

인공지능 기반 고분자 복합재 성형 공정 중 실시간 센싱 및 품질 예측 기술

Real-time In-line Sensing and Quality Prediction Technologies in AI-enabled Polymer Composite Molding Processes

서준형^{1,2} · 김진수³ · 호동해^{1,2} | Jun Hyeong Seo · Jinsu Kim · Dong Hae Ho

¹Department of Energy Science and Engineering, Daegu Gyeongbuk Institute of Science and Technology,
²Energy Science and Engineering Research Center, Daegu Gyeongbuk Institute of Science and Technology,
 333 Techno Jungang-daero, Hyeonpung-eup, Dalseong-gun, Daegu 42988, Korea

³Department of Convergence Materials, Korea Institute of Materials Science,
 797 Changwon-daero, Seongsan-gu, Changwon-si, Gyeongnam 51508, Korea
 E-mail: hodh123@dgist.ac.kr

1. 서론

고분자 매트릭스 기반 섬유 강화 복합재료는 우수한 비강도와 비강성을 바탕으로 우주항공, 미래 모빌리티, 풍력 발전 등 다양한 고부가가치 산업에서 핵심 경량 구조재로 활용되고 있다. 그러나 복합재 성형 공정은 고온·고압 조건 하에서 점탄성 수지 유동, 열경화 화학반응, 열응력 발생이 동시에 상호작용하며 일어나는 비선형적 과정이다. 기존 공정 설계 및 품질 보장은 주로 제조 완료 후 비파괴 검사와 사후 시험에 전적으로 의존해 왔다. 이는 높은 공정 실패율과 재작업 비용을 초래하여 생산성 저하 요인이 되고 있다. 최근 센서 기술과 인공지능의 융합으로 성형 공정 중 내부 상태를 실시간 진단하고 최종 품질 및 결함 발생 여부를 선제적으로 예측할 수 있게 되었다. 이에 따라 자율제어 스마트 제조 패러다임이 새롭게 제시되고 있다. 본 고분자 특성분석 지상강좌에서는 복합재 성형 공정 중 핵심 인라인 센싱 기술인 광섬유 센서, 압전 센서, 음향방출 및 유전분석의 작동 원리를 고찰한다. 또한, 센서로부터 획득한 시계열 및 공간적 고차원 센서 신호를 학습하여 경화도, 잔류 응력, 내부 기포 및 박리 결함을 실시간으로 예측하는 대표적인 인공지능 알고리즘(PCA, CNN, LSTM)의 연구 개발 동향을 체계적으로 소개한다. 아울러 복합재 스마트 성형의 실용화를 가로막는 데이터 부족 문제를 극복하기 위한 물리 기반 인공지능망(PINN) 기법과 현장 의사결정 신뢰성 향상을 위한 설명 가능한 인공지능(XAI), 그리고 신속한 도메인 적응을 위한 전이 학습 기술 등 최신 해결 전략을 함께 다룬다. 마지막으로, 이러한 기술들을 통합한 자율 제어형 복합재 스마트 제조로 나아가는 미래 발전 방향을 논의한다.

Author



서준형

2026 국립금오공과대학교 화학소재공학 (학사)
 2026-현재 대구경북과학기술원 에너지공학 (석사과정)



호동해

2015 성균관대학교 화학공학 (학사)
 2021 성균관대학교 나노공학 (박사)
 2022 연세대학교 화공생명 (Post-Doc.)
 2024 Virginia Tech 기계공학 (Post-Doc.)
 2024-현재 대구경북과학기술원 에너지공학과 조교수



김진수

2015 한국항공대학교 항공재료공학 (학사)
 2023 서울대학교 재료공학 (박사)
 2023 한국과학기술원 탄소융합소재 연구센터 (Post-Doc.)
 2023-현재 한국재료연구원 융복합재료본부 선임연구원

섬유 강화 고분자 복합재료는 가벼우면서도 철강 및 알루미늄 합금 등 기존 금속 소재에 준하거나 이를 능가하는 우수한 비강도와 비강성, 뛰어난 피로 수명 및 내식성을 나타내어 현대 최첨단 기술 구조 엔지니어링의 핵심 소재로 인정받고 있다.^{1,2} 최근 보잉 787 및 에어버스 A350과 같은 차세대 여객기 주구조물의 50% 이상이 탄소섬유 강화 복합 재료로 제작되는 등, 항공우주 분야를 필두로 한 고성능 구조재 분야에서 그 입지를 확고히 굳히고 있다.^{1,3} 또한, 탄소 중립 실현을 위한 액화수소 저장용 고압 용기 개발 및 친환경 전기자동차 차체 경량화, 도심 항공 모빌리티의 안전 기준 충족을 위해서도 고분자 복합재의 활용이 크게 늘어나는 추세이다.^{1,4}

그러나 고분자 복합재의 성형 공정은 매우 복잡하고 비선형적인 물리·화학적 특성을 지닌다. 대형 부품 제조에 쓰이는 오토클레이브 성형, 액상 수지를 직접 주입하는 resin transfer molding(RTM, 수지이송성형), sheet molding compound(SMC) 성형 등 대부분의 성형 방식은 외부 열과 압력 사이클 하에서 수행된다. 이 공정들에서는 분자 수지가 다공성 건식 섬유 적층 preform 사이를 침투하여 흐르는 유동 현상, 수지의 열경화 반응에 따른 급격한 중합 수축 및 자가 반응열 발생, 그리고 섬유와 수지의 열팽창 계수불일치에 기인한 잔류 응력 발생이 동시다발적으로 얽혀서 일어나는 열화학-역학적 다중물리 거동이 지배적이다.^{2,5}

이러한 물리적 거동 때문에 성형 과정 중 온도 구배의 편차, 불균일한 수지 함침 유동 속도, 혹은 경화 수축 타이밍의 국부적 불일치가 발생하기 쉽다. 그 결과 기포, 수지 미충전 영역(드라이 스팟), 섬유 구겨짐, 층간 박리 등의 결함이 성형 중간 단계에서 빈번하게 발생한다.^{6,7}

기존 제조 품질 보증 프로세스는 제조가 완료된 복합재 부품을 대상으로 초음파 탐상, 방사선 투과 시험, X선 컴퓨터 단층촬영 등의 비파괴 검사를 수행하여 사후에 불량률 가려내는 방식으로 진행되어 왔다.^{6,8} 이 방식은 공정 완료 전에 품질 이상을 감지하여 수정 및 보완 기회가 없으므로, 불합격 판정 시 고비용 탄소섬유와 고성능 에폭시 수지 원재료가 투입된 고가 부품을 전량 폐기하게 되어 막대한 제조비용 손실을 초래할 수 있다.^{2,8} 이러한 사후 관리 방식의 한계를 극복하기 위하여 복합재 성형 공정 중에 온도, 열팽창률, 점도, 압력 등 내부 물리 상태를 실시간으로 직접 계측하는 in-situ 및 in-line 센싱 기술이 활발히 연구되어 왔다.^{5,6}

최근에는 센서 네트워크에서 수집된 시 계열 및 다채널 데이터를 인공지능 모델과 결합하는 제조 지능화 패러다임이 대두되고 있다.^{1,8} 센서-AI 융합 구조의 개념도는 그림 1에 도시하였다.

그림 1은 복합재 성형 공정 중 실시간 in-line 센싱과 인공지능 분석의 융합 구조를 모식도로 나타낸 것이다.

resin transfer molding(RTM, 수지 이송 성형) 금형 내부의 건식 섬유 프리폼(fiber preform) 내에 (1) fiber bragg grating(FBG) 센서가 매립되어 경화 수축에 의한 국부 변형률 및 잔류 응력을 연속적으로 측정하며, 금형 외부에는 (2) acoustic emission(AE) 센서가 부착되어 내부 기포 형성 및 층간 박리 시에 발생하는 과도한 탄성파를 포착한다.

또한, outlet 부근에는 lead zirconate titanate(PZT) 압전 센서가 삽입되어 수지 유동선단을 통과할 시에 발생하는 초음파 신호를 송수신한다. FBG 신호는 양단의 FBG interrogator를 거쳐, AE 및 PZT 신호는 별도의 채널을 통해 in-line sensing & data acquisition(DAQ) 모듈로 집약된다. 이로부터 획득된 다채널 시계열 데이터는 먼저 principal component analysis(PCA, 주성분 분석)을 통해 차원 축소를 수행한 뒤, convolutional neural network(CNN, 합성곱 신경망)의 공간적 특징 추출과 long short-term memory(LSTM, 장·단기 메모리) 네트워크의 시계열 의존성 학습을 순차적으로 거친다.

최종적으로는 복합재 부품 내부 결함 분포와 기계적 물성을 공정 진행 중 실시간으로 예측한다.^{1,2} 이를 기반으로 경화 사이클 가열 속도나 수지 주입 압력을 자동 제어하는 실시간 피드백 제어 루프를 구축함으로써 결함 발생을 사전에 회피하는 자율 제어형 스마트 성형 공정의 현장에서의 적용이 확대되고 있다.^{9,10}

본 지상강좌에서는 고분자 복합재 성형 중 품질 예측의 정확도를 좌우하는 핵심 in-situ 센싱 기술의 원리를 정리한다. 또한, 핵심 인공지능 알고리즘의 작동 방식을 주요 지배 방정식과 연계하여 깊이 있게 탐구하고, 공정별 실증 사례와 산업계 현장 보급을 가로막는 기술적 병목점 및 해결 전략에 대하여 상세히 논의한다.




그림 1. 복합재 성형 과정에서의 대표적인 실시간 센서 탑재 및 물리 상태 변수 계측 모식도.

표 1. 복합재 성형 공정 실시간 모니터링 센서 기술 비교 요약

센싱 기법	주요 계측 파라미터	핵심 장점	주요 한계점	주요 대상 공정
광섬유 센서(FBG)	국부 온도, 화학 수축률, 잔류응력	초소형 내장성, 전자파 무관, 높은 정밀성	기계적 단선 위험, 계측 장비 고가	오토클레이브, 필라멘트 와인딩
압전 센서(PZT)	수지 경화도, 점도, 음향 점탄성	비파괴 능동 계측, 수지 상변화 매핑 우수	센서 표면의 탈형 한계, 신호 감쇠	RTM, 핫프레스 성형
음향방출(AE)	내부 기포 형성음, 미세 박리 탄성파	고감도 패시브 감지, 광역 결함 모니터링	외부 기계 노이즈에 매우 취약	오토클레이브, 액상 성형 공정
유전분석(DEA)	이온 전도도, 경화 속도 및 점도	유리전이온도와 완벽한 상관성	전극 세정 필요, 부품 표면 계측 국한	RTM, SMC, 핫프레스 성형

2. 본론

2.1 성형 모니터링을 위한 주요 In-situ 센싱 기술

복합재 제조 과정에서 온도, 열팽창률, 수지 점도, 그리고 내부 변형을 측정하는 대표적인 센싱 기술들은 저마다 독자적인 계측 원리와 장단점을 지닌다. 주요 센서 기술의 특성은 표 1에 정리하였다.

2.1.1 광섬유 센서

광섬유 센서는 일반적으로 직경이 125 μm 이하로 극히 얇아 복합재의 층간 경계면에 삽입하더라도 응력 집중이나 물리적 성능 저하를 거의 유발하지 않는다.^{11,12} 광섬유 센서 중 가장 대표적인 FBG센서는 광섬유 코어 내부에 일정 주기의 격자를 형성하여 특정 파장의 빛만 선택적으로 반사하는 원리에 기반한다.

외부 열 또는 기계적 외력을 광섬유 인가 시 격자 주기와 코어의 유효 굴절률이 변하게 되며, 이에 따른 브래그 파장 이동량($\Delta\lambda_B$)은 다음 식 (1)과 같이 물리적으로 계산된다.¹²⁻¹⁵

$$\Delta\lambda_B = \lambda_B[(1-P_e)\epsilon + (a_A + a_n)\Delta T] \quad (1)$$

여기서 λ_B 는 초기 브래그 파장, P_e 는 탄성 광학 계수, ϵ 은 기계적 변형률, a_A 는 열팽창 계수, a_n 은 온도 의존 굴절률 변화율, ΔT 는 온도 변화량이다. 식 (1)에 나타난 것처럼 파장 이동은 기계적 하중과 열팽창의 중첩 효과로 결정된다.¹¹ 온도 변화량을 별도로 측정하여 소거하면 수지의 경화 수축에 의한 응력 축적 현상과 탈형 시 유발되는 부품의 변형 각도를 정량적으로 추정할 수 있다.¹⁵

또한, 단일 점 계측의 단점을 보완하고자 격자의 반사 파장을 서로 다르게 조절하여 하나의 광섬유 라인에 수십 개의 격자를 통합하는 wavelength division multiplexing(WDM, 파장 분할 다중화) 기술이 활용된다.^{11,12} 최근에는 레일리 산란광의 위상 변화를 나노초 단위로 추적하는 optical frequency domain reflectometry(OFDR, 광주파수 영역 반사계) 기반 분산형 광섬유 센싱 기술이 도입되어, 대형

복합재 구조물의 밀리미터 단위 국부 열변형 거동을 정밀 매핑이 가능하다.⁶

2.1.2 압전 센서 및 유도 초음파

PZT 센서는 압전 효과를 기반으로 기계적 변형을 전기 신호로 변환하는 대표적인 소자이다.^{3,5} 소자는 복합재 성형 시 금형 내부에 부착되거나 얇은 적층 필름 형태로 삽입되어 고주파 초음파 신호를 능동적으로 송수신한다.^{3,5}

복합재는 성형 중 온도가 상승함에 따라 매트릭스를 구성하는 수지는 액상(단량체 상태)에서 가교 결합을 거쳐 네트워크화 된 고상으로 변화한다.^{3,5} 고상으로 변화하면서 증가하는 탄성률은 전파되는 초음파 속도 변화와 신호 진폭 감쇠율 변화에 반영된다. 따라서, 음향 임피던스 해석을 거쳐 수지 경화율 및 젤화 도달 여부를 계측할 수 있다. 센서 설치에 의한 적층 두께 감소와 국부 강도 저하를 최소화 하기 위해, 약 28 μm 두께의 얇은 유연 PVDF 필름 형태의 스마트 스킨 센싱 구조가 적용되고 있다.^{16,17} 공정 도중 탄성 응력파가 액상 수지 경계면을 지날 때 발생하는 대칭(S_0) 및 비대칭(A_0) Lamb wave(램파) 모드의 감쇠 패턴 차이를 기계학습 모델이 분석하여 젤화 반응 시점을 더욱 정밀하게 가려내는 연구가 수행되고 있다.^{3,6}

2.1.3 음향방출 모니터링

AE 기법은 소재 내부의 급격한 변형, 균열 생성 또는 물리적 상변화 시 방출되는 고주파수 대역의 과도 탄성 응력파를 표면 부착형 센서로 포착하는 방법이다.^{6,8} 성형 공정 중 내부 기포의 생성과 이탈, 층간 수축에 따른 박리 전파 현상 시 방출되는 고유 음향 에너지를 신호 크기, 상승 시간, 진동 횟수 등의 매개변수로 분석한다.⁸ 또한, 해당 기술을 확장하여 신호가 센서에 도달하는 시간차 정보를 바탕으로 불량 발생 위치를 역추정할 수 있다.^{6,8} 실제 AE 기술 사용시 성형 기계나 가열 팬 작동 시 수반되는 다양한 외부 진동 소음을 필터링하기 위해, 지능형 밴드패스 필터링 및 support vector machine 기반 실시간 노이즈 분리-분류기가 센싱 전처리부에 통합되어 적용되고 있다.^{8,18}

2.1.4 유전분석

Dielectric analysis(DEA, 유전분석)은 가열 경화 중 수지의 전기 전도도 특성 변화를 추적하는 기법이다. 전극 센서 사이에 고주파 교류 전압을 인가하면 수지 내부 이온들의 왕복 운동이 발생하며, 이온 이동도와 완화 거동에 따라 전기장 응답 위상 지연 및 에너지 소산이 발생한다.^{19,20} 이러한 에너지 소산은 유전 손실률로 관측되며, 이를 통해 이온들의 물리적 유동성 및 이동 가능성을 평가할 수 있다.

2.2 AI 기반 성형 품질 예측 및 진단 알고리즘

다양한 센서로부터 유입되는 노이즈 및 신호를 의미 있는 물성 지표로 매핑하는 데 인공지능 알고리즘이 적용된다.^{21,22}

2.2.1 주성분 분석 차원 축소

고밀도 센서 데이터의 고차원 특성은 연산 복잡도 증가 및 과적합 문제를 낳는다.^{18,23} Principal component analysis(PCA, 주성분 분석)은 센서 신호의 공분산 행렬을 분해하여 데이터 설명 비중이 높은 주성분 벡터 축으로 데이터를 투영하는 방법이다.

이를 통해 신호에 포함된 복잡한 노이즈를 소거하고 모델 학습 속도를 향상시킨다.^{7,18} 특히 다수의 광섬유 센서 노드에서 얻어진 수만 차원의 변형률 프로파일을 상위 3-4개의 고유 주성분 점수로 압축함으로써,²³ 딥러닝 인공신경망 입력 부하를 최소화하고 공정 이상 판별을 위한 학습 수렴 속도를 크게 향상시킬 수 있다.⁷

2.2.2 합성곱 신경망 기반 품질 맵 예측

Convolution neural network(CNN, 합성곱 신경망)은 커널 연산을 통해 2차원 공간적 패턴(온도 분포 카메라 이미지, 비파괴 결함 스캔 맵 등)의 특징을 효과적으로 감지한다.^{7,23} 예시로, RTM 공정에서 수지가 투입되는 순간의 비선형 유동 이미지를 CNN이 입력으로 받아 피처를 추출하고, 성형 완료 후 나타날 내부 공극 및 미충전 영역(드라이 스팟)의 2차원 품질 맵의 실시간 예측이 가능하다.^{7,23}

이때 드라이 스팟과 공극은 독립적인 결함이 아닌, 프리폼 내부의 국부적 투과도 변화와 유동 전선 불안정성에서 함께 기인하는 함침 결함으로 이해된다. 예를 들어 섬유 체적분율의 국부적 증가, 섬유 쏠림 현상, 주름 등이 수지 유동 경로를 불균일하게 만들고, 그 결과 특정 영역에서는 수지가 도달하지 못한 드라이 스팟이 형성되며 다른 영역에서는 공기가 갇혀 미세 공극이나 기포 결함을 생성한다.

이러한 프리폼 구조 및 유동 전선의 시각 정보는 픽셀 정규화와 특징 추출 과정을 거쳐 신경망에 전달되며, CNN은 대칭성이 붕괴된 비정형 유동 불균일 패턴과 그로부터 유도되는 결함위치를 학습하게 된다. 이를 통해 학습

데이터가 극히 희소한 조건에서도, RTM 공정 중 발생하는 대칭성이 붕괴된 비정형 유동 불균일 패턴을 정확하게 식별할 수 있다.^{23,24}

2.2.3 LSTM 기반 시계열 경화 이력 예측

경화 과정의 온도와 중합 반응 진행도는 전형적인 시계열 데이터이므로, 시퀀스 기억 능력이 보존된 long short-term memory(LSTM, 장단기 기억망)가 효과적이다.²⁴

LSTM은 망각, 입력, 출력 게이트를 이용해 경화 과정에서 축적되는 시간 의존적 정보를 선택적으로 보존하거나 갱신함으로써 온도이력과 반응 진행도의 장기 의존성을 효과적으로 학습할 수 있다.²⁴

예를 들어, FBG 센서가 실시간 전송하는 격자 파장의 시간 변화 데이터를 입력 받아 향후 경화가 완료될 시점을 예측하고 최적 타이밍의 감압 및 냉각 공정 개시를 결정할 수 있다.^{24,25}

특히, LSTM은 입력 게이트, 망각 게이트, 출력 게이트를 통해 셀 상태와 은닉 상태를 선택적으로 갱신함으로써, 장시간에 걸친 공정 이력의 의존성을 보존할 수 있다. 이 구조는 가열 사이클 동안 누적되는 온도 이력, 경화 수축, 열팽창 불일치 및 잔류 기계적 응력형성과 같은 시간 의존적 거동을 시계열 특성으로 인코딩할 수 있으며, 학습된 가중치는 이러한 공정 이력과 최종 품질 지표 사이의 비선형 관계를 근사하는데 사용된다.²⁴

2.3 성형 공정별 AI 품질 예측 적용 실증 사례

2.3.1 수지이송성형 공정(RTM)

RTM 공정에서는 건식 섬유 프리폼 적층 캐비티 내부로 가압 상태에서 수지를 유입시킨다. 프리폼 내의 섬유 밀도 변동이나 금형 두께 편차에 따라 프리폼의 투과도가 실시간으로 변하며, 액상 수지 유동 속도는 다공성 매질 해석식인 Darcy의 법칙을 따른다.^{2,26} 또한, 수지 주입 공정 및 열경화 과정에서 온도와 화학 반응도의 진행에 따른 에폭시 수지의 동점도 변화를 묘사하기 위해 Arrhenius 온도 의존성과 Castro-Macosko 전환율 의존성을 결합한 chemoviscosity model이 널리 사용된다(식 (2)).^{2,5,27,28}

$$\mu(T, \alpha) = \mu_0 \exp\left(\frac{E_\mu}{RT}\right) \left(\frac{\alpha_g}{\alpha_g - \alpha}\right)^{A+B\alpha}, \quad \alpha < \alpha_{gel} \quad (2)$$

여기서 μ_0 는 기본 점도 상수, E_μ 는 점성 유동 활성화 에너지, T 는 절대 온도, α 는 현재 수지의 경화도, α_g 는 수지가 젤화되는 임계 경화도, 그리고 A, B 는 고분자 재료 고유의 피팅 매개변수이다. RTM 공정에서 다채널 압력 센서를 통해 실시간 압력 구배를 수집하고, 인공신경망이 식 (2)를

기반으로 수지의 점도 상태 변화와 유동 선단을 역산하여 실시간 가시화한다. 이를 통해 미충전 드라이 스팟 생성 가능성을 높은 정확도로 사전에 경고할 수 있다.^{26,29}

그림 2는 다채널 압력 및 유동 in-line 모니터링 센서 정보를 딥러닝 모델과 결합한 실시간 RTM 성형 품질 제어 프레임워크를 나타낸 것이다. 좌측 상단의 공정 입력 변수 P_{inj} , T_{mold} , V_f (주입 압력, 금형 온도, 섬유 체적분율)와 재료 상수 k , C_p , H_f (투과도, 비열, 반응열) 등이 RTM 시뮬레이션 모델에 입력되어, 시간에 따른 수지 유동선단(flow front) 위치, 경화도 이력, 온도 분포 및 최종 경화 형상을 계산한다. 이렇게 생성된 대규모 시뮬레이션 결과는 좌측 데이터 베이스 모듈과 양방향으로 연동된다. 수집된 데이터셋은 artificial neural network(ANN, 인공신경망), CNN, LSTM 으로 구성된 AI 모델의 학습에 사용되며, 정해지지 않은 공정 조건에 대해서도 공극 분포, 결합 위치, 기계적 물성을 실시간으로 추정할 수 있도록 한다.

이때 수지는 섬유 사이를 흐르며 전단 속도 변화에 반응하는 비뉴턴 유동 특성을 나타낸다. AI 모델은 Castro-Macosko 모델의 피팅 상수들을 실제 주입 압력 동적 궤적 데이터로부터 인라인 역추정하여 점도 예측 편차를 2.5% 이내로 유지한 것이 보고되었다.^{5,24}

2.3.2 오토클레이브 공정

오토클레이브 공정에서는 두꺼운 적층판 복합재 부품을

진공백으로 밀봉한 뒤, 가압/가열된 기체 분위기에서 강제 대류 열전달을 통해 가열 및 가압한다. 이때 부품 표면은 오토클레이브 내부의 순환 기체와 금형으로부터 열을 전달받지만, 두께가 큰 적층판에서는 낮은 두께 방향 열전도도와 에폭시 경화 반응의 발열로 인해 부품 내부에 상당한 온도 구배가 발생할 수 있다. 두께 방향과도 열전달 및 열화학 지배방정식은 다음 식 (3)으로 표기된다.^{9,28,30}

$$\rho C_p \frac{\partial T}{\partial t} = \frac{\partial}{\partial z} \left(k_z \frac{\partial T}{\partial z} \right) + V_r \rho_{resin} H_r \frac{da}{dt} \quad (3)$$

여기서 ρ 는 복합재의 유효 밀도, C_p 는 유효 비열, k_z 는 두께 방향 유효 열전도도, V_f 는 수지 체적분율, ρ_{resin} 은 수지 밀도, H_r 는 수지 단위 질량당 총 반응열, a 는 경화 전환율이다.

또한 경화 전환율의 시간 변화율 da/dt 는 대표적으로 다음 식 (4)와 같이 Kamal-Sourour 자가촉매 경화 반응속도 모델로 표현된다.^{2,30-32}

$$\frac{da}{dt} = (K_1 + K_2 a^m)(1-a)^n \quad (4)$$

여기서 a 는 경화 전환율, m 과 n 은 경험적 반응 차수 지수이며, K_1 과 K_2 는 각각 비자가촉매 반응항과 자가촉매 반응 항의 온도 의존 속도상수이다. 일반적으로 두 속도상수는 다음 식 (5)와 같이 Arrhenius 형태로 표현된다.³⁰⁻³²

$$K_i(T) = A_i \exp \left(-\frac{E_i}{RT} \right), \quad i = 1, 2 \quad (5)$$

여기서 A_i 는 빈도인자, E_i 는 활성화 에너지, R 은 기체 상수, T 는 절대온도이다. 성형된 복합재에 내장된 FBG 센서는 경화 중 발생하는 온도 변화와 국부 변형률 이력을 실시간으로 측정할 수 있다. 이때 측정된 FBG 신호는 열전달 방정식과 경화 반응속도식을 결합한 열화학 모델의 입력 또는 물리 기반 제약조건으로 활용될 수 있으며, 딥러닝 모델은 이를 바탕으로 경화 전환율, 내부 온도 분포, 잔류 변형의 시간 변화를 추정한다.^{2,4,15}

따라서 이러한 물리 기반 데이터 융합 모델은 최종 경화 단계에서 발생할 수 있는 공정 유도 변형을 선제적으로 예측하고, 오토클레이브 온도 사이클을 동적으로 보정하는 데 활용될 수 있다. 특히 에폭시의 발열 급증 구간에 대처하기 위하여, 딥러닝 모델이 5분 후 중심부 도달 최고 열 폭주 온도를 초기에 예측하고, 오토클레이브 가열 파워를 자동 조절하여 국부 균열과 탄화를 방지하는 융합 피드백 모델은 현업 실증 단계에 진입하였다.^{10,30}




그림 2. 다채널 압력 및 유동 인라인 모니터링 센서 정보를 통한 딥러닝 기반 실시간 RTM 성형 품질 제어 프레임워크.

2.4 기술적 병목점 및 AI 기반 해결 전략

2.4.1 가상 물리 데이터 연계 및 PINN 기법

대형 탄소섬유 복합재 부품은 원자재 비용이 매우 높고 생산 주기가 길어, 실제 성형 실험 데이터만을 획득하는 것은 비용 한계가 명확하다. 이에 대한 대안으로서 finite element analysis(FEA, 유한 요소해석) 시뮬레이션을 통해 가상 성형 조건 데이터를 대량 생성하는 가상 시험 기술과, 물리 법칙 지배방정식을 인공지능망의 비용 손실 함수에 직접 내장하는 physics informed neural network(PINN, 물리 기반 인공지능망) 기술이 활용되고 있다.^{9,30} PINN의 전체 알고리즘 프레임워크는 그림 3과 같이 표현할 수 있다.

그림 3은 지배방정식의 물리 법칙을 인공지능망 학습 규칙에 내재화하여 데이터 희소성을 극복하는 PINN 기반 예측 플랫폼을 모식화 한 것이다. 그라데이션 컬러맵은 복합재 단면의 경화도(a) 또는 온도(T) 분포를 나타내며, 좌측 청색 영역은 미경화 상태, 중앙 적색 영역은 over-cured 상태, 우측 영역은 최적 상태를 의미한다.

인공지능망의 입력층에는 공정 매개변수, 경계 조건, 센서 데이터가 주입되며, 다층 은닉층을 거쳐 상태 변수(p, T, a)가 출력된다.

특히, PINN의 경우 물리 법칙을 어긋나지 않도록 가중치를 정규화함으로써, 적은 양의 센서 정보만으로도 높은 신뢰도로 전 부품 영역의 온도 필드 및 경화 상태 추정치를 안정적으로 도출할 수 있다.^{9,10} 이때 초기 학습 안정성과 최적화 정밀도를 확보하기 위해, 학습 단계에 따라 지배방정식 관련 손실의 규제 강도 가중치를 선형적으로 증가시키는 적응형 동적 손실 가중치 스케줄링 전략이 필수적으로 적용된다.^{9,10}




그림 3. 지배방정식 물리법칙을 학습 규칙에 강제화하여 데이터 희소성을 극복하는 PINN 기반 예측 아키텍처.

2.4.2 설명 가능한 인공지능 도입

가공 현장의 엔지니어가 딥러닝 예측 결과를 신뢰하고 공정 매개변수를 능동적으로 제어하도록 만들기 위해, 최근에는 인공지능망 예측 결과를 시각화하는 explainable artificial intelligence(XAI, 설명 가능한 인공지능) 기법이 활발히 연구되고 있다.^{2,8} 각 센서의 온도, 압력 데이터 기여도를 시각적으로 제시하여, 모델이 특정 결함을 예측한 물리적 근거를 설명함으로써 모델의 블랙박스 신뢰성을 제고한다.³³⁻³⁵

대표적인 XAI 기법인 shapley additive explanations(SHAP, 샤프리 부가 설명)는 결함 예측값을 기준 예측값과 각 입력 변수의 기여도 합으로 분해하여, 개별 센서 신호가 최종 예측에 미친 영향을 정량화한다. 예를 들어 특정 시점에서 공극 또는 미충전 결함의 발생 확률이 높게 예측된 경우, SHAP 분석은 금형 온도, 수지 주입 압력, FBG 변형률, 유전 손실 신호와 같은 입력 채널 중 어떤 변수가 예측값을 증가시키거나 감소시켰는지를 센서별 기여도 맵으로 제시할 수 있다.^{2,36}

따라서 엔지니어는 딥러닝 모델의 예측 결과를 단순한 블랙박스 출력으로 받아들이는 것이 아니라, 온도 상승 지연, 국부 압력 저하, 비정상 변형률 축적 등 실제 결함 형성 메커니즘과 연결하여 해석할 수 있다. 또한 SHAP 기반 기여도 분석은 센서 네트워크의 효율화에도 활용될 수 있다. 장시간 반복 공정에서 특정 센서 채널의 SHAP 값이 지속적으로 낮게 나타난다면, 해당 채널은 결함 예측에 대한 정보 기여도가 제한적인 것으로 판단할 수 있다.

반대로 특정 온도 또는 압력 센서의 기여도가 특정 공정 구간에서 급격히 증가한다면, 해당 위치가 결함 발생의 민감 영역 또는 공정 이상 징후와 관련되어 있음을 의미할 수 있다. 이와 같이 SHAP 분석은 센서별 중요도 평가, 기여도가 낮은 채널을 선택적 제외하거나 기여도가 높은 채널을 중심으로 옛지 추론 구조 설계에 활용될 수 있다. SHAP 분석은 결과적으로 실시간 복합재 제조 공정에서 예측 모델의 해석 가능성과 계산 효율성을 동시에 향상시킬 수 있다.^{5,25}

2.4.3 도메인 적응을 위한 전이 학습

RTM 공정에서는 성형 몰드 형상, 적층 두께, 프리폼 구조, 수지 점도, 주입 압력 조건이 달라지면 유동 전선과 결함 위치가 변한다. 그러나 수지 유동이 Darcy 법칙에 의해 지배되고, 결함이 국부 투과도 불균일성, 점도 변화, 압력 구배, 유동 전선 지연에 의해 형성된다는 기본 물리법칙은 유지된다. 전이 학습은 이러한 공통 물리 특성은 기존 모델에서 재사용하고, 목표 도메인에서 달라지는 변수만 소량의 데이터로 보정하는 방법이다.^{37,38} 전이 학습에서 고정할 항목과 미세 조정할 항목은 도메인 변화의 원인에 따라

결정된다. 센서 종류, 결합 판정 기준, 유동 전선의 기본 형상, 온도/압력 신호의 상대적 변화 패턴처럼 도메인 간 공통적인 정보는 초기 특징 추출 레이어에 보존된다. 반면 금형 두께, 적층 수, 주입구와 배출구 위치, 프리폼 투과도, 수지 점도 모델 상수, 경화 온도 사이클처럼 목표 공정에서 달라지는 변수는 상위 레이어 또는 출력부에서 미세조정된다.

예를 들어 16층 레이어 적층 모델을 32층 레이어 적층 공정에 적용할 경우, 수지 유동의 기본 영상 특징과 센서 신호 패턴은 일부 공유될 수 있다. 그러나 두께 증가에 따른 투과도 변화, 충전 시간 증가, 압력 구배 변화, 경화 중 온도 지연은 새롭게 보정되어야 한다.^{37,38} 따라서 초기 특징 추출부는 고정하고, 두께 의존 유동 지연과 결합 위치를 결정하는 후단부 레이어를 소량의 목표 도메인 데이터로 미세 조정한다. 검증 오차가 충분히 낮아지지 않으면 중간 레이어를 순차적으로 해제하여 재학습한다.

3. 결론

고분자 복합재료의 성형 공정 중 센싱 기술과 인공지능의 결합은 사후 판정 방식의 한계를 극복하고 실시간 인라인 품질 예측 및 생산 자율성을 실현하는 지능형 제조 공장의 핵심 기술이다. FBG 및 압전 소자 등의 센서 네트워크를 차원축소와 합성곱(CNN), 시계열 학습 모델에 결합함으로써 수지 유동 상태와 열변형을 정확하게 모니터링할 수 있는 가능성을 입증하였다. 향후 물리 법칙을 임베딩하는 PINN 기법과 XAI 기술과의 융합이 보편화된다면, 차세대 산업 구조용 고품질 복합재 부품 제조의 경쟁력을 대폭 향상시키는 계기가 될 것이다.

참고문헌

1. A. A. Zaidi, M. Asif, A. Aljabri, and S. Z. Khan, *Front. Mech. Eng.*, **12**, 1774757 (2026).
2. K. D. Humfeld, D. Gu, G. A. Butler, K. Nelson, and N. Zobeiry, *Compos. Part B: Eng.*, **223**, 109150 (2021).
3. N. Ghadarah and D. Ayre, *Sensors*, **23**, 6945 (2023).
4. R. He, S. Liu, J. Guo, X. Fu, X. Hao, and Y. Li, *Appl. Compos. Mater.*, **33**, 27 (2026).
5. K. I. Tifkisis and A. A. Skordos, *Polym. Compos.*, **41**, 5387 (2020).
6. B. Wang, S. Zhong, T.-L. Lee, K. S. Fancey, and J. Mi, *Adv. Mech. Eng.*, **12**, 1687814020913761 (2020).
7. J. Zhu, D. Droste, A. Dimassi, and A. S. Herrmann, *J. Compos. Mater.*, **56**, 2979 (2022).
8. B. X. Chai, M. Gunaratne, M. Ravandi, J. Wang, T. Dharmawickrema, A. Di Pietro, J. Jin, and D. Georgakopoulos, *Sensors*, **24**, 4852 (2024).
9. S. A. Niaki, E. Haghighat, T. Campbell, A. Poursartip, and R. Vaziri, *Comput. Methods Appl. Mech. Eng.*, **384**, 113959 (2021).
10. M. Ramezankhani, A. Nazemi, A. Narayan, H. Voggenreiter, M. Harandi, R. Seethaler, and A. S. Milani, in *2022 IEEE 5th International Conference on Industrial Cyber-Physical Systems (ICPS)*, 1–7 (2022).
11. L. Fazzi, G. Struzziero, C. Dransfeld, and R. M. Groves, *Adv. Manuf. : Polym. Compos. Sci.*, **8**, 33 (2022).
12. K. Wachtarczyk, M. Bender, E. Fauster, R. Schledjewski, P. Gasior, and J. Kaleta, *Materials*, **15**, 6497 (2022).
13. C. G. Askins, K. P. Koo, M. A. Davis, E. J. Friebele, A. D. Kersey, M. A. Putnam, M. LeBlanc, and H. J. Patrick, *J. Lightwave Technol.*, **15**, 1442 (1997).
14. K. O. Hill and G. Meltz, *J. Lightwave Technol.*, **15**, 1263 (1997).
15. E. Oromiehie, B. G. Prusty, P. Compston, and G. Rajan, *Adv. Manuf. : Polym. Compos. Sci.*, **3**, 52 (2017).
16. S. Masmoudi, A. El Mahi, and S. Turki, *Compos. Part B: Eng.*, **80**, 307 (2015).
17. C. Caneva, I. M. De Rosa, and F. Sarasini, *Strain*, **44**, 308 (2008).
18. F. Guo, W. Li, P. Jiang, F. Chen, and Y. Liu, *Materials*, **15**, 4270 (2022).
19. Y. Yang, B. Plovie, G. Chiesura, T. Vervust, L. Daelemans, D.-E. Mogosanu, P. Wuytens, K. De Clerck, and J. Vanfleteren, *IEEE Trans. Instrum. Meas.*, **70**, 6004809 (2021).
20. S. Yan, H. Zeizinger, C. Merten, and S. Schmauder, *Polym. Eng. Sci.*, **61**, 1673 (2021).
21. Y. Liang, X. Wei, Y. Peng, X. Wang, and X. Niu, *Polym. Compos.*, **46**, 1939 (2025).
22. R. F. Ribeiro Junior and G. F. Gomes, *Appl. Compos. Mater.*, **31**, 1 (2024).
23. Y. Shokrollahi, M. M. Nikahd, K. Gholami, and G. Azamirad, *J. Compos. Sci.*, **7**, 311 (2023).
24. S. Bolar, S. Corns, N. Pundhir, and K. Chandrashekhara, *Int. J. Adv. Manuf. Technol.*, **142**, 4779 (2026).
25. Y.-M. Huang, W.-R. Jong, and S.-C. Chen, *Polymers*, **13**, 3874 (2021).
26. M. Szarski and S. Chauhan, *J. Intell. Manuf.*, **34**, 197 (2023).
27. J. M. Castro and C. W. Macosko, *AIChE J.*, **28**, 250 (1982).
28. A. C. Loos and G. S. Springer, *J. Compos. Mater.*, **17**, 135 (1983).
29. R. Zhang, Y. Liu, T. Zheng, S. Eddin, S. Nolet, Y.-L. Liang, S. Rezazadeh, J. Wilson, H. Lu, and D. Qian, *J. Intell. Manuf.*, **35**, 1737 (2024).
30. A. Deodhar, M. Ramezankhani, R. Parekh, and D. Birru, in *ASME International Mechanical Engineering Congress and Exposition*, Vol. 88674, V009T11A009 (2024).
31. M. R. Kamal and S. Sourour, *Polym. Eng. Sci.*, **13**, 59 (1973).
32. S. Sourour and M. R. Kamal, *Thermochim. Acta*, **14**, 41 (1976).

33. X. Qing, Y. Liao, Y. Wang, B. Chen, F. Zhang, and Y. Wang, *Int. J. Smart Nano Mater.*, **13**, 167 (2022).
34. S. Bandara, M. Herath, and J. Epaarachchi, *J. Reinf. Plast. Compos.*, **42**, 1119 (2023).
35. X. Liu, F. Tao, and W. Yu, *Compos. Struct.*, **252**, 112658 (2020).
36. Z. Sadeghi, R. Alizadehsani, M. A. Cifci, S. Kausar, R. Rehman, P. Mahanta, P. K. Bora, A. Almasri, R. S. Alkhawaldeh, S. Hussain, B. Alatas, A. Shoeibi, H. Moosaei, M. Hladik, S. Nahavandi, and P. M. Pardalos, *Comput. Electr. Eng.*, **118**, 109370 (2024).
37. Z. Zhang, Q. Liu, and D. Wu, *Mater. Des.*, **218**, 110700 (2022).
38. L. B. Tan and N. D. P. Nhat, *Polymers*, **14**, 2838 (2022).