



Predictive Maintenance

Predictive Maintenance ist eine zustandsbasierte Instandhaltungsstrategie, die Wartungsbedarfe frühzeitig aus Betriebs- und Sensordaten ableitet. Ausfälle und ungeplante Stillstände werden vermieden und so Effizienz und Versorgungssicherheit erhöht.

Predictive Maintenance, auch prädiktive Instandhaltung genannt, bezeichnet eine Instandhaltungsstrategie, bei der Wartungsmaßnahmen gezielt dann durchgeführt werden, wenn sie tatsächlich erforderlich sind. Gleichzeitig sollen Ausfälle möglichst bereits vor ihrem Eintreten erkannt und vermieden werden. Grundlage hierfür ist die kontinuierliche Erfassung von Betriebs- und Zustandsdaten von Netzkomponenten wie Leitungen oder Transformatoren über Sensoren, die anschließend mithilfe von KI- oder datenbasierten Algorithmen ausgewertet werden, um Verschleiß oder potenzielle Ausfälle frühzeitig zu erkennen und vorherzusagen.

Dieser Ansatz wird branchenübergreifend insbesondere dort eingesetzt, wo ungeplante Stillstände hohe Kosten verursachen oder sicherheitskritische Auswirkungen haben. Im Mittelpunkt steht dabei der Übergang von reakti-

ven oder pauschalen Wartungsstrategien hin zu datenbasierten Entscheidungsmodellen (siehe Abbildung 1) (Karwa, 2024).

Im Kontext der Energieinfrastruktur kann Predictive Maintenance einen wichtigen Beitrag zur Versorgungssicherheit leisten. Durch die frühzeitige Identifikation potenzieller Ausfälle in Strom-, Wärme- oder Gasnetzen können betroffene Komponenten rechtzeitig ersetzt oder gewartet werden, wodurch die Versorgungssicherheit und Zuverlässigkeit des Netzbetriebs erhöht wird (Subramanian, 2026). Gleichzeitig können Betriebsmittel auf Basis ihres tatsächlichen Zustands länger betrieben werden, anstatt sie vorsorglich nach Erreichen ihrer nominellen Lebensdauer auszutauschen. Dadurch können vorzeitige Ersatzinvestitionen vermieden und Kapitalkosten reduziert werden.




Abbildung 1: Vergleich von Instandhaltungsstrategien

Bewertung der Umsetzbarkeit

Zur Bewertung der Umsetzbarkeit KI- und datenbasierter Methoden für Predictive Maintenance werden im Folgenden zunächst geeignete Modellansätze vorgestellt. Darauf aufbauend erfolgt eine Einordnung hinsichtlich Implementierungsaufwand, Datenanforderungen und praktischer Integrationsaspekte.

Stand der Technik

Der Einsatz von Predictive Maintenance ist technologisch gut etabliert, da vergleichbare Systeme in anderen Branchen wie Industrie, Bahn oder Telekommunikation bereits erfolgreich eingesetzt werden. Dabei liegen umfangreiche Erfahrungen und erprobte Methoden vor, die grundsätzlich auf den Energiesektor übertragbar sind.

Im Bereich der Energieinfrastruktur befindet sich die Anwendung jedoch teilweise noch im Ausbau, da spezifische Anforderungen an Datenverfügbarkeit, Heterogenität der

Betriebsmittel und Systemintegration bestehen. Insgesamt kann der Stand der Technik daher als fortgeschritten, aber noch nicht vollständig flächendeckend umgesetzt eingeordnet werden.

Für Predictive Maintenance eignen sich verschiedene Modellklassen, die je nach Datenlage und Anwendungsfall unterschiedliche Stärken aufweisen. Klassische ML-Modelle wie Random Forest und Gradient Boosting sind besonders robust gegenüber verrauschten Daten und liefern häufig gute Ergebnisse bei vergleichsweise geringem Interpretationsaufwand. Support Vector Machines (SVM) eignen sich insbesondere für die Klassifikation von Zuständen, etwa zur Unterscheidung zwischen Normalbetrieb und Anomalien.

Neural Networks (NN) hingegen bieten Vorteile bei komplexen, nichtlinearen Zusammenhängen und großen Datenmengen, beispielsweise bei der Auswertung von Zeitreihen oder Sensordaten. Insgesamt hängt die Wahl des geeigneten Modells stark von der Datenverfügbarkeit, der Komplexität des Systems und den Anforderungen an Interpretierbarkeit und Genauigkeit ab (Karwa, 2024).

Die zugrunde liegenden Modelle basieren dabei auf mehreren methodischen Annahmen. Dazu zählen insbesondere modellierte Degradationsverläufe sowie die Schätzung der Restlebensdauer von Betriebsmitteln. Zudem werden Schwellenwerte zur Detektion von Abweichungen gegenüber dem Normalbetrieb definiert und unterschiedliche Fehlerklassen wie thermische Überlastung oder mechanischer Verschleiß unterschieden. In vielen Anwendungen erfolgt zusätzlich eine Priorisierung von Betriebsmitteln anhand ihrer Kritikalität im Netz. Ergänzend kann Transfer Learning eingesetzt werden, um Modelle auf unterschiedliche Anlagen oder Netzbereiche zu übertragen.

Implementierungsaufwand & Ressourcenbedarf

Ein wesentlicher Teil des Implementierungsaufwands entfällt auf die Integration der Lösung in bestehende IT- und OT-Systeme, insbesondere zur Anbindung von Sensorik, Datenplattformen und Instandhaltungsprozessen. Dabei spielen auch die Verfügbarkeit und Aufbereitung geeigneter Daten eine zentrale Rolle. Ein weiterer wesentlicher Teil entfällt auf die Aufbereitung und Harmonisierung heterogener Datenquellen.

Der konkrete Aufwand hängt zudem stark von der gewählten Umsetzungsstrategie ab:

- Interne Entwicklung: Es sind insbesondere Kompetenzen in den Bereichen Datenverarbeitung, ML-Modellierung und Systemintegration erforderlich.
- Entwicklung durch externe Dienstleister oder Nutzung bestehender Plattformlösungen: Hier kann die technische Umsetzung teilweise vereinfacht werden, gleichzeitig entstehen jedoch Anforderungen an die Integration in bestehende Prozesse und Systemlandschaften.

Datenbedarf, Datenverfügbarkeit & Datenqualität

Datenbedarf

Der Datenbedarf für Predictive Maintenance ist umfangreich und umfasst unterschiedliche Datenkategorien, die je nach Anwendungsfall unterschiedlich genutzt werden. Grundsätzlich ist dabei zwischen Trainingsdaten und operativen Eingangsdaten zu unterscheiden. Der konkrete Datenbedarf eines Modells hängt dabei sowohl von dessen Eigenschaften als auch von der Art und Heterogenität der betrachteten Betriebsmittel ab.

Trainingsdaten dienen der Entwicklung und Kalibrierung der Modelle. Hierzu zählen insbesondere historische Betriebsmitteldaten wie Störungs- und Ausfallprotokolle, Instandhaltungs- und Betriebsstundenhistorien sowie Messdaten (z. B. Lastgänge, Temperaturverläufe oder Überlastereignisse). Ergänzend werden Asset-Stammdaten (z. B. Baujahr, Hersteller, Nennleistung) sowie externe Daten wie Wetterinformationen oder herstellerspezifische Degradations- und Ausfallmodelle herangezogen, um Zusammenhänge zwischen Betriebszuständen und Ausfällen zu erlernen.

Operative Eingangsdaten hingegen werden im laufenden Betrieb verwendet, um den aktuellen Zustand von Anlagen zu bewerten und Vorhersagen zu treffen. Dazu zählen aktuelle Messdaten wie Temperaturen einzelner Komponenten (Transformatoren, Kabel), Spannung oder Strom, Informationen zum Betriebszustand (z. B. Betrieb, Wartung, Ausfall), Schaltzustände sowie aktuelle und prognostizierte Wetterdaten, da Umwelteinflüsse die Alterung und Ausfallwahrscheinlichkeit von Betriebsmitteln maßgeblich beeinflussen können. Ergänzt werden diese durch Inspektions- und Wartungsinformationen sowie Daten aus der Instandhaltungsplanung.

Datenverfügbarkeit & Datenqualität

In der Praxis besteht die Herausforderung darin, historische Trainingsdaten und operative Eingangsdaten konsistent zu verknüpfen und in ausreichender Qualität bereitzustellen. Dies erfordert insbesondere eine eindeutige Zuordnung zu Betriebsmitteln sowie die zeitliche Synchronisation unterschiedlicher Datenquellen, die häufig in unterschiedlichen Datenformaten und in separaten Systemen vorliegen. Zudem müssen Datenlücken, Inkonsistenzen und unterschiedliche Granularitäten ausgeglichen werden, um eine verlässliche Grundlage für Modelltraining und Betrieb zu schaffen.

Besonders kritisch ist dabei die Verfügbarkeit qualitativ hochwertiger historischer Betriebs-, Zustands- und Ereignisdaten. Hierzu zählen beispielsweise Messgrößen wie Temperatur sowie Informationen zu Fehlern, Ausfällen und Wartungen. Historische Betriebs- und Zustandsdaten liegen je nach Betriebsmittel und vorhandener Messinfrastruktur teilweise nur in begrenztem Umfang oder unterschiedlicher Qualität vor. Zusätzlich stellen Fehler- und Ausfalldaten eine besondere Herausforderung dar, da Ausfälle von Betriebsmitteln wie Transformatoren seltene Ereignisse sind und entsprechende Daten bei einzelnen VNBs häufig nicht in ausreichender Menge vorliegen, um robuste Modelle zu trainieren. Hier bietet ein kollaborativer Ansatz, z. B. durch gemeinsames Training über mehrere VNBs hinweg, großes Potenzial. Konzepte wie Federated Learning¹ ermöglichen dabei das gemeinsame Modelltraining ohne den direkten Austausch sensibler Betriebsdaten. Hersteller von Betriebsmitteln sind zunehmend ebenfalls aktiv, wobei perspektivisch Initiativen wie der Digitale Produktpass standardisierte Lebenslauf- und Zustandsdaten für Betriebsmittel herstellerübergreifend zugänglich machen könnten. Insgesamt sind daher vor allem Datenintegration und -qualität entscheidend für den Erfolg von Predictive Maintenance.

Technische Eigenschaften & Effekte

Da es sich primär um Planungs- und Entscheidungsunterstützungssysteme handelt, bestehen keine harten Echtzeitanforderungen. Eine regelmäßige Datenverarbeitung in Intervallen von stündlich bis täglich ist in der Regel ausreichend.

¹ Federated Learning ist ein dezentrales Trainingsverfahren, bei dem ein gemeinsames KI-Modell trainiert wird, ohne dass die Rohdaten der beteiligten Teilnehmer zentral zusammengeführt werden. Stattdessen werden nur die lokal berechneten Modellparameter ausgetauscht.

Robustheit & Fehlertoleranz

Die Anforderungen an Robustheit und Fehlertoleranz sind im Vergleich zu echtzeitkritischen Anwendungen geringer, dennoch spielen insbesondere die Vermeidung von Fehlalarmen sowie der Umgang mit unvollständigen oder fehlerhaften Sensordaten eine wichtige Rolle. Fehlalarme sind dabei nicht nur ein technisches Problem, sondern haben unmittelbare wirtschaftliche Konsequenzen, da unnötig ausgelöste Wartungseinsätze direkte Kosten verursachen und langfristig die Akzeptanz des Systems beim Instandhaltungspersonal gefährden können.

Gleichzeitig ist eine zuverlässige Datenprüfung, insbesondere zur Erkennung und Behandlung von Ausreißern und Datenlücken, erforderlich, um die Qualität der Modelle und die Verlässlichkeit der Prognosen sicherzustellen. Dies kann beispielsweise durch Datenvalidierung, Ensemble-Ansätze oder die Kombination datenbasierter Verfahren mit physikalischen Degradations- und Zustandsmodellen unterstützt werden.

Erklärbarkeit & Nachvollziehbarkeit

Die Erklärbarkeit und Nachvollziehbarkeit spielen eine wichtige Rolle für die unternehmensinterne Akzeptanz von Predictive Maintenance. Da Entscheidungen auf Basis von Modellvorhersagen getroffen werden, ist ein transparentes Verständnis der zugrunde liegenden Einflussfaktoren erforderlich.

Der Einsatz von Methoden der erklärbaren KI (XAI) trägt dazu bei, die Modellentscheidungen nachvollziehbar zu machen. Techniken wie SHAP² ermöglichen eine globale Analyse der wichtigsten Einflussgrößen, während LIME³ lokale Erklärungen für einzelne Vorhersagen oder Anomalien liefert (P., 2024).

Eingriffstiefe der Anwendung in Prozesse

Die Eingriffstiefe in bestehende Prozesse hängt maßgeblich vom gewählten Integrations- und Automatisierungsgrad ab und ist durch den Netzbetreiber flexibel gestaltbar. Technisch erfolgt die Einbindung typischerweise entlang der bestehenden Systemarchitektur von der Sensorik über

SCADA-Systeme und Datenplattformen bis hin zum Asset-Management-System und der Instandhaltungsplanung.

- **Parallelbetrieb:** In einer ersten Stufe fungiert Predictive Maintenance als Entscheidungsunterstützung und läuft parallel zu bestehenden Instandhaltungskonzepten. Die KI generiert Zustandsberichte und Warnmeldungen, während die Instandhaltungsentscheidung vollständig beim Menschen verbleibt. Gleichzeitig werden die Modelle kontinuierlich anhand realer Ausfälle validiert und weiterentwickelt.
- **Prozessintegration:** In einer weiterentwickelten Stufe erfolgt eine stärkere Prozessintegration, bei der Ergebnisse automatisiert in die Wartungsplanung einfließen. Dies umfasst beispielsweise die Priorisierung von Inspektionen oder die automatische Erstellung von Wartungsaufträgen, wofür eine enge Anbindung an das Asset-Management-System erforderlich ist. Die finale Entscheidung über die Durchführung von Wartungsmaßnahmen verbleibt dabei stets beim zuständigen Instandhaltungspersonal – die KI übernimmt die Priorisierung und Vorbereitung, nicht die Ausführung.

Organisatorische & regulatorische Rahmenbedingungen

Organisatorisch ist insbesondere das Change-Management von zentraler Bedeutung, da bestehende Wartungsprozesse und Entscheidungsabläufe angepasst werden müssen. Der Übergang von zeit- oder intervallbasierter Instandhaltung hin zu zustandsbasierten, datenbasierten Entscheidungen erfordert eine enge Abstimmung zwischen Betrieb, Instandhaltung und IT sowie eine entsprechende Qualifizierung der Mitarbeitenden.

Aus regulatorischer Sicht ist der Einsatz von Predictive Maintenance im Regelfall nicht als Hochrisiko-Anwendungsfall im Sinne des EU AI Acts einzustufen, da keine direkten sicherheitskritischen Steuerungsentscheidungen automatisiert getroffen werden.

Risiken & Sicherheitsaspekte

Risiken

Die Sicherheitsaspekte von Predictive Maintenance sind insgesamt als eher unkritisch einzustufen. Es bestehen keine direkten Eingriffe in operative Systeme und keine

² SHAP (SHapley Additive exPlanations) ist eine Methode zur Erklärung von KI-Modellentscheidungen durch Quantifizierung des Einflusses einzelner Eingangsvariablen.

³ LIME (Local Interpretable Model-agnostic Explanations) ist eine Methode zur lokalen Erklärung von KI-Modellentscheidungen, die für einen einzelnen Datenpunkt ein vereinfachtes Ersatzmodell anpasst und damit aufzeigt, welche Eingangsvariablen die jeweilige Vorhersage maßgeblich beeinflusst haben.

Echtzeitanforderungen, sodass das Risikoprofil insgesamt gering ist. Ein fehlerhaftes Modell führt im schlimmsten Fall lediglich zu einem nicht vorhergesagten Ausfall, was dem Status quo ohne Predictive Maintenance entspricht und somit keine zusätzliche Verschlechterung darstellt.

Cybersicherheit

Dennoch ergeben sich spezifische Risiken im Bereich der Datenerfassung, insbesondere durch im Feld installierte IoT-Sensoren. Diese können potenziell Ziel von Manipulationen sein, etwa durch verfälschte Sensordaten. Daraus ergeben sich Anforderungen an eine sichere IoT-Kommunikation sowie an die physische Absicherung der eingesetzten Geräte. Da keine direkte Anbindung an operative Steuerungssysteme besteht, ergeben sich keine spezifischen OT-Sicherheitsanforderungen über die üblichen IT-Sicherheitsmaßnahmen hinaus.

Bewertung des Nutzens

Zur Bewertung des Nutzens erfolgt zunächst eine Darstellung der Kostenpositionen, die sowohl die einmaligen Investitionskosten (CAPEX) als auch die jährlichen Betriebskosten (OPEX) umfasst. Dadurch wird eine transparente Grundlage zur Einordnung des finanziellen Aufwands geschaffen. Darüber hinaus wird der Nutzen anhand des Beitrags zur betrieblichen Effizienz sowie des Potenzials für Wissensgewinn und kontinuierliche Verbesserung bewertet.

Einmalige Investitionskosten

Die einmaligen Investitionskosten werden weniger durch die Modellentwicklung als vielmehr durch Daten- und Systemintegration bestimmt. Ein zentraler Kostenblock ist die Dateninfrastruktur und -aufbereitung, da unstrukturierte Wartungs- und Ausfalldaten bereinigt, harmonisiert und integriert werden müssen. Ebenfalls relevant ist die Anbindung an bestehende IT- und OT-Systeme wie SCADA- und Asset-Management-Systeme, um eine durchgängige Nutzung in der Instandhaltungsplanung zu ermöglichen.

Die Modellentwicklung und das Training fallen vergleichsweise moderat aus, werden jedoch durch Validierung und Testbetrieb ergänzt. Weitere variable Kosten entstehen durch Sensorik sowie durch Schulung und Change-Management zur Anpassung bestehender Prozesse. Insgesamt liegen die größten Investitionen damit in der Datenintegration und organisatorischen Umsetzung, nicht in der KI-Entwicklung selbst.

Jährliche Kosten

Die jährlichen Betriebskosten werden vor allem durch organisatorische Aufwände sowie die kontinuierliche Modellpflege geprägt. Die Kosten für Inferenzserver bzw. virtuelle Maschinen sind gering, da keine Echtzeitanforderungen bestehen und die Modelle in der Regel in regelmäßigen Intervallen ausgeführt werden. Auch der GPU-Compute für gelegentliches Retraining fällt nur begrenzt an, da Modelupdates meist ereignis- oder zeitgesteuert erfolgen.

Ein wesentlicher Kostenblock entsteht durch die laufende Anpassung der Modelle an neue Betriebszustände, Anlagenalterung und veränderte Datenverteilungen. Ergänzend fallen Aufwände für Dokumentation und Monitoring an, um Nachvollziehbarkeit und Modellgüte sicherzustellen. Insgesamt werden die Betriebskosten somit primär durch die kontinuierliche Modellpflege bestimmt, während die Infrastruktur nur einen untergeordneten Anteil ausmacht.

Beitrag zur betrieblichen Effizienz

Der Beitrag zur betrieblichen Effizienz zeigt sich insbesondere in der Abkehr von reaktiven oder pauschalen Instandhaltungsstrategien hin zu datenbasierten, zustandsorientierten Entscheidungen. Durch die kontinuierliche Überwachung von Betriebsmitteln können potenzielle Fehler frühzeitig erkannt und Ursachen analysiert werden, wodurch ungeplante Ausfälle reduziert werden (Cao, 2024).

Gleichzeitig ermöglicht der Ansatz eine Senkung der Wartungskosten, da Maßnahmen bedarfsgerecht statt in festen Intervallen durchgeführt werden. Dies führt zu einem strukturierten Wartungsprozess von der Zustandsüberwachung über die Diagnose bis hin zur Planungsentscheidung.

Darüber hinaus ergeben sich Effizienzgewinne durch eine verlängerte Lebensdauer von Betriebsmitteln, eine höhere Anlagenverfügbarkeit sowie eine optimierte Ressourcenplanung für Personal, Ersatzteile und Wartungsfenster. Insgesamt wird die Asset-Bewertung transparenter und die Entscheidungsqualität im Instandhaltungsprozess verbessert.

Auf strategischer Ebene unterstützen diese Erkenntnisse zudem die Reinvestitionsplanung, Budgetprognosen und die Risikobewertung im Netzbetrieb. Insgesamt ermöglichen sie damit sowohl eine effizientere Betriebsführung als auch fundiertere langfristige Entscheidungen (Gandhi, 2024).

Potenzial für Wissensgewinn & kontinuierliche Verbesserung

Das Potenzial für Wissensgewinn und kontinuierliche Verbesserung liegt insbesondere in der fortlaufenden Erweiterung und Verfeinerung der zugrunde liegenden Daten- und Modellbasis. Durch die stärkere Übertragbarkeit auf unterschiedliche Anlagen und Betriebsbedingungen können Modelle flexibel auf neue Einsatzkontexte angepasst und skaliert werden. Die Integration realer Felddaten, insbesondere langfristiger Betriebs- und hochqualitativer Fehlerdaten, verbessert dabei kontinuierlich die Aussagekraft der Modelle (Marangis, 2024). Gleichzeitig ermöglicht dies eine frühzeitigere Fehlererkennung, da der Vorhersagehorizont sukzessive erweitert werden kann. Darüber hinaus führen die gewonnenen Erkenntnisse zu einer robusteren Erkennung von Fehlerbildern, einschließlich seltener oder bislang unbekannter Ereignisse. Insgesamt entsteht ein kontinuierlicher Lernprozess, bei dem sich Modelle und Systemverständnis über die Zeit hinweg systematisch verbessern.

Fazit

Predictive Maintenance stellt einen vielversprechenden Ansatz dar, um Instandhaltungsprozesse von reaktiven oder intervallbasierten Strategien hin zu datenbasierten Entscheidungen weiterzuentwickeln. Durch KI-basierte Methoden können Verschleiß und potenzielle Ausfälle frühzeitig erkannt werden, wodurch ungeplante Stillstände reduziert sowie Effizienz und Versorgungssicherheit erhöht werden. Gleichzeitig bietet der Ansatz Potenzial für einen kontinuierlichen Wissensgewinn und eine langfristige Optimierung von Betriebs- und Instandhaltungsprozessen.

Der mit der Umsetzung verbundene Aufwand ist insbesondere durch die erforderliche Daten- und Systemintegration geprägt. Wesentliche Kosten entstehen durch die Aufbereitung und Integration von Wartungs- und Ausfalldaten, die Anbindung bestehender IT- und OT-Systeme sowie die kontinuierliche Modellpflege und das Monitoring. Da keine Echtzeitanforderungen bestehen, bleibt der Aufwand für die Recheninfrastruktur gering.

Insgesamt ist Predictive Maintenance im Vergleich zu anderen betrachteten Anwendungen zunächst eher mit einer niedrigeren Priorität einzuordnen. Ausschlaggebend sind das begrenzte Nutzenpotenzial sowie der vergleichs-

weise höhere Aufwand für Datenintegration, Systemanbindung und organisatorische Umsetzung. Gleichzeitig bietet die Anwendung durch die Weiterentwicklung der KI-Methoden und die zunehmende Verfügbarkeit von Betriebs- und Instandhaltungsdaten langfristig weiteres Potenzial. Predictive Maintenance befindet sich damit an der Schwelle zu einer langfristigen Zielanwendung und eignet sich insbesondere für eine schrittweise Weiterentwicklung, sobald die erforderlichen Daten- und Systemgrundlagen geschaffen sind.

Referenzen

- Cao, N. (2024). *Research on Key Technology and Applications of Predictive Maintenance for Wind Turbines*.
- Gandhi, K. (2024). *Predictive Maintenance for Transformers and Substation Equipment Using Sensor Time-Series Models*.
- Karwa, R. R. (2024). *Predictive Maintenance: Machine Learning Approaches for Enhanced Equipment Reliability*.
doi:10.1109/IDICAIEI61867.2024.10842946
- Marangis, D. (2024). *Data-driven Predictive Maintenance Alerting Routine for utility-scale Photovoltaic Systems*.
- P., R. (2024). *A Surrogate Approach to Explainable AI for Predictive Maintenance: Techniques and Applications*.
doi:10.1109/I4C62240.2024.10748524
- Subramanian, N. (2026). *Digital twin applications and case studies in modern power grid management*.



Bundesministerium
für Wirtschaft
und Energie

Die Veröffentlichung dieser Publikation erfolgt im Auftrag des Bundesministeriums für Wirtschaft und Energie. Die Deutsche Energie-Agentur GmbH (dena) unterstützt die Bundesregierung in verschiedenen Projekten zur Umsetzung der energie- und klimapolitischen Ziele im Rahmen der Energiewende.

KONTAKT
Dr. Jakob Schieder-Hestermann
Themengebietsleiter Stromnetze

Tel.: +49 30 66 777-159
E-Mail:
Jakob.Schieder-Hestermann@dena.de

Deutsche Energie-Agentur GmbH (dena)
Chausseestraße 128 a
10115 Berlin

<https://www.dena.de/> | Stand: 10/2026

Alle Rechte sind vorbehalten. Die Nutzung steht unter dem Zustimmungsvorbehalt der dena.