

기계학습을 기반으로 한 자외선 경화형 도장의 부착성 불량 위험수준 정량화

윤주호¹ · 추병하² · 김병훈^{1*}

¹한양대학교 산업경영공학과 / ²(주)한국큐빅

Quantification of the Risk Level of Adhesion Defect of Ultraviolet Ray Curable Coating based on a Machine Learning Technique

Juho Yoon¹ · Byoungcha Chu² · Byunghoon Kim¹

¹Department of Industrial and Management Engineering, Hanyang University

²CUBIC KOREA INC.

Ultraviolet-curable coating is environmentally friendly and has the advantage of reducing the process time. The UV-curable coating is mainly applied to interior and exterior parts of automotive vehicles. In particular, adhesion is an important factor in the quality control of the automotive manufacturing process to improve the product reliability. Therefore, human being experts make an effort of testing the adhesion defect in the automotive manufacturing process. However, there is a disadvantage that the test result is subjective and costly because the engineer manually performs the adhesion test. In this study, the risk level of adhesion defect is quantified to predict the adhesion defect in a UV curable coating process. XGBoost is employed to predict the adhesion defect of a product and quantify the corresponding risk level in an automotive manufacturing process.

Keywords: Penetration Film Thickness, Quality Management, Classification, XGBoost, Risk Level of Adhesion Defect

1. 서론

도장은 도료를 피도장물의 표면에 도포함으로써 도막을 형성하는 작업으로 제품의 외관적인 가치와 신뢰성을 높여주는 기능을 한다. 기본적인 도장 공정은 피도장물의 전처리, 도장, 건조, 도막처리로 구성된다(Yun *et al.*, 1997).

일반적인 도장 공정이 건조 단계까지 약 2시간에서 3일이 소요되는데 반해, 자외선 경화형 도장은 <Figure 1>과 같이 도장 단계에서 환경친화성 도료인 자외선 경화형 도료를 사용하고, 건조 단계에서 적외선(Infrared, IR)과 자외선(Ultraviolet, UV)을 조사하여 도막을 경화시킴으로써 건조 단계까지 약 1시간

내외가 소요된다. 이처럼 자외선 경화형 도장은 환경친화적이고 리드 타임을 감소시켜 생산성이 향상되는 효과를 가져와 다양한 산업에서 폭넓게 적용되고 있다(Chu, 2020). 본 연구의 범주인 자동차 산업에서도 주로 내외장 부품에 적용되고 있다.

자동차는 차량이 판매된 후 다양한 필드의 가혹한 환경 조건에서 요구된 외관적인 가치와 신뢰성을 만족시켜야 하는 만큼 요구되는 신뢰성 항목들은 주로 내후성과 관련된다. 이러한 신뢰성 시험 항목들에는 부착성, 내마모성, 내스크래치성, 내습성, 내열성, 내열 사이클성, 내약품성, 내광성 등이 있고 이들 중에서도 가장 기본적이면서도 중요한 항목은 도막과 피도장물과의 부착성이다(Chu, 2020).

이 논문은 2020년도 산업통상자원부 및 한국산업기술진흥원의 재원으로 한국전자기술연구원의 지원을 받아 수행된 인력양성사업임(P0008691).

* 연락처 : 김병훈 교수, 15588 경기도 안산시 상록구 한양대로 55 5공학관 510호, 한양대학교 산업경영공학과, Tel : 031-400-5269,

Fax : 031-400-5959, E-mail : byungkim@hanyang.ac.kr

2020년 11월 13일 접수; 2021년 5월 14일 수정본 접수; 2021년 5월 24일 게재 확정.

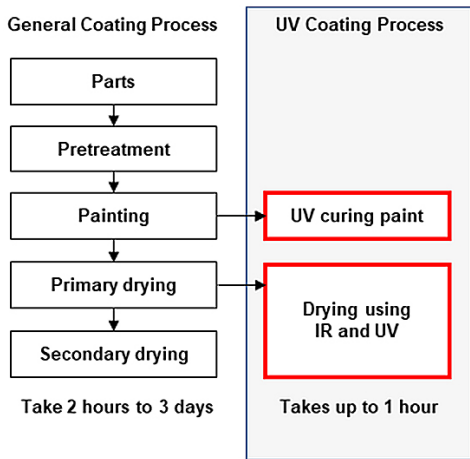


Figure 1. Comparison of General Coating Process and UV Coating Process

실무에서는 부착성 시험을 엔지니어가 직접 실시하므로 주관적인 판단을 배제할 수 없고, 소요되는 공수와 비용 역시 적지 않다. 부착성 시험은 완제품의 전체적인 수명과 직결되는 문제이므로 ISO 2409와 ASTM D3359 등의 국제 표준에서도 부착성에 대한 테스트 기준을 정해놓고 있다. 국제 표준에 따른 여러 부착성 테스트 가운데 주요한 방식 중 하나인 ‘크로스 컷’ 방식은 <Figure 2>와 같이 파괴시험으로 진행된다. 도장면을 직각의 격자무늬로 절단한 후 부착성 시험용 테이프를 그 위에 완전히 밀착시켰다가 떼어내어 도막의 박리 여부를 주어진 판정 기준과 비교하여 합격, 불합격을 판정하는 방식이다 (Kovac *et al.*, 2018).

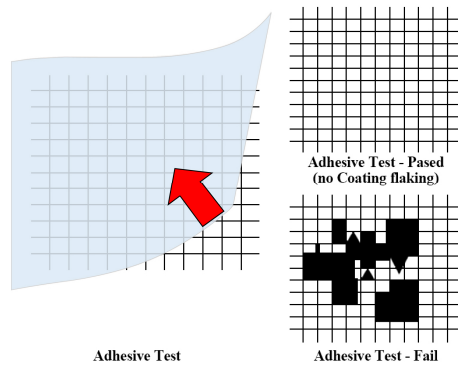


Figure 2. Cross-Cutting Adhesion Test Process and Results

일반적인 도장 공정은 방청을 위한 전처리 공정, 외판은 물론 차체 내부까지 균일하게 도장하여 차체의 부식을 방지하는 전착 도장 공정, 상도의 질을 높이기 위한 중도 도장 공정, 차체 표면의 미관과 색체의 외관 품질을 결정하는 상도 도장 공정 등으로 구성된다(Lee *et al.*, 2015). 이러한 모든 공정은 표면도막두께를 형성하는 과정이기도 하다. 즉, 일반적인 도장 공정은 표면도막두께에 따라 부착성이 결정되는 반면, 자외선 경화형 도장 공정에서는 피도장물의 표면 아래에 위치한 침투도막두께에 따라서 부착성이 결정되므로 망목특성인 침투도막두께가

도장의 품질을 좌우하는 중요한 요소이다(Chu, 2020).

최근 자외선 경화형 도장의 장점으로 사용량이 늘어나고, 부착성의 중요성이 인식됨에 따라 다양한 연구가 진행되었다. Lim *et al.*(1995)는 도료용 수지와 도막의 물성에 의해 부착성이 결정된다고 설명했고, Kim *et al.*(2001)은 자외선 경화형 도료의 배합과 물성 관계를 연구했다. Yang and Lee(2007)는 도료의 부착성 개선을 위한 분자동역학적 연구를 진행했고, Moon *et al.*(2008)는 광개시제의 함량에 따른 자외선 경화형 분체도료의 물리적 특성을 연구하였다. Park *et al.*(2011)는 자외선 경화형 도료 성분의 합성에 따른 경화거동에 대해 연구했다. Kwon and Cho(2011)는 자외선 경화 과정에서 필름 수축 현상 개선에 관해 연구했다. Hong *et al.*(2017)는 부착성에 유의한 영향을 미치는 설계변수들에 대한 정량적 기준을 제시하기 위해 실험계획법을 적용하여 최적화된 보수도장공정을 제시하였다. Chu(2020)는 자외선 경화 도장의 부착성에 영향을 미치는 인자의 최적 수준조합을 분석하고 부착성 불량을 예측하는 모델을 개발하였다. 그러나 기존 연구에서는 자외선 경화형 도료의 배합이나 피도장물의 물성에 따른 부착성에 국한되어 있어 도장 설비나 제조공정에 따른 부착성 불량 검사나 부착성의 위험수준을 추정하는 연구는 부족한 상황이다.

본 연구에서는 이에 착안하여 부착성 시험을 위해 작업자가 파괴시험을 하지 않고 도장 공정에서 발생한 데이터를 바탕으로 합격 여부를 판정할 수 있는 불량예측 모델을 제안한다. 나아가서, 결과의 신뢰성을 바탕으로 엔지니어들에게 제조공정에서 파괴시험 진행 여부를 판단하는 기준을 제시하기 위해서 부착성이 합격 혹은 불합격일 확률을 추정함으로써 위험수준을 정량화한다. 본 과정에서 불량예측의 정확도를 높이기 위해 XGBoost(eXtreme Gradient Boosting) 모델을 적용하였고, 최종적으로 로지스틱스 함수 확률값을 통해 예측의 신뢰성을 확보한다.

본 연구는 다음과 같이 구성된다. 제 2장에서는 부착성에 영향을 미치는 침투도막두께를 설명하고 기계학습을 이용한 불량예측 모델을 정의한다. 제 3장에서는 제안한 모델에 실제 자외선 경화형 도장 공정에서 발생한 데이터를 적용한 결과를 제시, 본 예측 모델의 효과를 분석한다. 마지막으로 제 4장에서는 결론과 향후 연구에 대하여 설명한다.

2. 자외선 경화형 도장의 부착성 불량예측 모델

자외선 경화형 도장의 부착성 불량을 예측하는 과정은 <Figure 3>과 같이 두 단계로 진행된다. 첫 번째 단계에서는 부착성에 영향을 미치는 침투도막두께를 측정하고, 두 번째 단계에서는 측정된 침투도막두께와 불량데이터를 바탕으로 XGBoost 분류모델을 학습한다. 침투도막두께에 따른 부착성 불량을 예측하고, 예측된 정보의 신뢰성을 확보하기 위해 부착성이 합격 혹은 불합격일 확률을 로지스틱스 함수의 확률값으로 추정함으로써 위험수준을 정량화한다.

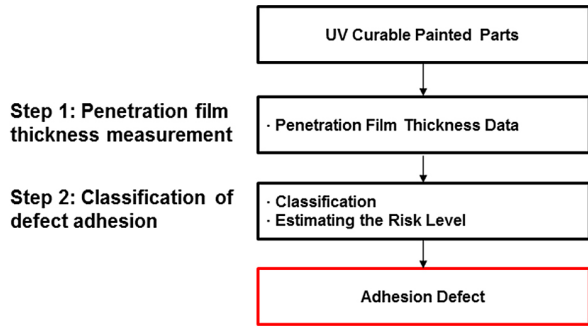


Figure 3. Overview of the Proposed Procedure

2.1 침투도막두께 측정

본 연구에 사용된 피도장물은 자동차 외장부품으로 폴리카보네이트 수지로 사출성형되어 라디에이터 그릴에 조립되는 플라스틱 커버이다. 부품에 자외선 경화형 도장이 완료되면 도막두께가 형성되는데 이를 단면도로 나타내면 <Figure 4>와 같이 표면도막두께와 침투도막두께로 층을 구분할 수 있다.




Figure 4. Cross-Sectional Drawing of Coating Thickness

일반적인 도장 공정에서는 전착 공정, 중도 공정, 상도 공정을 통해 형성된 표면도막두께에 따라 도장의 품질이 결정되지만, 자외선 경화형 도장 공정에서는 침투도막의 두께를 측정하는 것이 중요하다. 이는 최소한의 침투도막두께가 형성되어야 부착성이 확보되기 때문이다. 침투도막두께는 망목특성으로 <Figure 5>와 같이 자외선 경화형 도장이 완료된 피도장물의 표면에 침투도막두께를 측정할 수 있는 전용 계측기를 밀착시켜 침투도막의 두께를 측정할 수 있다. 측정된 침투도막두께로 구축된 데이터는 <Table 1>과 같다.



Figure 5. Penetration Film Thickness Measurement Using a Measuring Device

여기서 x_i 는 i 번째 제품의 위치별 침투도막두께이고, y_i 는 해당 제품의 부착성 시험 결과를 의미한다. 이때 y_i 가 1이면 해당 제품은 합격이고 아니면 0이다. 다음절에서는 구축된 데이터를 활용하여 부착성 불량예측하는 방법을 제안한다.

Table 1. Penetration Film Thickness Data Set

Penetration film thickness(μm)					Class label (y_i)
x_1	x_2	x_3	\dots	x_p	
x_{11}	x_{12}	x_{13}	⋮	x_{1p}	0
x_{21}	x_{22}	x_{23}		x_{2p}	0
x_{31}	x_{32}	x_{33}		x_{3p}	1
x_{i1}	x_{i2}	x_{i3}	⋮	x_{ip}	⋮

2.2 XGBoost 기반의 부착성 불량예측

본 절에서는 XGBoost 모델을 활용하여 부착성 불량예측을 하는 방법을 제안한다. XGBoost는 매우 효율적이고 유연하게 설계된 GBM(Gradient Boosting Machine)의 최적화된 비선형 알고리즘이다. 일반적으로 수치 특성에 잘 작동하고 우수한 성능을 얻기 위해 피쳐 엔지니어링이나 하이퍼 파라미터의 조정이 상대적으로 덜 필요하다(Chen and Guestrin, 2016).

XGBoost는 제조 분야에서도 성공적인 애플리케이션을 갖춘 기계학습 알고리즘으로 알려져 있다. Hebert(2016)는 복잡한 상호작용을 갖는 제조데이터에서 XGboost를 활용하여 희귀 고장 사고를 예측하였고, Chen and Guestrin(2016)은 금속 활성 가스 용접 공정에서 용접 품질의 실시간 예측을 위해 XGBoost 알고리즘에 기반한 데이터 기반 모델을 사용한 바 있다. Chen *et al.* (2018)는 XGboost 알고리즘을 이용하여 MAG 용접의 용접비드 형상을 예측하였고, Jabbar *et al.*(2018)는 XGBoost에 기반한 의사 결정 도구를 제안하여 인쇄 회로 기판 제조시 운영자를 지원한 바 있다. Peres *et al.*(2019)는 자동차 산업에서 XGBoost를 사용하여 복잡한 다단계 제조공정의 품질 관리를 시도한 결과 비선형 모델이 이러한 복잡한 환경을 모델링하여 기존 품질 관리 접근 방식을 개선하고, 결함 및 편차를 조기에 해결함으로써 비용 절감에 도움이 된다는 것을 보여주었다.

XGBoost는 약한 분류기를 세트로 묶어서 정확도를 예측하는 부스팅(Boosting) 방법을 사용하고 식 (1)과 같이 표현할 수 있다. f_k 는 x_i 에 따른 k 번째 의사결정나무 모델이다. n 개의 모델 f_k 를 더하여 추정한 값은 아래와 같다.

$$\log\left[\frac{p_i}{(1-p_i)}\right] = \sum_{k=1}^n f_k(x_i) \tag{1}$$

여기서 추정한 값인 $\log\left[\frac{p_i}{(1-p_i)}\right]$ 은 불합격일 확률의 로그 오즈비이고, p_i 는 부착성 시험 결과가 합격일 확률(즉, $P(y_i = 1)$)을 의미한다. $\log\left[\frac{p_i}{(1-p_i)}\right] \geq 0$ 이면 합격, 아니면 불합격이다. 이처럼 학습된 모델을 활용하여 불량예측을 수행할 수 있다.

위의 식 (1)을 추정하기 위해서는 <Table 1>과 같은 학습데이터를 활용하여 식 (2)를 최적화해야 한다. XGBoost의 목적함수로 l 은 학습손실함수이고, 함수 Ω 는 t 개의 나무를 구성할 때 발생하는 복잡도를 나타내는데 편향-분산 트레이드 오프를 맞춰 나무의 비중을 조절한다. $\Omega(f_t)$ 의 첫 번째 항의 T 는 잎의 개수를 의미하고 γ 는 잎의 개수를 조절해서 잎의 점수가 너무 커져서 모델이 과적합되는 것을 방지하는데 사용된다. 유클리드 노름은 만들어진 나무의 가중치가 너무 커지지 않게 조정한다.

$$Obj = \sum_{i=1}^n l(y_i, \hat{y}_i) + \sum_{t=1}^n \Omega(f_t) \quad (2)$$

$$\text{여기서 } \Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \| \omega \| ^2.$$

이때 목적함수에 대한 최적의 비중 값 ω^* 와 목적함수의 최적 값은 식 (3), 식 (4)와 같다.

$$\omega_j^* = -\frac{G_j}{H_j + \lambda} \quad \text{그리고} \quad (3)$$

$$Obj = -\frac{1}{2} \sum_{j=1}^T \frac{G_j}{H_j + \lambda} + \lambda T. \quad (4)$$

여기서 G_j 와 H_j 의 자세한 식은 식 (5), 식 (6)과 같고 g_i 를 일차 편미분, h_i 로 이차 편미분한 자세한 식은 다음과 같다.

$$G_j = \sum_{i \in I_j} g_i \quad (5)$$

$$H_j = \sum_{i \in I_j} h_i \quad (6)$$

$$\text{이때 } g_i = \partial_{y_{i-1}} l(y_i, \hat{y}_i^{t-1}), h_i = \partial_{y_i}^2 l(y_i, \hat{y}_i^{t-1}).$$

XGBoost는 식 (5)와 식 (6)을 이용하여 나무가 매 순간 분기하면서 얻을 수 있는 정보 획득량을 식 (7)과 같이 계산한다. 이때 L 은 왼쪽 종단 잎 점수를, R 은 오른쪽 종단 잎 점수를 의미한다. 식 (7)에 의해 $Gain$ 이 음수가 될 때 가지를 치면 해당 숲은 정보 획득량이 최대가 된다(Chen and Guestrin, 2016). 즉 정보 획득량이 높은 나무를 적합하면서 강건한 숲이 만들어진다.

$$Gain = \frac{G_L^2}{H_L} + \frac{G_R^2}{H_R} - \frac{(G_L + G_R)^2}{H_L + H_R} - \gamma. \quad (7)$$

2.3 부착성 위험수준 정량화

본 절에서는 부착성 불량예측의 위험수준을 정량화하기 위해서, 식 (1)에서 언급된 부착성 불량률의 확률값을 추정하는 방법을 제안한다. 예측된 부착성 시험 결과를 확률값으로 정량화하면 예측된 정보의 신뢰성을 확보할 수 있다. 이를 통해서 제

조공정에서 엔지니어에게 파괴시험의 진행 여부를 판단하는 기준을 제공할 수 있게 된다. 식 (1)에서 종단 잎의 값은 부착성 불량 확률의 로그 오즈비 값이므로, 식 (8)과 같이 로지스틱 함수를 활용하여 정량화할 수 있다(Wong and Mason, 1985).

$$P(y_i = 1) = \frac{1}{1 + e^{-\sum_{k=1}^n f_k(x_i)}} \quad (8)$$

침투도막두께가 주어졌을 때 부착성 시험 결과는 $P(y_i = 1) \geq \delta_1$ 이면 부착성 시험 합격, $P(y_i = 1) < \delta_2$ 이면 불합격이다. 위험수준은 통상 δ_1 과 δ_2 를 0.5로 기준으로 하지만, 엔지니어의 경험적 판단에서 파괴검사의 진행 여부가 결정할 수 있다. 예를 들어 해당 부품에 대하여 부착성이 불합격일 것이라고 예측하지만, 그 확률이 46.5% 라면 엔지니어의 파괴검사가 필요할 수도 있음을 시사한다.

3. 실험과 평가

3.1 데이터

본 연구에서는 자외선 경화형 도장 공법으로 자동차 부품을 생산하는 국내 업체에서 발생한 실제 데이터를 2주 동안 수집하여 활용한다. 데이터 셋은 24개의 샘플로 구성되어 그 수가 적기 때문에 모델의 성능이 민감하게 변할 수 있는 단점이 있으므로 이를 보완하기 위하여 k-겹 교차 검증을 사용하였다. 데이터를 동일한 크기를 가진 k개의 겹으로 분할하고, 첫 번째 겹은 검증 데이터로 사용하고 나머지 k-1개의 겹에 대해 훈련하여 검증 데이터 세트의 오차를 계산한다. 이 과정을 순차적으로 k번 반복하고 그 결과 얻어지는 오차 값들을 평균하여 계산한다. 이 검증 방법은 지나치게 높은 편향과 높은 분산으로 인한 문제 없이 검증을 진행할 수 있다는 장점이 있다(Ha et al., 2007). 자외선 경화형 도장 공정 내의 적외선과 자외선을 조사하는 단계에서 부품의 위치에 따라 부착성에 차이가 있으므로 <Figure 6>과 같이 상측면(x_1, x_2), 좌우측면(x_3, x_4), 하측면(x_5, x_6), 정면(x_7, x_8)으로 각기 다른 위치 8개소의 침투도막두께를 측정한다. 측정값과 그에 따른 부착성 시험 결과는 합격은 1로 불합격은 0으로 분류되고, 전체 데이터에서 합격인 샘플은 8개, 불합격인 샘플은 16개를 차지한다.




Figure 6. Penetration Film Thickness Measurement at 8 Different Locations on the Part

3.2 부착성 불량예측 모델 구축

(1) 침투도막두께

데이터 세트에 대한 상관 행렬은 <Figure 7>을 통해 확인되는 바와 같이 대부분의 위치별 침투도막두께는 타겟과 높은 상관관계를 가지며, 실제로 위치별 침투도막두께와 부착성 사이에 관계가 있는 경우 다중공선성에 대해 강건한 나무 기반 분류기가 더 적합할 수 있음을 보여준다(Malehi and Jahangiri, 2019).

자외선 경화형 도장이 완료된 부품의 침투도막두께를 측정하는 결과를 도시하면 <Figure 8>과 같다. 침투도막두께는 망목 특성으로 <Figure 6>에서와 같이 상측면(x_1, x_2), 좌우측면(x_3, x_4), 하측면(x_5, x_6), 정면(x_7, x_8)으로 대칭된 동일한 면(side)에서 침투도막두께가 일정 수준에 이를 때 합격과 불합격으로 판정됨을 확인할 수 있다.

또한 본 연구에서는 자외선 도장 공정에서 발생한 침투도막두께와 표면도막두께 데이터를 가지고 다변량 통계분석의 일종인 Hotelling's T^2 검정을 수행하여 <Table 2>와 같이 침투도막두께가 표면도막두께에 비하여 부착성에 통계적으로 유의한 영향을 끼치는 것을 확인하였다(Hotelling, 1992).






Figure 7. Matrix of the Absolute Correlations Between the Location-Specific Features Based on the Spearman Coefficient

Table 2. Hotelling's T^2 Test Results


Result	Penetration Film Thickness	Surface Film Thickness
Test stat	10.618	2.6164
Numerator df	8	8
Denominator df	15	15
P-value	6.139e-05	0.0516




(a) Upper Side(x_1, x_2)



(b) Left and Right Sides(x_3, x_4)



(c) Lower Side(x_5, x_6)



(d) Front Side(x_7, x_8)

Figure 8. Comparison of Adhesion According to Penetration Film Thickness

(2) 부착성 위험수준 정량화

부착성 불량예측 모델을 통해 위험수준을 추정한 결과는 <Table 3>과 같다. 가령 두 번째 부품의 부착성은 합격으로 예측되었으나 위험수준인 일정 구간에 해당하면 엔지니어의 파괴 검사가 필요할 수도 있음을 시사한다. 위험수준이 일정 수준 이하(δ_2)인 제품군에 대해서는 불합격, 일정 수준 이상(δ_1)인 제품은 합격으로 판정하여 불량을 조기에 검출하고 엔지니어가 위험수준에 따라 선택적으로 파괴검사를 실시한다면 공수와 비용을 줄일 수 있다.

3.3 제안된 부착성 불량예측 모델의 성능 평가

본 연구에서 사용된 데이터의 수가 적기 때문에 모델의 성능에 민감하게 반응할 수 있는 바 3-Fold Cross Validation을 사용하여 제안한 모델의 과적합을 방지하고 일반화 할 수 있도록 하였다. 제안한 부착성 불량예측 모델의 성능을 평가하기 위해 칩투도막두께 데이터 세트에 대하여 XGBoost와 같은 나무 기반 알고리즘인 의사결정나무, 랜덤포레스트 모델로 분류를 진행하였고, 표면도막두께와 칩투도막두께 각각의 데이터로 성능을 비교한 결과 <Table 4>와 같이 칩투도막두께 데이터를 사용한 XGBoost 모델이 F1-score와 균형 정확도가 가장 높았다. <Table 5>는 칩투도막두께에 따른 부착성을 예측한 결과로 오분류 된 결과값과 그 위험수준을 확인하고 본 기업에서는 위험수준이 0.5 근처인 제품군에 대하여서만 추가적인 파괴시험을 실시한다.

Table 5. Adhesion Classification Result and Risk Level by Penetration Film Thickness

Sample	Actual Label	Predicted Label	Risk Level
1	Adhesion Pass	Adhesion Pass	0.03
2	Adhesion Pass	Adhesion Pass	0.03
3	Adhesion Pass	Adhesion Pass	0.03
4	Adhesion Pass	Adhesion Pass	0.03
5	Adhesion Pass	Adhesion Pass	0.03
6	Adhesion Pass	Adhesion Pass	0.03
7	Adhesion Pass	Adhesion Pass	0.03
8	Adhesion Pass	Adhesion Pass	0.03
9	Adhesion Pass	Adhesion Pass	0.03
10	Adhesion Pass	Adhesion Pass	0.03
11	Adhesion Pass	Adhesion Pass	0.03
12	Adhesion Pass	Adhesion Pass	0.03
13	Adhesion Pass	Adhesion Pass	0.05
14	Adhesion Pass	Adhesion Pass	0.08
15	Adhesion Pass	Adhesion Pass	0.29
16	Adhesion Failure	Adhesion Pass	0.57
17	Adhesion Failure	Adhesion Pass	0.85
18	Adhesion Pass	Adhesion Failure	0.49
19	Adhesion Failure	Adhesion Failure	0.81
20	Adhesion Failure	Adhesion Failure	0.81
21	Adhesion Failure	Adhesion Failure	0.87
22	Adhesion Failure	Adhesion Failure	0.89
23	Adhesion Failure	Adhesion Failure	0.92
24	Adhesion Failure	Adhesion Failure	0.93

Table 3. Prediction of Defective Adhesion by Parts and Quantification of Risk Levels

Penetration Film Thickness(μm)					Predict	\hat{y}_i	Engineer
x_1	x_2	x_3	...	x_8			
4.9	3.5	0.8		7.8	0	0.948	PASS
4.1	3.0	0.5		8.6	1	0.593	Check
4.6	6.2	2.2		9.1	0	0.948	PASS
4.7	3.5	1.3		6.4	0	0.948	PASS
4.2	3.2	1.5		8.5	0	0.936	PASS
3.8	2.8	2.7		9.8	0	0.592	Check
5.0	4.2	1.8		8.1	0	0.616	PASS
4.0	4.4	2.5		10.4	0	0.592	Check
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

Table 4. Performance Comparison for each Data Set

Data	Method	Accuracy	Precision	Recall	F1-score
Penetration Film Thickness	Decision Tree	0.58	0.88	0.44	0.58
	Random Forest	0.83	0.88	0.88	0.88
	XGBoost	0.88	0.88	0.94	0.91
Surface Film Thickness	Decision Tree	0.62	0.71	0.75	0.73
	Random Forest	0.58	0.65	0.81	0.72
	XGBoost	0.58	0.65	0.81	0.72

Table 6. Shapiro-Wilk Test Results

Adhesion	P-value							
	x_1	x_2	x_3	x_4	x_5	x_6	x_7	x_8
Pass	0.32	0.62	0.78	0.09	0.74	0.42	0.05	0.44
Failure	0.98	0.86	0.22	0.22	0.22	0.22	0.03	0.79

그러나 본 실험에 사용된 데이터의 수가 적고, 실제 작업 현장에서 추가적으로 데이터를 확보하는 데 한계가 있는 바, 확률론적 모델링 기법(Stochastic modeling)인 몬테카를로 시뮬레이션(Monte Carlo Simulation)을 통해 확률분포에 기반하여 칩투도막 두께 데이터를 증폭하고, 불량예측 모델에 적합하여 본 실험 결과를 일반화하고자 한다(Boyle, 1977). 몬테카를로 분석은 확률 이론에 근거하며, 빌딩 시뮬레이션 분야에서 널리 사용되고, 그 적절성은 충분히 검증되었다(IBPSA 1985~2011). 몬테카를로 시뮬레이션을 수행하기 위해서는 입력변수 분포모형과 샘플링 방법을 결정해야 한다(Mooney, 1997). 본 시뮬레이션에서 입력 변수는 부착성의 합/불여부에 따른 각 8개소 위치별 칩투도막 두께가 된다. 실제 칩투도막 두께 데이터에 대하여 샤피로-윌크 검정(Shapiro-Wilk test)을 수행한 결과 <Table 6>과 같이 대체적으로 정규성(Normality)을 만족함에 따라서 입력변수의 분포모형은 정규분포로 설정하였다(Shapiro and Wilk, 1965). 샘플링 방법의 경우 변수들간의 상관관계를 고려하여 단순 무작위 샘플링(Simple Random Sampling, SRS) 방법과 라틴 하이퍼큐브 샘플링(Latin Hypercube Sampling, LHS) 방법을 적용한다. SRS 방법은 수열을 이용하여 균등난수를 추출하는 표본추출방법이며, 가장 일반적으로 사용된다(L'Ecuyer, 1998). 이때 사용된 파라미터는 모집단으로부터 가정한 평균(μ_i)과 공분산행렬(Σ_i)이다. 파라미터의 입력 범위를 확률적으로 동일하게 N 개의 구간으로 나눈 후, 각 구간에서 샘플을 추출하는 LHS 방법은 상대적으로 적은 샘플을 이용하여 유의한 결과를 얻을 수 있으며, 복잡한 비선형 모델에도 적합하다(De Wit and augenbroe, 2002). LHS 방법에 사용된 파라미터는 평균(μ_i)과 표준편차(σ_i)이다. 본 연구에서는 데이터의 정규성을 높이고 보다 정확한 결과 도출을 위해 실제 칩투도막 두께 데이터를 로그 변환한 뒤, 변환된 값에 지수값(10.0e-6)을 취하여 음수값을 피하였다(Chanyoung et al., 2014). 부착성의 합/불여부에 따라서 각각 1,000개의 칩투도막 두께 시뮬레이션 샘플링을 진행하였다. 불량예측 모델 훈련에는 1,400개의 결과를, 그리고 600개의 결과는 검증에 사용하였다. 몬테카를로 시뮬레이션을 통해 생성된 칩투도막 두께에 따른 부착성 불량예측 모델의 성능은 <Table 7>과 같다. 몬테카를로 시뮬레이션 적용한 결과값 역시 안정적인 정확도를 보였다.

Table 7. Simulation Results

Data	Accuracy	Precision	Recall	F1-score
SRS	0.99	0.99	1.0	0.99
LHS	0.99	1.0	0.99	0.99

4. 결론과 향후 연구

자외선 경화형 도장에서 제품의 외관적인 가치와 신뢰성을 확보하는 핵심은 도막과 피도장물의 부착성에 기인한다. 본 연구에서는 칩투도막 두께가 망목특성이라는 점을 고려하여 실제 자외선 경화형 도장 공정에서 발생한 데이터를 가지고 기계학습을 이용해 조기에 부착성 불량을 예측할 수 있는 모델을 구축한다. 이 과정에서 나무 기반 분류기들과 성능을 비교하였고 XGBoost 모델은 전반적으로 안정적인 정확도를 보였다. 나아가서 위험 수준을 정량화함으로써 실무에서 작업자가 파괴시험을 하는데 들어가는 공수와 비용을 줄일 수 있는 방안을 제시하였다. 향후 연구에서는 도장물의 위치 정보 이외에도 도장 공정에서의 온도, 도료의 토출압력, 적외선과 자외선의 조사 온도, 시간 등의 특성을 반영하여 제안한 모델에 적합시키면 더욱 견고한 모델이 될 것이라고 기대한다. 또한 온도, 토출압력, 시간 등 각각의 제조 설정이 미치는 영향력을 평가한다면 실무에서 선제적인 품질 관리 체계를 이룩할 수 있을 것이라고 사료된다.

참고문헌

Boyle, P. P. (1977), Options : A Monte Carlo Approach, *Journal of Financial Economics*, 4(3), 323-338.

Changyong, F. E. N. G., Hongyue, W. A. N. G., Naiji, L. U., Tian, C. H. E. N., Hua, H. E., and Ying, L. U. (2014), Log-Transformation and its Implications for Data Analysis, *Shanghai Archives of Psychiatry*, 26(2), 105.

Chen, K., Chen, H., Liu, L., and Chen, S. (2019), Prediction of Weld Bead Geometry of MAG Welding based on XGBoost Algorithm, *The International Journal of Advanced Manufacturing Technology*, 101(9-12), 2283-2295.

Chen, T. and Guestrin, C. (2016), Xgboost : A Scalable Tree Boosting System, *In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 785-794.

Chu, B.-H. (2020), Optimal Level Combination Analysis of Factors Affecting the Adhesion of Ultraviolet Curing Coating and Development of a Model for Prediction of Adhesion Fault(Masters dissertation), Hanyang University, Korea, 1-18.

De Wit, S. and Augenbroe, G. (2002), Analysis of Uncertainty in Building Design Evaluations and its Implications, *Energy and Buildings*, 34(9), 951-958.

George, Y. W. and William, M. M. (1985), The hierarchical Logistic Regression Model for Multilevel Analysis, *Journal of the American Statistical Association*, 80(391), 513-524.

- Ha, J.-E., Shin, H.-C., and Lee, Z.-K. (2017), Korean Text Classification Using Randomforest and XGBoost Focusing on Seoul Metropolitan Civil Complaint Data, *The Journal of Bigdata*, **2**(2), 100-101.
- Hebert, J. (2016), Predicting Rare Failure Events Using Classification Trees on Large Scale Manufacturing Data with Complex Interactions, *In 2016 IEEE International Conference on Big Data(Big Data)*, 2024-2028.
- Hotelling, H. (1992), The Generalization of Student's Ratio, In *Breakthroughs in statistics*, Springer, New York, NY, 54-65.
- IBPSA (1987-2011), Proceedings of the IBPSA(International Building Performance Simulation Association) Conference('87, '91, '93, '95, '97, '99, '01, '03, '05, '07, '09, '11).
- Jabbar, E., Besse, P., Loubes, J. M., Roa, N. B., Merle, C., and Dettai, R. (2018), Supervised Learning Approach for Surface-Mount Device Production, In *International Conference on Machine Learning, Optimization, and Data Science*, Springer, Cham, 254-263.
- Jenster, P. V. (1987), Using Critical Success Factors in Planning, *Long Range Planning*, **20**(4), 102-109.
- Kim, H.-K., Kim, J.-G., Yu, J.-A., and Hong, J.-W. (2001), Experimental Design Approach to Evaluate Chemical Composition Effects of UV Curable Hard Coatings, *Journal of the Korean Industrial and Engineering Chemistry*, **12**(3), 287-293.
- Kovac, O., Lukacs, P., and Rovensky, T. (2018), Software Evaluation of Cross-Cut Adhesion Testing, *In 2018 41st International Spring Seminar on Electronics Technology(ISSE)*, 1-3.
- Kwon, Y.-J. and Cho, U.-R. (2011), Study on the Improvement of Film Shrinkage in UV-curing Process, *Polymer(Korea)*, **35**(4), 320-324.
- L'Ecuyer, P. (1998), Uniform Random Number Generators, *In 1998 Winter Simulation Conference. Proceedings (Cat. No. 98CH36274)*, IEEE, **1**, 97-104.
- Lee, C.-H., Kim, N.-H., and Lim, J.-H. (2015), Experimental Research on the Anti-corrosion Effect of Anti-corrosion Paint, *KSAE 2015 Annual Conference and Exhibition*, 1252-1258.
- Leidecker, J. K. and Bruno, A. V. (1984), Identifying and Using Critical Success Factors, *Long Range Planning*, **17**(1), 23-32.
- Lim, J.-C., Kim, B.-S., and Choi, S.-Y. (1995), Resin for Paint and Physical Properties of Coating Film, *Polymer Science and Technology*, **6**(3), 213-225.
- Malehi, A. S. and Jahangiri, M. (2019), Classic and Bayesian Tree-Based Methods, *In Enhanced Expert Systems*, IntechOpen, 1-2.
- Moon, J.-I., Choi, J.-H., Hwang, H.-D., Kim, H.-J., and Kim, N.-H. (2008), Physical Properties of UV-Curable Powder Coatings with Different Photoinitiator Contents, *Journal of Adhesion and Interface*, **9**(2), 32-37.
- Mooney, C. Z. (1997), Monte Carlo Simulation, Sage Publications, Inc., 116.
- Park, E.-S., Hwang, H.-D., Park, C.-H., Lee, Y.-H., Moon, J.-I., and Kim, H.-J. (2011), Synthesis and Curing Behavior of UV-curable Polycarbonate-based Polyurethane Methacrylate : Effect of Polyol Molecular Weight, Contents of Photoinitiator and Monomers on the Flexibility and Properties, *Journal of Adhesion and Interface*, **12**(2), 47-55.
- Rockart, J. F. and Morton, M. S. (1984), Implications of Changes in Information Technology for Corporate Strategy, *Interfaces*, **14**(1), 84-95.
- Shapiro, S. S. and Francia, R. S. (1972), An Approximate Analysis of Variance Test for Normality, *Journal of the American statistical Association*, **67**(337), 215-216.
- Yang, Y.-J. and Lee, C.-W. (2007), Molecular Dynamics Study for Improving the Adhesion of Paint, *Journal of the Korean Society of Marine Engineering*, **31**(8), 932-938.
- Yun, J.-H., Kim, Y.-R., and Gang, B.-S. (1997), Construction Status of Test and Evaluation Facilities for Clean Coating Technology Development, *Clean Technology*, **3**(1), 66.

저자소개

윤주호 : 명지전문대학 산업시스템경영공학과에서 석사학위를 취득하고, 한양대학교에서 산업경영공학과 석박사통합과정에 재학중이다. 주요 관심분야는 머신러닝, 데이터 마이닝이다.

추병하 : 한양대학교 산업경영공학과에서 석사학위를 취득하고, (주)한국큐빅 생산팀에서 근무중이다. 주요 관심분야는 머신러닝, 데이터 마이닝이다.

김병훈 : 려거스 대학교에서 산업시스템공학 박사를 취득하고, 현재 한양대학교 산업경영공학과에 재직 중이며 주요 관심분야는 통계 데이터 마이닝 방법론 개발, 반도체 제조 공정용 데이터 마이닝 모델 개발, 심층 생성 모델이다.