

doi.org/10.37544/1436-4980-2026-03-22  
Datum der Einreichung: 28.11.2025  
Datum der Annahme: 26.03.2026  
Datum der Veröffentlichung: 07.04.2026

## Explorative Datenanalyse in der Zellkontaktierung

# KI-Modell zur Bewertung der Drahtbondqualität

J. Lindlmeier, C. Holzapfel, S. Berger, C. Härdlein, C. Seidel

**ZUSAMMENFASSUNG** Das Drahtbonds als Technologie zur Herstellung elektrischer Verbindungen ist geprägt von zahlreichen nichtlinearen und sich gegenseitig beeinflussenden Prozessparametern. Das entwickelte Random-Forest-Modell, trainiert mit 690 Datenpunkten auf unterschiedlichen Substraten, prognostiziert die Bondqualität auf Basis von zehn Anlagenparametern, dem eingesetzten Material sowie der Oberflächenreinheit. Es liefert explorative Einblicke in die relativen Einflusstärken der Prozessparameter und unterstützt durch materialübergreifendes Lernen eine effizientere, wissensbasierte Prozessentwicklung.

## AI model for assessing wirebond quality

**ABSTRACT** Wirebonding as a technology for producing electrical connections is characterized by numerous non-linear and mutually influencing process parameters. The developed random forest model was trained on 690 data points on different substrates and predicts bond quality, based on ten system parameters, the material used, and surface cleanliness. It provides exploratory insights into the relative influence of process parameters and, through cross-material learning, supports more efficient, knowledge-based process development.

### STICHWÖRTER

Produktionstechnik, Künstliche Intelligenz (KI), Qualitätssicherung

## 1 Einleitung

Die Technologie des Drahtbondens (englisch: Wirebonding, von „to bond“ = zusammenfügen) ist seit den 1960er-Jahren eine Schlüsseltechnologie der Mikroelektronik und hat sich bis heute als zentrales Verfahren für die elektrische Kontaktierung in zahlreichen Anwendungsgebieten etabliert [1]. Das Drahtbonds erlaubt die Herstellung reproduzierbarer und qualitativ hochwertiger Verbindungen mit niedrigen Übergangswiderständen durch eine präzise Steuerung der Prozessparameter [2]. Gleichzeitig stellt die Vielzahl an Einflussgrößen sowie deren komplexe Wechselwirkung eine Herausforderung für die Prozessauslegung und Qualitätssicherung dar [3].

Mit steigenden Leistungsanforderungen und fortschreitender Miniaturisierung elektronischer Systeme wurde das Drahtbonds kontinuierlich weiterentwickelt und an neue Werkstoffe und Anwendungen angepasst [4]. Vor allem im Zuge der angestrebten Energiewende und der zunehmenden Bedeutung der Elektromobilität gewinnt das Verfahren auch für die Kontaktierung von Leistungs- und Batteriespeichern an Relevanz [5]. Eine hochwertige elektrische Verbindung ist entscheidend für Effizienz, Lebensdauer und Sicherheit der Batteriesysteme. Hohe Übergangswiderstände können zu einer ungleichmäßigen Stromverteilung, lokalen Überhitzung und erhöhten Zellegradation führen [6].


Für das Drahtbonds müssen zentrale Prozessparameter wie Ultraschalleistung, Bondkraft und Prozesszeit exakt auf die verwendeten Materialien abgestimmt werden. Unterschiedliche

Materialpaarungen weisen deutlich divergierende physikalische, chemische und mechanische Eigenschaften auf, was eine material-spezifische Parametrierung und nachgelagerte Qualitätsprüfung erforderlich macht [7]. Die nichtlinearen Zusammenhänge zwischen Prozessparametern und resultierender Bondqualität [8] erschweren eine robuste Prozessauslegung zusätzlich und erfordern ein hohes Maß an prozessspezifischem Fachwissen, Erfahrung und empirisch gestützter Optimierung [2].

Mit künstlicher Intelligenz (KI) eröffnet sich ein vielversprechendes Potenzial zur Verbesserung des Prozessverständnisses und der Bondqualität durch die datenbasierte Simulation von Versuchen. KI-Modelle können dazu beitragen, die komplexen Zusammenhänge zwischen Prozessparametern und Bondqualität sichtbar zu machen. Bisher mangelt es jedoch an übertragbaren Konzepten, wie dieses Potenzial für verschiedene Materialien und Prozessbedingungen genutzt werden kann.

Ziel dieser Arbeit ist daher die Entwicklung eines explorativen, KI-gestützten Modells zur Vorhersage der Bondqualität auf Basis experimentell erhobener Daten. Durch die datenbasierte Abbildung komplexer, nichtlinearer Zusammenhänge zwischen Prozessparametern, Materialien und der technischen Sauberkeit soll ein Beitrag zur Reduktion physischer Versuche, zur Optimierung der Parametereinstellungen sowie zum besseren Verständnis der Bondmechanismen geleistet werden.

Um dieses Ziel zu erreichen, wurden auf Grundlage der identifizierten Forschungslücken zunächst relevante Einfluss- und Zielgrößen analysiert und systematisch Versuche geplant und



**Bild 1** Schematische Darstellung des Ultraschall-Wedge/Wedge-Dickdrahtbondens mit den einzelnen Prozessphasen. *Grafik: Fraunhofer IGCV*

durchgeführt. Die erhobenen Daten wurden aufbereitet und zur Entwicklung verschiedener KI-Modelle eingesetzt. Anschließend erfolgte ein Vergleich verschiedener Regressionsverfahren hinsichtlich ihrer Eignung zur Vorhersage der Bondqualität. Auf dieser Basis wurde ein Modell ausgewählt, implementiert und mit experimentell erhobenen Prozessdaten trainiert. Die explorativen Modellergebnisse wurden abschließend diskutiert, um das Potenzial KI-gestützter Verfahren zur datenbasierten Modellierung und Optimierung von Drahtbondprozessen aufzuzeigen.

## 2 Grundlagen und Stand der Technik

### 2.1 Grundlagen Drahtbonden

Drahtbonden ist ein Verfahren zur Herstellung elektrischer Verbindungen mittels feiner Drähte [9]. Es ist ein etabliertes Verfahren in der Mikroelektronik [10] und wird in verschiedenen Industriebereichen verwendet. Im Bereich der Leistungselektronik sowie bei der elektrischen Kontaktierung von Batteriezellen kommt aufgrund der größeren Drahtdurchmesser Ultraschall-Wedge/Wedge-Dickdrahtbonden (UWB) zum Einsatz. Hierbei werden Aluminium- und Kupferdrähte mit Durchmessern zwischen  $75\ \mu\text{m}$  und  $500\ \mu\text{m}$  verwendet [11]. Der Begriff „Wedge“ bezieht sich auf das keilförmige Bondwerkzeug, das den Draht auf das Substrat presst. Das UWB ist ein spezielles Verfahren des Ultraschallschweißens, das in der Fügetechnik laut DIN 8593-6 zu den Schweißverfahren zählt. Nach DIN EN ISO 4063 (Prozess 41) wird es der Gruppe der Reibschweißungen zugeordnet.

Im Zuge des Forschungsprojektes „ElHyPowerBat: Hochstrom-Batteriesystem für hybridelektrische Antriebsysteme“ wird am Fraunhofer IGCV das UWB zur elektrischen Kontaktierung des Batteriespeichers angewendet. Das Vorhaben befasst sich in der Gesamtheit mit der Entwicklung und Demonstration eines fertigungsgerechten Hochstrom-Batteriesystems für hybridelektrische Antriebsysteme der emissionsfreien Luftfahrt. Aufgrund der erhöhten Anforderungen in der Luft- und Raumfahrt, ist die Optimierung der Prozessparameter des UWB notwendig, um die Verbindungsqualität der elektrischen Kontaktierungen und damit die Stromversorgung sicherzustellen.

Das Grundprinzip des UWB basiert auf der Kombination einer definierten Anpresskraft mit der Einkopplung hochfrequenter Ultraschallschwingungen, wodurch an der Kontaktstelle eine

stoffschlüssige Verbindung zwischen Draht und Substrat entsteht [11]. Der Ultraschall wird durch einen piezoelektrischen Wandler erzeugt, der elektrische Energie in mechanische Schwingungen umwandelt. Diese Schwingungen werden auf das Bondwerkzeug übertragen und in den Draht eingekoppelt. Der Arbeitspunkt des Bondwerkzeugs liegt bei seiner Resonanzfrequenz, an der die Energieübertragung besonders effizient erfolgt. Dabei bestimmt die angelegte Spannung die Schwingungsamplitude, während der Strom geregelt wird, um das System in Resonanz zu halten und eine stabile Ultraschallerzeugung sicherzustellen [12]. **Bild 1** beschreibt die Prozesssequenzen des UWB, die für jede elektrische Verbindung wiederholt werden.

Der Draht wird mit einer definierten Aufsetzkraft durch das Wedge auf das Substrat gepresst und verformt. Für eine vorgegebene Zeit (Phasendauer) wird die Ultraschallschwingung und Bondkraft vom Wedge auf den Draht übertragen. Aufgrund der Relativbewegung zwischen Draht und Substrat wird der erste Bond gebildet (1). Der Bondkopf bewegt sich zur zweiten Bondposition, wobei eine definierte Drahtschleife (Loop) gebildet wird (2). An der zweiten Bondposition wird der Vorgang wiederholt (3). Der Draht wird zu ca. 80% durch das Messer eingeschnitten und durch Klemmung sowie Relativbewegung des Bondkopfes abgerissen (4). Der Draht ist dadurch erneut unter dem Wedge positioniert und der Prozess kann wiederholt werden [2, 11].

### 2.2 Grundlagen Machine Learning

Maschinelles Lernen (ML) wird in überwachtes, unbeobachtetes und verstärkendes Lernen unterteilt [13]. ML ermöglicht die datenbasierte Analyse von Fertigungsprozessen. Überwachte Verfahren können eingesetzt werden, um Beziehungen zwischen Einflussgrößen (Beispiel: Prozessparameter) und Zielgrößen (Beispiel: Verbindungsqualität) zu modellieren [14]. Dadurch können relevante Einflussgrößen identifiziert, unbekannte Parameterkombinationen simuliert, nichtlineare Zusammenhänge beschrieben und optimale Parameterkombinationen abgeleitet werden. So lassen sich Versuchsaufwand und Materialkosten reduzieren und zugleich lässt sich das Prozessverständnis vertiefen [8]. Im Rahmen des Beitrags werden folgende gängige Abkürzungen und Kennzahlen genutzt:

- $y_i$ : tatsächlicher Wert der Zielgröße,  
 $\hat{y}_i$ : vorhergesagter Wert der Zielgröße durch das Modell,  
 $n$ : Stichprobenumfang
- Mean Squared Error (MSE): Durchschnittlicher quadratischer Unterschied zwischen  $y_i$  und  $\hat{y}_i$
- Mean Absolute Error (MAE): Durchschnittlicher absoluter Unterschied zwischen  $y_i$  u.  $\hat{y}_i$
- Bestimmtheitsmaß (Pseudo- $R^2$ )  $\in (-\infty, 1]$ : Beschreibt, wie viel Prozent der Varianz in den Zielwerten durch das Modell erklärt wird (0: keine Erklärungskraft). Negative Werte deuten darauf hin, dass das Modell schlechter ist als eine einfache Vorhersage des Mittelwerts [15]. Im Folgenden wird der Begriff  $R^2$  vereinfachend für das Pseudo- $R^2$  verwendet.

### 2.3 Stand der Technik

Der Einsatz von KI in der industriellen Produktion kann nach *Bauernhansl* [16] den Anwendungsfeldern Robotik (Handhabung, Programmierung, fahrerlose Transportsysteme), Bildverarbeitung (Objekterkennung, Anomalieerkennung, automatische Sichtprüfung), Signalanalyse (Zeitreihenvorhersage, Qualitätsprognose, Prozessoptimierung, Zustandsüberwachung, Anomalieerkennung) und vertrauenswürdige KI (Erklärbarkeit, Verifizierbarkeit) zugeordnet werden. Zur Schaffung einer geeigneten Wissensbasis wurden Veröffentlichungen mit Schwerpunkt aus den Bereichen Signalanalyse und Bildverarbeitung analysiert. Dadurch sollen geeignete Ziel- und Einflussgrößen, KI-Modelle und bestehende Forschungslücken identifiziert werden.

In der Bildverarbeitung helfen künstliche neuronale Netze (englisch: artificial neural networks, ANN) bei der automatischen Sichtprüfung sowie der Objekt- und Anomalieerkennung und leisten damit einen Beitrag zur Qualitätskontrolle im Drahtbondprozess. Beispielsweise werden optische Aufnahmen, Röntgenbilder und 3D-Scans eingesetzt, um Strukturen im Bondprozess zu analysieren und Defekte wie Materialfehler oder Bondabbrüche automatisiert zu erkennen [17, 18]. Im Bereich Signalverarbeitung werden prozessbezogene Daten wie Anlagenparameter, Maschinenzustände oder Sensordaten genutzt, um Zusammenhänge zwischen Prozessführung und Bondqualität, Prozessstabilität oder Werkzeugverschleiß zu modellieren [2, 19, 20]. Zur Auswertung der Daten werden sowohl klassische Verfahren des ML als auch ANN eingesetzt. Häufig genutzte Modelle für sowohl Klassifikations- als auch Regressionsaufgaben sind Support Vector Machines (SVM), Decision Trees (DT) und Random Forests (RF). Als Modellarchitektur von ANN werden beispielsweise Multi-Layer-Perceptrons (MLPs) eingesetzt.

Der Einsatz von ML im Drahtbonds ermöglicht Qualitätsvorhersagen [2] oder Fehlerklassifikationen mit nahezu 100% Genauigkeit in Bild-, Sensor- und Audioanalysen [17, 21]. Automatisierte Inspektionen, zum Beispiel Bondabstandsmessung mit  $MAE < 1\%$  bei 0,64 s pro Bild [22] oder Defekterkennung in Röntgenbildern [18], können zeitintensive manuelle Prüfungen robuster und schneller gestalten. Die betrachteten Studien beschränken sich jedoch meist auf ein spezifisches Substrat- und Drahtmaterial. In der industriellen Praxis kommen aber zahlreiche Materialien mit unterschiedlichen physikalischen, chemischen und mechanischen Eigenschaften zum Einsatz, was eine material-spezifische Parametrisierung des Bondprozesses erfordert. Aufgrund dieser Unterschiede ist die klassische Modellübertragbarkeit zwischen Substraten und Drahtmaterialien bislang nur einge-

schränkt gegeben. Vor diesem Hintergrund untersucht die vorliegende Arbeit Modelle, die auch bei unterschiedlichen Materialien Vorhersagen liefern können.

Ebenfalls unzureichend berücksichtigt wird die Einbeziehung von Störgrößen in die Modellbildung. In den vorhandenen Arbeiten werden Einflüsse wie Verschmutzungen, Verschleiß oder Umgebungsbedingungen meist nicht systematisch erfasst, obwohl sie die Bondqualität wesentlich beeinflussen können. In der Literatur wird betont, dass Modelle künftig um solche Störgrößen erweitert werden sollten, um eine höhere Robustheit und Praxistauglichkeit zu erreichen [2, 19]. In diesem Beitrag wird eine repräsentative Störgröße ausgewählt und in das Modell implementiert.

## 3 Versuchsplanung und Datenerhebung

Das Ziel des Versuchs besteht darin, eine Datenbasis für die Umsetzung von KI-Modellen zu schaffen, die zur Entwicklung von KI-Modellen dient. Durch die systematische Variation der Prozessparameter über unterschiedliche Substratmaterialien hinweg wird die materialübergreifende Modellvalidierung untersucht. Ergänzend wird mit der technischen Sauberkeit eine relevante Störgröße in die Modellbildung integriert, um die Berücksichtigung von Störeinflüssen exemplarisch abzubilden.

Im folgenden Abschnitt werden die Versuchsplanung sowie der technische Aufbau des Versuchs beschrieben.

### 3.1 Einflussgrößen

#### 3.1.1 Material

Die Materialeigenschaften beeinflussen den Bondprozess und damit die resultierende Verbindungsqualität (Abschnitt 2.3). Für die experimentelle Untersuchung werden drei für das Zellkontaktierungssystem des Forschungsprojekts „ElHyPowerBat“ relevante Substratmaterialien ausgewählt:

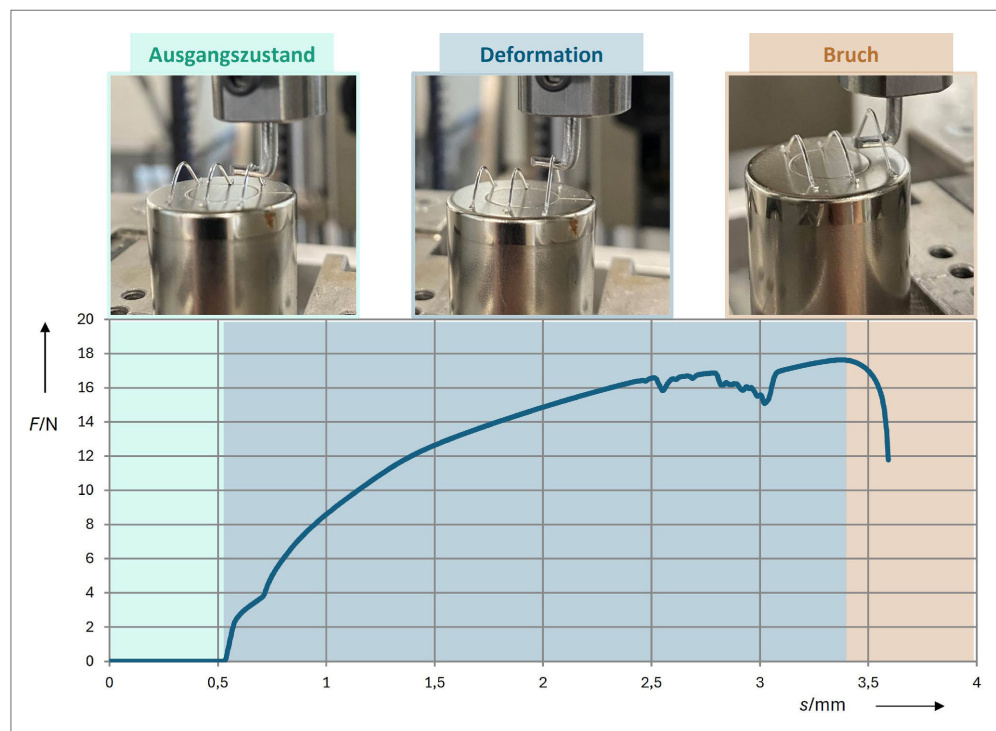
1. Aluminiumblech (EN AW-1050A, Reinheit von 99,5%, gemäß DIN EN 485-2),
2. Kupferkaschierte Leiterplatte aus Hartpapier (FR2) mit einseitiger Kupferkaschierung (35  $\mu\text{m}$ ),
3. Batterierundzellgehäuse aus vernickeltem Stahl vom Format 21700.

Auf jedem Substrat werden entsprechend der Anforderungen der Zugprüfung (zum Beispiel ausreichend Abstand zwischen Bonds) mehrere Bondverbindungen angebracht. Als Drahtmaterial wird Aluminiumdraht mit einem Durchmesser von 500  $\mu\text{m}$  und einer Zugfestigkeit von 1000–1400 cN/mm<sup>2</sup> verwendet.

#### 3.1.2 Anlagenparameter

Die Herstellung der Bondverbindungen erfolgte mit dem Drahtbonder Modell „Bondjet BJ985“ der Firma Hesse und dem Bondkopf „HBK 10“ für Aluminiumdrähte im Bereich 50  $\mu\text{m}$  bis 600  $\mu\text{m}$ . Entsprechend der Prozessbeschreibung in Abschnitt 2.1 können an der Anlage Parameter aus den Bereichen Aufsetzen, Schweißen, Loop und Abreißen eingestellt werden. Folgende Anlagenparameter wurden zur Betrachtung ausgewählt:

1. Aufsetzparameter: Aufsetzkraft/cN, mit der der Draht auf das Substrat aufgesetzt und kaltverformt wird.
2. Schweißparameter: Spannung/V, Bondkraft/cN, Ultraschallrampe/ms, Kraftrampe/ms und Phasendauer/ms. Die Spannung bestimmt die Energiezufuhr zur Erzeugung der Ultraschall-



**Bild 2** Phasen bei der Überprüfung einer Bondverbindung in einem Kraft-Weg-Diagramm des Zugtests. Fotos: IGCV, Grafik: IGCV

schwingung, während die Bondkraft festlegt, wie stark der Draht während des Schweißvorgangs auf das Substrat gepresst wird. Der Bondprozess wird in mehrere zeitlich getrennte Prozessphasen (Phasendauer) unterteilt, in denen Spannung und Bondkraft jeweils individuell eingestellt werden können. Zusätzlich besteht die Möglichkeit, sogenannte Rampen zu definieren, über die die Parameter nicht abrupt, sondern mit einer definierten Steigung auf ihren Zielwert gebracht werden.

3. Loop- und Abreißparameter werden konstant gehalten, um geometrische und mechanische Einflüsse zu minimieren.

Die Parameterbereiche sind in Abschnitt 3.1, Tabelle 1, zusammengefasst und wurden gemäß anlagentechnischen Grenzen und Experteneinschätzung so gewählt, dass sie im Sinne der Zielsetzung eine praxisnahe und physikalisch sinnvolle Untersuchung der Prozessparameter auf die Bondqualität ermöglichen.

### 3.1.3 Technische Sauberkeit

Neben Material- und Anlagenparametern können weitere Faktoren wie Oberflächenbeschaffenheit, Temperatur, Positionierung oder Werkzeugzustand die Bondqualität beeinflussen [2]. In dieser Arbeit wird die technische Sauberkeit der Substratoberfläche, welche Einfluss auf die Qualität nimmt [23], als exemplarische Störgröße betrachtet. Dafür wird ein Laserscanner zur bildgebenden Fluoreszenzanalyse des Fraunhofer-Instituts für Physikalische Messtechnik IPM eingesetzt. Organische Materialien wie Fette, Öle, Kleber oder Trennmittel fluoreszieren unter UV-Licht, indem sie einen Teil des UV-Lichts in sichtbares Licht umwandeln, während die meisten anorganischen Materialien, insbesondere Metalle, dieses Verhalten nicht zeigen. Das Fluoreszenzmesssystem nutzt eben diesen Effekt aus.

Das Substrat wird in die Probenkammer eingelegt und durch einen Laser mit UV-Licht einer Wellenlänge von 405 nm beleuchtet. Ein Filter vor der Detektionsoptik lässt nur Licht der Wellenlängen von 420 nm bis 520 nm hindurch. Fluoreszierende Mate-

rialien erscheinen daher hell, während metallischer Untergrund dunkel erscheint. Anhand dieser Bilder lässt sich jeder Bondstelle ein Sauberkeitswert zuordnen. Dazu werden vor und nach der Verbindungsherstellung Fluoreszenzbilder aufgenommen, übereinandergelegt und die Graustufenwerte an den Bondpositionen ausgewertet.

### 3.2 Qualitätsgrößen

Die Bewertung der Bondqualität erfolgt mittels Zugversuch gemäß DVS-Richtlinie 2811 [24]. Die Versuche werden mit einer Prüfmaschine vom Typ „Zwick/Roell Z050“ durchgeführt, ausgestattet mit einem Kraftsensor „Xforce HP“ (Nennkraft  $F_{nom} = 100\text{ N}$ , Genauigkeit: 1 % von  $F_{nom}$ ). Typische Bruchkräfte liegen bei 15–20 N, sodass die Messgenauigkeit für diese Anwendung ausreichend ist. Der Prüfablauf umfasst drei Phasen (Bild 2) [24]:

1. Ausgangszustand: Zugbelastung bei konstanter Traversengeschwindigkeit 0,1 mm/s.
2. Deformationsphase: Elastisch-plastische Deformation und Annahme einer annähernd dreiecksförmigen Geometrie. Die aufgebrachte Zugkraft steigt kontinuierlich (siehe Bild 2b).
3. Bruch der Verbindung.

Während des Versuchs wird die Zugkraft kontinuierlich aufgezeichnet, wodurch ein Kraft-Wege-Diagramm entsteht (Bild 2). Potenzielle Messunsicherheiten entstehen durch die manuelle Positionierung des Hakens und die damit variierende Krafteinleitung. Gemäß DVS 2811 werden anschließend die Brucharten klassifiziert und dokumentiert. Insgesamt werden drei Qualitätsgrößen erhoben:

1. Maximale Zugkraft in N
2. Bruchkraft in N zum Versagenszeitpunkt
3. Bruchcode nach DVS 2811

Im weiteren Verlauf der Arbeit wird die maximale Zugkraft in N betrachtet, eine vollständige Analyse aller Zielgrößen erfolgt zu

**Tabelle 1** Parameter und Faktorenbereiche für die durchzuführenden Versuche.

Kategorie	Parameter	Variation	Bereich/Kommentar
Steuergrößen	Aufsetzkraft	DoE	500-1600 cN
	Spannung	DoE	20-60 V
	Bondkraft	DoE	500-1600 cN
	Phasendauer	DoE	20-200 ms
	Kraftrampe	DoE	0-160 ms
	Ultraschallrampe	DoE	0-160 ms
	Geometrie	Konstant	Länge 15 mm, Höhe 4 mm
	Alle	Konstant	Herstellerwerte
Material	Substratmaterial	DoE	Aluminium, Kupfer, Ni-beschichteter A3-Stahl
	Drahtmaterial	Konstant	Aluminium
Störgröße	Technische Sauberkeit	Messung	Fluoreszenzmessung, normierte Skala 0-1
Qualitätsgröße	Mechanische Belastbarkeit	Messung	Durchführung von Zugtests

einem späteren Zeitpunkt, da dies den Rahmen dieses Beitrags übersteigt.

### 3.3 Design of Experiment

**Tabelle 1** gibt einen Überblick über die Parameter, ihre Variationsbereiche und die angewandten Mess- beziehungsweise Einstellmethoden und fasst so die Grundlagen für die Durchführung der Versuche zusammen.

Zur Erhebung der Datengrundlage für KI-Modelle wird eine geeignete Methode zur systematischen Planung des Versuchs gewählt. Die verschiedenen methodischen Ansätze werden unter dem Begriff „Design of Experiment (DoE)“ zusammengefasst. Aufgrund der hohen Anzahl steuerbarer Parameter (Tabelle 1) und der nichtlinearen Wirkzusammenhänge zwischen Prozess- und Qualitätsgrößen erweisen sich nicht alle DoE-Strategien als geeignet. Raumfüllende DoE verzichten auf feste Levels oder Gitterstrukturen und streben stattdessen eine gleichmäßige Abdeckung des Parameterraums an [25]. Dies bietet zentrale Vorteile hinsichtlich der frei wählbaren Stichprobengröße aufgrund der limitierten Materialressourcen sowie bei der Nutzung von KI-Modellen [26]. Unter den raumfüllenden Ansätzen zeigt das Maximum Projection Design (MaxPro) die beste Modellgüte und Robustheit bei der Generierung von Trainingsdaten für KI-Modelle [27]. Daher wird MaxPro als Versuchsplanungsstrategie für diese Arbeit ausgewählt.

Das MaxPro-Design ist ein DoE, welches durch die Optimierung eines Latin-Hypercube-Designs eine möglichst gleichmäßige Verteilung der Stichproben im gesamten Designraum sowie in dessen Projektionen erzeugt und damit eine besonders effiziente Abdeckung hoher Dimensionsräume ermöglicht [28]. Insgesamt wurden auf diese Weise 690 unterschiedliche Parameterkombinationen untersucht. Vor dem Hintergrund der hohen Dimensionalität des Designraums und der begrenzten Versuchsressourcen wurde der Fokus bewusst auf die Untersuchung einer möglichst großen Anzahl unterschiedlicher Parameterkonfigurationen ge-

legt, während auf statistische Wiederholungsmessungen verzichtet wurde. Bei 627 Drähten konnte eine Verbindung zum Substrat hergestellt werden, die anschließend dem Zugtest unterzogen wurde.

## 4 Datenanalyse

Vor der Implementierung der KI-Modelle wurden die Daten aufbereitet und einer explorativen Datenanalyse (EDA) unterzogen, um Struktur und Qualität zu prüfen. Im Anschluss kann die KI-Modellbildung erfolgen (**Bild 3**).

### 4.1 Modellwahl

Im Rahmen dieser Arbeit wird ausschließlich die Zugkraft als kontinuierliche Zielgröße betrachtet, weswegen die Modellierung mit einem Regressionsverfahren erfolgt. Der Standardprozess der Modellwahl umfasst die Bewertung einer Reihe von Modellkandidaten und die anschließende Identifizierung der am besten geeigneten Option [29]. In der Literatur (Abschnitt 2.3) werden SVR, RF, MLP sowie DT als geeignete Verfahren für vergleichbare Aufgabenstellungen beschrieben [14, 30, 31]. Diese Modelle wurden im Rahmen einer Vorstudie miteinander verglichen. Dazu wurde der Datensatz im Verhältnis 80:20 in Trainings- und Testdaten aufgeteilt. Die Einflussgrößen wurden mithilfe des MinMax-Scalers auf den Wertebereich [0,1] normalisiert. Dabei werden zwei verschiedene Modellvarianten untersucht:

1. Materialspezifisches Modell: Training und Test ausschließlich auf den Bondverbindungen mit Aluminiumsubstrat.
2. Materialübergreifendes Modell: Training und Test auf dem Gesamtdatensatz. Das kategoriale Merkmal „Substratmaterial“ wird mittels Dummy-Kodierung mit Referenzkategorie (k-1 Dummies) numerisch abgebildet.

Diese Unterscheidung dient dazu, in der späteren Ergebnisdiskussion die Robustheit der Modelle gegenüber verschiedenen Materialien bewerten zu können.

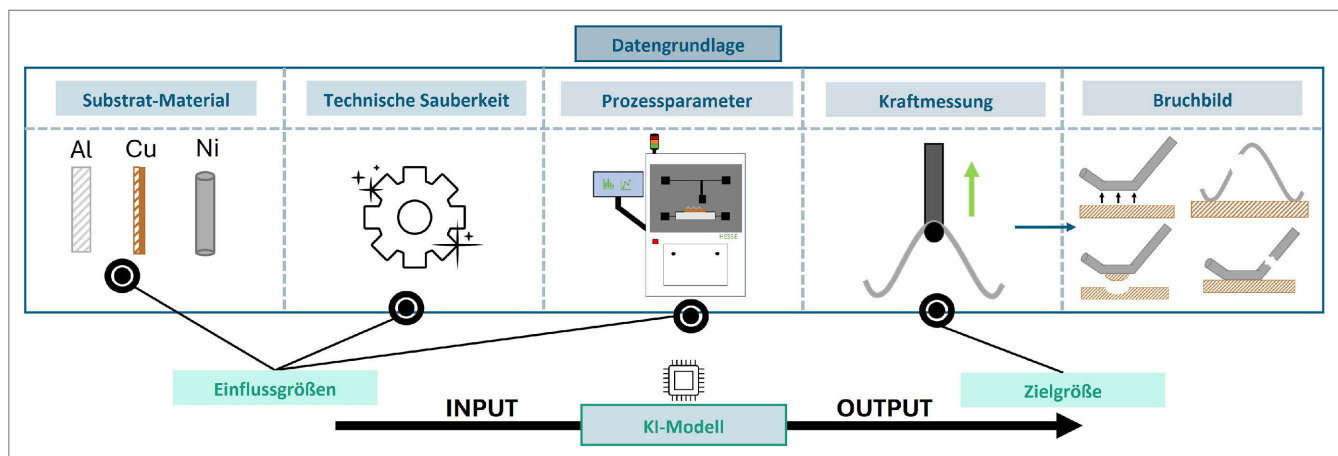


Bild 3 Datengrundlage des KI-Modells. Grafik: IGCV

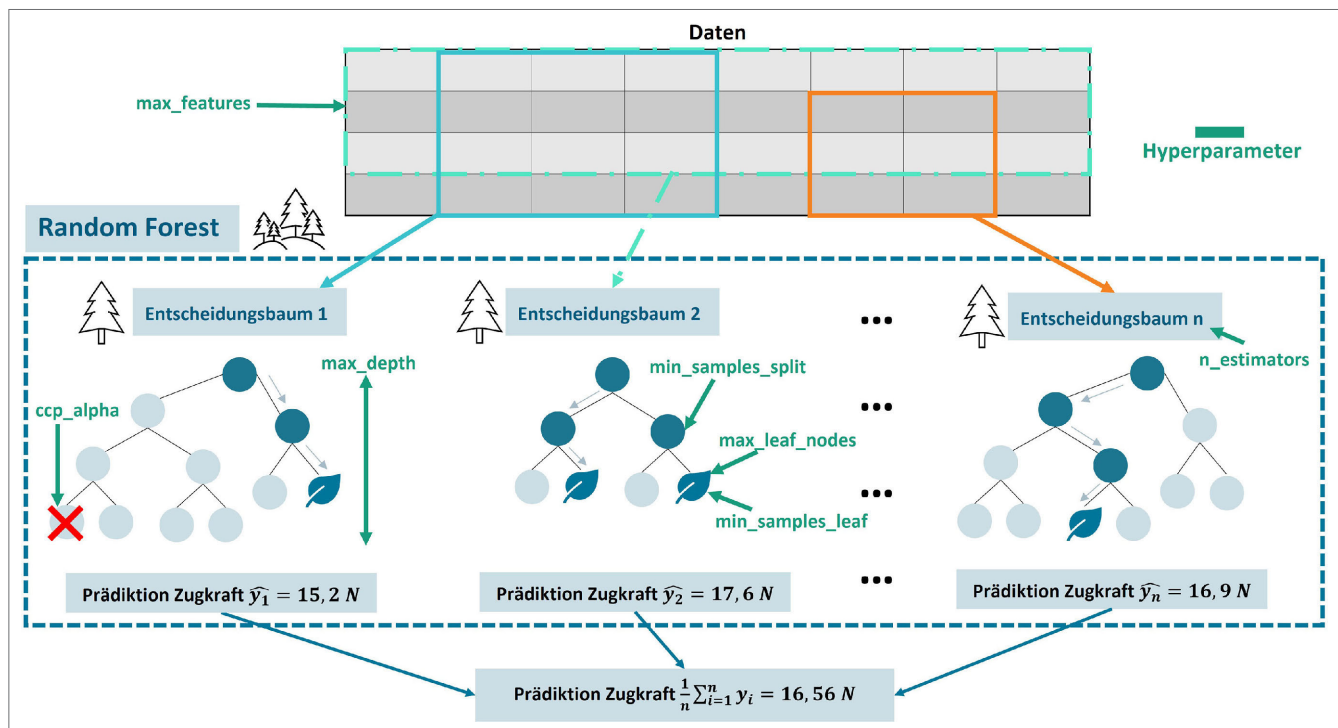


Bild 4 Schematischer Aufbau eines Random-Forest-Regressors, bestehend aus einem Ensemble mehrerer Entscheidungsbäume. Grafik: IGCV


Alle vier Modelle wurden implementiert und mithilfe einer begrenzt rechenintensiven Hyperparameteroptimierung trainiert. Diese erfolgte mittels der Klasse „Randomized-SearchCV“ aus der Bibliothek „scikit-learn“ [32]. Pro Modell wurden zehn zufällige Hyperparameterkombinationen durch eine fünffache Kreuzvalidierung evaluiert, was insgesamt 50 Trainingsdurchläufe pro Modell entspricht. Bewertet wurden die Modelle anhand des Pseudo- $R^2$  und des MSE (Abschnitt 2.2). Insgesamt wiesen SVR und RF sowohl im materialspezifischen als auch im materialübergreifenden Fall die besten Ergebnisse auf. RF bot aber zusätzliche Vorteile, die im Kontext dieser Arbeit besonders relevant sind. Er ist robuster gegenüber irrelevanten Eingangsgrößen [31], was vor dem Hintergrund der unklaren Einflüsse verschiedener Parameter relevant ist. Zum anderen ermöglicht RF eine strukturierte Interpretation der Eingangsgrößen durch Verfahren wie Feature-Importance-Analysen und Partial Dependence Plots (PDP).

## 4.2 Modellarchitektur, Modellimplementierung und Bewertung

Aufbauend auf den Ergebnissen der Modellwahl (siehe Abschnitt 4.1) wurde ein RF-Regressionsmodell implementiert, um die maximale Zugkraft der Bondverbindungen vorherzusagen. RF basieren auf dem Prinzip des Ensemble-Learnings, bei dem mehrere Entscheidungsbäume auf zufällig gezogenen Teilmengen der Trainingsdaten und Einflussgrößen trainiert werden [33]. Durch die Aggregation der Einzelergebnisse aller Bäume wird das Modell robust gegenüber verrauschten oder irrelevanten Einflussgrößen und eine Überanpassung an die Trainingsdaten vermieden [31]. Die finale Vorhersage ergibt sich durch Mittelwertbildung der Einzelbäume. Bild 4 zeigt die schematische Modellarchitektur eines RF-Regressors, inklusive der zufällig gezogenen Teildatensätze, Merkmalskombinationen und zentraler Hyperparameter (grün hervorgehoben).

**Tabelle 2** Leistungskennzahlen der Random-Forest-Regressionsmodelle,  $R^2$  = Bestimmtheitsmaß, MSE = Mean Squared Error, MAE = Mean Absolute Error.

Modell	$R^2$ (mean $\pm$ std)	MSE/N <sup>2</sup> (mean $\pm$ std)	MAE/N (mean $\pm$ std)	Anzahl Trainingsdaten	Anzahl Testdaten
Aluminium	0,499 $\pm$ 0,052	1,716 $\pm$ 0,173	1,085 $\pm$ 0,051	280	71
Kupfer	0,488 $\pm$ 0,054	6,866 $\pm$ 1,396	2,033 $\pm$ 0,196	180	45
Nickel	0,002 $\pm$ 0,222	20,798 $\pm$ 8,120	3,580 $\pm$ 0,590	40	11
ALL	0,477 $\pm$ 0,070	5,029 $\pm$ 1,625	1,601 $\pm$ 0,196	$\Sigma$ 500	$\Sigma$ 127

**Bild 5** Modellgüte im Vergleich:  $R^2$ , MSE, MAE für materialspezifische Modelle in Abhängigkeit von der Anzahl der Trainingsdaten (Mittelwert  $\pm$  Standardabweichung,  $n=5$ ). Grafik: IGCV

Die Implementierung erfolgte unter Verwendung der scikit-learn-Bibliothek [32]. Zunächst wurde der jeweilige Datensatz in Trainings- und Validierungsdaten im Verhältnis 80:20 unter Verwendung unterschiedlicher Zufallsinitialisierungen aufgeteilt. Die Validierungsdaten wurden während der Hyperparameteroptimierung nicht genutzt und dienen der finalen Leistungsbewertung (Abschnitt 5.1). Die Optimierung der Modellhyperparameter (Bild 4, grün markiert) erfolgte mittels Randomized Search mit 500 zufällig gezogenen Kombinationen aus insgesamt 10 Hyperparametern. Alternative Optimierungsstrategien können potenziell bessere Modellkonfigurationen liefern, waren jedoch nicht Gegenstand der vorliegenden Arbeit. Jede Kombination wurde mittels fünffacher Kreuzvalidierung ausschließlich auf den Trainingsdaten bewertet. Dabei wurden die Trainingsdaten in fünf wechselnde Trainings-/Testsplits unterteilt. Die finale Modellkonfiguration wurde anhand der Kreuzvalidierung bestimmt. Abschließend wurde das optimierte Modell auf dem zuvor zurückgehaltenen Validierungsdatensatz evaluiert.

## 5 Diskussion der Ergebnisse

Vor dem Hintergrund der Herausforderungen werden im Folgenden die Ergebnisse bewertet, interpretiert und diskutiert.

### 5.1 Modellbewertung

Tabelle 2 zeigt die Leistungskennzahlen ( $R^2$ , MSE, MAE, siehe Abschnitt 2.2) der trainierten RF-Regressionsmodelle für die materialspezifischen Datensätze (Aluminium, Kupfer, Nickel) sowie für den kombinierten Gesamtdatensatz (ALL). Die angegebenen Werte entsprechen Mittelwert  $\pm$  Standardabweichung aus fünf wiederholten Trainings- und Evaluationsdurchläufen (siehe Abschnitt 4.2). Grundlage der Bewertung sind die Vorhersagen

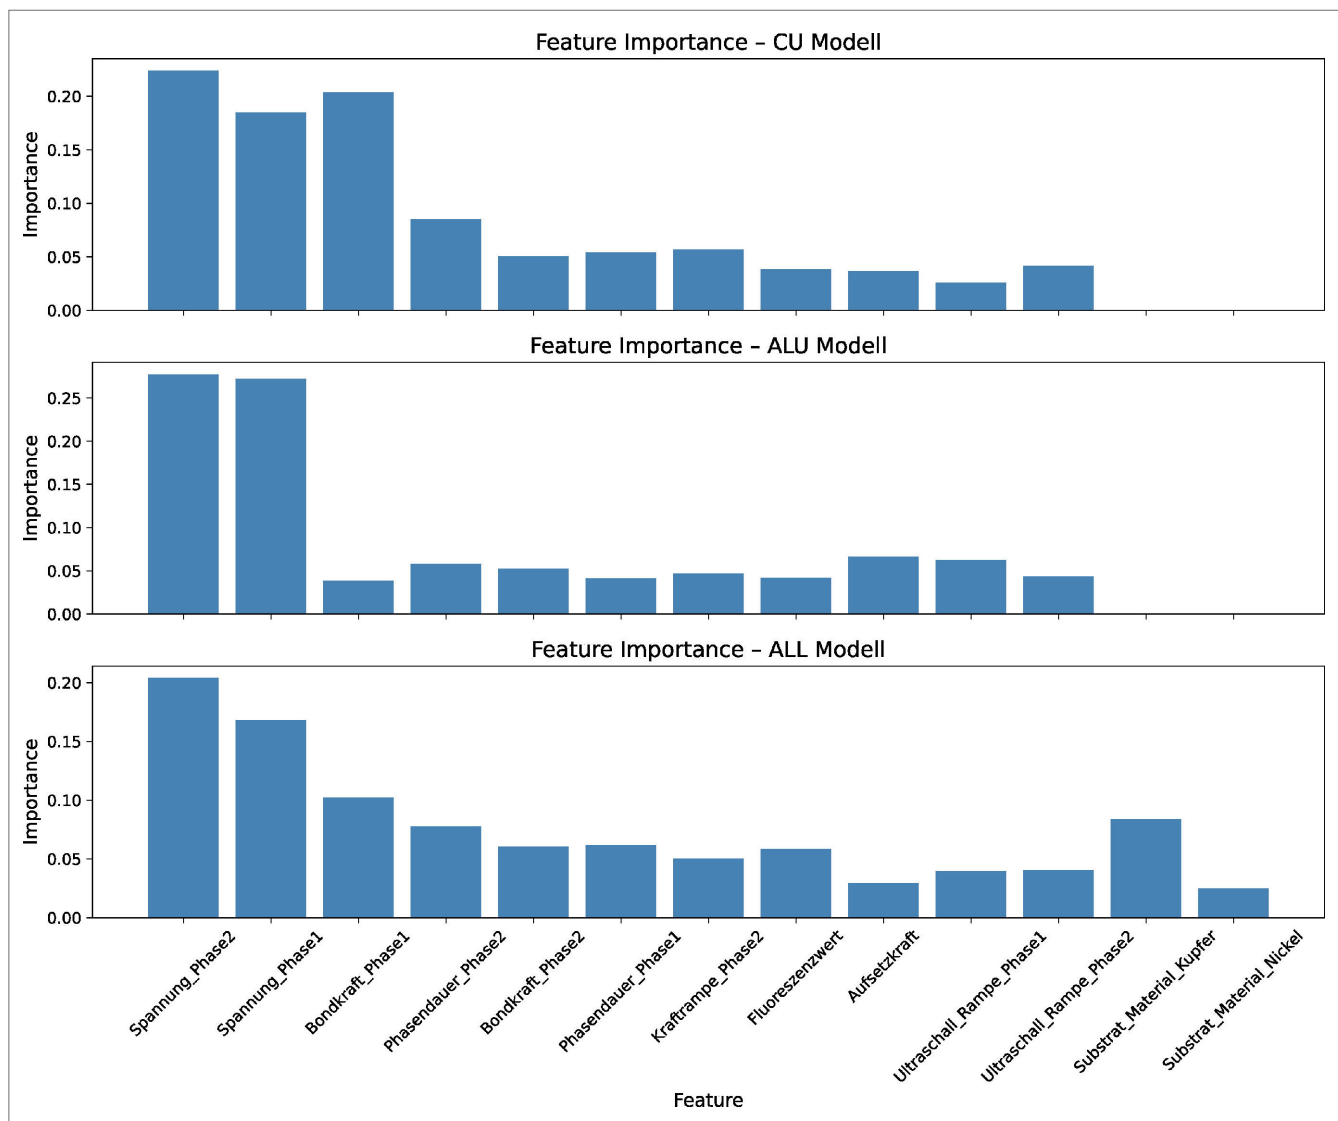
auf den in jedem Durchlauf unabhängigen, dem Modell zuvor unbekanntem Validierungsdaten.

Insgesamt erreichen Kupfer- und Aluminiummodell eine moderate bis gute, das Nickelmodell hingegen eine deutlich schwächere Vorhersageleistung (MAE, MSE) und Erklärungsvarianz ( $R^2$ ) (Tabelle 2). Die mittleren absoluten Vorhersagefehler liegen mit  $1,09 \pm 0,05$  N (Alu),  $2,03 \pm 0,2$  N (Cu) und  $3,6 \pm 0,59$  N (Ni) jeweils unter dem Bereich der natürlichen Streuung der Zugkraftmessungen (Standard-Abweichung: 2,09 N, 3,73 N, 4,84 N), sodass die Modelle praktische Abschätzungen der Bondqualität erlauben. Ob die erzielte Vorhersagegenauigkeit für den praktischen Einsatz ausreichend ist, hängt vom Anwendungsfall und den Anforderungen an die Bondqualität ab. Dabei zeigt sich ein Zusammenhang zwischen Datenmenge und Modellgüte (Bild 5).

Die Verbesserung der Modellqualität verläuft dabei nicht linear. Zwischen Nickel und Kupfer ist ein großer Sprung in der Verbesserung der Fehlermetriken erkennbar. Der Zugewinn von Kupfer zu Aluminium fällt deutlich moderater aus. Dies deutet auf einen Plateau-Effekt hin, bei dem zusätzliche Daten zwar noch Verbesserungen bringen, diese aber zunehmend geringer ausfallen. Die Modellgüte könnte potenziell durch statistische Wiederholungsmessungen oder ein weiterführendes Hyperparameter-tuning erhöht werden.

### 5.2 Modellinterpretationen

Zur Bewertung der Einflussgrößen (Features) auf die Vorhersage der Bondqualität wird die Feature Importance (FI) der RF-Modelle betrachtet (Bild 6). Dieses Maß zeigt, wie stark jedes Feature zur Modellqualität beiträgt. Die Werte sind auf einer Skala von 0 bis 1 normiert, höhere Werte zeigen einen größeren Einfluss [31].



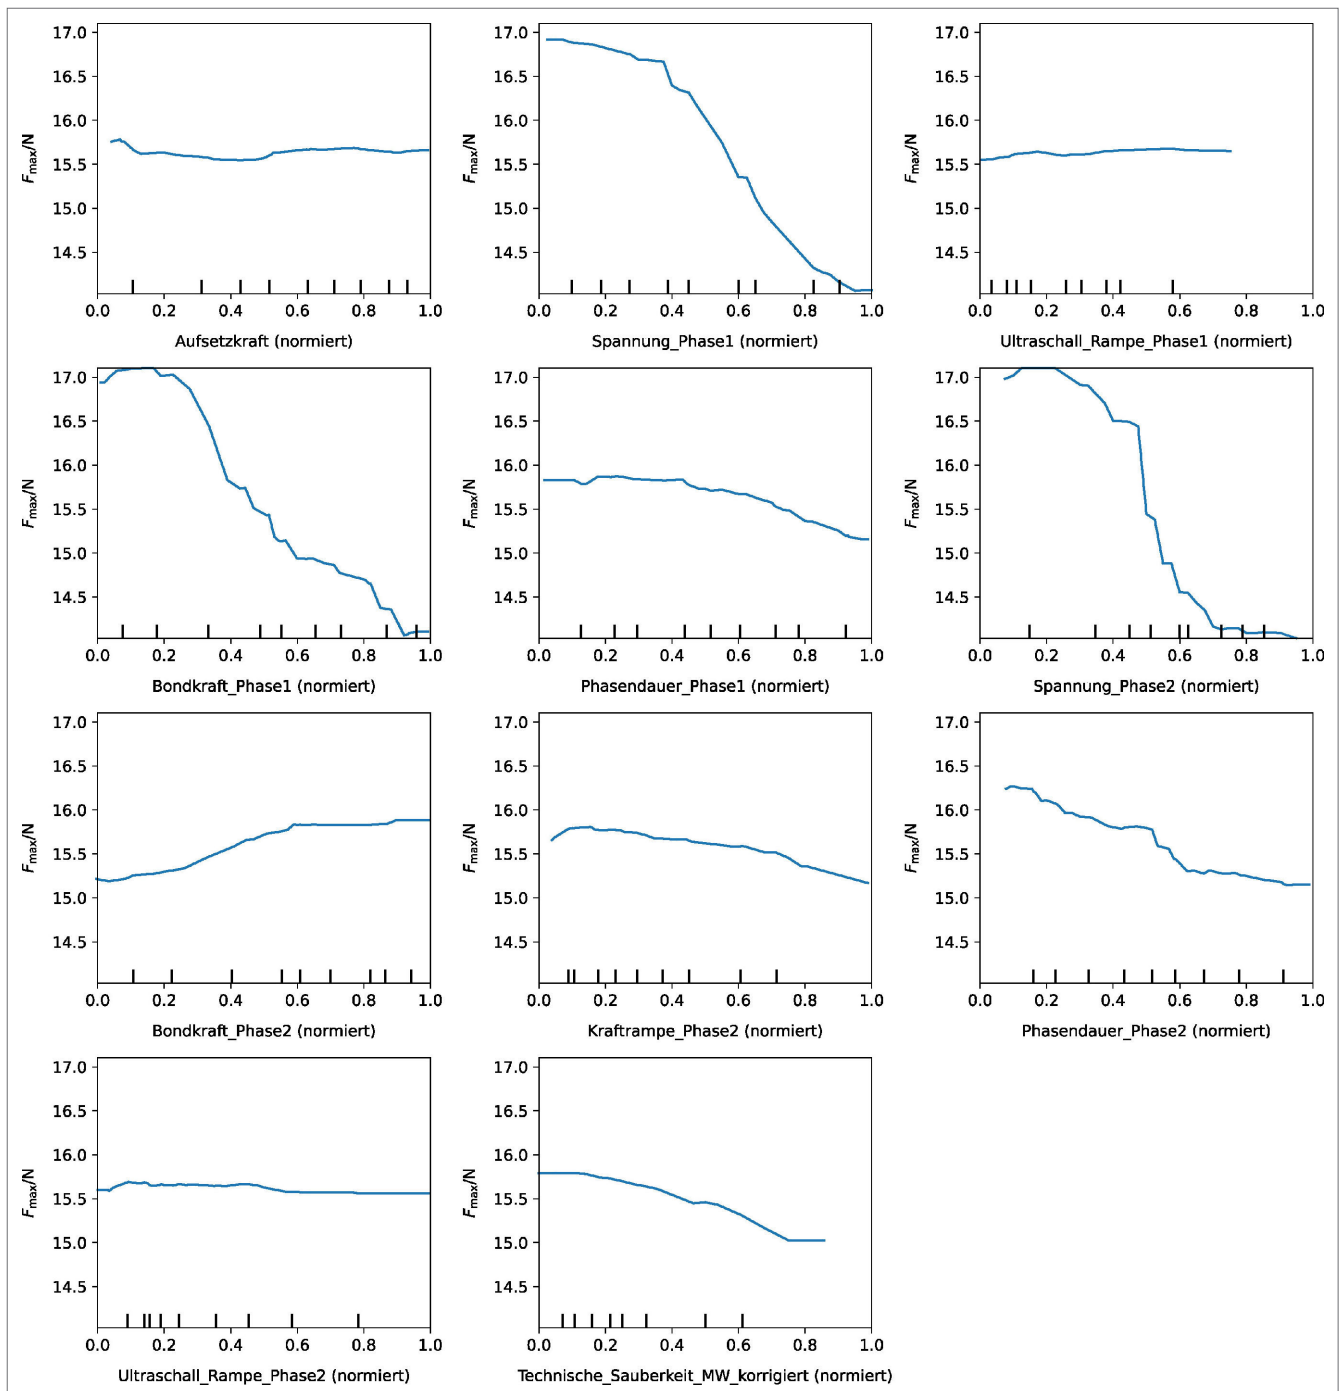
**Bild 6** Feature-Importance-Plots für die Vorhersage der Zugkraft (Ni ausgenommen aufgrund Modellqualität). Normierter Einfluss (Skala 0–1) der Features auf die Modellqualität. Grafik: IGCV

Die Dauer der Schweißphasen sowie Rampenzeiten und die technische Sauberkeit tragen kaum zur Modelleistung bei ( $FI < 0,08$ ). In allen Modellen dominiert die Spannung, welche direkt den Energieeintrag beeinflusst. Im Kupfermodell ist zusätzlich die Bondkraft relevant ( $\sim 0,2$ ), während sie im Aluminiummodell eine geringere Rolle spielt. Die kategoriale Variable Substratmaterial verdeutlicht, dass die materialspezifische Unterscheidung im kombinierten Modell weiterhin relevant bleibt. Zur Interpretation der Richtung und Stärke der Zusammenhänge werden Partial Dependence Plots eingesetzt. Die PDPs in **Bild 7** zeigen, wie sich der mittlere Modelloutput verändert, wenn eine Variable variiert wird, während alle anderen konstant gehalten werden.

PDPs mit annähernd horizontalen Verläufen (Beispiel: Aufsetzkraft) weisen auf einen geringen Einfluss der Parameter auf die vorhergesagte Zugkraft hin. Eine erhöhte Dauer der Schweißphasen scheint tendenziell zu einer geringeren Belastbarkeit der Bondverbindung zu führen. Die in den FI-Plots (**Bild 6**) identifizierten Einflüsse bestätigen sich in den PDPs. Deutlich wird der Einfluss bei der Spannung in Phase 1 und 2 sowie der Bondkraft in Phase 1. Hier fällt die vorhergesagte Zugkraft bei Überschrei-

ten eines Schwellenwerts von etwa 0,5 (entspricht circa 40 V) deutlich ab, was auf eine klare obere Grenze für den Spannungsbereich hinweist. Hohe Bondkräfte scheinen sich ebenfalls negativ auf die Verbindungsqualität auszuwirken. Zur Erfassung von Wechselwirkungen und Bereichen, in denen die Modellvorhersage besonders hoch oder niedrig ist, können zweidimensionale PDPs genutzt werden (**Bild 8**).

Die 2D-PDPs zeigen, dass besonders dann Unterschiede in der vorhergesagten Zugkraft entstehen, wenn die Spannung als einer der beiden Einflussgrößen im Plot berücksichtigt wird. In diesen Fällen zeichnen sich in den Plots nahezu vertikale Übergänge zwischen Regionen mit hoher und niedriger Zugkraft ab. Im Vergleich dazu zeigen sich bei den übrigen Merkmalskombinationen nur moderate Variationen. Die Unterschiede zwischen den Regionen mit maximaler und minimaler vorhergesagter Zugkraft liegen hier bei circa 0,2 N. 2D-PDPs verdeutlichen das Potenzial von RF zur Optimierung der Prozessparameter und des Prozessverständnisses. Angesichts der Vielzahl an Features und möglicher Wechselwirkungen zwischen den verschiedenen Prozessparametern ist



**Bild 7** Partial Dependence Plots für ausgewählte Features. Auf der x-Achse: skalierte Werte der jeweiligen Features (Bereich 0–1), y-Achse: Vom Modell vorhergesagte Zugtest-Höchstkraft in N. Grafik: IGCV

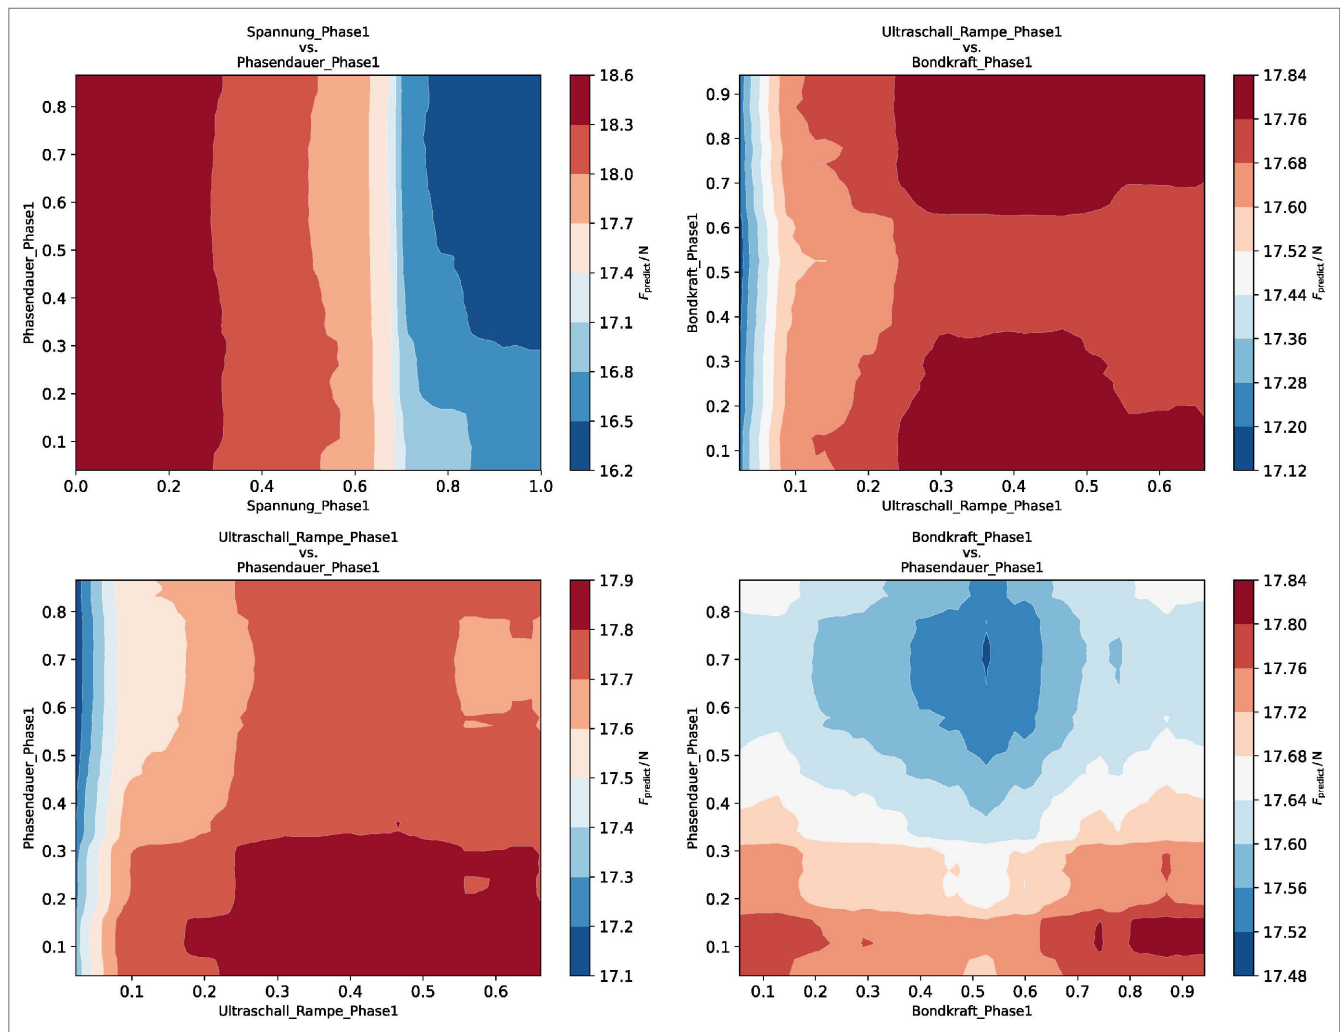
es im Rahmen dieses Beitrags nicht möglich, alle möglichen Zusammenhänge ausführlich zu diskutieren.

### 5.3 Modellrobustheit über verschiedene Materialien

Um die Modellrobustheit über verschiedene Substratmaterialien zu prüfen, wurde das Modell, das alle Materialien mithilfe eines dummy-kodierten kategorialen Merkmals berücksichtigt (siehe Abschnitt 4.1), materialweise ausgewertet. Dabei wurde die Performance des Gesamtmodells jeweils nur auf den Daten des betreffenden Materials berechnet, sodass ein direkter und

vergleichbarer Bezug zu den materialspezifischen Einzelmodellen hergestellt werden kann (**Tabelle 3**).

Tabelle 3 zeigt, dass das ALL-Modell in vielen Fällen mindestens gleichwertige oder bessere Vorhersagen liefert als die Einzelmodelle. Besonders Nickel profitiert von der materialübergreifenden Modellierung, da das Einzelmodell nur auf eine geringe Datenmenge zurückgreifen kann. Für Kupfer verbessert das Gesamtmodell die Fehlermetriken, während Aluminium mit großem Datenumfang nur minimal vom spezialisierten Modell profitiert. **Bild 9** zeigt die Vorhersagen des ALL-Modells für die



**Bild 8** 2D-Partial Dependence Plots des ALU-Modells mit der vorhergesagten mittleren Zugkraft in N für simulierte Parameterkombinationen. Einflussgrößen auf 0–1 normiert. Hinweis: unterschiedliche Ordinatenkalibrierung beachten. *Grafik: IGCV*

**Tabelle 3** Vergleich der Modellleistung ( $R^2$ , MSE, MAE) zwischen materialspezifischen Einzelmodellen und dem materialübergreifenden ALL-Modell, materialweise aufgeschlüsselt.

Material	Modelltyp	$R^2$	MSE/N <sup>2</sup>	MAE/N
Nickel	Einzelmodell	0,070	37,645	5,035
	ALL-Modell	0,157	17,503	2,971
Kupfer	Einzelmodell	0,594	6,538	1,897
	ALL-Modell	0,749	2,398	1,243
Aluminium	Einzelmodell	0,390	2,103	1,085
	ALL-Modell	0,319	3,254	1,074


Testdaten in Form eines Scatterplots, wobei die Substratmaterialien farblich codiert sind.

Bild 9 verdeutlicht, dass die prognostizierten Zugkräfte des ALL-Modells gut mit den tatsächlichen Werten übereinstimmen. Zwei Ausreißer (echte Zugkraft ~ 5 N, Bild 9) werden deutlich schlechter vorhergesagt. Ursache ist deren Unterrepräsentation im Datensatz, da Bondverbindungen mit so geringer Anhaftung in der Praxis selten sind und häufig bereits vor dem Zugtest versagen. Insgesamt zeigt sich, dass das verwendete materialüber-

greifende Modell robuste Vorhersagen über verschiedene Materialien ermöglicht, den Aufwand für separate Modelle reduziert und neue Materialien effizient integrierbar macht.

### 5.4 Technische Sauberkeit als Einflussgröße

Neben den Anlagen- und Materialparametern wurde untersucht, ob die technische Sauberkeit als zusätzliche Eingangsgröße die Vorhersageleistung der Modelle für die Bondqualität verbes-



**Bild 9** Vorhergesagte versus gemessene Zugkraft des ALL-Modells für alle Testdaten, farbcodiert nach Substratmaterial. Die Diagonale entspricht einer perfekten Vorhersage. Grafik: IGCV

sert. Dafür wurde die Sauberkeit der Substratoberfläche mittels fluoreszenzbasierter Bildanalyse quantifiziert und der jeweiligen Bondverbindung zugeordnet. Anschließend wurden die RF-Modelle unter identischen Bedingungen trainiert, einmal mit und einmal ohne Berücksichtigung der technischen Sauberkeit als Einflussgröße, und die Ergebnisse miteinander verglichen.

Die Ergebnisse zeigen, dass die Berücksichtigung der technischen Sauberkeit bei standardmäßig gereinigten Substraten die Modellgüte insgesamt kaum verändert. Im Kupfermodell steigt der  $R^2$ -Wert von 0,576 auf 0,594 bei gleichzeitig sinkendem MSE von 6,820 auf 6,538, während für Aluminium und Nickel kein relevanter Effekt festgestellt werden kann. Eine Regressionsanalyse bestätigt im vorliegenden Datensatz den fehlenden signifikanten Zusammenhang zwischen technischer Sauberkeit und Zugkraft. Die Ergebnisse werden wie folgt eingeordnet:

1. Reinigungsmethode: Die technische Sauberkeit wurde im Rahmen der Datenerhebung nach standardisierter Reinigung (Isopropanol und Mikrofasertuch) vorgenommen. Die Ergebnisse beziehen sich daher ausschließlich auf verbleibende Rückstände nach der Reinigung und lassen keine Rückschlüsse auf vollständig ungereinigte Substrate zu. Dass in diesem Bereich kein signifikanter Einfluss auf die Bondqualität festgestellt wurde, spricht für die Wirksamkeit der eingesetzten Reinigungsmethode.
2. Aufwand-Nutzen: Die Erhebung der Sauberkeitsdaten war mit erheblichem manuellem Aufwand verbunden (Messung, Zuordnung). Angesichts der geringen Auswirkung auf die Modellgüte erscheint dieser Aufwand nur bedingt gerechtfertigt, sofern übliche Grenzen im Bereich der technischen Sauberkeit eingehalten werden.

3. Interaktionen und nichtlineare Effekte: Zur Untersuchung möglicher Wechselwirkungen zwischen der technischen Sauberkeit und weiteren Prozessparametern (Beispiel: Erhöhte Bondkräfte entfalten reinigende Wirkung oder Phasendauer muss bei hoher Verschmutzung erhöht werden) wurden 2D-PDPs (Bild 8) analysiert. Dabei konnten keine signifikanten Interaktionen identifiziert werden.
4. Modellwahl: Die Berücksichtigung von Einflussgrößen mit vermeintlich geringer Relevanz verändert die Modellqualität nicht. Dieses Verhalten bestätigt die Robustheit von RF-Modellen (Abschnitt 4.1) gegenüber irrelevanten Eingangsgrößen und spricht für die Modellwahl.

## 6 Zusammenfassung und Ausblick

Angesichts der Herausforderungen im Bondprozess durch komplexe Wechselwirkungen zwischen Prozessparametern, Materialien und Störgrößen wurden in dieser Arbeit KI-gestützte Vorhersagemodelle zur Prognose der Zugkraft untersucht. Aufbauend auf einem experimentell erhobenen Datensatz von 690 Bondverbindungen über drei industrielle Substratmaterialien können die Modelle die maximale Zugkraft auf bisher ungesesehenen Testdaten vorhersagen. Die mittleren absoluten Fehler (MAE) der Vorhersagen liegen bei Alu bei  $1,09 \pm 0,05$  N (Messung reale Werte Zugkraft:  $\mu = 17,67$  N,  $\sigma = 2,09$  N), Cu  $2,03 \pm 0,2$  N ( $\mu = 15,64$  N,  $\sigma = 3,73$  N) und Ni  $3,6 \pm 0,59$  N ( $\mu = 15,28$  N,  $\sigma = 4,84$  N), was im Verhältnis zur beobachteten Streuung eine praktikable Abschätzung der Bondqualität ermöglicht. Die Analyse der Feature Importance und Partial Dependence Plots zeigt, dass insbesondere Spannung und Bondkraft dominierende Einflussgrößen sind,

während die Dauer der Prozessphasen, Rampenzeiten und die technische Sauberkeit nur gering zur Modelleistung beitragen.

Das materialübergreifende RF-Modell mit dem Material als Einflussgröße zeigt, dass auch bei datenarmen Materialien bereits Vorhersagen möglich sind, was den experimentellen Aufwand beim Anlauf neuer Materialkombinationen potenziell reduziert. Für die technische Sauberkeit zeigte sich unter den im gereinigten Zustand vorliegenden Prozessbedingungen kein relevanter Einfluss auf die Modellgüte, sodass eine zusätzliche Erfassung in vergleichbaren Umgebungen nicht erforderlich erscheint. Die beschriebene Vorgehensweise für das Modelltraining kann in der Praxis dazu verwendet werden, Prozessparameter zu optimieren, physische Versuche zu reduzieren und das Verständnis der Einflussgrößen im Drahtbonden zu erhöhen.

Für zukünftige Arbeiten bieten sich mehrere Ansatzpunkte: Neben der Zugkraft sollten auch andere qualitätsrelevante Eigenschaften wie elektrische Leitfähigkeit oder Scherfestigkeit betrachtet werden. Eine Erweiterung der Analyse um zusätzliche Prozessparameter, statistische Absicherung durch Wiederholungsmessungen sowie der Einsatz alternativer KI-Methoden wie Klassifikation, Anomalieerkennung oder Clusteranalyse könnte die Vorhersagefähigkeit weiter verbessern und das Verständnis der Zusammenhänge zwischen Materialeigenschaften, Prozessparametern und Bondqualität vertiefen.

## FÖRDERHINWEIS

Das Projekt „ElHyPowerBat“ wird durch das bayerische Staatsministerium für Wirtschaft, Landesentwicklung und Energie (StMWi) gefördert (Förderkennzeichen: HAM-2307-0014).

## DANKSAGUNG

Diese Arbeit ist Simon Berger gewidmet. Die Autoren gedenken ihm als Kollegen, welcher uns stets mit Tatkraft und gutem Rat zur Seite stand und als Freund, mit dem man gegessen, gelacht und gerne noch viele weitere Jahre verbracht hätte.


## LITERATUR

- [1] Zhou, H.; Zhang, Y.; Cao, J. et al.: Research Progress on Bonding Wire for Microelectronic Packaging. *Micromachines* 14 (2023) 2, doi.org/10.3390/mi14020432
- [2] Buchner, C.; Seidler, C. T.; Huber, M. F. et al.: Machine learning-based shear force quality prediction of ultrasonic wire bonds: utilizing process data and machine data without additional sensors. *The International Journal of Advanced Manufacturing Technology* 133 (2024) 11–12, pp. 5657–5672
- [3] IEEE Microwave and Guided Wave Letters (Hrsg.): Empirical Study of Multi-Objective Parameter Optimization in Wire Bonding Process. 2019 14th International Microsystems, Packaging, Assembly and Circuits Technology Conference (IMPACT), Taipei, Taiwan, 23–25 October 2019
- [4] Gan, C. L.; Hashim, U.: Evolutions of bonding wires used in semiconductor electronics: perspective over 25 years. *Journal of Materials Science: Materials in Electronics* 26 (2015) 7, pp. 4412–4424
- [5] International Energy Agency: Batteries and Secure Energy Transitions. Stand: 2024. Internet: [iea.blob.core.windows.net/assets/cb39c1bfd2b3-446d-8c35-aae6b1f3a4a0/BatteriesandSecureEnergyTransitions.pdf](https://iea.blob.core.windows.net/assets/cb39c1bfd2b3-446d-8c35-aae6b1f3a4a0/BatteriesandSecureEnergyTransitions.pdf). Zugriff am 26.03.2026
- [6] Kampker, A.; Heimes, H. H. (Hrsg.): Elektromobilität. Grundlagen einer Fortschrittstechnologie. Heidelberg: Springer 2024
- [7] Unger, A.; Hunstig, M.; Meyer, T. et al.: Intelligent Production of Wire Bonds using Multi-Objective Optimization – Insights, Opportunities and Challenges. *International Symposium on Microelectronics 2018* (2018) 1, pp. 572–577
- [8] Long, Y.; Twiefel, J.; Wallaschek, J.: A review on the mechanisms of ultrasonic wedge-wedge bonding. *Journal of Materials Processing Technology* 245 (2017), pp. 241–258
- [9] Prasad, S. K.: Advanced wirebond interconnection technology. Design – materials – equipment – process – quality – reliability. Boston, Mass.: Kluwer Academic Publishers 2004
- [10] Sextro, W.; Brökelmann, M. (Hrsg.): Intelligente Herstellung zuverlässiger Kupferbondverbindungen. Abschlussbericht zum Spitzenclusterprojekt InCuB. Heidelberg: Springer 2018
- [11] Kästle, C.: Qualifizierung der Kupfer-Drahtbondtechnologie für integrierte Leistungsmodule in harschen Umgebungsbedingungen. FAU Studien aus dem Maschinenbau Band 310. Erlangen: FAU University Press
- [12] Harman, G. G.: Wire bonding in microelectronics. New York: McGraw-Hill 2010
- [13] Priyadarshini, R. (Edit.): Artificial intelligence. Applications and innovations. Boca Raton, FL: Chapman & Hall/CRC Press 2023
- [14] James, G.; Witten, D.; Hastie, T. et al.: An introduction to statistical learning. With applications in R. Heidelberg: Springer 2013
- [15] Fahrmeir, L.; Heumann, C.; Künstler, R. et al.: Statistik. Der Weg zur Datenanalyse. Heidelberg: Springer 2023
- [16] Bauernhansl, T.: Handbuch Industrie 4.0. Heidelberg: Springer 2023
- [17] Ayuni, M. N.; Lin, M. F.; Zhe, L. Q.: Deep Learning-Based Classification Approach for Wire Bonding Defects Inspection. 2023 IEEE 8th International Conference On Software Engineering and Computer Systems (ICSECS), Penang, Malaysia, 2023, pp. 286–290
- [18] Zhan, D.; Huang, R.; Yi, K. et al.: Convolutional Neural Network Defect Detection Algorithm for Wire Bonding X-ray Images. *Micromachines* 14 (2023) 9, doi.org/10.3390/mi14091737
- [19] Haldos, R. R. C.; Reyes, R. S.; Abu, P. A. R. et al.: Predictive Monitoring of Wirebond Ultrasonic Signal on Electrical Test Result Using Machine Learning. 2021 7th International Conference on Electrical, Electronics and Information Engineering (ICEEIE), Malang, Indonesia, 2021, pp. 1–6
- [20] Feng, W.; Chen, X.; Wang, C. et al.: Application research on the time-frequency analysis method in the quality detection of ultrasonic wire bonding. *International Journal of Distributed Sensor Networks* 17 (2021) 5, #155014772110183
- [21] Huai, H.; Chidanandappa, N.; Wilde, J.: Application of Machine Learning to Recognize Wire Bond Lift-Off in Power Electronics Manufacturing. 2023 24th International Conference on Thermal, Mechanical and Multi-Physics Simulation and Experiments in Microelectronics and Microsystems (EuroSimE), Graz, Austria, 2023, pp. 1–6
- [22] Zhang, Y.; Pu, C.; Zhang, Y. et al.: Integrated Circuit Bonding Distance Inspection via Hierarchical Measurement Structure. *Sensors (Basel, Switzerland)* 24 (2024) 12, doi.org/10.3390/s24123933
- [23] Schneuwly, A.; Gröning, P.; Schlapbach, L. et al.: Influence of surface contamination on metal/metal bond contact quality. *Journal of Electronic Materials* 27 (1998) 8, pp. 990–997
- [24] DVS – Deutscher Verband für Schweißen und verwandte Verfahren e.V.: Merkblatt DVS 2811. Prüfverfahren für Drahtbondverbindungen. Februar 2017
- [25] Kleppmann, W.: Versuchsplanung. Produkte und Prozesse optimieren. München: Hanser Verlag 2020


- [26] Cavazzuti, M.: Optimization Methods. From Theory to Design Scientific and Technological Aspects in Mechanics. Heidelberg: Springer 2012
- [27] Arboretti, R.; Ceccato, R.; Pegoraro, L. et al.: Design choice and machine learning model performances. Quality and Reliability Engineering International 38 (2022) 7, pp. 3357–3378
- [28] Joseph, V. R.; Gul, E.; Ba, S.: Maximum projection designs for computer experiments. Biometrika 102 (2015) 2, pp. 371–380
- [29] Ding, J.; Tarokh, V.; Yang, Y.: Model Selection Techniques: An Overview. IEEE Signal Processing Magazine 35 (2018) 6, pp. 16–34
- [30] Goodfellow, I.; Bengio, Y.; Courville, A.: Deep learning. Cambridge, Massachusetts, London, England: The MIT Press 2016
- [31] Hastie, T.; Tibshirani, R.; Friedman, J. H.: The elements of statistical learning. Data mining, inference, and prediction. New York, NY: Springer 2009
- [32] Pedregosa, F.; Varoquaux, G.; Gramfort, A. et al.: Scikit-learn: Machine learning in Python. Journal of Machine Learning Research (2011) 12, pp. 2825–2830
- [33] Breiman, L.: Random Forests. Machine Learning 45 (2001) 1, pp. 5–32

**Christoph Holzapfel, M.Eng.**   
*christoph.holzapfel@igcv.fraunhofer.de*

**Simon Berger, M.Eng.**

**Christian Härdtlein, M.Eng.**   
 Fraunhofer-Institut für Gießerei-,  
 Composite- und Verarbeitungstechnik IGCV  
 Am Technologiezentrum 10, 86159 Augsburg  
 www.igcv.fraunhofer.de

**Jonas Lindlmeier, M.Sc.**   
*lindlmeier.jonas@hm.edu*

**Prof. Dr.-Ing. Christian Seidel**   
 Hochschule München  
 Fakultät für angewandte Naturwissenschaften  
 und Mechatronik  
 Smart Manufacturing Lab  
 Lothstr. 34, 80335 München

LIZENZ



Dieser Fachaufsatz steht unter der Lizenz Creative Commons  
 Namensnennung 4.0 International (CC BY 4.0)