

Konstruktion + Simulation

KI-gestützte Bauteiloptimierung
für E-Fahrzeuge Seite 26

Fertigung + Produktion

Sparsam reinigen mit dem
passenden Filter Seite 34

Robotik + Industrie 4.0

Schmierstoffe intelligent
überwachen Seite 48

Zerspanungstechnik

Schwingungen vermeiden und Qualität verbessern

KI-gestützte Bauteiloptimierung für effizientere E-Fahrzeuge

Inmitten des Elektromobilitätsbooms und steigender Ladeleistungen über 150 kW stehen Batteriefahrzeuge vor der Herausforderung der effektiven Wärmeableitung. Der Einsatz von Machine Learning und innovative Ansätze wie die passive Speicherung von Wärme in Phasenwechselmaterialien bieten vielversprechende Wege zur Entwicklung effizienter Wärmemanagementlösungen.

Im gegenwärtigen dynamischen Zeitalter der Elektromobilität, das von einem Paradigmenwechsel in der Energieversorgung begleitet wird, nimmt die Energieeffizienz einen zentralen Stellenwert ein. Die Transformation hin zu elektrisch angetriebenen Fahrzeugen erfordert nicht nur innovative Technologien, sondern stellt auch die Forschung vor die anspruchsvolle Aufgabe, komplexe Lösungen für das Wärmemanagement in Batteriefahrzeugen zu entwickeln. Diese Lösungen müssen nicht nur effektiv Wärme ableiten, sondern auch den Grundsätzen des Leichtbaus entsprechen, um die Reichweite und Effizienz der Elektrofahrzeuge zu maximieren.

Bild 1 illustriert einen entscheidenden Aspekt dieses Fortschritts: ein Elektrofahrzeug an einer Schnellladesäule. Hier wird deutlich, dass die Zukunft Ladeleistungen mit sich bringen wird, die weit über 150 kW

hinausgehen. Die Herausforderung liegt jedoch in den damit verbundenen hohen Ladeströmen, die eine beträchtliche Erwärmung der Batteriesysteme und der Ladeinfrastruktur zur Folge haben. Diese Erwärmung führt zu Verlusten, sei es durch den klassischen Joule'schen Wärmeeffekt aufgrund des erhöhten Widerstands in den Kupferleitungen oder durch den verstärkten Rückkühlbedarf des Kühlmediums aufgrund der Batterieerwärmung.

Ansätze für die Minimierung von Wärmeverlusten

Inmitten dieses komplexen Szenarios entfaltet der Einsatz von künstlicher Intelligenz (KI) neue Möglichkeiten zur Bewältigung dieser Herausforderungen. Zum Beispiel können durch die Anwendung von Machine Learning komplexe Zusammen-

hänge zwischen verschiedenen Parametern systematisch analysiert werden. Hierbei wird der Designraum definiert, um die Auswirkungen verschiedener Eingangsparameter auf die Ausgangsparameter vorherzusagen. Dies eröffnet nicht nur die Möglichkeit einer systematischen Untersuchung verschiedener Kombinationen, sondern ermöglicht auch die effiziente Lösung von Optimierungsproblemen in einem energie- und zeitsparenden Rahmen.

Um die Verluste im Wärmemanagement zu minimieren, werden unterschiedliche Ansätze in Betracht gezogen:

- Eine Möglichkeit besteht in der Erhöhung der Kabelquerschnitte, um die Stromdichte zu reduzieren und somit einer Überhitzung entgegenzuwirken. Allerdings geht dies mit einem erhöhten Gewicht einher, was den Energieverbrauch des Fahrzeugs beeinflusst und dem Prinzip des Leichtbaus widerspricht. Zudem erfordert dies einen höheren Ressourcenbedarf, was nicht im Einklang mit den Prinzipien der Nachhaltigkeit steht.
- Eine weitere Strategie besteht darin, den Ladestrom zu reduzieren, um die Temperatur im Ladekabel nicht über eine kritische Schwelle ansteigen zu lassen. Diese Herangehensweise führt jedoch zwangsläufig zu längeren Ladezeiten, was die Vorteile von Schnellladern untergraben könnte.
- Die aktive Kühlung der Ladekabel im Elektrofahrzeug stellt eine weitere vielversprechende Option dar. Dabei wird Wärme aus den Kabeln in das Kühlsystem des Fahrzeugs geleitet, was die Möglichkeit bietet, den Kabelquerschnitt zu reduzieren. Dies geht jedoch mit einem zusätzlichen Energieverbrauch



Bild 1 > Energieeffizienz hat viele Facetten – Geschwindigkeit und Energieeffizienz an Schnellladesäulen gehören zu den großen Herausforderungen der Elektromobilität (© AUDI AG)

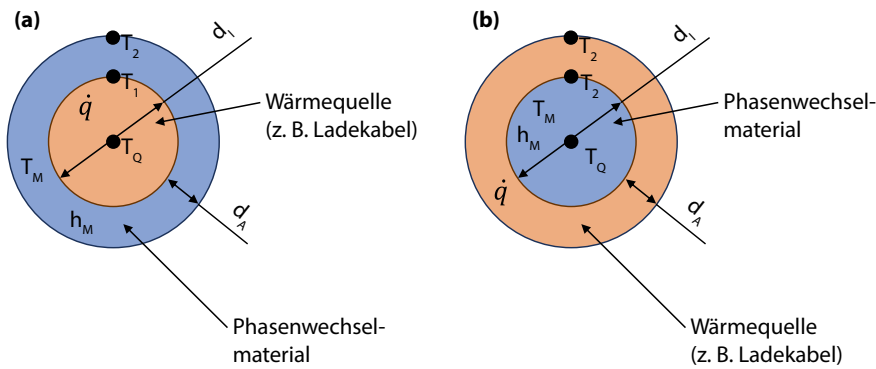


Bild 2 > Darstellung des Aufbaus mit beschrifteten Komponenten am Beispiel eines Ladekabels: a) mit innen liegender Wärmequelle und außen liegendem Phasenwechselmaterial; b) mit innen liegendem Phasenwechselmaterial und außen liegender Wärmequelle (© Digital Physics AI GmbH)

für die Kühlung einher, was wiederum zu Verlusten führen kann. Trotzdem könnten die Vorteile des Leichtbaus und der Nachhaltigkeit durch die reduzierte Erwärmung des Leiters überwiegen.

- Eine alternative Möglichkeit ist die aktive Kühlung der Ladekabel in der Ladesäule, um das Fahrzeugkühlsystem zu entlasten. Dies erfordert jedoch eine erweiterte Kühlung in den Ladesäulen, was zu zusätzlichen Energieverlusten führt und einheitliche Ladekabel voraussetzt, sodass gewisse Einschränkungen vorhanden sind.
- Zusätzlich zu den aktiven Ansätzen kann auch eine passive Kühlung in Erwägung gezogen werden. Durch die Zwischenspeicherung der zusätzlichen Wärme in bestimmten Bereichen der Verkabelung kann Energie zu einem späteren Zeitpunkt an die Umgebung abgegeben oder an das Fahrzeugkühlsystem zurückgegeben werden. Dies könnte zu Gewichts- und Ressourceneinsparungen führen, ohne die Vorteile des Leichtbaus zu beeinträchtigen.
- Eine besonders interessante Möglichkeit ist die passive Zwischenspeicherung der

Wärme für eine zeitversetzte Nutzung, beispielsweise zur Vorwärmung von Bauteilen oder für die Innenraumheizung. Dies könnte den Rückkühlbedarf minimieren und den Kabelquerschnitt reduzieren, ohne zusätzlichen Energiebedarf für die Rückkühlung zu erzeugen.

Passive Zwischenspeicherung der Wärme

Um den zusätzlichen Ressourcenbedarf oder die erhöhten Energieverluste durch verstärkte Rückkühlung des Kühlmediums bei der aktiven Kühlung der Ladekabel oder Verkabelungen zu vermeiden, wird hier als Anwendungsbeispiel die passive Zwischenspeicherung der Wärme herangezogen. Dabei wird überschüssige Wärme, insbesondere beim Schnellladen von Elektrofahrzeugen, in Phasenwechselmaterialien zwischengespeichert. Diese kann zu einem späteren Zeitpunkt an die Umgebung oder das System zurückgegeben werden, wenn aufgrund der Fahrtenbewegung und der damit verbundenen aktiven Konvektion ein erhöhtes Rückkühlpotenzial vorhanden ist.

Phasenwechselmaterialien nutzen die Umwandlungsenthalpie, beispielsweise beim Phasenübergang von Fest zu Flüssig, um Energie aufzunehmen. Dabei wird die Temperatur im System bis zur vollständigen Umwandlung des Materials nahezu konstant gehalten und steigt erst anschließend wieder. Zu einem späteren Zeitpunkt kann die Wärmeenergie aufgrund der Rückumwandlung, etwa von Flüssig zu Fest, gezielt und zeitlich verzögert zurück in das System oder die Umgebung abgegeben werden. Dadurch lassen sich notwendige Kühlpitzen reduzieren oder sogar vermeiden. In *Tabelle 1* sind beispielhafte Phasenwechselmaterialien für diese Anwendung mit zugehörigen Schmelzenthalpien im Umwandlungstemperaturbereich zwischen -30 und 80 °C dargestellt. Es wurden zwei Grundsysteme entwickelt, die visuell in *Bild 2* veranschaulicht sind. In *Bild 2a* wird das erste Grundsystem dargestellt, bei dem sich die Wärmequelle im äußeren Bereich befindet. Diese kann beispielsweise eine stromdurchflossene Kupferleitung oder eine mit heißem Fluid durchflossene Rohrleitung sein. Das ummantelnde Phasenwechselmaterial nimmt die Energie auf und hält die Temperatur konstant. *Bild 2b* zeigt das identische Grundsystem in umgekehrter Reihenfolge, wobei das Phasenwechselmaterial im Innenbereich durch die Wärmequelle umschlossen wird.

Temperaturen des Phasenwechselmaterials

Zur Charakterisierung der zeitabhängigen Temperaturentwicklung im System wurden FEM-Modelle mit variierten Geometrieparametern und Randbedingungen erstellt. Zusätzlich wurde ein Funktionsprototyp für das zweite Grundsystem auf-

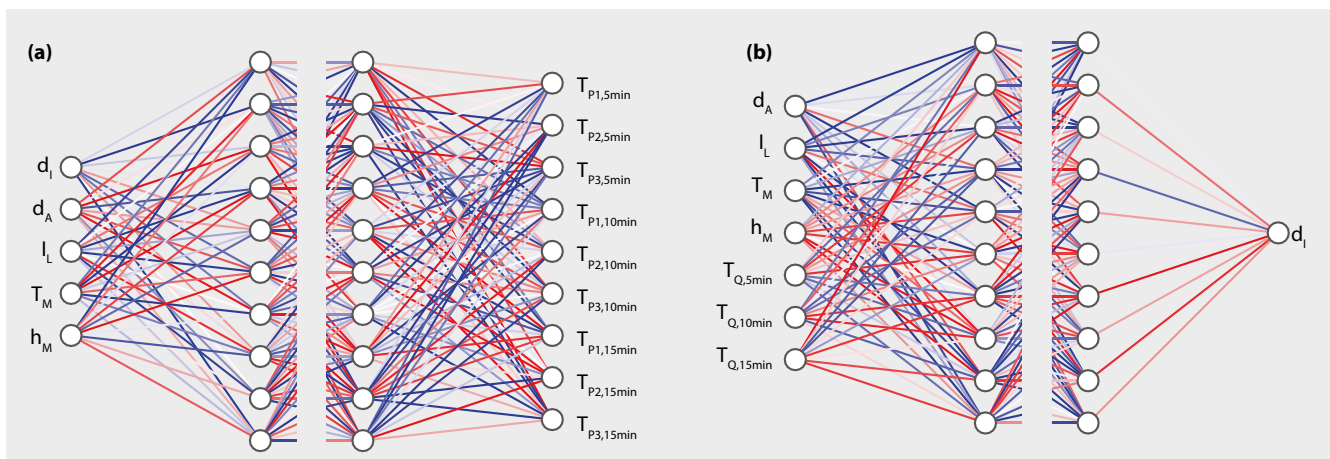


Bild 3 > Darstellung der Machine-Learning-Struktur mit beschrifteten Eingangs- und Ausgangsparametern: a) für die direkte Vorhersage der Temperaturen des Phasenwechselmaterials an diversen Positionen zu unterschiedlichen Zeitpunkten; b) für die Konvertierung der ursprünglichen Struktur und Vorhersage von ursprünglichen Eingangsparametern (© Digital Physics AI GmbH)

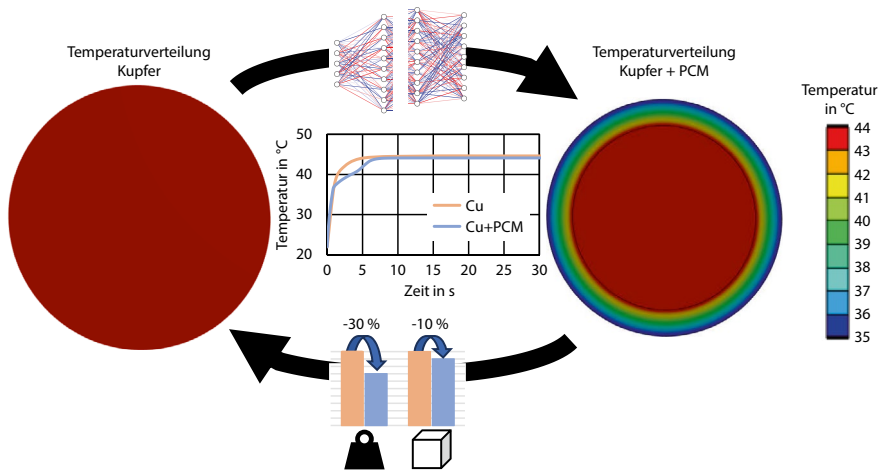


Bild 4 > Darstellung des Vorhersageergebnisses durch die Machine-Learning-Struktur und Abgleich mittels FEM-Simulation inklusive Angabe des Einsparpotenzials (© Digital Physics AI GmbH)

gebaut, der die Temperaturentwicklung in verschiedenen Bereichen des Phasenwechselmaterials sensorisch aufnimmt. Die Simulationsergebnisse wurden durch den Prototyp verifiziert, was zusätzlich zu einer verbesserten Datenlage führte. In *Tabelle 2* sind die variierten Parameter mit zugehörigem Designraum und die Verwendung als Eingabe- und Ausgabeparameter bei der Simulation und Optimierung durch Machine Learning aufgeführt. Dabei sind die verwendeten Parameter aus *Tabelle 2* ebenfalls in *Bild 2* zugeordnet und weisen folgende Struktur auf:

- Der Innendurchmesser d_i zeigt den Durchmesser der Kernkomponente (bei *Bild 2a* die Wärmequelle und bei *Bild 2b* das Phasenwechselmaterial) und wird als Geometrieparameter im Bereich von $\varnothing 2$ bis $\varnothing 15$ mm verwendet. Bei der Ausführung mit der Wärmequelle im Inneren (*Bild 2a*) führt ein geringerer Innendurchmesser zu einer erhöhten Stromdichte, wodurch erhöhte Verlustleistung entsteht. Bei einer Ausführung mit Phasenwechselmaterial im Kern (*Bild 2b*) hat eine Reduktion des Innendurchmessers eine Verringerung der möglichen Speichermenge der Wärmeenergie zur Folge.
- Die Außendicke d_A zeigt die Stärke der äußeren Komponente (bei *Bild 2a* das Phasenwechselmaterial und bei *Bild 2b* die Wärmequelle) und wird im Bereich von 0,5 bis 5 mm verwendet. Während bei der Ausführung mit dem Phasenwechselmaterial im Äußeren (*Bild 2a*) eine geringere Außendicke zu einer Verringerung der möglichen Speichermenge der Wärmeenergie führt, hat eine Ausführung mit der Wärmequelle im Äußeren (*Bild 2b*) eine Reduktion der Außendicke zu einer erhöhten Stromdichte zur Konsequenz, wodurch erhöhte Verlustleistung entsteht.

- Der Ladestrom I_L zeigt die verwendete Stromstärke beim Laden der Batterie und kann aus der Ladeleistung P_L und der Batteriespannung U ermittelt werden. Die Ladeströme wurden im Bereich zwischen 100 und 1000 A verwendet, um das gesamte Spektrum beim Schnellladen für Ladeleistungen zwischen 100 und 600 kW und Batteriespannungen von 400 bis 800 V abzudecken. Je höher der Ladestrom ist, desto höher ist auch die Stromdichte und somit auch die Verlustleistung.
- Die Schmelztemperatur des Phasenwechselmaterials zeigt die Temperatur des Phasenwechselmaterials, bei dem es von Fest auf Flüssig übergeht. Da Materialien im Bereich zwischen -30 und 80 °C untersucht wurden, wurden diese als Grenzwerte festgelegt. Eine Reduktion der Umwandlungstemperatur führt zu einer früheren Umwandlung, wodurch der Kern etwas früher auf einem kleineren Temperaturniveau festgehalten wird und somit der Innenwiderstand niedriger gehalten wird.

Die Schmelzenthalpie zeigt die Wärmemenge, die beim Fest-Flüssig-Übergang vom Phasenwechselmaterial aufgenommen werden kann. Diese Schmelzenthalpien wurden im Bereich zwischen 100 und 300 J/g untersucht, da sich die untersuchten Materialien beispielsweise aus

Tabelle 1 in diesem Bereich befinden. Je höher dieser Wert ist, umso mehr Energie kann auf kleinem Raum zwischengespeichert werden. Diese Schmelzenthalpie ist jedoch mit der Materialauswahl nur eingeschränkt verfügbar.

Die Temperaturen des Phasenwechselmaterials wurden an zwei unterschiedlichen Positionen und die Temperatur der Wärmequelle wurde im Zentrum ausgewertet. Die Verwendung von Machine Learning ermöglicht es, den Zusammenhang zwischen Energiemenge, Geometrien, Materialien und Simulations- oder Messergebnissen (etwa den Temperaturen der Phasenwechselmaterialien und der Wärmequelle) zu trainieren. Dadurch können verschiedene Kombinationen untersucht werden, ohne zusätzliche Simulationen oder Messungen durchführen zu müssen, *Bild 3a*. Durch Umstellung der Eingangs- und Ausgangsstruktur kann die Machine-Learning-Struktur neu trainiert werden, was in der Regel schneller ist als Simulationen. Dadurch kann ein Optimierungsproblem umgangen werden. Es ist möglich, aus vorgegebenen Geometrieparametern, Randbedingungen und gewünschten Temperaturen zu bestimmten Zeiten einen Geometrieparameter zu ermitteln, der die jeweilige Aufgabenstellung erfüllt.

Ergebnis

Aufgrund des trainierten Systems für die Optimierung des Innendurchmessers für eine gewünschte Maximaltemperatur bei festgelegten weiteren Randbedingungen und Geometrieparametern konnte ein Innendurchmesser durch Machine Learning ermittelt werden, *Bild 3b*. Mithilfe der ersten Machine-Learning-Struktur, *Bild 3a*, konnten die Temperaturverläufe an den drei Messpunkten im System vorhergesagt werden. Diese Vorhersagewerte wurden durch eine mit den ermittelten Durchmessern durchgeführte Simulation verglichen, wobei eine Vorhersagegenauigkeit von über 95 % durch die trainierte Machine-Learning-Struktur erzielt werden konnte. Zusätzlich war es in dieser Aufgabenstellung durch die Reduktion des Leitungsquerschnitts

Material	Chemische Formel	Schmelztemperatur T_M in °C	Schmelzenthalpie Δh_M in J/g
n-Dekan	$C_{10}H_{22}$	-29,65	201,70
n-Eicosan	$C_{20}H_{42}$	36,35	246,80
n-Pentacosan	$C_{25}H_{52}$	53,15	161,90
n-Triacontan	$C_{30}H_{62}$	65,05	161,50
n-Tetracontan	$C_{40}H_{82}$	80,85	240,70

Tabelle 1 > Richtwerte von Schmelztemperaturen und Schmelzenthalpien beispielhaft ausgewählter Alkane [1] (© Digital Physics AI GmbH)

Kategorie	Parameter		Grenzwerte		Einheit	Simulation	ML-Vorhersage	ML-Optimierung
Geometrie	Innendurchmesser	d_i	2	15	mm	Eingang	Eingang	Ausgang
	Außendicke	d_a	0,5	5	mm	Eingang	Eingang	Eingang
Randbedingung	Ladestrom	I_L	100	1.000	A	Eingang	Eingang	Eingang
	Schmelztemperatur Phasenwechselmaterial	T_M	30	70	°C	Eingang	Eingang	Eingang
	Schmelzenthalpie Phasenwechselmaterial	h_M	100	300	J/g	Eingang	Eingang	Eingang
Randbedingung	Temperatur 1 Phasenwechselmaterial	T_1	3 Zeitpunkte		°C	Ausgang	Ausgang	-
	Temperatur 2 Phasenwechselmaterial	T_2	3 Zeitpunkte		°C	Ausgang	Ausgang	-
	Temperatur Wärmequelle	T_Q	3 Zeitpunkte		°C	Ausgang	Ausgang	Eingang

Tabelle 2 > Darstellung der gesamten Parameter inklusive Angabe der Grenzwerte für die Verwendung in der Simulation sowie Struktur der Einzelparameter als Eingangsparameter oder Ausgangsparameter für die Simulation und bei der Machine-Learning-Vorhersage und -Optimierung (© Digital Physics AI GmbH)

mithilfe von abgestimmten Phasenwechselmaterialien möglich, eine Gewichts- einsparung von bis zu 30 % zu erreichen. Ebenso konnte das Volumen um bis zu 10 % reduziert werden, ohne Einbußen in der Performance hinnehmen zu müssen. *Bild 4* zeigt die Vergleiche der Strukturen ohne Phasenwechselmaterial (links) mit jenen mit Phasenwechselmaterial (rechts), wobei diese eine ähnliche maximale Temperaturentwicklung zeigen. Diese Einsparungen können für verschiedene gewünschte Temperaturbereiche, Geometrien und Randbedingungen innerhalb der jeweiligen Grenzwerte in wenigen Sekunden durch die Machine-Learning-Struktur untersucht werden, ohne erneute Simulationen durchführen zu müssen. Somit ermöglicht die Kombination von Simulation, sensorischen Messungen und Machine Learning eine effiziente Durchführung zahlreicher Untersuchungen und Bewertungen.

Zusammenfassung und Ausblick

Im Zuge des Elektromobilitätsbooms und des damit einhergehenden Wandels in der Energieversorgung gewinnt die Energieeffizienz bei Elektrofahrzeugen an Bedeutung. Die Forschung steht vor der Herausforderung, innovative Lösungen für das Wärme- management zu entwickeln. Besonders relevant ist dies im Hinblick auf die steigende Nachfrage nach schnellem Laden mit über 150 kW Leistung. Hierbei entstehende hohe Ladeströme bringen jedoch erhebliche Erwärmungsprobleme in den Batteriesystemen und der Ladeinfrastruktur mit sich. Um diesen Herausforderungen zu begegnen, bietet der Einsatz von Machine Learning

neue Möglichkeiten. Diese Technologie ermöglicht eine systematische Analyse komplexer Zusammenhänge zwischen verschiedenen Parametern. Dies erlaubt nicht nur eine eingehende Untersuchung verschiedener Kombinationen, sondern auch eine effiziente Lösung von Optimierungsproblemen. Verschiedene Ansätze zur Minimierung von Verlusten im Wärmemanagement werden diskutiert, darunter die passive Zwischenspeicherung von Wärme in Phasenwechselmaterialien. Die vorgestellten Grundsysteme und ihre Simulationsergebnisse zeigen, wie durch die gezielte Anwendung von Phasenwechselmaterialien in Verbindung mit Machine Learning eine effektive Reduktion von Gewicht und Ressourcen möglich ist. Diese Kombination erlaubt es, unterschiedliche Szenarien innerhalb kurzer Zeit zu analysieren, ohne aufwendige Simulationen durchführen zu müssen. Der Beitrag erläutert anhand des gewählten Beispiels die Chancen der KI-gestützten Bauteiloptimierung im Kontext der Erhöhung der Lade- und Energieeffizienz und präsentiert somit eine vielversprechende Perspektive für die weitere Entwicklung von effizienten Wärmemanagementlösungen in der Elektromobilität. //

Literaturhinweis

[1] Dirand, M.; Bouroukba, M.; Briard, A. J.; Chevallier, V.; Petitjean, D.; Corriou, J. P.: Temperatures and enthalpies of (solid+ solid) and (solid+ liquid) transitions of n-alkanes. In: The Journal of Chemical Thermodynamics 8 (2002), S. 1255-1277

Autoren | Kontakt

Florian Dirisamer B. Sc., Complex Systems Engineer, Digital Physics AI GmbH, florian.dirisamer@digital-physics.com

Dipl.-Ing (FH) M. Eng. Markus Thurmeier, Vorentwicklung Exterieur, AUDI AG, markus.thurmeier@audi.de

Digital Physics AI GmbH

Obere Landstraße 19
A-4055 Pucking
office@digital-physics.com
www.digital-physics.com

AUDI AG

I/ER-11
85045 Ingolstadt
imprint@audi.de
www.audi.com



Elektromobilität



Markus Rochowicz: Elektromobilität erfordert angepasste Partikelprüfung. www.springerprofessional.de/link/25550620