

EfficientNet의 전이학습을 통한 아스팔트 바인더의 레올로지적 특성 예측

Prediction of Rheological Properties of Asphalt Binders Through Transfer Learning of EfficientNet

지봉준^{1*}Bongjun Ji^{1*}

(Received September 10, 2021 / Revised September 23, 2021 / Accepted September 24, 2021)

Asphalt, widely used for road pavement, has different required physical properties depending on the environment to which the road is exposed. Therefore, it is essential to maximize the life of asphalt roads by evaluating the physical properties of asphalt according to additives and selecting an appropriate formulation considering road traffic and climatic environment. Dynamic shear rheometer(DSR) test is mainly used to measure resistance to rutting among various physical properties of asphalt. However, the DSR test has limitations in that the results are different depending on the experimental setting and can only be measured within a specific temperature range. Therefore, in this study, to overcome the limitations of the DSR test, the rheological characteristics were predicted by learning the images collected from atomic force microscopy. Images and rheology properties were trained through EfficientNet, one of the deep learning architectures, and transfer learning was used to overcome the limitation of the deep learning model, which require many data. The trained model predicted the rheological properties of the asphalt binder with high accuracy even though different types of additives were used. In particular, it was possible to train faster than when transfer learning was not used.

키워드 : 전이학습, 아스팔트, 레올로지, EfficientNet, 첨가제

Keywords : Transfer learning, Asphalt, Rheology, EfficientNet, Additives

1. 서론

아스팔트는 도로 포장에 널리 사용되는 재료이며 다양한 요인에 의해 그 물리적 특성이 영향을 받는다. 예를 들어 바인더와 첨가제의 종류 및 골재의 입도와 비중, 그리고 노화 시간 등에 따라 민감성이 달라지며 이는 러팅(Rutting) 및 균열과 같은 물리적 특성에 영향을 미치게 된다(McDaniel 2001; Tayfur et al. 2007). 그러므로 기후나 교통환경 등에 따라 그에 적합한 재료를 선택하고 최적의 배합으로 생산할 수 있어야 한다. 화물차와 같이 고하중의 교통량이 많은 경우 회복 탄성력이 높은 배합이 필요하고 적설량이 많고 기온이 낮은 지역의 경우 내마모성이 우수한 배합이 필요하다. 이와 같이 배합에 따른 혼합물이 어떠한 물리적 특성을 나타내는지 평가하고 주변기후와 교통환경에 적합한 첨가제 배합을

사용하는 것은 오랜 포장수명을 확보하기 위해 필수적인 과정이다. 이러한 배경에서 폴리머 개질 아스팔트는 그 성능적인 면에서 유망한 첨가제로 주목받고 있다. 대표적인 폴리머로는 Styrene Butadiene Styrene(SBS), Low Density Poly Ethylene(LDPE), High Density Poly Ethylene(HDPE), Ethylene Propylene Diene Monomer(EPDM), Styrene Isoprene Styrene(SIS)와 Ground Tire Rubber(GTR) 등이 사용 되어지고 있다(Kim et al. 2019a). 이 중 SIS는 SBS와 더불어 고분자 개질 아스팔트(Polymer Modified Asphalt) 첨가제 중 하나로, 회복성이 우수한 열가소성 탄성체(Thermoplastic Elastomer)이다. SIS는 SBS에 비해 고가이지만 강한 레올로지적 특성을 가지고 있기 때문에 뛰어난 내구성이 요구되는 교량이나 중장비의 통행이 잦은 포장에 이용된다(Mazumder et al. 2020).

* Corresponding author E-mail: bongjun_ji@postech.ac.kr

¹포항공과대학교 산업경영공학과 박사 (Department of Industrial and Management Engineering, Pohang University of Science and Technology, Gyeongbuk, 37673, Korea)

GTR은 페타이어를 미분으로 파쇄시킨 물질로 첨가제로서의 효과들과 친환경적 특성으로 많은 연구들에서 실험 대상이 되었다. GTR은 소음을 줄여줄 뿐 아니라 소성변형과 균열에 대한 저항성을 높여 유지관리 비용을 절감시키며, 이에 따라 아스팔트 포장의 수명을 증가시킨다(Huang et al. 2002; Kim and Lee 2015, Kim et al. 2018). 이는 형체를 유지한 채, 유동성있는 필러 역할을 하기 때문이다(Kim et al. 2019b). 또한 GTR은 매년 발생하는 막대한 양의 산업폐기물 중 하나인 페 타이어를 활용하기 때문에 친환경적인 측면에서도 기여하는 바가 크다.

본 연구에서는 다양한 아스팔트 바인더의 물리적 특성 중 소성 변형에 대한 저항성을 평가하는 지표인 $G^*/\sin\delta$ 를 연구 대상으로 한다. $G^*/\sin\delta$ 는 DSR 테스트를 통해 측정되는데 스프링과 시편 사이의 갭(Gap) 설정과 시편을 플레이트(Plate)에 장착시키는 과정에 따라 결과가 상이하고(Divya and Krishnan 2019) 특정 온도 범위 내의 시편만 측정이 가능한 단점이 있다(Hanz et al. 2010). 이러한 DSR 테스트의 단점을 극복하기 위한 연구의 하나로 DSR 테스트를 대체할 수 있는 딥러닝 기반의 이미지 처리 방법이 연구되었다. Ji et al.(2020)은 다양한 딥러닝 모델을 적용하여 기존의 DSR 테스트를 딥러닝 모델로 대체할 수 있는 가능성을 보여주었다. 해당 연구는 AFM(Atomic Force Microscopy)로 촬영된 아스팔트 바인더의 이미지를 입력받아 $G^*/\sin\delta$ 를 예측하는 연구로 이미지만으로 높은 신뢰도의 $G^*/\sin\delta$ 를 추론할 수 있음을 보였다. 하지만 해당 연구는 고용등급(PG) 64-22에 SIS 개질 아스팔트 바인더만을 대상으로 한다는 점에서 한계점이 있다. 따라서 본 연구는 PG 64-22와 SIS 뿐만 아니라 PG 76-22에 GTR을 첨가한 아스팔트 바인더의 AFM 이미지를 딥러닝 모델로 학습하여 $G^*/\sin\delta$ 를 예측하고자 한다. 특히, 단일 첨가제가 아닌 이종의 첨가제에서도 앞선 연구와 같이 딥러닝 모델이 높은 성능을 발휘할 수 있는지 평가하고자 하는데 목적이 있다. 이를 위해 앞서 언급한 것과 같이 강한 레올로지적 특성을 보이는 첨가제인 SIS와 친환경적인 첨가제인 GTR을 실험대상으로 한다.

2. 이론적 배경

2.1 EfficientNet

EfficientNet은 Compoud coefficient라는 개념을 도입하여 Convolutional Neural Network 아키텍처를 구성하는 방법이다(Tan and Le, 2019). 기존의 Convolutional Neural Network 구성방법은 시행착오 기반의 조정을 통해 이루어졌다. 이들 방법은 채널의 개수를 늘리는 넓이 조정, Layer의 개수를 늘리는 깊이 조

정, 해상도를 높이는 해상도 조정 등이 있으며 이들 중 한 가지를 선택하여 조정을 하는 방법이 널리 사용되었다. 대표적인 딥러닝 모델인 ResNet의 경우 ResNet-18부터 ResNet-200까지 깊이 조정을 사용하여 아키텍처의 깊이를 깊게 만들어 딥러닝 모델을 구성하였다(He et a. 2016). 하지만 기존 방식들은 ResNet과 같은 한 가지 조정에 집중하였고, 넓이, 깊이, 해상도를 복합적으로 고려하지 않았다. 또한 고려하더라도 이들 세 가지 요소를 어떤 비율로 조정해야하는지에 대한 가이드라인이 부재하였다. EfficientNet은 이러한 한계를 극복하고자 하는 모델이다. EfficientNet은 메인 블록으로 Linear Bottleneck을 갖는 Mobile Inverted Bottlenet Convolution(MBConv)을 사용하며 Fig. 1과 같은 베이스라인 아키텍처를 가진다. Input은 Convolution Layer 하나를 거치고, 크기가 각기 다른 15개의 MBConv Layer를 거쳐 예측값을 산출한다.

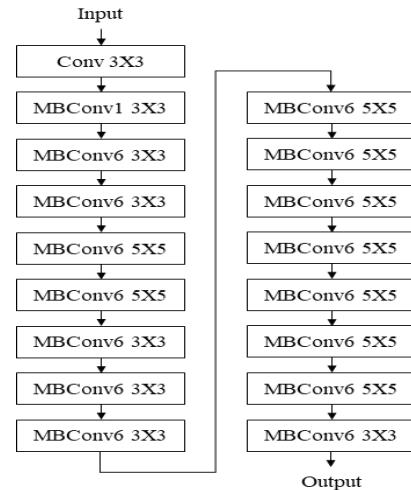


Fig. 1. Base architecture of EfficientNet-B0

EfficientNet은 AutoML을 통해 세 가지 요소의 조정에 대한 가이드라인을 찾아 제공한다. 아래의 식은 각 요소들의 Notation과 가이드라인을 나타낸다.

$$\begin{aligned}
 \text{depth} : d &= \alpha^{\phi} \\
 \text{width} : w &= \beta^{\phi} \\
 \text{resolution} : r &= \gamma^{\phi} \\
 \text{s.t. } \alpha \cdot \beta^2 \cdot \gamma^2 &\approx 2 \\
 \alpha \geq 1, \beta \geq 1, \gamma \geq 1
 \end{aligned} \tag{1}$$

위의 수식에서와 같이 깊이, 넓이, 해상도를 각각 α, β, γ 로 정의하고, 이들 간의 관계가 $\alpha \cdot \beta^2 \cdot \gamma^2 \approx 2$ 를 만족하도록 가이드를 하고 있다. 넓이와 해상도의 경우 가로, 세로가 각각 곱해지므로

제공배가 증가하고 깊이의 경우 1배가 증가한다. ϕ 는 전체 모델 사이즈를 결정하는 계수로 α, β, γ 가 ϕ 의 제곱으로 결정된다. 즉, 활용 가능한 Resource 내에서 ϕ 의 값을 설정하여 아키텍처의 구조를 결정할 수 있다. 이를 통해 EfficientNet은 기존의 아키텍처들에 비해 훨씬 적은 수의 파라미터 수로 높은 성능(State-of-the-Art)을 달성하였다.

2.2 전이학습

전이학습이란 기존의 학습된 딥러닝 모델이나 기존의 학습에 사용되었던 데이터를 활용하여 새로운 도메인에서의 모델 학습에 사용하는 방법을 말한다(Bang et al, 2019).

적용하고자 하는 문제의 데이터가 부족한 경우, 모델의 성능을 향상시키기 위해 널리 쓰이는 학습 기법으로, 영상 처리, 음성 인식, 컴퓨터 비전, 자연어 처리 등 다양한 분야에서 활용 되고 있다. 이들 분야는 딥러닝이라 불리는 깊은 층의 레이어로 구성된 아키텍처들을 주로 사용하는데, 해당 아키텍처들은 높은 성능을 얻기 위해 대량의 데이터와 높은 컴퓨팅 파워, 충분한 학습 시간을 요구한다. 따라서 기존의 데이터를 활용하여 전이학습 하거나(Fig. 2(a)) 이미 높은 성능을 보이는 모델로부터 전이학습(Fig. 2(b))함으로써, 상대적으로 적은 데이터, 낮은 컴퓨팅 파워, 빠른 시간 내에

학습을 수행할 수 있다. 컴퓨터 비전 분야의 이미지 분류 모델들은 전이학습은 학습 데이터를 활용하는 방법보다, 학습된 모델을 로드하여 학습된 가중치(Weight)를 미세조정하는 방식을 주로 사용한다. 이를 통해 무작위로 선택되는 가중치보다 빠른 시간 안에 최적값에 수렴할 수 있다. 널리 활용되는 가중치로는 ImageNet에서 높은 성능을 보이는 가중치로 본 연구에서도 ImageNet에서 높은 성능을 보이는 가중치를 시작점으로 삼아 미세조정하는 방식으로 전이학습을 적용하고 균열을 감지하고자 한다.

3. 실험

본 연구가 제안하는 프레임워크는 다음과 같이 크게 두 단계로 나뉜다. 첫 번째 단계는 데이터를 준비하는 단계로 AFM을 이용하여 아스팔트 바인더의 이미지를 수집하고, DSR테스트를 통해 $G^*/\sin\delta$ 데이터를 수집한다. 두 번째 단계는 학습과 테스트 단계로 첫 번째 단계에서 수집된 데이터를 전이학습을 통해 딥러닝 모델을 훈련 시키고, 그 성능을 테스트 한다.

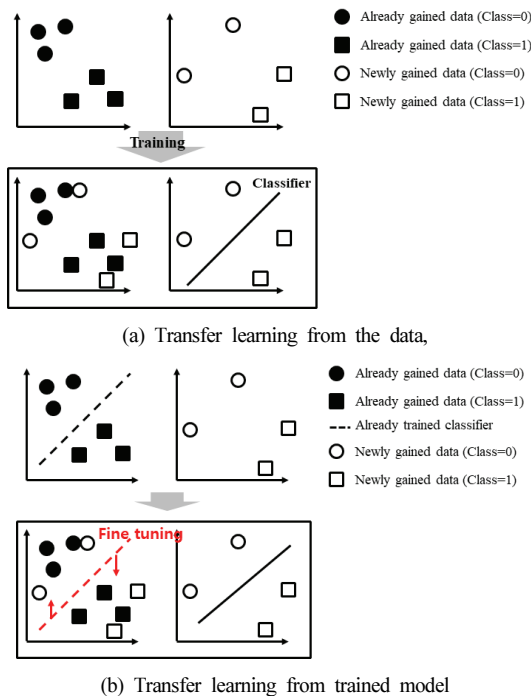


Fig. 2. Concept of transfer learning

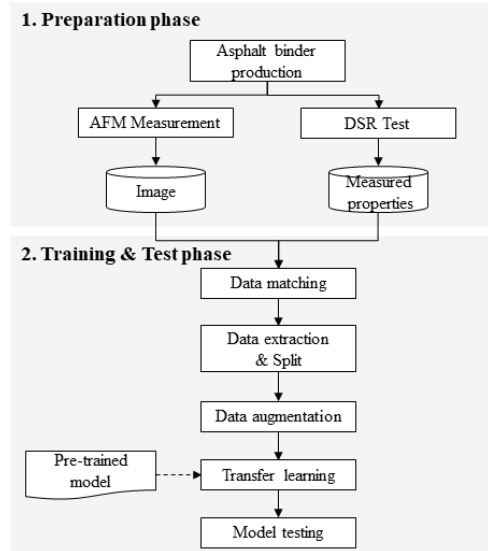


Fig. 3. Proposed framework

3.1 준비 단계

3.1.1 아스팔트 바인더 준비

아스팔트의 성능등급(Performance Grade, PG)평가를 위해 Multiple Stress Creep Recovery Test가 AASHTO TP 70에 의거하여 수행되었다. PG 64-22와 PG 76-22 두 가지의 아스팔트 바인더가 사용되었으며 아스팔트 바인더의 특성은 Table 1과 같다.

Table 1. Specification of asphalt binder used for experiment

Aging states	Test properties	PG 64-22	PG76-22
Unaged binder	Viscosity @ 135°C (Pa-s)	0.531	3.244
	$G^*/\sin \delta$ @ 64°C (kPa)	1.415	1.9
RTFO aged residual	$G^*/\sin \delta$ @ 64°C (kPa)	2.531	3.3
RTFO+PAV aged residual	$G^*/\sin \delta$ @ 25°C (kPa)	2558	3650
	Stiffness @ -12°C (MPa)	287	285
	m-value @ -12°C	0.307	0.302

두 아스팔트 모두 노화 전 아스팔트로 SIS 바인더는 700rpm의 속도에서 개방형 블레이드 믹서에 의해 180°C에서 80분 동안 교반되었다. SIS의 함량은 각각 0%, 5%, 10%로 조정하였다. PG 76-22 바인더에 SIS와 GTR을 첨가한 아스팔트 바인더 또한 준비되었다. SIS와 GTR의 비율이 각각 0%와 10%인 아스팔트 바인더, 5%와 5%인 아스팔트 바인더, 5%와 10%인 바인더가 준비되었다. 결론적으로 총 6개의 아스팔트 바인더가 준비되었다. Table 2는 실험에 사용된 아스팔트 바인더의 배합을 나타낸다.

Table 2. Asphalt binder used for experiment

Base binder	SIS(%)	GTR(%)
PG 64-22	0	0
PG 64-22	5	0
PG 64-22	10	0
PG 76-22	0	10
PG 76-22	5	5
PG 76-22	5	10

3.1.2 AFM을 통한 표면 측정

아스팔트 바인더의 표면 이미지를 수집하기 위해 AFM이 사용되었다. 사용된 AFM은 Bruker Instrument Inc 사의 840-002-380 Bruker Dimension Icon AFM로, 탐침(Probe)이 움직이며 아스팔트 바인더의 표면을 스캔한다. 탐침과 아스팔트 바인더 사이의 간격이나 상호작용에 의해 달라지는 반데르발스 힘(Van Der Waals Force)에 의해 유발된 힘을 측정한다. AFM 이미징 기법은 탐침이 샘플 표면과 접촉하여, 표면의 형상을 이미징하는 접촉 모드(Contact mode)와 비접촉 상태에서 탐침이 진동하며 표면과 상호작용에 의한 진동 주파수 변화를 측정하는 탭핑 모드(Tapping mode)가 존재하는데, 본 연구에서는 탭핑 모드가 사용되었다.




Fig. 4. Measured surface of asphalt binder by AFM

Fig. 4는 측정된 아스팔트 바인더를 나타낸다. (a), (c), (d)는 SIS를 단독으로 첨가한 이미지, (b)는 GTR을 단독으로 첨가한 이미지이며 (e), (f)는 SIS와 GTR을 혼합한 이미지이다. SIS를 단독으로 첨가한 경우, 특징적으로 벌 모양(Bee Shape)이 보이며, $G^*/\sin \delta$ 값이 커질수록 벌 모양은 작아지며 벌 모양의 주변부는 음영 대비가 커진다. GTR이 단독으로 첨가된 경우 작은 벌 모양이 특징적이며, 두 첨가제가 함께 혼합된 경우 원 모양의 음영 대비가 특징적이다.

3.1.3 DSR 테스트

DSR 테스트를 통해 아스팔트 바인더의 레올로지적 특징이 측정되었다. 본 연구에서는 테스트 방법으로 DSR 테스트 방법인 AASHTO T 315가 사용되었는데 76°C에서 25mm 스펀들을 사용하였으며 아스팔트 바인더는 1초에 10 라디안(Radian)의 Frequency로 측정되었다(약 1.59Hz). 또한 측정된 바인더는 노화 전 상태(Original)이었다. 측정 결과는 Table 3과 같다.

Table 3. Result of DSR test

Base binder	SIS(%)	GTR(%)	$G^*/\sin \delta$
PG 64-22	0	0	0.51
PG 64-22	5	0	2.72
PG 64-22	10	0	6.61
PG 76-22	0	10	1.27
PG 76-22	5	5	8.38
PG 76-22	5	10	13.67

3.2 학습과 테스트 단계

본 장에서는 3.1장에서 수집한 AFM 이미지와 $G^*/\sin\delta$ 간의 관계를 딥러닝 모델을 통해 학습시킨다. 학습된 딥러닝 모델은 AFM 이미지가 주어졌을 경우, $G^*/\sin\delta$ 값을 예측할 수 있게 된다. 딥러닝 모델의 학습을 위한 준비 단계로 데이터 매칭, 추출 및 분리, 증대가 이루어지고, 딥러닝 모델을 학습한 후, 성능 평가를 위해 테스트 단계에서 예측값과 실제값을 비교한다.

3.2.1 데이터 매칭

딥러닝 모델의 학습을 위해 측정된 아스팔트 바인더의 이미지와 $G^*/\sin\delta$ 의 데이터가 매칭되었다. 측정된 아스팔트 바인더의 이미지는 딥러닝 모델의 입력값이 되고, $G^*/\sin\delta$ 는 딥러닝 모델이 예측해야 하는 값, 즉 출력값이 된다. 따라서 본 연구에서 제안하는 딥러닝 모델은 이미지가 입력되었을 때 $G^*/\sin\delta$ 를 예측한다.

3.2.2 데이터 추출 및 분리

딥러닝 모델의 학습을 위하여 데이터를 학습데이터, 검증데이터, 테스트데이터 세가지로 나누어야 한다. 이와같이 데이터를 나누는 이유는 모델의 성능을 정확히 측정하기 위함으로 각 데이터마다 역할이 다르기 때문이다. 학습 데이터는 딥러닝 모델의 학습에 직접적으로 이용되어 딥러닝 모델을 구성하는 가중치의 값을 조정하는데 사용된다. 검증 데이터는 학습 과정에서 딥러닝 모델의 성능을 임시로 측정하기 위해 사용되는 데이터이다. 학습이 완료되지 않은 시점이라든, 검증 데이터로 모델의 성능을 중간 평가하고 모델의 아키텍처 혹은 모델의 하이퍼 파라미터 등을 수정할 수 있다. 테스트 데이터는 모델의 최종성능을 평가하기 위한 데이터로, 학습에 활용되지 않은 데이터를 통해 예측한 값과, 실제 값의 차이를 계산하여 성능을 평가하는데 사용된다.

본 논문에서는 AFM을 통해 수집된 이미지 데이터를 일부를 추출하여 사용한다. Fig. 5는 그 과정을 설명한다. AFM을 통해 수집한 이미지 데이터는 너비 20 μm , 높이 20 μm 의 크기로 해당 이미지의 일부로도 레올로지적 특징을 추출할 수 있다. 따라서 3.2 μm 의 크기로 학습 데이터, 검증 데이터, 테스트 데이터를 추출하여 이를 학습과 테스트에 사용한다. 테스트 데이터는 학습, 검증 데이터와 중복되지 않아야 하기에 좌상단의 5.6 μm 부분은 테스트 데이터만을 추출하기 위한 영역이고, 그 외의 부분에서 학습 데이터와 검증 데이터를 추출한다. 학습데이터는 4,200개를 추출하였고, 검증 데이터는 1,800개, 테스트 데이터는 1,200개를 추출하였다.

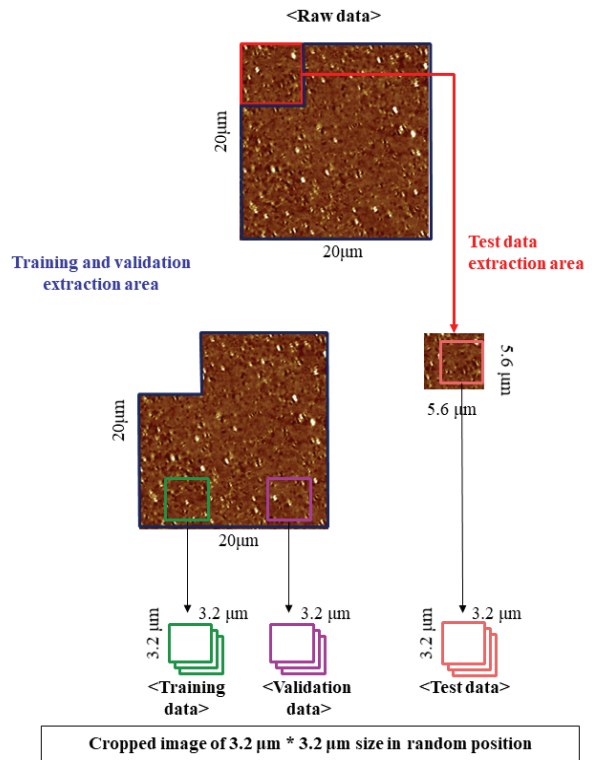


Fig. 5. Concept of data extraction

3.2.3 데이터 증대

딥러닝 모델은 많은 데이터를 요구하나, 현실에서는 많은 데이터를 쉽게 얻기 힘든 경우가 있다. 이런 경우, 데이터를 증대 (Augmentation)하여 딥러닝 모델의 성능을 높이는 기술이 널리 사용된다. 데이터 증대는 다양한 방법으로 가능한데 이미지를 쉬프트, 회전, 상하 또는 좌우로 뒤집기, 자르기, 확대 등등 이 그 예시이다. Fig. 6는 데이터 증대의 예시를 보여준다. Fig. 6의 (a)는




Fig. 6. Examples of data augmentation

데이터 증대를 적용하기 전 원본데이터이다. Fig. 6(b)는 이미지를 오른쪽으로 쉬프트 한 후, 빈 공간은 가장 근접한 색으로 채운 데이터이다. Fig. 6(c)는 마찬가지로 방법으로 이미지를 위쪽으로 쉬프트 한 결과, Fig. 6(d)는 좌우 뒤집기, Fig. 6(e)는 상하 뒤집기, Fig. 6(f)는 회전을 통해 데이터 증대를 한 예시이다. 이를 통해 학습데이터에 있지 않은 데이터에도 Robust한 결과를 산출할 수 있는 딥러닝 모델의 개발이 가능하다.

3.2.4 전이학습

본 장에서는 딥러닝 모델의 학습을 위하여 전이학습이 활용되었다. 전이학습의 방법 중 기존학습된 모델(Pretrained model)의 가중치 값으로부터 학습을 시작하여 미세조정하는 방법을 적용하였다. 기존학습된 모델은 Imagenet의 데이터를 학습한 모델을 활용하였다. 전이학습이 이루어지는 실험환경은 Table 4와 같다.

Table 4. Experimental environment

Environment	Category	Specification
Hardware	CPU	Ryzen 7 5800X
Hardware	GPU	NVIDIA RTX 3070 Ti
Hardware	RAM	64GB
Software	Python	3.6.9
Software	Tensorflow	2.4.0
Software	CUDA	11.0

전이학습 시 마지막 합성곱 층 이후의 Fully Connected Layer는 초기화 하고, 기존 분류모델로 학습된 EfficientNet의 구조를 연속된 숫자를 예측하는 Regression문제에 적합하도록 Fully Connected Layer를 2개 추가하고 마지막 Activation 함수는 Linear 함수로 대체하였다. 이를 통해 예측값을 연속된 숫자로 출력 가능했다.

딥러닝 모델의 학습을 위해서는 Loss 함수를 정의하여야한다. 실제값과 예측값의 차이에 따른 페널티를 부과하여 페널티를 줄이는 방식으로 가중치의 조정이 이루어지는데 Loss 함수에 따라 페널티가 주어지게 된다. Loss 함수는 크게 분류 문제인지 또는 Regression 문제인지에 따라 다르게 선택된다. Regression 문제의 경우, 예측값과 실제값의 차이를 정량화 하는 방법으로 페널티를 부여하는 Mean Squared Error(MSE), Mean Absolute Error(MAE), Root Mean Squared Error(RSME), Mean Absolute Percentage Error(MAPE) 등을 사용한다. 데이터 포인트 수를 n , 예측값을 \hat{y} , 실제값을 y 로 정의할 때, 각각의 Loss 함수는 아래와

같이 정의 된다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2)$$


$$MAE = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (3)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2} \quad (4)$$


$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (5)$$

본 연구에서는 MAPE를 Loss 함수로 선택하였다. MAPE는 실제값과 예측값 차이의 비율의 합으로 스케일의 차이가 클 때 주로 사용된다. 본 연구에서 사용된 $G^*/\sin\delta$ 의 범위가 가장 작은 값은 0.51부터 가장 큰 값은 13.67로 스케일의 차이가 26배에 가까우므로 MAPE를 선택하였다. 전체 데이터를 이용하여 모델의 가중치를 한번 업데이트 하는 것을 Epoch라고 정의하는데, 전이학습을 사용했을 때와, 사용하지 않았을 때의 Epoch별 Loss는 Fig. 7과 같다.

전이학습을 사용하지 않고, 무작위로 초기화된 가중치로부터 학습을 진행하였을 때는 Fig. 7(a)와 같이 Training Loss는 작지만,



(a) Training from scratch



(b) Transfer learning is adopted

Fig. 7. Training and validation loss over epoch

Validation Loss는 큰 현상이 나타났다. 이는 학습된 모델이 학습 데이터에 대해서는 높은 정확도로 레올로지적 특성을 예측하나, 학습되지 않은 데이터에서는 낮은 성능을 보이는 것을 나타낸다. 따라서 학습데이터에 과적합되어 있다고 판단할 수 있다. 전이학습을 사용한 Fig. 7(b)의 경우, 초기 학습 시 전이학습을 사용하지 않았을 때보다 낮은 성능을 보이지만, 점차 높은 성능을 보이고 학습되지 않은 데이터인 검증 데이터에도 안정적인 성능을 보이는 것으로 나타났다.

3.2.5 모델 테스트

본 모델의 성능을 평가하기 위해 실제값과 학습된 모델을 통해 예측된 값을 비교하였다. 결과는 Table 5와 같다.

Table 5. Result of DSR test

Base binder	SIS(%)	GTR(%)	Actual $G^*/\sin \delta$	Predicted $G^*/\sin \delta$ (Mean)
PG 64-22	0	0	0.51	0.51
PG 64-22	5	0	2.72	2.28
PG 64-22	10	0	6.61	6.13
PG 76-22	0	10	1.27	1.28
PG 76-22	5	5	8.38	7.57
PG 76-22	5	10	13.67	10.27

테스트 결과, 딥러닝 모델은 첨가제의 종류에 관계 없이 모든 배합의 $G^*/\sin \delta$ 를 높은 정확도로 예측하였다. 특히, 값이 작을수록 대체로 높은 정확도를 보였다. $G^*/\sin \delta$ 값이 큰 경우에는 상대적으로 낮은 정확도를 보였는데 실제값과 24.9%의 정도의 차이로, 수집된 $G^*/\sin \delta$ 값이 Sparse하기 때문에 발생한 문제로 추정된다.

4. 결론

본 연구는 아스팔트 바인더의 레올로지적 특성을 AFM 이미지를 통해 예측하기 위해 EfficientNet기반의 전이학습을 적용하였고 다음과 같은 결론을 얻었다.

- 1) 딥러닝 모델 중 하나인 EfficientNet을 이용하여 아스팔트 바인더의 AFM 이미지로부터 레올로지적 특성을 추정하고자 했다. 딥러닝의 특성 상, 많은 양의 데이터가 필요했지만 현실적으로 데이터가 한정적이다. 따라서 적은 데이터로도 좋은 성능을 도출할 수 있도록 데이터를 학습, 검증, 테스트 데이터 영역을 정하여, 추출, 증대가 필요하였다.

- 2) EfficientNet은 ImageNet에서 사전 학습한 가중치를 사용하여 전이학습을 수행하였다. 이는 적은 데이터에 대한 대응 방안이기도 하다. ImageNet은 여러 클래스를 분류 하는 문제이고 본 연구는 숫자 값을 예측하는 문제로 출력값이 다르다. 따라서 본 연구에서는 EfficientNet에 Fully Connected Layer를 추가하고 Activation 함수를 Linear 함수로 교체하여 출력값이 연속된 숫자를 가지도록 하였다.
- 3) 기존 연구에서는 AFM이미지로 레올로지적 특성을 예측할 때, 단일 재료인 SIS 비율의 차이만 존재하는 아스팔트 바인더만을 사용하였다. 하지만 본 연구에서는 SIS 뿐만 아니라 GTR을 첨가제로 사용한 이미지도 학습하였다. 실험결과 SIS 뿐만 아니라, GTR이 첨가되어도 높은 정확도로 AFM 이미지를 통해 레올로지적 특성을 예측할 수 있었다. 즉, 단일 첨가제 뿐만 아니라, 두 개의 첨가제에 대해서도 딥러닝 모델은 성공적으로 레올로지적 특성을 예측할 수 있는 가능성을 확인하였다.

본 연구는 SIS와 GTR을 활용하였지만 다양한 첨가제의 일부이다. 따라서 본 연구가 제안한 프레임워크에 따라 다양한 첨가제에 대해 추가 학습 및 예측이 이루어진다면 AFM 이미지로부터 레올로지적 특성을 예측하는 강건(Robust)하고 일반화 가능한 모델이 개발 가능할 것으로 기대된다.

Conflicts of interest

None.

References

Bang, S.H., Ak, R., Narayanan, A., Lee, Y.T., Cho, H. (2019). A survey on knowledge transfer for manufacturing data analytics, *Computers in Industry*, **104**, 116–130.

Divya, P.S., Krishnan, J.M. (2019). How to consistently collect rheological data for bitumen in a Dynamic Shear Rheometer?, *SN Applied Sciences*, **1(1)**, 1–5.

Hanz, A.J., Faheem, A., Mahmoud, E., Bahia, H.U. (2010). Measuring effects of warm-mix additives: use of newly developed asphalt binder lubricity test for the dynamic shear rheometer, *Transportation Research Record*, **2180(1)**, 85–92.

He, K., Zhang, X., Ren, S., Sun, J. (2016). Deep residual learning for image recognition, In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 770–778.

- Huang, B., Mohammad, L.N., Graves, P.S., Abadie, C. (2002). Louisiana experience with crumb rubber-modified hot-mix asphalt pavement, *Transportation Research Record*, **1789(1)**, 1-13.
- Ji, B.J., Lee, S.J., Mazumder, M., Lee, M.S., Kim, H.H. (2020). Deep regression prediction of rheological properties of SIS-modified asphalt binders, *Materials*, **13(24)**, 5738.
- Kim, H.H., Lee, M.S., Lee, S.J. (2019b). Performance evaluation of polymer modified asphalt(PMA) binders containing ground tire rubber(GTR), *International Journal of Pavement Research & Technology*, **12(2)**, 215-222.
- Kim, H.H., Lee, S.J. (2015). Effect of crumb rubber on viscosity of rubberized asphalt binders containing wax additives, *Construction and Building Materials*, **95**, 65-73.
- Kim, H.H., Mazumder, M., Lee, M.S., Lee, S.J. (2019a). Evaluation of high-performance asphalt binders modified with SBS, SIS, and GTR, *Advances in Civil Engineering*, **2019**.
- Kim, H.H., Mazumder, M., Lee, S.J. (2018). Recycling of aged asphalt binders with wax warm additives, *Road Materials and Pavement Design*, **19(5)**, 1203-1215.
- Mazumder, M., Siddique, A., Ahmed, R., Lee, S.J., Lee, M.S. (2020). Rheological and morphological characterization of styrene-isoprene-styrene(SIS) modified asphalt binder, *Advances in Civil Engineering*, **2020**.
- McDaniel, R.S. (2001). Asphalt Additives to Control Rutting and Cracking, Ph.D Thesis, Purdue University, United States.
- Tan, M., Le, Q. (2019). Efficientnet: rethinking model scaling for convolutional neural networks, In *International Conference on Machine Learning*, 6105-6114.
- Tayfur, S., Ozen, H., Aksoy, A. (2007). Investigation of rutting performance of asphalt mixtures containing polymer modifiers, *Construction and Building Materials*, **21(2)**, 328-337.

EfficientNet의 전이학습을 통한 아스팔트 바인더의 레올로지적 특성 예측

도로 포장에 널리 사용되는 아스팔트는 도로가 노출되는 환경에 따라 요구되는 물리적 특성이 상이하다. 이에 따라 첨가제의 배합에 따라 아스팔트가 어떤 물리적 특성을 나타내는지 평가하고 도로의 교통, 기후 환경에 맞추어 적절한 배합을 선택하는 것이 아스팔트 도로의 수명을 확보하기 위해 필수적이다. 아스팔트의 다양한 물리적 특성 중 소성변형에 대한 저항성을 측정하기 위해서는 Dynamic shear rheometer(DSR) 테스트를 주로 사용한다. 하지만 DSR 테스트는 실험 세팅에 따라 결과가 상이하고 특정 온도 범위 내에만 측정이 가능한 단점이 있다. 따라서 본 연구에서는 DSR 테스트의 단점을 극복하고자, Atomic force microscopy로부터 수집된 이미지를 학습하여 레올로지적 특성을 예측하고자 했다. 딥러닝 아키텍처 중 하나인 EfficientNet을 통해 이미지를 학습하였고 딥러닝 모델의 한계인 많은 데이터를 요구한다는 점을 극복하기 위해 전이학습을 이용하여 학습을 진행하였다. 학습된 모델은 이종의 첨가제를 사용하였음에도 높은 정확도로 아스팔트 바인더의 레올로지적 특성을 예측하였다. 특히, 전이학습을 사용하지 않았을 때와 비교하여 빠르게 학습이 가능했다.