

# 인공지능을 기반으로 한 대면적 CNT 기반 촉각 센서의 실시간 위치 탐색 연구

조민영<sup>1,†</sup> · 김성훈<sup>2</sup> · 김지식<sup>3,\*</sup>

<sup>1</sup>세종대학교 나노신소재공학과

<sup>2</sup>경북대학교 소프트웨어학과

<sup>3</sup>경북대학교 나노소재공학부

## Real-Time Position Detecting of Large-Area CNT-based Tactile Sensors based on Artificial Intelligence

Min-Young Cho<sup>1,†</sup>, Seong Hoon Kim<sup>2</sup>, and Ji Sik Kim<sup>3,\*</sup>

<sup>1</sup>Dept. of Nano & Adv. Mat's Eng., Sejong Univ., Seoul 37224, Republic of Korea

<sup>2</sup>Department of Software, Kyungpook Nat. Univ., Sangju 37224, Republic of Korea

<sup>3</sup>School of Nano & Adv. Mat's Eng., Kyungpook Nat. Univ., Sangju 37224, Republic of Korea

**Abstract:** For medical device and artificial skin applications, etc., large-area tactile sensors have attracted strong interest as a key technology. However, only complex and expensive manufacturing methods such as fine pattern alignment technology have been considered. To replace the existing smart sensor, which has to go through a complicated process, a new approach including a simple piezoresistive patch based on artificial intelligence has been suggested. Specifically, a 16-electrode terminal was connected to the edge of a polydimethylsiloxane pad where multi-walled carbon nanotube sheets are well dispersed, and a voltage input to the center of the specimen. The collected data was calculated using a voltage divider circuit to collect the voltage data. 54 random positions were marked on the pad. 4 positions were configured as the validation data set and 50 positions as the training data set. We examined whether it was possible to determine points in untrained positions using a deep neural network (DNN) and 12 different machine learning (ML) algorithms. The result of a deep neural network for untrained point location identification was MSE: 0.00026, R2: 0.991158, and the result of Random Forest, an ensemble model among ML algorithms, was MSE: 0.00845, R2: 0.971239. Real-time position detection is possible using smart sensors created by combining simple bulk materials and artificial intelligence models from research results.

(Received 27 June, 2022; Accepted 18 July, 2022)

**Keywords:** carbon nanotube, piezoresistive materials, tactile sensing, artificial intelligence, machine learning

### 1. 서 론

최근 몇 년 동안 수 많은 스마트 촉각 센서는 온도 측정, 수분, 비틀림 및 화학 물질 감지 등 다양한 기능을 가지고 발전했다 [1-25]. 이러한 유형의 센서는 압저항, 압전, 마찰 전기, 용량, 광학, 자기 등 다양한 원리를 기반으로 의학 장치, 인공 피부, 로봇의 터치 센서와 같은 여러 어

플리케이션에서 적용되었다 [26-45]. 기존의 대면적 터치 센서 기술은 가압 위치를 특정한 점으로 지정해주거나, 추가적인 논리 회로 기반으로 위치를 실시간으로 탐지할 수 있는 대면적 촉각 센서를 구성하였다 [46-53]. 또한 소재를 제작할 때 미세한 패턴 정렬 기술과 같은 고비용의 제조 공정 방식을 추구해왔는데, 본 연구에서는 기존의 센서를 만드는 방식에서 벗어나 단순 벌크 소재를 기계 학습 기반의 훈련을 통해 스마트 센서로 만드는 개념을 가지고 연구를 진행하였다. 최근 소재 분야에서 인공지능을 활용하여 금속, 압광체, 형광체, 전고체, X선 회절 등 전방위적으로 많은 연구가 진행되어 왔고 성공적인 결과를 보여주었다 [54-73]. 이를 통해 단순 벌크 소재를 스마트 촉각 센서로

<sup>†</sup>경북대학교 나노소재공학과 겸임

- 조민영: 연구원, 김성훈, 김지식: 교수

\*Corresponding Author: Ji Sik Kim

[Tel: +82-54-530-1418, E-mail: jjsikkim@knu.ac.kr]

Copyright © The Korean Institute of Metals and Materials




Fig. 1. Sample form and total schematic diagram

변환하는 핵심 기술이 바로 인공지능 기술을 소재와 통합하는 것임을 알 수 있다. 대표적인 절연체로 잘 알려져 있는 폴리 디메틸 실록산 (Polydimethylsiloxane, PDMS)에 전기전도도가 높은 탄소 나노튜브 (Carbon Nanotube, CNT)를 사용하였고 다양한 탄소 나노튜브 종류 중에서 경제적으로 저렴한 다중벽 탄소 나노튜브 (Multi-Walled Carbon Nanotube, MWCNT)를 이용하여 압저항 역할을 하는 단순 벌크 소재를 만들었다. 소재 가장자리에 전극 단자를 연결하여 수집되는 전압 데이터와 가압 위치를 기록하였고, 이를 훈련 및 검증 데이터 세트로 이용하였다. 전극으로부터 수집된 데이터를 활용하여 훈련과 검증 과정을 거쳐 위치를 예측할 수 있었다. 이번 연구에서는 앞서 언급된 복잡한 고비용의 제조 공정이 필요하지 않았고, 지극히 단순한 다중벽 탄소 나노튜브 + 폴리 디메틸 실록산 혼합체가 미세 공정으로 만들어진 최첨단 센서를 대체할 수 있음을 보여주었다. 이전 연구에서는 Fab과 같은 미세 제조 공정이 없이 단일층 압저항 패드를 만들어 인공 피부 및 휴대용 키패드 기술에 대해서 보고 한 적이 있다 [74-76]. 더욱이 최첨단 촉각 감지 정확도와 공간 분해능을 달성했으며, 휴대용이며 주머니 안에 넣을 수 있을 정도로 매우 유연한 스마트 키패드를 만들었다. 그럼에도, 추가적인 촉각 감지 방식이 필요하다. 기존의 연구에서는 홀드 아웃 테스트를 통해 데이터 세트의 일부분을 훈련 데이터와 검증 데이터로 나누어 진행하였고 성공적인 결과를 보여주었다. 이번 연구에서는 정해진 규격 (73 mm × 73 mm)의 대면적 패드 위에 무작위 위치를 표시하고, 선택된 위치를 검증 데이터로 사용하였다. 이를 통해 수집된 데이터를 이용하여 미지의 위치를 실시간으로 판단할 수 있는지를 알아보았다. 훈련과 검증을 위해 사용된 모델로는 기본

심층 신경망 (DNN)과 3가지로 분류된 12개의 기계 학습 알고리즘을 이용하여 계산을 진행되었다. 선형 회귀 알고리즘인 Basic Linear, Ridge, Lasso, Least-angle (LARS), Elastic Net, Bayesian ridge (BRR), Partial Least Square (PLS) 모델, 의사 결정 기반 앙상블 모델인 Random Forest (RF), Ada Boost, Gradient Boost, XG Boost 모델, 마지막으로 비선형 기계 학습 알고리즘인 K-Nearest Neighbor (KNN)을 사용하였다.

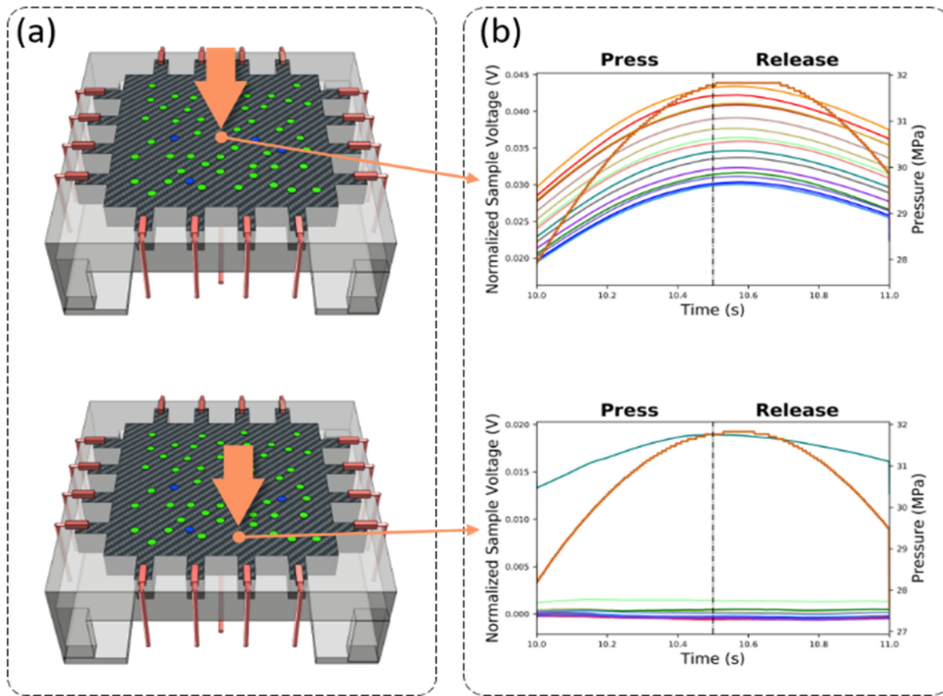
## 2. 실험 방법

### 2.1 MWCNT + PDMS 압저항 패드 제작

균일하게 분산된 압저항 패드를 제작하기 위해 길이 5  $\mu\text{m}$ , 직경 20 nm의 다중벽 탄소 나노튜브 (Carbon Nano-material Technology Co. Ltd)와 실리콘 재료인 폴리 디메틸 실록산 (PDMS) (Sylgard 184 Silicone Elastomer)를 가지고 제작하였다. 시편을 만들기 위해 1 wt% 다중벽 탄소 나노튜브와 99 wt% 폴리 디메틸 실록산 주제를 혼합하였다. 다중벽 탄소 나노튜브의 분산을 위해 직경 10 mm의 알루미늄 불을 함께 넣고 플라네타리 믹서에서 회전속도 400 rpm, 유지 시간 30분 동안 잘 혼합해준다. 혼합된 재료에 폴리 디메틸 실록산 경화제를 1:10 중량비로 첨가한 뒤 다시 10분동안 믹서를 이용하여 혼합한다. 마지막으로 혼합물 내부의 기포를 제거하기 위해 30분 동안 탈포 작업을 진행한다. 다중벽 탄소 나노튜브 + 폴리 디메틸 실록산층의 손상을 줄이기 위해 바닥 폴리 디메틸 실록산을 3 mm 도포한 아크릴 몰드에 혼합물을 4 mm 도포한 뒤 60  $^{\circ}\text{C}$ , 45분동안 경화시켜준다. 마지막으로 절연을 위해 폴리 디메틸 실록산을 코팅해준다. 이 모든 과정은 닥터 블레이드 방법으로 진행했다. 이렇게 만들어진 다중벽 탄소 나노튜브 + 폴리 디메틸 실록산 압저항 패드 가장자리에 일정한 간격으로 구리선을 이용하여 16개의 전극 단자를 구성하였고, 중앙에는 탄소섬유를 고정시켜 중앙 전극을 연결하였다.

### 2.2 압저항 패드 훈련

기계식 피로 시험기 (Instron E3000)를 이용하여 훈련을 진행하였다. 그림 2(a)와 같이 대면적의 압저항 패드 내부 (73 mm × 73 mm)에 무작위로 훈련을 위한 위치 50개와 검증을 위한 위치 4개, 총 54개의 위치를 가압하였다. 기계식 피로 시험기 끝에 직경이 2 mm인 나무 막대를 장착하여 시편에 표시된 위치를 일정하게 누를 수 있도록 하였다. 위치를 변경하기 위해 x축과 y축을 자유롭게 이동할



**Fig. 2.** (a) 54 random positions (●: Training Positions, ●: Test Positions), (b) Time(s) vs Normalized sample voltage(V) / Pressure(MPa) graph (—)

**Table 1.** Deep Neural Network, 12 Machine Learning Training and Test Results (MSE, R<sup>2</sup>)

Result	DNN	Basic Linear	Ridge	Lasso	LARS	Elastic Net	BRR	PLS	Random Forest	Ada Boost	Gradient Boost	XG Boost	KNN
Training MSE	.00001	.024255	.035982	.034121	.031324	.034121	.024264	.031133	.00001	.005755	.001608	.001492	0
Training R <sup>2</sup>	.999752	.638982	.464312	.492079	.533935	.492079	.638982	.536784	.999853	.914377	.976078	.977801	1
Test MSE	.00026	.026778	.013242	.012405	.014034	.012405	.026765	.017567	.00845	.005686	.001714	.001899	.002106
Test R <sup>2</sup>	.991158	.088716	.549354	.577836	.522418	.577836	.089173	.402182	.971239	.806509	.941686	.935395	.928325

수 있는 xy스테이지를 이용하였고, 가장자리에 위치한 16개의 전극 단자를 통해 전압 데이터를 수집하였다.

### 2.3 데이터 준비

16개의 전극에서 수집된 데이터는 가압과 감압이 반복적으로 움직이는 동안 데이터가 수집되었다. 이 때의 나무막대의 움직임은 깊이 4 mm, 가압과 감압이 반복적으로 이뤄지는 주기는 1초, 이 주기가 연속적으로 18회 진행되었다. 시편에서 수집된 데이터는 16개의 전극 단자 각각에 100 KΩ의 고정 저항과 전체 7V의 입력 전압을 전압 분리 (Voltage Divider) 회로를 통해 계산되어 수집되었다. 전압 신호의 샘플링 속도는 1000 데이터/초이다. 1초당 1000개의 데이터를 수집함으로써, 실시간으로 가압/감압 시 발생하는 데이터를 수집하였다. 기존 인공지능을 활용한 압저

항 패드 연구에서는 홀드 아웃 테스트 방법을 통해 16개의 전압 시계열 데이터에서 1차원 데이터(16x1)를 추출하여 이용하거나, 이를 그룹화한 다차원의 입력 데이터 (16x50)를 재배열하여 사용하였다. 하지만 이번 연구에서는 완벽하게 독립적인 위치를 훈련과 검증에 이용하였다. 수집한 총 54개의 위치 데이터를 가지고 무작위로 선정된 4개의 점은 검증에 이용되었고, 그 외에 다른 50개 위치는 훈련에 이용되었다.

## 3. 결과 및 고찰

### 3.1 압저항 패드 신호

일반적인 촉각 센서에서 신호의 선형적인 거동은 센서 성능에 아주 중요한 문제다. 이전 연구에서 압저항 패드의

점탄성 (비선형) 거동이 문제가 되어 알고리즘 개선을 통해 문제를 해결하고자 하였다. 본 연구에서는 알고리즘을 이용한 해결 방법이 아닌 소재 주변에서 신호에 영향을 미치는 것을 개선하여 점탄성 거동 문제를 해결하고자 하였다. 시편을 지지하고 있는 아크릴 몰드의 중앙에 위치한 입력 전압 부분 형상을 개선하였고, 입력 전압을 연결하는 탄소섬유의 위치를 조정함으로써, 이전보다 신호가 30% 내외로 선형성이 증가된 상태로 작동될 수 있도록 하였다. 그 결과 그림 2(b)의 실제 실험 데이터를 보아 소재에서 수집된 데이터는 비교적 선형적인 모습을 보여주었다. 그럼에도 불구하고 압력의 움직임을 통한 점탄성 거동의 잔존현상 여전히 확인할 수 있었다. 사실 이러한 점탄성 거동의 개선을 위해서 소재적 측면 이외에 RNN을 이용한 분석적 측면의 보완도 요구된다. 다만, 소재적 측면에서의 선형성 개선이 30% 이 이루어진 상황에서, RNN의 적용이 신경망 모델의 학습 오차 및 실시간 해상도 감소에 끼칠 악영향을 고려하여 본 연구 내용에는 포함하지 않았다. 이러한 논의와는 별도로 소재 자체의 추가적 개선을 통한 완전한 선형성 확보야 말로 근본적인 해결책이 될 것이다.

### 3.2 신경망 모델

앞서 언급했듯이 무작위 54개의 위치 중 50개의 훈련 데이터 세트와 4개의 검증 데이터 세트로 나누어 탄소 섬유 회귀 모델을 이용하였다. 그리고 추가적으로 K fold 교차 검증을 3중으로 시행하였다. 이러한 훈련 및 검증 데이터 세트와 K fold 교차 검증은 탄소 섬유와 다른 기계 학습 모델에도 사용되었다. 우선 가장 단순한 심층 신경망 모델 (Deep Neural Network, DNN)을 이용하여 학습을 진행하였다. 훈련 및 검증 결과를 그림 3의 그래프와 표 1에 수치적으로 나타냈다. 훈련 결과 MSE 0.00001,  $R^2$  0.999752 그리고 검증 결과 MSE 0.00026,  $R^2$  0.991158로 훈련된 위치와 상관없는 빈 공간 내에서 원하는 위치를 잘 찾는 모습을 보여줬다.




Fig. 3. DNN test result graph (a) X positions, (b) Y positions

### 3.3 기계 학습 모델

회귀 모델은 선형 회귀 모델, 의사 결정 기반 앙상블 모델, 비선형 기계 학습 알고리즘 총 3가지로 분류시켜 계산을 진행하였다. 선형 회귀 알고리즘은 훈련 데이터가 부족할 경우에서 잘 작동된다. 훈련 데이터가 부족할 경우 고분산 문제가 발생되는데 선형 회귀 알고리즘은 손실 함수를 이용하여 이를 해결하고자 한다. 다양한 선형 회귀 모델 중 이번 연구에 적용한 모델은 총 7개로 Basic Linear, Ridge, Lasso, Least-angle (LARS), Elastic Net, Bayesian ridge (BRR), Partial Least Square (PLS) 모델들을 이용하였다. 그 결과 표 1 같이 MSE와  $R^2$ 가 나왔고, 대표적으로 Lasso 회귀 결과를 그림 4의 (a)와 (b)로 나타냈다. 결과를 통해 학습되지 않은 위치를 찾아가는 모델의 경우 선형 회귀 방법은 잘 맞지 않는다는 사실을 확인하였다. 앙상블 회귀 모델의 경우 Random Forest (RF), Ada Boost, Gradient Boost, XG Boost 총 4개의 모델을 통해 계산을 진행하였다. RF 알고리즘은 원래 데이터에서 여러 세트를 생성하여 반복적으로 조합하여 데이터 세트에서 훈련을 위해 추가 데이터를 생성하여 예측의 분산을 줄이고 가중치를 부가하여 기계 학습 알고리즘의 안정성과

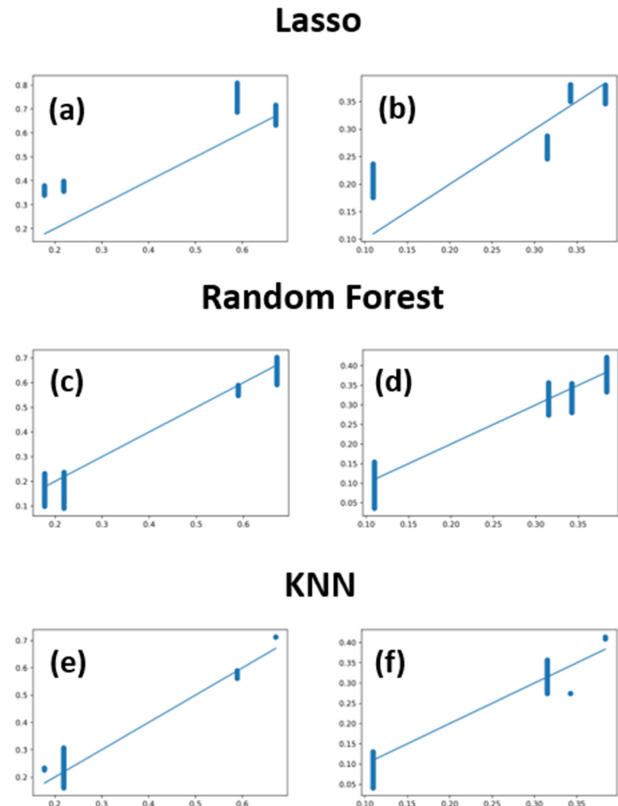


Fig. 4. Lasso, RF, KNN test result graph ((a), (c), (e) X positions, (b), (d), (f) Y positions)

**Table 2.** DNN and Machine Learning Parameter

Method	Parameter			
DNN	Weight	Learning rate	Epoch	
	64 128 64 2	0.001	100	
Basic Linear	n_jobs			
	-1			
Ridge	alpha	max_iter	tol	
	10	default	1.00E-03	
Lasso	Alpha	mat_iter		
	1.00E-04	1.00E+03		
LARS	alpha	max_iter		
	1.00E-05	500		
Elastic Net	l1_ratio	alpha		
	1	1.00E-04		
BRR	tol			
	1.00E-04			
PLS	n_components	tol		
	4	1.00E-03		
Random Forest	n_estimators	max_depth	max_features	
	50	10	sqrt	
Ada Boost	learning rate	n_estimators	loss	
	0.1	200	square	
Gradient Boost	learning rate	n_estimators	subsample	loss
	0.1	150	1	lad
XG Boost	Learning rate	subsample	max_depth	
	0.1	0.5	2	
KNN	weights	n_neighbors	p	
	distance	500	1	

정확도를 향상시키기 위해 고안된 일종의 앙상블 학습법 베타 알고리즘인 배깅을 사용하고 있고, Boost 모델들은 여러 개의 알고리즘이 순차적으로 학습과 예측을 하면서 이전에 학습한 알고리즘의 예측이 틀린 데이터를 올바르게 예측할 수 있도록 다음 알고리즘에 가중치를 부여하는 부스팅을 사용한다. 그리고 모든 앙상블 회귀 모델들은 기본적으로 의사 결정 트리 방식을 채택하여 작동한다. 이러한 내용을 기반으로 하는 Random Forest의 경우 훈련 결과 MSE: 0.00001, R<sup>2</sup>: 0.999853 그리고 검증 결과 MSE: 0.00845, R<sup>2</sup>: 0.971239로 앞서 진행해본 선형 회귀 모델보다 개선된 MSE와 R<sup>2</sup> 값을 보여줌으로써 비교적 빈 공간을 잘 찾아가는 모습을 보여주었다. RF 회귀 모델의 검증 결과로 그림 4의 (c)와 (d)에서 나타났다. 마지막으로 비선형 기계 학습 알고리즘인 K-Nearest Neighbor (KNN)을 활용하여 학습을 한 결과로 훈련 결과 MSE: 0, R<sup>2</sup>: 1,

검증 결과 MSE: 0.002106, R<sup>2</sup>: 0.928325로 앙상블 모델인 Random Forest보다 낮게 나왔다. KNN 결과는 그림 4의 (e)와 (f)에서 보여준다. 회귀 모델에서는 Random Forest의 테스트 MSE와 R<sup>2</sup> 값이 비교적 높은 값으로 나왔다. 결과적으로 심층신경망 모델과 앙상블 모델인 Random Forest은 실시간으로 위치를 찾아갈 수 있는 모습을 보여줬다. 학습을 위해 사용된 Parameter들은 표 2에 정리하였다.

### 4. 결 론

본 연구에서는 기존의 인공지능 기반의 압저항 패드 연구와는 다르게 패드 내의 학습된 위치 이외의 학습되지 않은 위치를 찾을 수 있는지에 대해 다양한 인공지능 모델들을 이용하여 연구를 진행하였다. 다중벽 탄소 나노튜브 + 탄소 나노튜브 압저항 패드 내에 총 54개의 위치를 가압/감압하여 데이터를 1초당 1000개씩 수집하였다. 이 중 무작위의 4개의 위치를 검증 데이터로 사용하였고, 그 이외의 50개의 위치를 훈련 데이터로 사용하였다. 수집된 데이터를 학습시키기 위해 신경망 모델과 각종 회귀 모델 12개를 이용하여 연구를 진행하였다. 심층 신경망 모델에서는 훈련 결과 MSE: 0.00001, R<sup>2</sup>: 0.999752, 검증 결과 MSE: 0.00026, R<sup>2</sup>: 0.991158가 나왔고, 회귀 모델 중에서는 앙상블 모델의 한 종류인 RF 모델에서 훈련 결과 MSE: 0.00001, R<sup>2</sup>: 0.999853, 검증 결과 MSE: 0.00845, R<sup>2</sup>: 0.971239가 좋은 결과를 보여주었다. 따라서 고비용의 제조 공정 없이 단순한 재료와 제작 방법을 통해 배열이 없는 단일 층 압저항 패드를 보여주었습니다. 이러한 압저항 패드를 다양한 알고리즘 모델을 통해 훈련시키는 것만으로 스마트한 촉각 센서로 변환했음을 알 수 있었고, 학습되지 않은 위치를 실시간으로 원하는 위치를 탐색하는 연구 결과를 보여주었다.

### 감사의 글

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 이공분야기초연구사업, 창의도전연구기반지원임 (NRF-2021R111A1A01059583).

### REFERENCES

1. Y. Gao, H. Ota, E. W. Schaler, K. Chen, A. Zhao, W. Gao, H. M. Fahad, Y. Leng, A. Zheng, F. Xiong, C. Zhang, L.-C.



- Tai, R. S. Fearing, and A. Javey, *Adv. Mater.* **29**, 1701985 (2017).
2. A. Chortos and Z. Bao, *Mater Today*. **17**, 321 (2014).
  3. S. C. B. Mannsfeld, *Nat. Mater.* **9**, 859 (2010).
  4. R. S. Dahiya and M. Valle, *Sensors: Focus Tactile Force Stress Sensors*, pp.209-304, InTech, Croatia (2008).
  5. A. Chortos, J. Liu, and Z. Bao, *Nat. Mater.* **15**, 937 (2016).
  6. W. Gao, H. Ota, D. Kiriya, K. Takei, and A. Javey, *Chem. Res.* **52**, 523 (2019).
  7. M. L. Hammock, A. Chortos, B. C. K. Tee, J. B. H. Tok, and Z. Bao, *Adv. Mater.* **25**, 5997 (2013).
  8. K. Takei, W. Gao, C. Wang, and A. Javey, *Proc. IEEE*. **107**, 2155 (2019).
  9. W. Gao, S. Emaminejad, H. Y. Y. Nyein, K. Chen, A. Peck, H. M. Fahad, H. Ota, H. Shiraki, D. Kiriya, D.-H. Lien, G. A. Brooks, R. W. Davis, and A. Javey, *Nature* **529**, 509 (2016).
  10. J. Liu, J. Wang, Z. Zhang, F. M. Lopez, G.-J. N. Wang, B. C. Schroeder, X. Yan, Y. Zeng, O. Zhao, H. Tran, T. Lei, Y. Lu, Y.-X. Wang, J. B. H. Tok, R. Dauskardt, J. W. Chung, Y. Yun, and Z. Bao, *Nat. Commun.* **11**, 3362 (2020).
  11. M. Stoppa and A. Chiolerio, *Sensors* **14**, 11957 (2014).
  12. S. R. A. Ruth, V. R. Feig, H. Tran, and Z. Bao, *Adv. Funct. Mater.* **30**, 2003491 (2020).
  13. N. Matsuhisa, X. Chen, Z. Bao, and T. Someya, *Cem. Soc. Rev.* **48**, 2946 (2019).
  14. K. Chen, W. Gao, S. Emaminejad, D. Kiriya, H. Ota, H. Y. Y. Nyein, K. Takei, and A. Javey, *Adv. Mater.* **28**, 4397 (2016).
  15. S. R. A. Ruth, L. Beker, H. Tran, V. R. Feig, N. Matsuhisa, and Z. Bao, *Adv. Funct. Mater.* **30**, 1903100 (2020).
  16. S. Niu, N. Matsuhisa, L. Beker, J. Li, S. Wang, J. Wang, Y. Jiang, X. Yan, Y. Yun, W. Burnett, P. S. Y. Ada, J. B. H. Tok, X. Chen, and Z. Bao, *Nat. Electron.* **2**, 361 (2019).
  17. A. Chortos, I. Pochorovski, P. Lin, G. Pitner, X. Yan, T. Z. Gao, J. W. F. To, T. Lei, J. W. Will, H.-S. P. Wong, and Z. Bao, *ACS Nano*. **11**, 5660 (2017).
  18. C. M. Boutry, A. Nguyen, Q. O. Lawal, A. Chortos, S. R. Gagne, and Z. Bao, *Adv. Mater.* **27**, 6954 (2015).
  19. L. Pan, A. Chortos, G. Yu, Y. Wang, S. Isaacson, R. Allen, Y. Shi, R. Dauskardt, and Z. Bao, *Nat. Commun.* **5**, 3002 (2014).
  20. S. J. Benight, C. Wang, J. B. H. Tok, and Z. Bao, *Prog. Polym. Sci.* **38**, 1961 (2013).
  21. C. Wang, D. Hwang, Z. Yu, K. Takei, J. Park, T. Chen, B. Ma, and A. Javey, *Nat. Mater.* **12**, 899 (2013).
  22. B. C. K. Tee, C. Wang, R. Allen, and Z. Bao, *Nat. Nanotechnol.* **7**, 825 (2012).
  23. A. N. Sokolov, B. C. K. Tee, C. J. Bettinger, J. B.-H. Tok, and Z. Bao, *Acc. Chem. Res.* **45**, 361 (2012).
  24. M. Ramuz, B. C. K. Tee, J. B. H. Tok, and Z. Bao, *Adv. Mater.* **24**, 3223 (2014).
  25. I. You, D. G. Mackanic, N. Matsuhisa, J. Kang, J. Kwon, L. Beker, J. Mun, W. Suh, T. Y. Kim, J. B. H. Tok, Z. Bao, and U. Jeong, *Sicence* **370**, 961 (2020).
  26. A. M. Almassri and W. Z. W. Hasan, *J. Sens.* **12**, 846487 (2015).
  27. L. M. Castano and A. B. Flatau, *Smart Mater. Struct.* **23**, 053001 (2014).
  28. N. Bai, L. Wang, Q. Wang, J. Deng, Y. Wang, P. Lu, J. Huang, G. Li, Y. Zhang, J. Yang, K. Xie, X. Zhao, and G. F. Guo, *Nat. Commun.* **11**, 209 (2020).
  29. T. Zhao, T. Li, L. Chen, L. Yuan, X. Li, and J. Zhang, *ACS Appl. Mater. Interfaces*. **11**, 29466 (2019).
  30. A. Nallathambi, T. Shanmuganantham, and D. Sindhanaiselvi, *Mater. Today: Proc.* **5**, 1897 (2018).
  31. K. Meng, J. Chen, X. Li, Y. Wu, W. Fan, Z. Zhou, Q. He, X. Wang, X. Fan, Y. Zhang, J. Yang, and Z. L. Wang, *Adv. Funct. Mater.* **29**, 1806388 (2018).
  32. P. Ribeiro, M. A. Khan, A. Alfadhel, J. Kosel, F. Franco, S. Cardoso, A. Bernardino, A. Schmitz, J. Santos-Victor, and L. Jamone, *IEEE Robot. Autom. Lett.* **2**, 971 (2017).
  33. G. Zhu, W. Q. Yang, T. Zhang, Q. Jing, J. Chen, Y. S. Zhou, P. Bai, and Z. L. Wang, *Nano Lett.* **14**, 3208 (2014).
  34. A. Song, Y. Han, H. Hu, and J. Li, *IEEE Trans. Instrum. Meas.* **63**, 1739 (2014).
  35. B. C. K. Tee, A. Chortos, R. R. Dunn, G. Schwartz, E. Eason, and Z. Bao, *Adv. Funct. Mater.* **24**, 5427 (2014).
  36. W. Hu, X. Niu, R. Zhao, and Q. Pei, *Appl. Phys. Lett.* **102**, 083303 (2013).
  37. M. Vatani, E. D. Engeberg, and J.-K. Choi, *Sens. Actuators A Phys.* **195**, 90 (2013).
  38. X. Wang, T. Li, J. Adams, and J. Yang, *J. Mater. Chem. A*. **1**, 3580 (2013).
  39. L. Lin, Y. Xie, S. Wang, W. Wu, S. Niu, X. Wen, and Z. L. Wang, *ACS Nano*. **7**, 8266 (2013).
  40. Y. Zhu and F. Xu, *Adv. Mater.* **24**, 5117 (2012).
  41. P. Puangmali, H. Liu, L. Seneviratne, P. Dasgupta, and K. Althoefer, *IEEE/ASME Trans. Mechatron.* **17**, 646 (2012).
  42. H. B. Muhammad, C. Recchiuto, C. M. Oddo, L. Beccai, C. J. Anthony, M. J. Adams, M. C. Carrozza, and M. C. L. Ward, *Microelectron. Eng.* **88**, 1811 (2011).

43. D. J. Lipomi, M. Vosgueritchian, B. C. K. Tee, S. L. Hellstron, J. A. Lee, C. H. Fox, and Z. Bao, *Nat. Nanotechnol.* **6**, 788 (2011).
44. D. P. J. Cotton, I. M. Graz, and S. P. Lacour, *IEEE Sens. J.* **9**, 2008 (2009).
45. W. K. Schomburg and A. V. Shirinov, *Actuators A Phys.* **142**, 48 (2008).
46. D. D. Dana, H. N. Taylor, P. Rolf, and M. O. Allison, *IEEE/ASME Trans. Mechatron.* **20**, 263 (2015).
47. F. Visentin, P. Fiorini, and K. Suzuki, *Sensors*, **16**, 1928 (2016).
48. Z. Pan and Z. Zhu, *Ind. Robot.* **32**, 485 (2005).
49. H. Wu, J. Chen, Y. Su, Z. Li, and J. Ye, *Sens. Actuators A Phys.* **242**, 146 (2016).
50. S. T. David, R. David, and V. Mari, *IEEE Trans. Robot.* **27**, 425 (2011).
51. H. Wu, Y. Su, J. Shi, J. Li, and J. Ye, *Ind. Robot Int. J.* **41**, 534 (2014).
52. Y. Zhang, J. Ye, Z. Lin, S. Huang, H. Wang, and H. Wu, *Sensors*, **19**, 27 (2019).
53. S. J. Kim, S. H. Lee, H. Moon, H. R. Choi, and J. C. Koo, *Sensors*, **20**, 6185 (2020).
54. S. Timilsina, H. G. Shin, K. S. Sohn, and J. S. Kim, *Adv. Intell. Syst.* 2200036 (2022).
55. B. D. Lee, J. W. Lee, M. Kim, W. B. Park, and K. S. Sohn, *npj Comput. Mater.* **8**, 1 (2022).
56. B. D. Lee, J. W. Lee, W. B. Park, J. Park, M.-Y. Cho, S. P. Singh, M. Pyo, and K. S. Sohn, *Adv. Intell. Syst.* 2200042 (2022).
57. J. Y. Seo, S. Shim, J. W. Lee, B. D. Lee, S. Park, W. B. Park, S. Han, M. Pyo, and K. S. Sohn, *J. Mater. Chem. A*, **10**, 1831 (2022).
58. J. W. Lee, C. Park, B. D. Lee, J. Park, N. H. Goo, and K. S. Sohn, *Sci. Rep.* **11**, 1 (2021).
59. B. D. Lee, W. B. Park, J. W. Lee, M. Kim, M. Pyo, and K. S. Sohn, *Chem. Mat.* **33**, 782 (2021).
60. C. Park, J. W. Lee, M. Kim, B. D. Lee, S. P. Singh, W. B. Park, and K. S. Sohn, *Inorg. Chem. Front.* **8**, 4610 (2021).
61. J. W. Lee, W. B. Park, M. Kim, S. P. Singh, M. Pyo, and K. S. Sohn, *Inorg. Chem. Front.* **8**, 2492 (2021).
62. J. W. Lee, N. H. Goo, W. B. Park, M. Pyo, and K. S. Sohn, *Eng. Rep.* **3**, e12274 (2021).
63. J. W. Lee, W. B. Park, B. D. Lee, S. Kim, N. H. Goo, and K. S. Sohn, *Sci. Rep.* **10**, 1 (2020).
64. M. Kim, S. P. Singh, S. Shim, W. B. Park, and K. S. Sohn, *Chem. Mat.* **32**, 6697 (2020).
65. J. W. Lee, W. B. Park, J. H. Lee, S. P. Singh, and K. S. Sohn, *Nat. Commun.* **11**, 1 (2020).
66. J. H. Lee, S. P. Singh, M. Kim, M. Pyo, W. B. Park, and K. S. Sohn, *Inorg. Chem. Front.* **6**, 3493 (2019).
67. M. Kim, S. P. Singh, J. W. Lee, T. Izawa, D. Kim, B. Yun, C. Yoon, W. B. Park, and K. S. Sohn, *J. Alloy. Compd.* **774**, 338 (2019).
68. M. Y. Cho, S. Timilsina, J. W. Roh, W. Commerell, H. G. Shin, Y. N. Kwon, and J. S. Kim, *Korean J. Met. Mater.* **59**, 346 (2021).
69. B. K. Kim, N. H. Goo, J. H. Lee, and J. H. Han, *Korean J. Met. Mater.* **58**, 822 (2020).
70. H. J. Lee, I. K. Hwang, S. J. Jeong, I. S. Cho, and H. S. Kim, *Korean J. Met. Mater.* **59**, 430 (2021).
71. J. Y. M. Lee, Y. H. Moon, Y. Noh, and T. Lee, *Korean J. Met. Mater.* **58**, 413 (2020).
72. I. K. Hwang, H. J. Lee, S. J. Jeong, I. S. Cho, and H. S. Kim, *Korean J. Met. Mater.* **59**, 838 (2021).
73. S. Boateng, K. R. Lee, Deepika, H. Cho, K. H. Lee, and C. Kim, *Korean J. Met. Mater.* **58**, 728 (2020).
74. M. Y. Cho, J. W. Lee, C. Park, B. D. Lee, J. S. Kyeong, E. J. Park, K. Y. Lee, and K. S. Sohn, *Adv. Intell. Syst.* **4**, 2100123 (2022).
75. J. W. Lee, J. Chung, M. Y. Cho, S. Timilsina, K. Sohn, J. S. Kim, and K. S. Sohn, *ACS Appl. Mater. Interfaces*, **10**, 20862 (2018).
76. K. S. Sohn, J. Chung, M. Y. Cho, S. Timilsina, W. B. Park, M. Pyo, N. Shin, K. Sohn, and J. S. Kim, *Sci. Rep.* **7**, 1 (2017).