pg-Pg'	0.003	10.8	12.2
		Me-Me'	0.001	6.8	8.1
Fe-males	Class II	G-G'	N.s.	5.5	5.7
		N-N'	0.006	5.5	6.2
		Rh-Rh'	N.s.	2.4	2.7
		A-Sn	0.001	13.8	15.9
		Pr-Ls	0.002	13.6	15.0
		U1-St	0.002	4.9	6.7
		Id-Li	N.s.	15.6	16.3
		B-Lms	0.006	11.1	12.1
		Pg-Pg'	0.001	10.1	12.6
		Me-Me'	0.001	6.2	8.5
Fe-males	Class I	G-G'	N.s.	5.8	5.7
		N-N'	N.s.	5.2	5.6
		Rh-Rh'	N.s.	2.2	2.5
		A-Sn	N.s.	13.8	14.0
		Pr-Ls	N.s.	12.8	12.3
		U1-St	N.s.	5.0	5.4
		Id-Li	N.s.	12.5	13.1
		B-Lms	0.001	9.8	10.7
		Pg-Pg'	0.001	9.6	11.2
		Me-Me'	0.009	6.0	6.8
Fe-males	Class II	G-G'	N.s.	5.4	5.7
		N-N'	N.s.	5.3	5.4
		Rh-Rh'	N.s.	2.2	2.2
		A-Sn	0.031	13.0	13.8
		Pr-Ls	N.s.	11.8	12.3
		U1-St	N.s.	4.2	4.7
		Id-Li	0.004	13.7	14.8
		B-Lms	0.001	10.0	11.3
		Pg-Pg'	N.s.	10.6	11.2
		Me-Me'	N.s.	6.5	7.0

Discussion

There are many factors influencing therapeutic options for patients with skeletal malocclusion such as the severity of malocclusion and the patient's expectations. In severe skeletal malocclusions the combined orthodontic and surgical treatment is often applied. It involves orthognathic surgery which aims to obtain normal skeletal relations of the maxilla and the mandible by a surgical

Table 7 Gender-related differences in the STFP thickness in adults (U Mann-Whitney test)

	Landmarks	Descriptive statistics				Gender differences
		Male		Female		p-value
		Mean	S.D	Mean	S.D	
Class I	G-G'	6.1	0.9	5.7	1.0	0.129 (N.s)
	N-N'	6.5	0.9	5.6	0.8	0.001
	Rh-Rh'	2.8	0.6	2.5	0.6	0.029
	A-Sn	17.0	1.5	14.0	1.2	0.001
	Pr-Ls	15.0	1.7	12.3	1.4	0.001
	U1-St	7.2	1.6	5.4	1.3	0.001
	Id-Li	15.5	1.6	13.1	1.6	0.001
	B-Lms	11.7	1.3	10.7	1.0	0.001
	Pg-Pg'	12.2	1.6	11.2	1.5	0.013
Class II	Me-Me'	8.1	1.5	6.8	1.3	0.002
	G-G'	5.7	0.8	5.7	0.6	0.853 (N.s)
	N-N'	6.2	0.9	5.4	1.0	0.001
	Rh-Rh'	2.7	0.5	2.2	0.4	0.001
	A-Sn	15.9	1.3	13.8	1.4	0.001
	Pr-Ls	15.0	1.7	12.3	2.1	0.001
	U1-St	6.7	2.2	4.7	1.5	0.001
	Id-Li	16.3	1.4	14.8	1.4	0.001
	B-Lms	12.1	1.0	11.3	1.4	0.028
Class III	Pg-Pg'	12.6	1.8	11.2	1.8	0.007
	Me-Me'	8.5	1.7	7.0	1.5	0.001
	G-G'	6.4	1.0	5.9	1.1	0.069 (N.s)
	N-N'	6.9	1.5	5.7	0.9	0.002
	Rh-Rh'	2.6	0.7	2.2	0.5	0.025
	A-Sn	17.4	1.7	15.7	1.7	0.001
	Pr-Ls	17.1	2.2	13.9	2.0	0.001
	U1-St	9.5	1.9	6.3	1.8	0.001
	Id-Li	15.2	1.8	13.2	1.4	0.001
B-Lms	11.7	1.0	10.8	1.2	0.007	
Pg-Pg'	11.7	2.5	10.2	1.7	0.021	
Me-Me'	8.2	1.8	6.7	1.6	0.001	

repositioning. Alternatively, the treatment plan may involve orthodontic camouflage of the underlying skeletal malocclusion, which aims to achieve the normal dental relations without changing the morphology and position of the maxilla and the mandible. The orthodontic camouflage will not significantly alter the patient's face despite improvement of occlusion in contrast to the orthognathic surgery. The thickness of the STFP is important when planning the orthodontic treatment in patients with skeletal malocclusions as such differences may camouflage the existing skeletal discrepancies. It was shown in the present study that differences in the STFP thickness are related to the type of skeletal malocclusion, patient's age and gender.

In the majority of studies evaluating differences in soft tissue thickness of the facial profile, the number of patients included in the study group ranged from 20 to 77 [7–9, 13, 14]. In the present study the minimum number of participants was 60 in each study group. Kamak & Celikoglu evaluated facial soft tissue thickness among

different skeletal malocclusions [8]. They have calculated, that the sample size to detect a clinically meaningful difference required 30 male and 30 female patients in each skeletal group, which was included in the present study.

STFP thickness in relation to the skeletal class

The increased soft tissue thickness in the subnasal, the upper lip and the lip contact areas in adults with skeletal Class III indicated, that STFP may mask the presence of skeletal disproportion by adjustment of their thickness. By analogy, soft tissue compensation was also demonstrated for the increased lower lip thickness in patients with Class II malocclusion. Similar conclusions were reported in few published reports [7–11, 13, 14, 26, 27].

In the present study, only the growing patients with Class I and II malocclusions were compared. That was related to the insufficient number of recruited children with skeletal Class III malocclusion, which is a much rarer sagittal malocclusion in the population. It was demonstrated, that in growing patients the thickness of

Table 8 Gender-related differences in the STFP thickness in children and adolescents (U Mann-Whitney test)

	Landmarks	Descriptive statistics				Gender differences
		Male		Female		p-value
		Mean	S.D	Mean	S.D	
Class I	G-G'	6.1	1.1	5.8	0.8	0.300 (N.s.)
	N-N'	5.9	0.9	5.2	0.8	0.003
	Rh-Rh'	2.3	0.6	2.2	0.4	0.824 (N.s.)
	A-Sn	14.9	1.5	13.8	1.4	0.006
	Pr-Ls	13.9	1.7	12.8	1.6	0.010
	U1-St	5.7	1.5	5.0	1.3	0.139 (N.s.)
	Id-Li	13.7	1.1	12.5	1.7	0.009
	B-Lms	10.9	1.5	9.8	0.7	0.004
	Pg-Pg'	10.8	1.6	9.6	1.3	0.003
	Me-Me'	6.8	1.2	6.0	0.9	0.007
Class II	G-G'	5.5	1.0	5.4	0.9	0.917 (N.s.)
	N-N'	5.5	1.2	5.3	1.0	0.965 (N.s.)
	Rh-Rh'	2.4	0.5	2.2	0.5	0.052 (N.s.)
	A-Sn	13.8	1.4	13.0	1.4	0.027
	Pr-Ls	13.6	2.0	11.8	1.5	0.001
	U1-St	4.9	1.5	4.2	1.1	0.041
	Id-Li	15.6	1.4	13.7	1.3	0.001
	B-Lms	11.1	1.1	10.0	1.3	0.002
	Pg-Pg'	10.1	1.4	10.6	1.9	0.314 (N.s.)
	Me-Me'	6.2	1.3	6.5	1.4	0.301 (N.s.)

Table 9 Intraclass Correlation Coefficient which determines absolute concordance between the first and the second measurement

	G-G'	N-N'	Rh-Rh'	A-Sn	Pr-Ls	U1-St	Id-Li	B-Lms	Pg-Pg'	Me-Me'
ICC	0.95	0.95	0.92	0.94	0.91	0.89	0.96	0.87	0.96	0.97
p (test F)	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001	<0.001

the lower lip is higher in patients with Class II than in patients with Class I malocclusion. By analogy, the measurement of thickness at the subnasal area (A-Sn) in both genders had lower values in Class II in comparison with Class I skeletal malocclusions. These differences in children and adolescents in relation to the skeletal class were analogous to the results for adults. The correlation between the STFP and the skeletal malocclusion in growing patients were not often previously reported. Pithon et al. demonstrated that the soft tissue thickness in the lip contact area in boys and girls with skeletal Class III malocclusion was greater than in the Class II. In girls with Class II malocclusion the thickness of the lower lip was greater than in the Class III group. In boys with skeletal Class III malocclusion the chin soft tissues (Pg-Pg') were significantly thicker in comparison with the Class II. On the other hand, Lopatiene evaluated children aged 14–16 years and did not report differences in the upper lip thickness in relation to the skeletal malocclusion [28].

Patients who had lower thickness of the STFP, especially in areas with skeletal discrepancies in the sagittal dimension, the camouflage treatment can be regarded as a compromise, because despite improvement of occlusion, the patient's profile will still expose underlying

skeletal malocclusion, which may be unsatisfactory to the patient. In such clinical situations, the combined orthodontic-surgical treatment should be considered.

STFP thickness in relation to age

The comparisons of STFP between the adult and growing patients confirmed their increased thickness in adults. Significant differences, however, were not shown for all the measurements. This may be due to the fact that the participating children and adolescents were mixed in the sense that their craniofacial development was at different stages. At the age of 16, both boys and girls finished the greatest growth associated with the period of adolescence, which may indicate the stabilization of the morphology of the craniofacial structures. We have decided to set the age at 16 years based on the results by Maman-dras [29], who evaluated lip thickness from the age of 2 until the age of 18 years. He concluded, that no significant changes were observed after the age of 16. For these reasons, it was decided to define the age of 16 as the boundary age for individuals in the growth period in the conducted study. Cervical vertebrae maturation (CVM) is a valuable method for assessing the craniofacial skeletal maturational stage of an individual. In the present

study the CVM method was not used, but it is worthy to consider this method in evaluation of the STFP thickness in the future.

Studies published so far indicated, that the STFP thickness increases with age in growing patients [18–22]. Smith et al. demonstrated that soft tissues become thicker with age with the most prominent changes occurring in the nasal and subnasal areas [30]. Jeelani indicated the increase of the STFP thickness in the lower part of the face with age, which was not manifested for the soft tissues at the forehead [31]. The STFP thickness changes in adults were not much reported in the literature. Chen et al. performed a MRI examinations in adults and demonstrated a close association of the STFP thickness in relation to age. The mean STFP thickness increased with age in adult males and females, gradually declining after the age of 60 years. The thickest STFP in male and females was found at the ages of 45–59 and 35–44 years, respectively [23]. A study by Drgáčová et al. in adults aged 21–83 years based on CT scans revealed that STFP increased its thickness with age in both males and females [24]. These results were confirmed by Formby et al. who reported age-related STFP thickness changes in adult patients. The soft tissue thickness of the nose and chin increased with age in males, but decreased in the upper lip; the thickness also decreased slightly in the lower lip. In females, the soft tissue thickness increased at the nose, while decreased at the chin and the upper lip. The lower lip thickness increased only slightly [25]. There is a lack of studies which compare the STFP thickness between adult and growing patients.

STFP thickness in relation to gender

Different authors demonstrated the presence of sexual dimorphism regarding STFP thickness based on cephalometric radiographs [7–9, 13, 15, 32]. They demonstrated higher values of STFP thickness in most of the measurements in males in comparison to females. Inconclusive results were presented by Perović et al. [33], according to which females in group II division 1 malocclusion had significantly thicker STFP while in Class III there were no significant differences between genders. These differences may result from the selection of different landmarks used in the cephalometric analysis as well as different allocation of subjects to groups. Thicker STFP in males in comparison with females was demonstrated in two other studies, where Arnett's cephalometric analysis was used [16, 34]; yet, both studies compared males and females with normal occlusion. Thicker STFP in males were also obtained from studies in which the cone-beam computed tomography (CBCT) [14, 35] and the magnetic resonance imaging (MRI) [23, 36] examinations were used. Domaracki et al. [37] conducted a study on human cadavers using a needle puncture and did not

reveal any statistically significant differences in STFP thickness between males and females. This may be due to the examination method used in this study.

Studies of children aged 8–12 years conducted in Brazil by Pithon et al. [12] demonstrated that boys with the skeletal Class I malocclusion had significantly thicker soft tissues than girls at the base of the nose, in the subnasal and the upper lip areas. Lopatiene examined children aged 14–16 years and found higher values for the upper lip thickness in boys compared with girls [23]. Hoffelder reported, that the upper and lower lips were thicker in boys than in girls in most of the examined age groups [20]. Gibelli noted thicker STFP in boys versus girls, and the differences were higher in the oldest of the examined age groups (14–18 years) [18]. Sexual dimorphism in relation to STFP in children was also observed in other studies [19]. According to Jeelani, sexual dimorphism with regard to STFP thickness manifested itself at the age of 13 years [31]. Utsuno et al. [17] denied any manifestation of sexual dimorphism relative to STFT in children younger than 11 years; it can be observed after the age of 12 years.

Limitations

Absence of data on body mass or the body mass index in the study group may be regarded as a limitation of this study. According to reports in the literature, BMI may significantly affect facial soft tissue thickness and therefore it should be considered [38, 39]. However, due to the retrospective character of this study and absence of routinely collected data on height and weight in adult patients, calculating BMI was not possible. Considering the large sample size in the present study, it can be assumed that the results represent a mean body masses in the Polish/ Caucasian populations. All the patients included in the study were Caucasians, which is another limitation of the study. The performed cephalometric analysis of the STFP was used to compare the thickness of soft tissues in specific areas between groups. It does not have specific norms serving as a reference point regarding the normal values of the STFP thickness at the different facial areas.

Conclusions

The evaluation of the STFP thickness revealed the presence of sexual dimorphism. Males have higher STFP thickness than females, both in adult and in growing patients.

The study also demonstrated the presence of compensatory soft tissue adaptations to skeletal malocclusions, manifested as increased thickness of the STFP in the upper lip and nasolabial area in patients with skeletal Class III malocclusion, as well as increased thickness of the lower lip in patients with skeletal Class II

malocclusion. The results of the study indicated increased thickness of the STFP in adults compared to children and adolescents, particularly within the male gender.

Acknowledgements

Not applicable.

Author contributions

Study design and methodology, M.K., K.P. and E.C.; collection of material, M.K. and K.K.; validation, M.K. and E.C.; writing—original draft preparation, M.K. and E.C.; writing—review and editing, M.K., K.P., K.K., M.Z. and E.C.; supervision, E.C. and M.Z. All authors have read and agreed to the published version of the manuscript.

Funding

No funding was received for the study.

Data availability

The datasets used and analysed during the study are available from the corresponding author on the reasonable request.

Declarations

Ethics approval and consent to participate

The study was approved by the Bioethics Committee of the Medical University of Warsaw (AKBE/86/2022) following the Declaration of Helsinki. The study is based on the retrospective data available at the Department of Orthodontics, Medical University in Warsaw. The Bioethics Committee of the Medical University of Warsaw waived the need for informed consent from the patients (whose data are used for research).

Consent for publication

Not applicable.

Competing interests

The authors declare no competing interests.

Received: 17 March 2024 / Accepted: 14 June 2024

Published online: 20 June 2024

References

- Arnett GW, Gunson MJ. Facial planning for orthodontists and oral surgeons. *Am J Orthod Dentofac Orthop.* 2004;126:290–5. PubMed.
- Wilkinson C. Facial reconstruction - anatomical art or artistic anatomy? *J Anat.* 2010;216:235–50. PubMed.
- Ackerman JL, Proffit WR, Sarver DM. The emerging soft tissue paradigm in orthodontic diagnosis and treatment planning. *Clin Orthod Res.* 1999;2:49–52. PubMed.
- Holdaway RA. A soft-tissue cephalometric analysis and its use in orthodontic treatment planning. Part II. *Am J Orthod.* 1984;85:279–93. PubMed.
- Arnett GW, Jelic JS, Kim J, Cummings DR, Beress A, Worley CM Jr, Chung B, Bergman R. Soft tissue cephalometric analysis: diagnosis and treatment planning of dentofacial deformity. *Am J Orthod Dentofac Orthop.* 1999;116:239–53. PubMed.
- Kielczykowski M, Kamiński K, Perkowski K, Zadurska M, Czochrowska E. Application of Artificial Intelligence (AI) in a cephalometric analysis: a narrative review. *Diagnostics (Basel).* 2023;13:2640. PubMed.
- Hamid S, Abuaffan AH. Facial soft tissue thickness in a sample of Sudanese adults with different occlusions. *Forensic Sci Int.* 2016;266:209–14. PubMed.
- Kamak H, Celikoglu M. Facial soft tissue thickness among skeletal malocclusions: is there a difference? *Korean J Orthod.* 2012;42:23–31. PubMed.
- Gungor K, Bulut O, Hizliol I, Hekimoglu B, Gurcan S. Variations of midline facial soft tissue thicknesses among three skeletal classes in Central Anatolian adults. *Leg Med (Tokyo).* 2015;17:459–66. PubMed.
- Kurkcuoglu A, Pelin C, Ozener B, Zagyapan R, Sahinoglu Z, Yazici AC. Facial soft tissue thickness in individuals with different occlusion patterns in adult Turkish subjects. *Homo.* 2011;62:288–97. PubMed.
- Utsuno H, Kageyama T, Uchida K, Yoshino M, Oohigashi S, Miyazawa H, Inoue K. Pilot study of facial soft tissue thickness differences among three skeletal classes in Japanese females. *Forensic Sci Int.* 2010;195:165. PubMed.
- Pithon MM, Rodrigues Ribeiro DL, Lacerda dos Santos R, Leite de Santana C, Pedrosa Cruz JP. Soft tissue thickness in young north eastern Brazilian individuals with different skeletal classes. *J Forensic Leg Med.* 2014;22:115–20. PubMed.
- Hussein HM. The variation of facial soft tissue thickness in Iraqi adult subjects with different skeletal classes. *J Baghdad Coll Dent.* 2012;24:143–9. ResearchGate.
- Farias Gomes A, Moreira DD, Zanon MF, Groppo FC, Haiter-Neto F, Freitas DQ. Soft tissue thickness in Brazilian adults of different skeletal classes and facial types: a cone beam CT - study. *Leg Med (Tokyo).* 2020;47:101743. PubMed.
- Utsuno H, Kageyama T, Uchida K, Kibayashi K. Facial soft tissue thickness differences among three skeletal classes in Japanese population. *Forensic Sci Int.* 2014;236:175–80. PubMed.
- Uysal T, Yagci A, Basciftci FA, Sisman Y. Standards of soft tissue Arnett analysis for surgical planning in Turkish adults. *Eur J Orthod.* 2009;31:449–56. PubMed.
- Utsuno H, Kageyama T, Deguchi T, Umemura Y, Yoshino M, Nakamura H et al. Facial soft tissue thickness in skeletal type I Japanese children. *Forensic Sci Int.* 2007;172:137–43. PubMed.
- Gibelli D, Collini F, Porta D, Zago M, Dolci C, Cattaneo C, Sforza C. Variations of midfacial soft-tissue thickness in subjects aged between 6 and 18 years for the reconstruction of the profile: a study on an Italian sample. *Leg Med (Tokyo).* 2016;22:68–74. PubMed.
- Nanda RS, Meng H, Kapila S, Goorhuis J. Growth changes in the soft tissue facial profile. *Angle Orthod.* 1990;60:177–90. PubMed.
- Hoffelder LB, de Lima EM, Martinelli FL, Bolognese AM. Soft-tissue changes during facial growth in skeletal class II individuals. *Am J Orthod Dentofac Orthop.* 2007;131:490–5. PubMed.
- Sahin Sağlam AM, Gazilerli U. Analysis of Holdaway soft-tissue measurements in children between 9 and 12 years of age. *Eur J Orthod.* 2001;23:287–94. PubMed.
- Bergman RT, Waschak J, Borzabadi-Farahani A, Murphy NC. Longitudinal study of cephalometric soft tissue profile traits between the ages of 6 and 18 years. *Angle Orthod.* 2014;84:48–55. PubMed.
- Chen F, Chen Y, Yu Y, Qiang Y, Liu M, Fulton D, Chen T. Age and sex related measurement of craniofacial soft tissue thickness and nasal profile in the Chinese population. *Forensic Sci Int.* 2011;212:272. PubMed.
- Drgáčová A, Dupej J, Velemínská J. Facial soft tissue thicknesses in the present Czech Population. *Forensic Sci Int.* 2016;260:106. PubMed.
- Formby WA, Nanda RS, Currier GF. Longitudinal changes in the adult facial profile. *Am J Orthod Dentofac Orthop.* 1994;105:464–76. PubMed.
- Sarilita E, Rynn C, Mossey PA, Black S, Oscandar F. Facial average soft tissue depth variation based on skeletal classes in Indonesian adult population: a retrospective lateral cephalometric study. *Leg Med (Tokyo).* 2020;43:101665. PubMed.
- Chu G, Han MQ, Ji LL, Li MJ, Zhou H, Chen T, Guo YC. Will different sagittal and vertical skeletal types relate the soft tissue thickness: a study in Chinese female adults. *Leg Med (Tokyo).* 2020;42:101633. PubMed.
- Lopatienė K, Šidlauskas A, Vasiliauskas A, Čečytė L, Švalkauskienė V, Šidlauskas M. Relationship between malocclusion, soft tissue profile, and pharyngeal airways: a cephalometric study. *Med (Kaunas).* 2016;52:307–14. PubMed.
- Mamandras AH. Growth of lips in two dimensions: a serial cephalometric study. *Am J Orthod.* 1984;86:61–6. PubMed.
- Smith SL, Buschang PH. Midsagittal facial soft-tissue growth of French Canadian adolescents. *Am J Hum Biol.* 2002;14:457–67. PubMed.
- Jeelani W, Fida M, Shaikh A. Age and sex-related variations in facial soft tissue thickness in a sample of Pakistani children. *Aust J Forensic Sci.* 2017;49:1–14. Article.
- Wang J, Zhao X, Mi C, Raza I. The study on facial soft tissue thickness using Han population in Xinjiang. *Forensic Sci Int.* 2016;266:585. PubMed.
- Perović T, Blažej Z. Male and female characteristics of facial soft tissue thickness in different Orthodontic malocclusions evaluated by Cephalometric Radiography. *Med Sci Monit.* 2018;24:3415–24. PubMed.
- Kalha AS, Latif A, Govardhan SN. Soft-tissue cephalometric norms in a south Indian ethnic population. *Am J Orthod Dentofac Orthop.* 2008;133:876–81. PubMed.
- Hwang HS, Park MK, Lee WJ, Cho JH, Kim BK, Wilkinson CM. Facial soft tissue thickness database for craniofacial reconstruction in Korean adults. *J Forensic Sci.* 2012;57:1442–7. PubMed.

36. Kaur K, Sehwat JS, Bahadur R. Sex dependent variations in craniofacial soft-tissue thickness estimated from MRI and CT scans: a pilot study based on Northwest Indian subjects. *Int J Diagn Imaging*. 2017;4:47–56. ResearchGate.
37. Domaracki M, Stephan CN. Facial soft tissue thicknesses in Australian adult cadavers. *J Forensic Sci*. 2006;51:5–10. PubMed.
38. Dong Y, Huang L, Feng Z, Bai S, Wu G, Zhao Y. Influence of sex and body mass index on facial soft tissue thickness measurements of the northern Chinese adult population. *Forensic Sci Int*. 2012;222:396. PubMed.
39. De Greef S, Vandermeulen D, Claes P, Suetens P, Willems G. The influence of sex, age and body mass index on facial soft tissue depths. *Forensic Sci Med Pathol*. 2009;5:60–5. PubMed.

Publisher's Note

Springer Nature remains neutral with regard to jurisdictional claims in published maps and institutional affiliations.

Wnioski i podsumowanie

1. Morfologia TMPT oceniana na podstawie analizy cefalometrycznej teleradiogramów bocznych głowy ma znaczenie w planowaniu leczenia ortodontycznego szkieletowych wad zgryzu. Istnieje zależność pomiędzy grubością TMPT a szkieletową wadą zgryzu i płcią, co może stanowić cenną wskazówkę w leczeniu ortodontycznym u pacjentów ze szkieletowymi wadami zgryzu, szczególnie w odniesieniu do leczenia kamuflażem ortodontycznym.
2. Użycie algorytmów AI w celu przeprowadzenia analizy cefalometrycznej zarówno twardych i miękkich tkanek twarzoczaszki może znacząco ułatwić i przyspieszyć diagnostykę ortodontyczną, szczególnie dla mniej doświadczonych klinicystów. Skuteczność automatycznego wyznaczania punktów cefalometrycznych przez algorytmy AI jest wysoka, a dalszy rozwój technologiczny może sprawić, że w przyszłości zastąpi manualną analizę cefalometryczną.
3. Istnieje zależność między grubością TMPT a klasą szkieletową wady zgryzu u pacjentów ortodontycznych. Wykazano obecność kompensacji w zakresie grubości TMPT w rejonie niewystarczającego wzrostu szczęk, która może maskować dysproporcję kostną i wpływać na estetykę twarzy pacjenta z wadą szkieletową. Stopień tej kompensacji może mieć znaczenie w podejmowaniu decyzji o leczeniu operacyjnym lub kamuflażowym wad gnatycznych.
4. Grubość TMPT różni się w zależności od wieku pacjentów i ich grubość jest większa u dorosłych w porównaniu do pacjentów w wieku rozwojowym.
5. Kobiety i mężczyźni cechują się różną grubością TMPT. Wykazano obecność dymorfizmu płciowego w zakresie grubości TMPT zgodnie z którym TMPT są grubsze u mężczyzn w porównaniu do kobiet niezależnie od wieku pacjentów ortodontycznych.

Biorąc pod uwagę powyższe wnioski można podsumować, że analiza cefalometryczna z uwzględnieniem grubości TMPT powinna być uwzględniana w planowaniu leczenia ortodontycznego u pacjentów ze szkieletowymi wadami zgryzu. Rozwój technologiczny, w szczególności zastosowanie algorytmów AI w diagnostyce ortodontycznej ułatwi jej rutynowe stosowanie w przyszłości. Wskazane jest kontynuowanie badań dotyczących oceny TMPT w powiązaniu z innymi czynnikami takimi jak masa ciała pacjentów i ich przynależność do różnych ras. Także należy opracować jak najbardziej dokładny algorytm AI do analizy cefalometrycznej TMPT oparty na odpowiednio licznych i wiarygodnych bazach danych.



Komisja Bioetyczna przy Warszawskim Uniwersytecie Medycznym

Tel.: 022/ 57 - 20 -303
Fax: 022/ 57 - 20 -165

ul. Żwirki i Wigury nr 61
02-091 Warszawa

e-mail: komisja.bioetyczna@wum.edu.pl
www.komisja-bioetyczna.wum.edu.pl

Warszawa, dnia 14 marca 2022r.

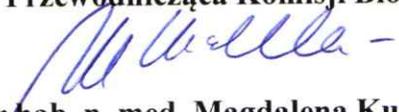
AKBE/ 86 / 2022

Lek. dent. Michał Kielczykowski
Zakład Ortodontji,
ul. Stanisława Binińskiego 6,
02-097 Warszawa

OŚWIADCZENIE

Niniejszym oświadczam, że Komisja Bioetyczna przy Warszawskim Uniwersytecie Medycznym w dniu 14 marca 2022r. przyjęła do wiadomości informację na temat badania pt „Ocena tkanek miękkich profilu twarzy w zależności od morfologii twarzowej części czaszki.” Przedstawione badanie nie stanowi eksperymentu medycznego w rozumieniu art. 21 ust. 1 ustawy z dnia 5 grudnia 1996 r. o zawodach lekarza i lekarza dentystry (Dz.U. z 2018 r. poz. 617) i nie wymaga uzyskania opinii Komisji Bioetycznej przy Warszawskim Uniwersytecie Medycznym, o której mowa w art. 29 ust.1 ww. ustawy.

Przewodnicząca Komisji Bioetycznej


Prof. dr hab. n. med. Magdalena Kuźma –Kozakiewicz

Prof. dr hab. n. med. Ewa Czochovska

OŚWIADCZENIE

Jako współautor pracy pt. „Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór merytoryczny nad wyborem piśmiennictwa, analiza i interpretacja otrzymanych wyników, współtworzenie manuskryptu i odpowiedz na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 20 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.



(podpis oświadczającego)

Prof. dr hab. n. med. Ewa Czołowska

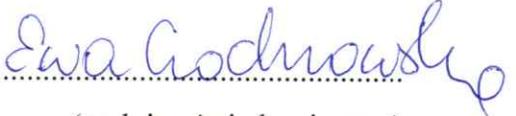
OŚWIADCZENIE

Jako współautor pracy pt. „Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór merytoryczny nad wyborem piśmiennictwa, analiza i interpretacja otrzymanych wyników, współtworzenie manuskryptu i odpowiedź na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 30 %.

Wkład Michała Kiełczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kiełczykowskiego.


.....
(podpis oświadczającego)

Prof. dr hab. n. med. Ewa Czochrowska

OŚWIADCZENIE

Jako współautor pracy pt. „Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: współtworzenie projektu badania, analiza i interpretacja otrzymanych wyników, nadzór merytoryczny nad prowadzeniem badania, współtworzenie manuskryptu i odpowiedź na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 26 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.



(podpis oświadczającego)

Dr n. med. Konrad Perkowski

OŚWIADCZENIE

Jako współautor pracy pt. „Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór merytoryczny nad wyborem piśmiennictwa, analiza i interpretacja otrzymanych wyników, współtworzenie manuskryptu i odpowiedź na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 31 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.



.....
(podpis oświadczającego)

Dr n. med. Konrad Perkowski

OŚWIADCZENIE

Jako współautor pracy pt. „Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór merytoryczny nad wyborem piśmiennictwa, analiza i interpretacja otrzymanych wyników, współtworzenie manuskryptu i odpowiedź na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 21 %.

Wkład Michała Kiełczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kiełczykowskiego.



.....
(podpis oświadczającego)

dr n. med. Konrad Perkowski

OŚWIADCZENIE

Jako współautor pracy pt. „Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: współtworzenie projektu badania, analiza i interpretacja otrzymanych wyników, nadzór merytoryczny nad prowadzeniem badania, współtworzenie manuskryptu i odpowiedz na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 25 %.

Wkład Michała Kiełczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kiełczykowskiego.



.....

(podpis oświadczającego)

Warszawa, 26.07.2024r

Prof. dr hab. n. med. Małgorzata Zadurska

OŚWIADCZENIE

Jako współautor pracy pt. „Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór nad tworzeniem protokołu badawczego, interpretacja otrzymanych wyników, odpowiedz na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.

.....
Michał

(podpis oświadczającego)

Warszawa, 26.07.2024r

Prof. dr hab. n. med. Małgorzata Zadurska

OŚWIADCZENIE

Jako współautor pracy pt. „Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór nad tworzeniem protokołu badawczego, interpretacja otrzymanych wyników, odpowiedz na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.



.....
(podpis oświadczającego)

Warszawa, 26.07.2024r

Prof. dr hab. n. med. Małgorzata Zadurska

OŚWIADCZENIE

Jako współautor pracy pt. „Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór nad tworzeniem protokołu badawczego, interpretacja otrzymanych wyników, odpowiedz na uwagi recenzentów, udostępnienie miejsca i sprzętu do prowadzenia badań.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.

.....
Mładek

(podpis oświadczającego)

Lek. dent. Konrad Kamiński

OŚWIADCZENIE

Jako współautor pracy pt. „Różnica grubości tkanek miękkich profilu twarzy w zależności od klasy szkieletowej oraz płci. Przegląd piśmiennictwa” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: współtworzenie protokołu badawczego, wykonanie badań, odpowiedz na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kiełczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedz na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kiełczykowskiego.

.....

(podpis oświadczającego)

Lek. dent. Konrad Kamiński

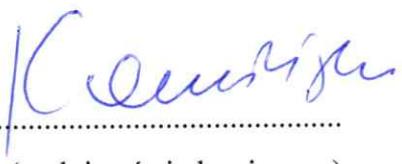
OŚWIADCZENIE

Jako współautor pracy pt. „Application of Artificial Intelligence (AI) in a Cephalometric Analysis: A Narrative Review.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: nadzór merytoryczny nad wyborem piśmiennictwa, analiza i interpretacja otrzymanych wyników, współtworzenie manuskryptu i odpowiedź na uwagi recenzentów.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.


.....
(podpis oświadczającego)

Lek. dent. Konrad Kamiński

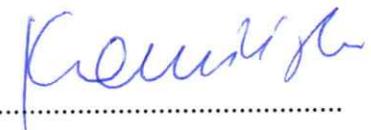
OŚWIADCZENIE

Jako współautor pracy pt. „Evaluation of the soft tissue facial profile in different skeletal malocclusions in relation to age.” oświadczam, iż mój własny wkład merytoryczny w przygotowanie, przeprowadzenie i opracowanie badań oraz przedstawienie pracy w formie publikacji stanowi: współtworzenie protokołu badawczego, analiza danych, interpretacja otrzymanych wyników.

Mój udział procentowy w przygotowaniu publikacji określam jako 7 %.

Wkład Michała Kielczykowskiego w powstawanie publikacji określam jako 35 %, obejmował on opracowanie protokołu badawczego, opracowanie metodologii, przeprowadzenie badań, analizę i interpretację wyników, przygotowanie manuskryptu i odpowiedź na uwagi recenzentów.

Jednocześnie wyrażam zgodę na wykorzystanie w/w pracy jako część rozprawy doktorskiej lek. dent. Michała Kielczykowskiego.



.....
(podpis oświadczającego)