Korean Journal of Clinical Dental Hygiene

Original Article

QLF 형광 영상 기반 딥러닝을 이용한 교합면 초기 우식 단계 분류의 개념적 타당성 평가

정은하
경북대학교 치위생학과

Deep Learning-Based Classification of Early Occlusal Caries from QLF Fluorescence Images: A Conceptual Validation Study

Received: January 12, 2026
Revised: January 27, 2026
Accepted: January 30, 2026

Eun-Ha Jung
Department of Dental Hygiene, College of Science and Technology, Kyungpook National University, Sangju, 37224, Korea

*Corresponding Author: 정은하, (37224) 경상북도 상주시 경상대로 2559 경북대학교 과학기술대학 치위생학과, Tel: 054-530-1426, E-mail: jeunha725@knu.ac.kr

Abstract

Objective: This study explored the preliminary feasibility of automatically classifying early-stage occlusal caries using deep learning applied to QLF fluorescence images. We examined whether the QS-Occlusal classification system could be implemented within an artificial intelligence framework by learning fluorescence-derived image patterns. **Methods:** QLF images were acquired from a single extracted tooth and classified into four QS-Occlusal stages (QS 0–3) according to fluorescence loss and red fluorescence characteristics. A total of 100 images were included; 83 were used for training and 17 for evaluation. A DenseNet-201 convolutional neural network pretrained on ImageNet was fine-tuned for four-class classification. Model performance was evaluated using confusion matrix analysis, accuracy, precision, recall, and F1-score. **Results:** Most samples were correctly classified in the confusion matrix. Agreement was highest for QS 0 and QS 3, while moderate misclassification was observed between QS 1 and QS 2, likely due to overlapping fluorescence patterns in early enamel lesions. Overall performance metrics indicate stable and reliable classification. **Conclusions:** Within the limitations of a single-tooth, proof-of-concept dataset, this study demonstrates the feasibility of deep learning–based QS-Occlusal classification using QLF images. This approach has the potential to support standardized assessment of early occlusal caries and provides a foundation for further validation using larger and more diverse datasets.

Key words: Automatic classification, Deep learning, Early caries, QLF, Quantitative evaluation

색 인: 자동 분류, 딥러닝, 초기 우식, QLF, 정량적 평가

Copyright © 2026 by Korean Journal of Clinical Dental Hygiene. This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(https://creativecommons.org/licenses/by-nc/4.0/).

1. 서론

치아우식증은 전 세계적으로 가장 흔한 만성 구강질환 중 하나로, 최근 수십 년간 불소 사용 확대와 예방 중심의 구강보건 정책에 힘입어 상아질까지 진행된 와동성 우식의 유병률은 감소하는 경향을 보이고 있다(1). 반면, 법랑질 단계에 국한된 비와동성 우식(Non-cavitated caries)의 상대적 비중은 지속적으로 증가하고 있으며, 이는 조기 진단과 비침습적 관리 전략의 중요성을 더욱 부각시키고 있다(2). 비와동성 우식은 재광화 치료 및 생활습관 개선을 통해 진행을 억제할 수 있음에도 불구하고(3), 임상적으로 정확한 진단이 어렵다는 한계로 인해 여전히 과소 또는 과잉 치료의 위험이 존재한다(4).

현재 임상에서는 우식증을 진단하기 위하여 시진 및 촉진을 이용한 탐지와 치과용 X-ray를 기반으로 한 영상 검사 등이 널리 사용되고 있으며, 특히 최근에는 비와동형 우식의 발생 빈도가 증가함에 따라 초기 우식 탐지에 적합한 ICDAS (International Caries Detection and Assessment System)가 활용되고 있다(5). ICDAS는 우식의 육안적 표현을 단계적으로 분류할 수 있는 표준화된 체계로 평가받고 있으나, 초기 병소에서의 민감도가 제한적이며 검사자의 숙련도와 주관적 판단에 크게 의존한다(6). 특히 교합면 우식의 경우, 해부학적으로 깊고 복잡한 소와 및 열구 구조로 인해 초기 탈회 병소를 육안으로 식별하기 어려우며, 치과용 X-ray 검사는 법랑질 단계 병소에 대한 민감도가 낮고 반복 촬영에 따른 방사선 노출 문제를 동반한다(7, 8).

이러한 한계를 보완하기 위해 형광 기반 진단 기술이 보조적 도구로 제안되어 왔으며, 그 중 QLF (Quantitative Light-Induced Fluorescence) 기술은 405 nm 파장의 청색광을 이용하여 치아의 자가형광 특성을 시각화함으로써 초기 탈회 병소를 탐지할 수 있는 기술로 주목받아 왔다. 탈회가 발생한 부위에서는 법랑질 결정 구조의 변화로 인해 형광 소실(Fluorescence loss, ΔF)이 관찰되며, 동시에 세균 대사 산물인 Porphyrin에 의해 적색 형광(Red fluorescence, ΔR)이 나타난다(9, 10). 이러한 형광 특성은 우식의 존재뿐만 아니라 병소의 활성도와 진행 정도를 반영할 수 있는 잠재적 바이오마커로 간주된다. 그러나 기존 QLF 기반 진단은 주로 전용 분석 소프트웨어를 통해 ΔF, ΔR과 같은 정량 지표를 산출하는 방식으로 이루어져 왔으며, 이 과정은 시간과 비용이 소요되고 임상 현장에서의 즉각적인 의사결정을 저해하는 요인으로 작용한다. 또한 정량 수치는 병소의 공간적 분포나 형광 패턴의 형태학적 특성을 충분히 반영하지 못하며, 임상의가 직관적으로 병소 상태를 이해하고 설명하는데 한계가 있다(11). 이러한 이유로 QLF 기술은 우식 진단의 잠재력을 지니고 있음에도 불구하고, 실제 임상 적용과 대규모 스크리닝에는 제한적으로 활용되고 있다.

이러한 한계점을 극복하기 위하여 선행 연구에서는 QLF 형광 영상에서 관찰되는 형광 소실과 적색 형광의 시각적 패턴을 기반으로 QS-Occlusal 분류체계를 제안하였다(11). 해당 체계는 교합면 우식을 QS 0에서 QS 3까지 네 단계로 분류함으로써, 정량 분석 없이도 병소의 진행 정도를 임상적으로 해석할 수 있는 새로운 접근을 제시하였다. QS-Occlusal은 ICDAS 및 조직학적 병소 깊이와 유의한 상관성을 보이며, 형광 패턴의 형태학적 특징을 진단 기준으로 도입하였다는 점에서 기존 진단 체계와 차별성을 가진다. 그럼에도 불구하고 QS-Occlusal은 여전히 사람 판독에 의존하는 분류 방식으로, 검사자 간 일관성 확보와 대규모 자동화 적용에는 구조적 한계가 존재한다.

한편, 인공지능 기반 영상 분석 기술, 특히 합성곱신경망(Convolutional Neural Network, CNN)은 의료 영상 분야에서 미세한 패턴 인식과 고차원 특징 추출에 탁월한 성능을 보여 왔다(12). 치과 영역에서도 방사선 영상, 구강 사진, 형광 영상을 대상으로 한 다양한 딥러닝 연구가 보고되고 있으나, 대부분 우식의 이분법적 분류 또는 단순 존재 여부 판단에 초점을 맞추고 있다. 형광 영상에서 나타나는 우식 진행 단계별 패턴을 임상적으로 의미 있는 분류체계와 직접적으로 연결한 연구는 아직 충분히 이루어지지 않았다. 따라서 QS-Occlusal과 같은 임상적 의미를 지닌 형광 기반 분류체계를 딥러닝 모델의 학습 라벨로 활용하고, 형광 패턴의 공간적·형태학적 특징을 자동으로 학습할 수 있는 인공지능 모델을 구축하는 것은 중요한 연구 공백으로 남아 있다.

이에 본 연구는 QLF 기술을 이용하여 촬영한 구치부 치아의 형광 이미지를 QS 0-3 단계로 분류하고, 이를 학습 라벨로 활용하여 DenseNet-201을 백본으로 하는 딥러닝 네트워크를 구축함으로써 형광 패턴 기반 우식 단계 분류의 가능성을 탐색하고자 한다. 본 연구의 목적은 정량 형광 지표를 직접 산출하지 않고도 형광 이미지 자체에 내재된 시각적 정보를 기반으로 우

식 진행 단계를 자동으로 분류할 수 있는 인공지능 모델의 개념적 타당성을 제시하는 데 있다.

2. 재료 및 방법

2.1. QLF 영상 데이터셋 구성

본 연구는 교정, 치주 및 보철치료 등의 목적으로 발거된 건전한 소구치 및 대구치 치아를 대상으로 촬영된 QLF 형광 영상을 이용하여 수행하였다. QLF 형광 영상은 QLF-D (Quantitative Light-induced Fluorescence-Digital) 장비를 사용하였으며, 조리개 값은 6.3, 셔터 스피드 1/45초, 초점 거리 0.32mm, ISO 감도 1600 하에서 Figure 1과 같이 촬영되었다. 본 연구의 평가를 수행하기에 앞서 연구에 이용된 100개의 촬영 이미지에는 식별번호를 부여하였고, 훈련된 연구자(Jung EH)가 QS-Occlusal 기준(Table 1)에 따라 교합면 QLF 형광 영상을 분류하였다.

QLF 형광 영상 데이터셋을 구성하기 전 이미지 사용은 OO 대학교 연구윤리 승인위원회의의 심의 면제를 받은 후 활용하였다.

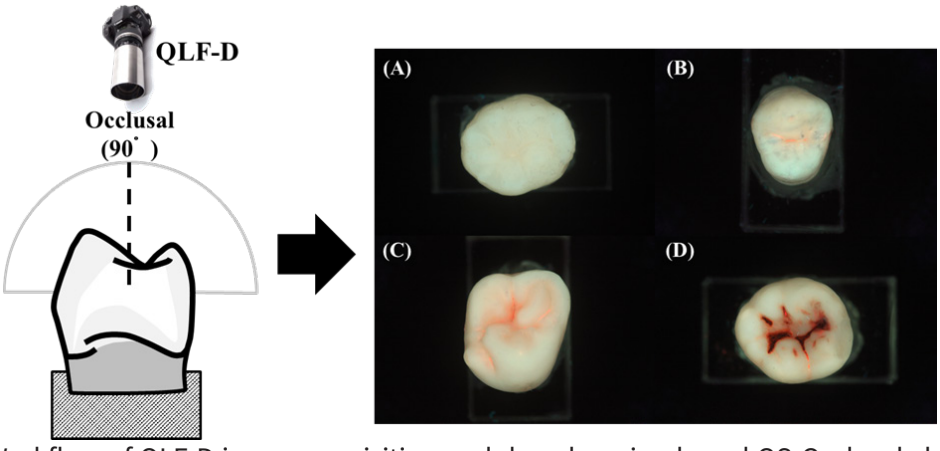


Figure 1. Workflow of QLF-D image acquisition and deep learning-based QS-Occlusal classification. QLF-D images were categorized by QS-Occlusal stages: (A) QS 0, (B) QS 1, (C) QS 2, and (D) QS 3.

Table 1. Description of QS-Occlusal values (11)

QS-Occlusal value	Description
0 Sound	No fluorescence loss and no red fluorescence increase in pits and/or fissures
1 Suspected or initial caries	Fluorescence loss and red fluorescence present as a line or spot in pits and/or fissures
2 Enamel caries	Fluorescence loss and red fluorescence glow extending around pits and fissures
3 Dentin caries	Red fluorescence glow extending around pits and fissures and a dark shadow from dentin present

2.2. 딥러닝 모델 및 파라미터

Figure 2는 제안하는 방법의 과정을 도식화한 것이다. 본 연구에서는 QLF-D 영상을 기반으로 QS 0-3 단계의 우식 진행 수준을 분류하기 위하여 합성곱신경망(CNN)을 이용한 다중 분류 모델을 구축하였다. 전체 데이터셋은 총 100장의 이미지로 구성되었으며, 이 중 83장은 학습(Training)에, 17장은 평가(Evaluation)에 사용했다. 각 클래스의 데이터는 QS 0이 16장, QS 1이 23장, QS 2가 25장, QS 3이 19장으로 균형 있게 설정하였으며, 각 클래스는 이미지가 저장된 폴더 이름을 라벨로 사용하는 방식으로 정의하였다. 모든 입력 영상은 원본 이미지의 중심부를 기준으로 1400×1400×3 pixels 영역을 추출한 뒤, 네트워크 입력에 적합하도록 후속 단계에서 224×224×3 pixels 크기로 리사이즈되도록 전처리 과정을 수행하였다. 학습 데이터에 한하여 데이터 증강(Data augmentation)을 적용하였다. 증강 기법은 형광 물성의 왜곡을 최소화하는 범위 내에서 회전(−10°~+10°), 좌우 반전, 수평 및 수직 이동(±20 pixels), 스케일 변환(0.9-1.1)을 포함하였고 20배로 증강하여 훈련을 수행하였다. 검증 및 평가 데이터에는 데이터 증강을 적용하지 않았다.

본 연구에서는 ImageNet 데이터셋으로 사전 학습된 DenseNet-201을 백본(Backbone) 네트워크로 사용하였다(13). DenseNet-201은 고해상도 영상에서 Dense connection 구조를 통해 특성 재사용(Feature reuse)을 극대화함으로써, 상대적으로 적은 학습 데이터 환경에서도 파라미터 수가 비교적 적어 과적합을 방지할 수 있어 안정적인 성능을 기대할 수 있다. 사전 학습된 DenseNet-201의 마지막 Fully connected 층(fc1000)을 제거하고, QS 0-3의 네 개 클래스를 분류하기 위한 새로운 Fully connected 층을 추가하였다. 이때 새로 추가된 분류층의 가중치와 바이어스에 대해 학습률 가중치를 10으로 설정하여, 사전 학습된 백본에 비해 상대적으로 빠르게 학습되도록 구성하였다. 최종 출력층에는 Softmax 함수를 적용하여 각 QS 단계에 대한 확률을 산출하였다. 네트워크 학습은 Adam 옵티마이저를 사용하여 수행하였다(14). 주요 학습 파라미터는 미니배치 크기 16, 최대 학습 Epoch 200, 초기 학습률 1×10^{-6}으로 설정하였다. 학습 데이터는 Epoch마다 무작위로 셔플되었으며, 학습 과정 중 100 Iteration마다 검증 데이터에 대한 성능 평가를 수행하였다. 손실 함수로는 다중 클래스 분류 문제에 적합한 Categorical cross-entropy를 사용하였다.

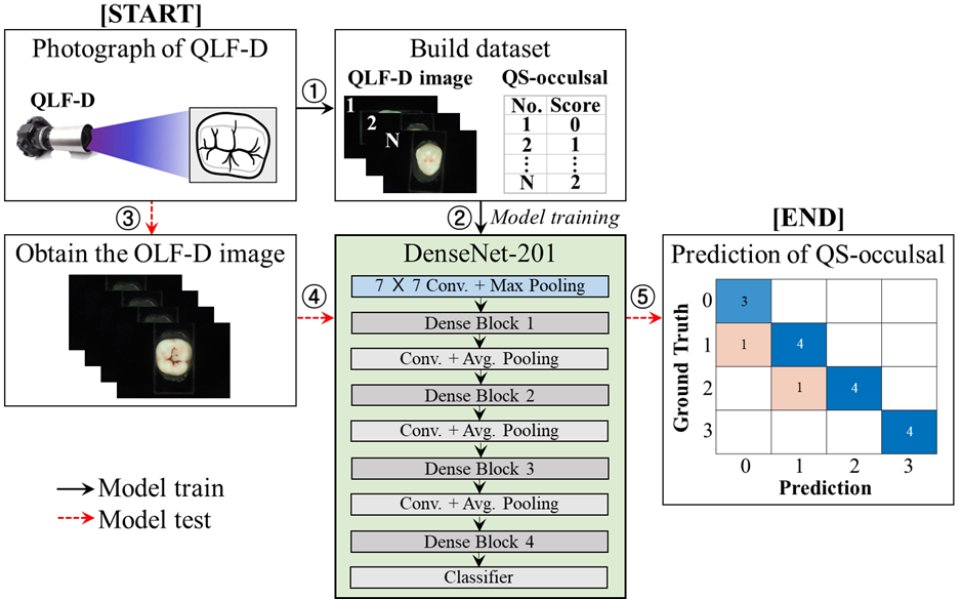


Figure 2. Simplified flowchart of the proposed QS-Occlusal prediction method using DenseNet-201 on QLF-D images.

2.3. 정량적 분석지표

모델 성능 평가는 혼동행렬(Confusion matrix), 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), 그리고 F1-score를 평가 지표로 사용하였다. 혼동행렬은 실제 클래스(Actual class)와 예측 클래스(Predicted class) 간의 일치 여부를 기반으로 분류 모델의 예측 성능을 평가하는 도구로, 각 클래스에 대한 분류 결과를 체계적으로 분석할 수 있게 한다. 정확도, 정밀도, 재현율 및 F1-score는 식 [1]와 같이 정의할 수 있다(15).

식 [1]

$$Accuracy = \frac{TP+TN}{TP+FP+FN+TN},\ Precision = \frac{TP}{TP+FP},\ Recall = \frac{TP}{TP+FN},\ F1-score = 2 \times \frac{Precision \times Recall}{Precision+Recall}$$

여기서, *TP*는 True positive, *FP*는 False positive, *FN*은 False negative, *TN*은 True negative이다. *F1–score*는 정밀도와 재현율을 동시에 고려하기 위한 지표로서, 두 지표의 조화 평균(Harmonic mean)으로 정의된다. 0과 1사이에 범위를 가지며, 1에 가까울수록 분류 모델의 성능이 우수함을 의미한다.

3. 연구결과

Figure 3는 혼동행렬 분석결과로 제안된 딥러닝 모델은 QS 0부터 QS 3까지의 각 단계에 대해 전반적으로 안정적인 분류 성능을 보였다. 실제 클래스와 예측 클래스 간의 분포를 비교한 결과, 대부분의 샘플이 대각선 성분에 집중되어 나타나 정확한 분류가 이루어졌음을 확인할 수 있다.

Table 2는 각 Class별 정확도, 정밀도, 재현율 및 F1-score를 분석한 결과이다. 전체 분류 성능을 나타내는 정확도는 학습 및 평가 데이터셋 전반에 걸쳐 약 0.88로 유지되었다. 정밀도, 재현율 및 F1-score에 대한 결과값은 class 0은 각각 0.75, 1, 0.86를, class 1의 경우에는 0.8, 0.8, 0.8을, class 2는 1, 0.8, 0.89를, 마지막으로 class 3의 결과값은 1, 1, 1를 각각 나타내었다.

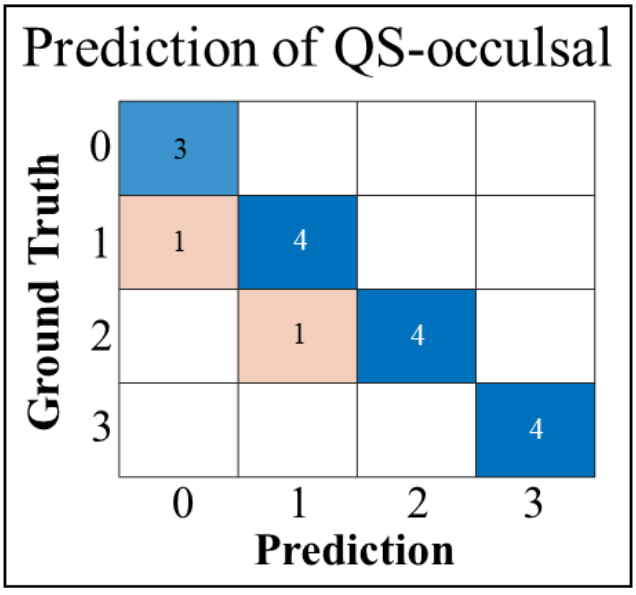


Figure 3. Confusion matrix for QS-Occlusal stage classification using QLF-D images.

Table 2. Precision, recall, and F1-score for each QS-Occlusal stage predicted by the deep learning model

QS-Occlusal value	Precision	Recall	F1-Score
0	0.75	1.00	0.86
1	0.80	0.80	0.80
2	1.00	0.80	0.89
3	1.00	1.00	1.00

4. 고안

QLF 형광 영상을 이용한 형광 변화와 정량 지표(ΔF, ΔR, ΔQ 등)를 기반으로 한 치아우식 평가는 이미 다수의 선행 연구를 통해 그 유용성이 입증된 바 있다(16). 그러나 이러한 정량적 평가는 전용 분석 소프트웨어를 통해 모든 치면에 대해 수치를 산출해야 하며, 이 과정은 시간과 비용이 소요될 뿐 아니라 임상 현장에서 즉각적인 의사결정을 저해하는 요인으로 작용해 왔다(17). 이러한 한계를 극복하기 위한 시도로, 선행 연구에서는 QLF 형광 영상에서 관찰되는 형광 소실과 적색 형광의 시각적 패턴을 체계화한 QS-Occlusal 분류체계를 제안함으로써, 정량 분석 없이도 교합면 우식의 진행 단계를 임상적으로 해석할 수 있는 새로운 접근을 제시하였다(11). 해당 분류체계는 우식의 조직학적 깊이 및 ICDAS와 유의한 상관성을 보이며 우수한 타당성과 재현성을 보고하였으나, 여전히 검사자의 경험과 주관적 판단에 의존한다는 한계와 분류 기준을 별도로 학습해야 하는 부담이 존재하였다.

이러한 배경에서 본 연구는 QS-Occlusal 분류체계를 딥러닝 모델의 학습 라벨로 활용하여, 형광 영상에 내재된 시각적 패턴을 자동으로 학습하고 분류할 수 있는 가능성을 탐색하고자 하였다. DenseNet-201을 백본으로 하는 딥러닝 네트워크를 구축하여 QLF-D 영상을 QS 0-3 단계로 분류한 결과, 혼동행렬 및 정확도, 정밀도, 재현율, F1-score 분석에서 전반적으로 안정적인 분류 성능을 확인하였다. 특히 전체 샘플 중 올바르게 분류된 비율을 나타내는 정확도는 약 0.88 수준으로 유지되었으며, 이는 제한된 데이터셋 환경에서도 딥러닝 모델이 QLF 영상의 전반적인 형광 패턴을 효과적으로 학습하였음을 시사한다.

분류 단계별로 살펴보면, 건전 치면(QS 0)과 상아질 우식 단계(QS 3)에서 상대적으로 높은 분류 일치도가 관찰되었다. 이는 형광 소실의 유무, 적색 형광의 강도, 그리고 상아질 병소에서 나타나는 Dark shadow와 같은 특징이 해당 단계에서 비교적 명확하게 구분되기 때문으로 해석된다. 반면, 우식 의심 병소 단계(QS 1)와 법랑질 우식 단계(QS 2) 사이에서는 일부 오분류가 관찰되었는데, 이는 초기 법랑질 병소에서 형광 소실과 적색 형광이 연속적인 스펙트럼 상에서 변화하며 경계가 모호해지는 특성이 반영된 결과로 판단된다. 이에 훈련 모델에 입력되는 영상 클래스의 분산을 증가시켜 오분류 결과를 도출할 수 있다. 이러한 현상은 기존 ICDAS를 이용한 시진 평가(18) 및 QS-Occlusal 분류체계를 이용한 육안 판독(11)에서도 반복적으로 보고된 어려움으로, 본 연구에서 관찰된 QS 1-2 간 혼동은 딥러닝 모델의 한계라기보다는 초기 우식 진단 자체가 지니는 임상적 어려움을 반영한 결과로 해석할 수 있다.

본 연구에서 DenseNet-201을 백본 네트워크로 선택한 것은 형광 영상과 같이 미세한 명암 및 색상 변화가 중요한 영상 특성을 효과적으로 학습하기 위함이다. DenseNet 구조는 각 층이 이전 층의 특성을 직접 참조하는 Dense connection을 통해 저수준 및 고수준 특징의 재사용(Feature reuse)을 가능하게 하며, 이는 상대적으로 적은 학습 데이터 환경에서도 과적합을 완화하고 안정적인 학습을 유도하는 장점으로 알려져 있다. 이러한 구조적 특성은 형광 패턴의 미묘한 차이를 기반으로 우식 단계를 구분해야 하는 본 연구의 목적에 부합하는 선택으로 판단된다.

또한 본 연구의 중요한 의의 중 하나는 ΔF 및 ΔR과 같은 정량 형광 지표를 직접 산출하지 않고, 형광 이미지 자체를 입력으로 활용하여 우식 단계를 분류하였다는 점이다. 이는 전용 소프트웨어에 대한 의존성을 낮추고, 형광 영상 획득 이후 추가적인 분석 단계를 생략할 수 있는 가능성을 제시한다. 이러한 접근은 향후 임상 현장에서의 즉각적인 의사결정 지원뿐 아니

라, 원격 구강검진이나 대규모 스크리닝 환경으로의 확장 가능성 측면에서도 의미를 가진다(4, 17).

기존의 QLF 영상 기반 딥러닝 연구들은 주로 우식의 존재 여부에 대한 이분법적 분류 또는 정량 형광 지표의 예측에 초점을 맞추어 왔다(12). 이에 비해 본 연구는 QS-Occlusal이라는 임상적으로 의미 있는 단계적 분류체계를 학습 라벨로 활용함으로써, 딥러닝 기반 영상 분석 결과를 실제 임상 의사결정 단위와 보다 직접적으로 연결하고자 하였다는 점에서 차별성을 가진다. 이는 형광 기반 우식 진단을 단순한 보조 도구를 넘어, 표준화되고 재현성 높은 자동 분류 체계로 발전시킬 수 있는 기초적 근거를 제공한다.

그럼에도 불구하고 본 연구는 몇 가지 한계점을 지닌다. 첫째, 전체 데이터셋이 단일 발거치에서 획득된 100장의 이미지로 구성되어 있어 데이터 다양성과 일반화 가능성에 제약이 있다. 단일 치아 기반 데이터는 형광 패턴의 반복성과 구조적 유사성이 높아 모델 성능이 과대평가될 가능성을 내포한다(12). 둘째, 학습 및 평가 데이터 분할이 이미지 단위로 이루어졌기 때문에 동일 병소 영역의 구조적 유사성이 완전히 배제되었다고 보기 어렵다. 셋째, 본 연구에서는 조직학적 기준이나 정량 형광 지표와의 직접적인 비교가 이루어지지 않아, QS 단계 분류 결과의 병리학적 정확성을 정량적으로 검증하는 데에는 한계가 있다.

향후 연구에서는 이러한 한계를 극복하기 위해 다수의 발거치 및 다양한 우식 진행 단계를 포함하는 대규모 데이터셋을 구축하고, 치아 단위 또는 병소 단위 분할 전략을 적용하여 학습과 평가 간 데이터 누수를 최소화할 필요가 있다. 또한 조직학적 분석 또는 ΔF, ΔR과 같은 정량 형광 지표와의 비교를 통해 딥러닝 기반 QS-Occlusal 분류 결과의 병리학적 타당성을 검증하는 연구가 요구된다(2, 17). 궁극적으로 이러한 확장 연구는 QLF 영상과 인공지능을 결합한 비침습적 우식 진단 기술을 임상 및 원격 구강검진 환경에 적용하기 위한 중요한 발판이 될 수 있을 것이다(12). 즉, 실제 임상 진료 환경에서 본 시스템은 QLF 형광 영상을 획득한 이후, 별도의 정량 분석 소프트웨어 없이 영상 자체를 입력하여 우식 단계를 자동으로 제시함으로써, 검사자의 숙련도에 따른 판독 편차를 줄이고 진단의 일관성을 보완하는 역할을 수행할 수 있다. 또한 이러한 자동 분류 결과는 환자에게 형광 영상과 함께 시각적으로 제시될 수 있어, 초기 우식 상태에 대한 환자의 이해를 높이고 예방 중심의 치료 계획 수립 및 순응도 향상에도 기여할 수 있을 것으로 기대된다.

5. 결론

본 연구는 QLF 형광 영상과 QS-Occlusal 분류 라벨을 기반으로 DenseNet-201을 백본으로 하는 딥러닝 모델을 구축하고, 초기 교합면 우식 단계를 자동으로 분류할 수 있는 가능성을 개념 검증 수준에서 확인하였다. 본 연구의 결론은 다음과 같다.

1. 형광 기반 교합면 초기 우식 평가에서 QS-Occlusal 분류체계를 인공지능 모델에 적용함으로써, 우식 단계 분류의 표준화 및 자동화 가능성을 제시하였다.

2. 초기 우식 단계 분류를 인공지능 기반 자동 분류 모델로 확장하여, 병소 탐지–비침습적 관리–치료 고려로 이어지는 임상적 의사결정 흐름에서 치아우식 수준 판단을 보조하는 의사결정 지원 시스템으로 활용될 수 있는 가능성을 제시하였다.

3. 소규모의 통제된 환경에서 개념 검증 연구를 통해 제안하는 접근법의 방법론적 타당성을 확인하였다.

제안하는 방법은 QS-Occlusal 분류체계를 기계학습 기반 자동화 구조로 확장한 초기 시도로서, 향후 다수의 발거치 및 대규모 임상 데이터셋과 결합될 경우 비침습적 우식 진단 및 원격 구강검진 시스템으로의 확장 가능성을 제공할 것으로 기대된다.

Author contributions

Conceptualization, Investigation, Supervision, Data curation, Formal analysis, Writing—original draft, review, editing, and Funding acquisition: EH Jung.

References

1. Pitts NB, Zero DT, Marsh PD, Ekstrand K, Weintraub JA, Ramos-Gomez F, et al. Dental caries. Nat Rev Dis Primers 2017;3:17030. 10.1038/nrdp.2017.30.
2. Featherstone JD. The continuum of dental caries—evidence for a dynamic disease process. J Dent Res 2004;83(Spec Iss C):C39-C42. 10.1177/154405910408301S08.
3. Featherstone JDB. Dental caries: a dynamic disease process. Aust Dent J 2008;53(3):286-291. 10.1111/j.1834-7819.2008.00064.x.
4. Martignon S, Pitts NB, Goffin G, Mazevet M, Douglas GVA, Newton JT, et al. CariesCare practice guide: consensus on evidence into practice. Br Dent J 2019;227(5):353-362. 10.1038/s41415-019-0678-8.
5. Pitts NB, Ekstrand KR. International Caries Detection and Assessment System (ICDAS) and its International Caries Classification and Management System (ICCMS)—methods for staging of the caries process and enabling dentists to manage caries. Community Dent Oral Epidemiol 2013;41(1):e41-e52. 10.1111/cdoe.12025.
6. Ismail AI, Sohn W, Tellez M, Amaya A, Sen A, Hasson H, et al. The International Caries Detection and Assessment System (ICDAS): an integrated system for measuring dental caries. Community Dent Oral Epidemiol 2007;35(3):170-178. 10.1111/j.1600-0528.2007.00347.x.
7. Dove SB. Radiographic diagnosis of dental caries. J Dent Educ 2001;65(10):985-990.
8. Bloemendal E, de Vet HC, Bouter LM. The value of bitewing radiographs in epidemiological caries research: a systematic review of the literature. J Dent 2004;32(4):255-264. 10.1016/j.jdent.2003.12.001.
9. Hope CK, de Josselin de Jong E, Field MRT, Valappil SP, Higham SM. Photobleaching of red fluorescence in oral biofilms. J Periodontal Res 2011;46(2):228-234. 10.1111/j.1600-0765.2010.01334.x.
10. Amaechi BT, Higham SM. Quantitative light-induced fluorescence: a potential tool for general dental assessment. J Biomed Opt 2002;7(1):7-13. 10.1117/1.1427044.
11. Jung EH, Lee ES, Jung HI, Kang SM, de Josselin de Jong E, Kim BI. Development of a fluorescence-image scoring system for assessing noncavitated occlusal caries. Photodiagnosis Photodyn Ther 2018;21:36-42. 10.1016/j.pdpdt.2017.10.027.
12. Park EY, Jeong SM, Kang SH, Cho JR, Cho JY, Kim EK. Tooth caries classification with quantitative light-induced fluorescence (QLF) images using convolutional neural network for permanent teeth in vivo. BMC Oral Health 2023;23(1):981. 10.1186/s12903-023-03669-6.
13. Huang G, Liu Z, Van der Maaten L, Weinberger KQ. Densely connected convolutional networks. Proc IEEE Conf Comput Vis Pattern Recognit 2017:4700-4708. 10.1109/CVPR.2017.243.
14. Kingma DP, Ba J. Adam: a method for stochastic optimization. arXiv 2014;arXiv:1412.6980. 10.48550/arXiv.1412.6980.
15. Paul C, Bora P. Detecting hate speech using deep learning techniques. Int J Adv Comput Sci Appl 2021;12(2):619-623. 10.14569/IJACSA.2021.0120278.
16. Pretty IA. Caries detection and diagnosis: novel technologies. J Dent 2006;34(10):727-739. 10.1016/j.jdent.2006.06.001.
17. Gomez J, Pretty IA, Santarpia RP, Cantore B, Rege A, Petrou I, et al. Quantitative light-induced fluorescence to measure enamel remineralization in vitro. Caries Res 2014;48(3):223-227. 10.1159/000354655.
18. Ekstrand KR, Gimenez T, Ferreira FR, Mendes FM, Braga MM. The International Caries Detection and Assessment System (ICDAS): a systematic review. Caries Res 2018;52(5):406-419. 10.1159/000486429.