

MATT 컬러강판 표면 질감의 정밀 분류를 위한 슬라이스 기반 딥러닝 앙상블 모델 연구

조진표*, 박영규*, 김지유*, 이훈*, 현승균*, 김광희*
*인하대학교 제조혁신전문대학원
e-mail : realwind@inha.ac.kr

Slice-Based Deep Learning Ensemble Model for Fine Classification of Surface Textures in MATT

Jin-Pyo Cho*, Yeong-Gyu Park*, Ji-You Kim*, Hoon Lee*, Seung-Gyun Hyun*,
Kwang-Hee Kim*
*Manufacturing Innovation School, Inha University

요약

최근 건축 외장재 및 지붕재 분야에서 고급스러운 외관과 내후성을 갖춘 MATT 컬러강판에 대한 수요가 증가하고 있다. MATT 컬러강판은 도막 표면에 미세한 주름(Wrinkle) 패턴을 형성하여 고급스러운 무광 질감을 구현하지만, 이러한 질감은 시각적으로 미세하고 반복적인 구조를 가지므로 기존 육안 검사나 일반 비전검사 시스템으로는 품질 편차를 정확히 감지하기 어렵다. 특히 연속 생산 공정에서는 검사자의 피로 누적, 기준 오차, 조도 변화 등으로 인해 품질 이상이 누락되는 사례가 빈번히 발생한다.

본 연구에서는 MATT 컬러강판의 표면 질감 수준을 9단계로 분류하고, 각 단계별 이미지를 CNN 기반 딥러닝 분류기로 학습시키기 위해 슬라이스 기반 앙상블 기법을 제안하였다. 이미지 전체를 3×3 영역으로 분할한 뒤, 각 슬라이스에 대해 동일한 CNN 분류 모델을 적용하고 soft voting 방식으로 결과를 통합함으로써, 국소적인 질감 정보까지 반영한 정밀한 예측을 가능하게 하였다. 또한, 이미지 임베딩 기반 이상치 제거, 클래스 간 분포 기반 증화 샘플링, Canny edge 기반 특징 보강 등의 데이터 중심 최적화 전략과, Bayesian Optimization을 통한 하이퍼파라미터 자동 탐색 등의 모델 중심 전략을 병행 적용하였다. 그 결과, 제안된 슬라이스 기반 앙상블 모델은 기존 단일 CNN 모델 대비 정확도와 F1-score에서 모두 향상된 성능을 보였으며, 반복적인 질감 구조를 갖는 산업용 강판의 자동 검사에 효과적으로 활용될 수 있음을 확인하였다. 본 연구는 향후 산업 현장에서의 품질 편차 감지 자동화 및 시각적 품질 분류 시스템의 고도화에 기여할 수 있을 것으로 기대된다.

1. 서론

산업 전반에 걸쳐 제품의 외관 품질에 대한 요구가 고도화되면서, 건축 외장재 및 지붕재 분야에서도 고급 질감과 차별화된 외형을 갖춘 소재에 대한 수요가 증가하고 있다. 특히 MATT 컬러강판은 도료 내 특수 조성물과 건조 조건의 제어를 통해 도막 표면에 불규칙한 주름(Wrinkle) 패턴을 형성함으로써 은은한 무광 효과와 고급스러운 외관을 구현한다. 이러한 특성으로 인해 MATT 컬러강판은 건축물의 디자인 품질을 결정짓는 핵심 요소로 자리매김하고 있다.

그림 1에는 MATT 강판의 외장재 사용예를 보여준다. 미려한 주름 무늬의 외관으로 고급스러운 분위기를 연출하여 수요가 많은 실정이다.

주름의 모양을 대변하기는 매우 힘들고 이러한 미세 질감은 명확한 경계나 색상 차이가 아닌 반복적이고 불규칙한 요철 형태로 나타나기 때문에, 기존의 시각 기반 품질 검사 방식으로는 정밀

한 분류가 어렵다. 실제 산업 현장에서는 숙련 작업자의 육안 검사에 의존하고 있으며, 연속 생산 과정에서 발생하는 검사자의 피로, 판단 기준의 편차 등으로 인해 불량률이 누락되거나 불필요한 불량 판정이 내려지는 경우가 빈번하다. 또한 기존의 비전 검사 시스템은 dent, scratch 등 국소적인 결함 검출에 최적화되어 있어, MATT 강판의 전면에 걸쳐 분포된 미세한 질감 변화에는 민감하게 반응하지 못하는 한계를 지닌다.



[그림 1] MATT 강판 외장재 사용예



[그림 2] MATT 주름 분류(1-9단계)


본 연구는 이러한 한계를 극복하고자 MATT 컬러강판의 표면 질감을 9단계로 정량화하여 학습 데이터셋을 구축하고, 딥러닝 기반의 슬라이스 분할 이상불 분류 기법을 적용하여 질감 수준의 정밀한 분류를 시도하였다. 그림 2에는 MATT 표면 질감을 9단계로 분류한 이미지를 나타내었다. 특히 사전학습된 CNN 모델을 기반으로 전체 이미지를 다수의 영역으로 분할하여 각 영역별 예측을 수행하고, 이를 통합하는 방식으로 모델의 정확도를 향상시키고자 하였다. 또한 이상치 제거, 데이터 균형 조정, 특징 강조 등의 데이터 중심 전략과 하이퍼파라미터 튜닝 등 모델 중심 전략을 병행함으로써, 산업 환경에서도 적용 가능한 고성능 분류 모델을 구현하고자 한다.

2. 연구방법

본 연구에서는 MATT 컬러강판의 미세한 표면 질감 변화를 효과적으로 분류하기 위해, 데이터 수집 및 품질 정제부터 CNN 기반 학습, 성능 최적화, 그리고 성능 한계 극복을 위한 슬라이스 기반 이상불 분류기법까지 단계적으로 진행하였다.

2.1 MATT 컬러강판 질감 수준별 샘플링

MATT 컬러강판의 표면에는 도막 두께, 도료 내 촉매 성분, 건조 온도 및 풍량 등 공정 조건에 따라 다양한 크기의 주름(Wrinkle) 패턴이 형성된다. 이에 실험실에서 도막 두께를 일정하게 유지한 상태에서 촉매 함량과 풍량을 조절해 주름 크기가 각기 다른 9단계의 표준샘플을 제작하였으며 양산 단계에서 육안 검사와 정량적 평점을 위한 표준 인덱스 01 ~ 09로 정의하였다. 인덱스 01은 해당 도료로 생성할 수 있는 가장 작은 주름 크기, 09는 가장 큰 주름 크기를 의미하며 이는 도료마다 다른 값을 가진다. 연구에 사용된 도료의 경우 접촉식 조도계로 Rz(십점 평균 조도, 3회 평균) 측정 시 인덱스 01의 경우 Rz 47.46 μ m에서 인덱스 09의 경우 Rz 40.96 μ m으로 점차 하향하는 범위에 분포하였다.(0.5mm/s, 30mm, SE-3500, Kosaka)



[그림 3] MATT 주름 분류 샘플링 이미지 데이터 수집

2.2 데이터 수집

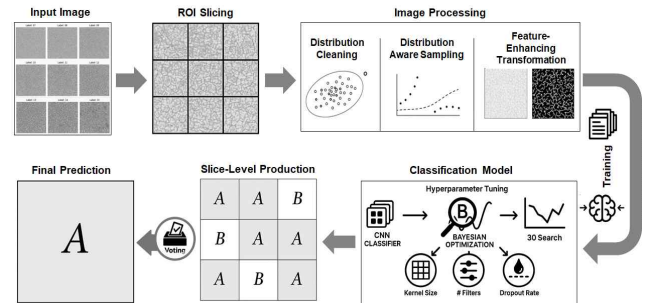
그림 3에는 샘플링 이미지 데이터 수집장치 구성도가 보여진다. 샘플 이미지는 라즈베리파이5와 카메라모듈V2, LED 링라이트를 조합하고 촬영거리를 고정하여 조도와 촬영면적을 일정하게 유지하도록 통제된 환경에서 촬영되었다. 인덱스 01 ~ 09로 구분된 샘플에서 가로 320픽셀, 세로 320픽셀 정지영상을 각 200장씩, 총 1800장 촬영하였으며 인덱스 번호 01 ~ 09를 분류 모델의 클래스 이름으로 사용하였다.

2.2 데이터 전처리 및 모델 최적화, 슬라이스 기반 이상불 기법

이미지 임베딩 벡터를 활용한 이상치 제거 및 분포 기반 Stratified Sampling으로 데이터 품질을 정제하였다. 정제된 데이터에는 다양한 전처리 기법을 적용하고 CNN 모델을 학습했으며, 성능 향상을 위해 Bayesian Optimization 기반 하이퍼파라미터 튜닝을 수행하였다. 이후 슬라이스 기반 이상불 기법을 도입하여 분류 성능을 향상시켰다. 그림 4는 제안된 기법의 주요 흐름도이다.

3. 연구결과

사전학습된 CNN에서 추출한 임베딩 벡터를 활용하여 마할라노비스 거리 기반 이상치를 제거하고, 각 클래스 내 거리 분포를 고려한 층화 샘플링(Stratified Sampling)을 통해 데이터 품질을 정제하였다. 본 연구에서는 분할된 훈련/검증/테스트 세트 간 마할라노비스 거리 평균 및 분산의 차이를 최소화



[그림 4] 슬라이스기반 이상불 이미지 처리기법 도식화

표 1 수행된 모든 해석 모델 비교

Model	Description	Preprocessing			Test Set Performance Evaluation		
		Input Size	Data Refinement	Image Processing	Accuracy	Loss	Macro F1
01	Baseline Model			-	0.8949	0.3766	0.8928
02	With Image Filter	(320, 320)	Outlier Removal, Distribution-Based Sampling	Canny Edge Detection(Overlay)	0.8922	0.3348	0.8915
03	HPO Applied				0.9515	0.2004	0.9515
04	Slice-Based Ensemble	(100, 100)			0.9650	N/A	0.9648

화하는 값을 기준으로 최적 분할을 자동 탐색한 결과, 클래스 비율만 고려하는 단순 층화 샘플링 대비 평균과 분산의 차이가 현저히 줄어들었음을 확인하였다.

이후 이미지 특징 강화를 위한 다양한 전처리 기법(Sobel, Canny 등)을 단독 또는 조합하여 CNN 모델에 적용하고, 성능 차이를 비교하였다. 최적의 조합으로는 Canny Overlay 방식이 높은 안정성과 해석 가능성을 고려하여 최종 채택되었다. 성능 극대화를 위해 Bayesian Optimization 기반의 하이퍼파라미터 튜닝을 수행하였으며, 커널 크기, 필터 수, 드롭아웃 비율, 학습률 등을 30회 탐색하였다. 최적 조합으로 재학습된 모델은 기존 모델 대비 정확도는 +5.7 ~ +5.9%p 향상, 손실값은 기존 모델의 53.2 ~ 59.9% 수준으로 크게 감소하였다.

MATT 컬러강판과 같은 유사한 질감(Wrinkle Structure 등)이 넓은 영역에 반복적으로 분포되어 있는 경우 국소 슬라이스에 서도 전체 클래스의 특성이 일관되게 반영된다는 점에 착안하여 기존 방식의 성능 향상 한계를 극복하고자 슬라이스 기반 앙상블 기법을 제안하였다. 이를 구현하기 위해 전체 이미지를 3×3의 ROI 슬라이스로 분할한 후, 슬라이스 단위로 CNN 모델이 예측을 수행한 후, 슬라이스당 softmax 확률 출력을 기반으로 Hard Voting, Soft Voting, Top-K Voting(K=5), Weighted Voting 네 가지 방식의 앙상블 방식을 적용하였다. 본 연구에 사용된 데이터셋의 경우 Top-K Voting(K=5)이 Macro F1-Score 0.9648로 가장 우수한 방식으로 선택되었으며, 이 방식은 Confidence가 가장 높은 상위 K개를 선택하여 결과를 예측하여, 모델의 softmax confidence를 효과적으로 반영함으로써 분류 정확도를 향상시킨다. 예를 들어 True Label 14에 대해 일부 슬라이스는 13 또는 15로 잘못 예측했지만 다수 슬라이스에서 14를 선택했고, Voting 방식은 이를 통합하여 부분 오류를 전체에서 상쇄하고 올바른 결론을 도출하였다.

표 1에서 모든 모델에 동일한 Test Set을 사용한 성능 평가 결과를 정리하였다. 슬라이스 기반 앙상블 기법은 기존 모델 대비 정확도는 +1.35%p 향상되었으며, Macro F-1 Score는 0.9648로 모든 클래스에서 높은 분류 성능이 확보되었다.

4. 결론

본 연구에서는 MATT 컬러강판과 같이 표면 질감이 일정하게 반복되는 산업용 이미지에서 미세한 질감 변화를 효과적으로 분류하기 위한 딥러닝 기반 분류 전략을 제안하였다. 실험 결과, 이미지 임베딩 벡터의 분포를 기반으로 한 이상치 제거 및 리샘플링을 통해 클래스 비율만 고려하는 단순 층화 샘플링 대비 평균과 분산의 차이를 현저히 줄일 수 있음을 확인하였다.

무엇보다도, 제안된 슬라이스 기반 결과 앙상블 기법은 이미지 내 지역별 정보를 사용하여 개별적으로 예측하고, 이를 통합하는 방식으로 기존 단일 예측 모델의 한계를 극복하며 정확도 및 F1-score를 향상시켰다. 특히 질감이 반복되고 균일한 구조를 가진 산업 표면 검사 환경에서는 본 방법이 신뢰성 높은 자동 분류 기법으로서 실질적인 활용 가능성을 보여주었다.

본 연구에서 제안한 슬라이스 기반 예측은 지역 정보만 사용하므로 형상이 정해진 객체(문자, 도형, 마킹, 국소결합 등)의 인식에는 부적합하다는 단점이 있다. 향후에는 보다 복잡한 형상이나 비균일한 질감 구조에 대응하기 위한 지역 가중치 조정, 또는 self-attention 기반의 영역 중요도 반영 기법 등을 추가함으로써, 본 슬라이스 기반 접근을 더욱 확장할 수 있을 것이다.

[후기]

본 논문은 인하대학교 제조혁신전문대학원 석사학위 프로젝트 진행과 학위논문 제출을 위해 발표한 논문입니다.

참고문헌

[1] Violeta Roizman, Matthieu Jonckheere, Frédéric Pascal, 2021, Robust clustering and outlier rejection using the Mahalanobis distance distribution, 2020 28th European Signal Processing Conference (EUSIPCO) European Signal Processing Conference (EUSIPCO), 2020 28th. :2448-2452 Jan, 2021

[2] LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. Nature, 521(7553), 436-444.