




**PROCON IT**  
A CONET COMPANY

# LÖSUNG IN SICHT

In 6 Schritten zum erfolgreichen  
Computer-Vision-Projekt



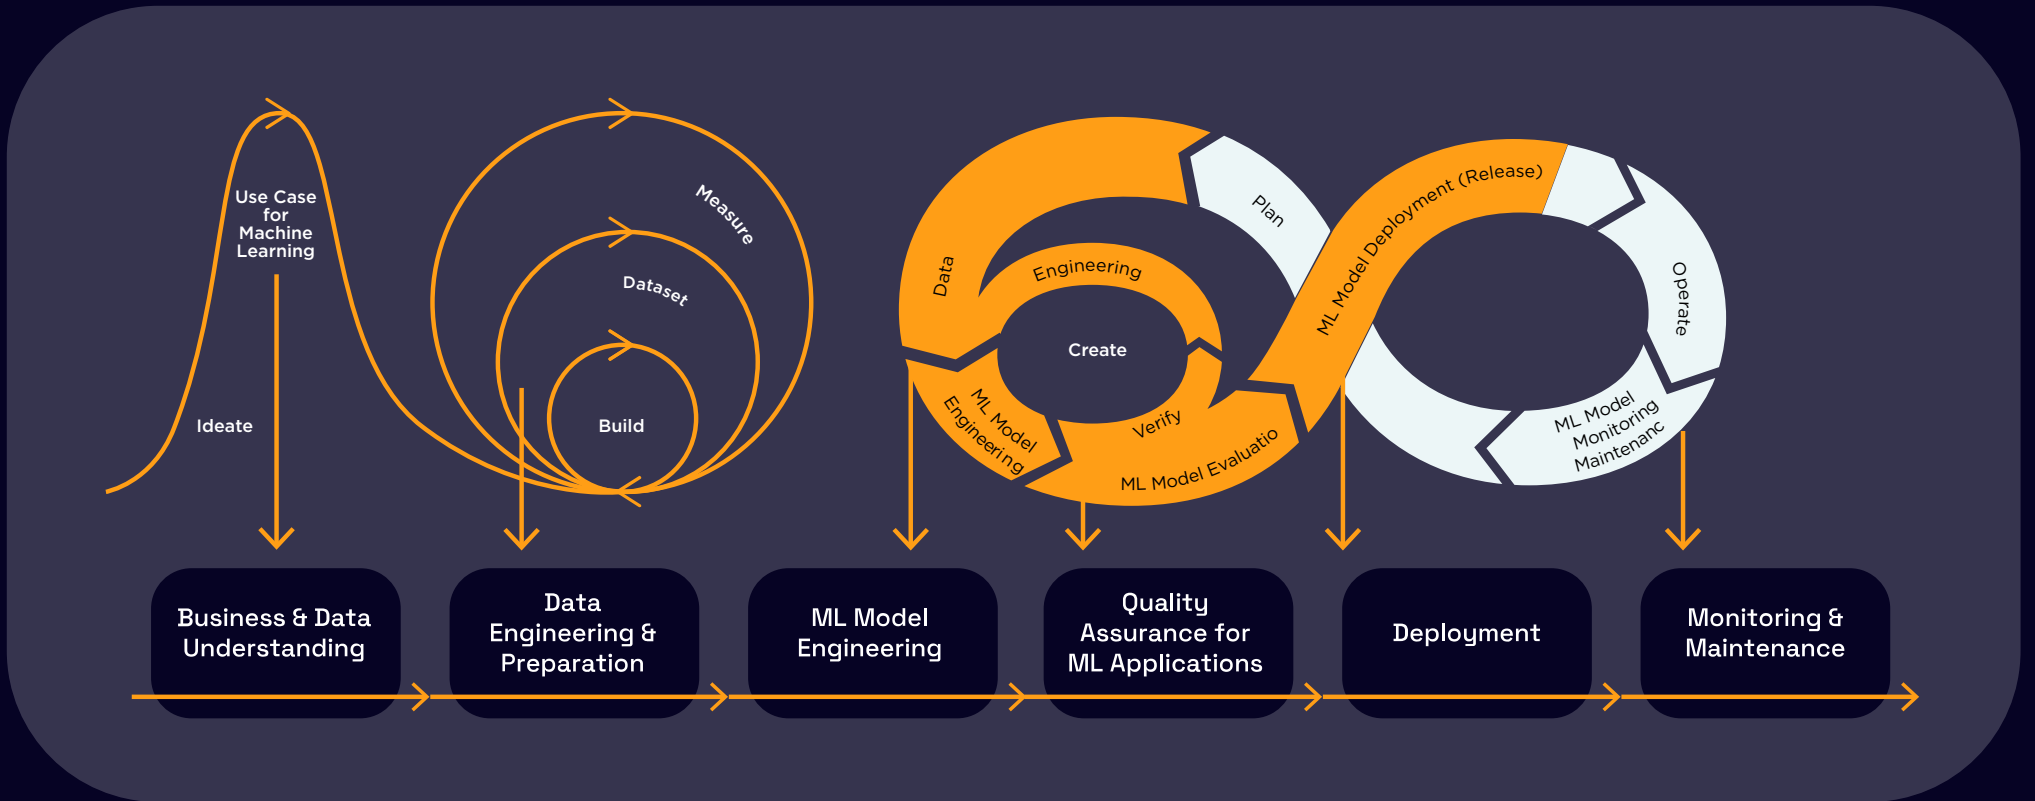
# VON PIXELN ZU PERSPEKTIVEN

## Ein tiefgehender Blick auf Computer Vision

Computer Vision ist der Bereich der Künstlichen Intelligenz, der es Maschinen ermöglicht, visuelle Daten wie Bilder und Videos zu interpretieren. Durch den Einsatz von fortschrittlichen Deep-Learning-Algorithmen wie Convolutional Neural Networks oder Vision Transformers können so beispielsweise Defekte oder Verschmutzungen erkannt und lokalisiert, Bauteile gezählt oder Schrift automatisiert eingelesen werden. Auch im Bereich generativer KI nimmt Computer Vision einen zentralen Platz ein: So können Bildbeschreibungen generiert, Schwarz-Weiß-Bilder eingefärbt oder gar neue Bilder anhand von Textbeschreibungen erstellt werden.

Bei der Entwicklung eines Computer-Vision-Projekts ist die Erstellung von problemspezifischen Machine-Learning-Modellen entscheidend. Wie die Modelle selbst haben sich auch die Methoden zur Steuerung von Machine-Learning-Projekten in den vergangenen Jahren enorm weiterentwickelt.

Durch den Erfolg von DevOps-Prinzipien in der klassischen Softwareentwicklung haben entsprechende Vorgehensweisen auch Einzug in die Umsetzung von Machine Learning (ML) unter dem Begriff MLOps gefunden – und damit auch in Computer-Vision-Projekte. Um eine einheitliche Ausrichtung für den Entwicklungszyklus von ML-Projekten vorzugeben, wurde der Cross-Industry Standard Process for the development of Machine Learning applications with Quality assurance methodology (CRISP-ML(Q) [1,2]) entwickelt, der ML-Projekte in 6 kontinuierlich wiederkehrende Phasen unterteilt.



## HOCHWERTIGE & STABILE COMPUTER-VISION-MODELLE ENTWICKELN Mit dem Projektmanagement-Ansatz CRISP-ML(Q)

CRISP-ML(Q) ist ein Prozessmodell für die Entwicklung von Machine-Learning-Anwendungen. Aufbauend auf dem Industriestandard CRISP-DM (DM = Data Mining) [3] stellt es Maschinenlernpraktikern eine Art Checkliste von aufeinander aufbauenden Tasks zur Verfügung. Diese wiederholen sich über die gesamte Projektlaufzeit hinweg, um das Gesamtprodukt kontinuierlich zu verbessern. Diese Tasks lassen in die 6 im obigen Bild [2] dargestellten Phasen unterteilen:

**Business & Data Understanding – Data Engineering & Preparation – ML Model Engineering – Quality Assurance for ML Applications – Deployment – Monitoring & Maintenance**



CRISP-ML(Q) ist ein explizit iteratives Prozessmodell. Das heißt, dass inkrementelle Produktverbesserungen durch das Zurückkehren zu vorhergehenden Phasen fester Bestandteil der Vorgehensweise sind. Im Vergleich zu CRISP-DM, das sich als Industriestandard für Data-Mining-Projekte etabliert hat, legt CRISP-ML(Q) einen stärkeren Fokus auf kontinuierliche Qualitätssicherung und Risikominimierung in jeder einzelnen Projektphase. Anforderungen und äußere Beschränkungen werden durch messbare Kenngrößen definiert. Des Weiteren führt CRISP-ML(Q) eine weitere Projektphase für Monitoring & Maintenance in den Lebenszyklus mit ein. Hier wird das ML-Modell im Produktivbetrieb kontinuierlich überwacht, um sich ändernde Bedingungen wie Model oder Data Drift aufspüren und frühzeitig gegensteuern zu können. Die beiden Phasen Business and Data Understanding, die in CRISP-DM getrennt voneinander betrachtet werden, werden in CRISP-ML(Q) zu einer Phase zusammengefasst, um der engen Verzahnung beider Bereiche Rechnung zu tragen.

Im Folgenden präsentieren wir Ihnen die Umsetzung eines Computer-Vision-Projekts in einer Großbäckerei mithilfe von CRISP-ML(Q) und gehen dabei auf die spezifischen Anforderungen von Bildverarbeitungsprojekten ein.

Quellen:

[1] Studer, S.; Bui, T.B.; Drescher, C.; Hanuschkin, A.; Winkler, L.; Peters, S.; Müller, K.-R. Towards CRISP-ML(Q): A Machine Learning Process Model with Quality Assurance Methodology. *Mach. Learn. Knowl. Extr.* 2021, 3, 392-413. <https://doi.org/10.3390/make3020020>

[2] Visengeriyeva, L., Kammer, A., Bär, I., Kniesz, A., Plöd, M., & Eberstaller, S. (2023, August 11). ML-ops.org. CRISP-ML(Q). <https://ml-ops.org/content/crisp-ml>

[3] Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinartz, T., Shearer, C., & Wirth, R. (2000). CRISP-DM 1.0: Step-by-step data mining guide. SPSS inc, 9 (13), 1-73.

# 1. BUSINESS AND DATA UNDERSTANDING

## Die Grundlage aller datenbasierten Projekte


In der Großbäckerei Knusperkönig werden täglich tausende Kekse hergestellt und verpackt. Um gerissenes oder gebrochenes Gebäck auszusortieren, soll ein innovatives Projekt mit KI und Machine Learning gestartet werden. Mithilfe von Kameras und Computer-Vision-Modellen sollen die Gebäckstücke automatisch gescannt und analysiert werden. Durch die Entfernung von fehlerhaftem Gebäck soll nicht nur die Produktqualität sichergestellt, sondern auch wertvolle Arbeitszeit eingespart werden, da die manuelle Inspektion durch das menschliche Auge entfällt.

### **Business Understanding – geschäftliche Aspekte:**

Vor den technischen Aspekten muss der geschäftliche Kontext verstanden werden. Ziel ist es, Gebäck, das nicht dem Qualitätsstandard entspricht, automatisch von der Produktionslinie zu entfernen, um dadurch Kosten und Arbeitskraft einzusparen. Dadurch wird außerdem die Qualität der Produkte erhöht und somit die Kundenzufriedenheit langfristig gesteigert, wodurch Kunden zu einem erneuten Kauf des Produkts animiert werden.

### **Data Understanding – der Datenschatz des Unternehmens:**

Computer-Vision-Daten sind visuell und können Bilder oder Videos umfassen. Diese Daten sind besonders, da sie spezielle Verarbeitungstechniken erfordern. Computer-Vision-Modelle können Merkmale aus visuellen Daten lernen und nutzen, um Aufgaben wie die Erkennung von Produktionsfehlern zu bewältigen. Die Daten der Firma Knusperkönig umfassen Bilder oder Videosequenzen von Gebäckstücken. Die Aufnahmen können unter verschiedenen Winkeln, Abständen oder unterschiedlicher Beleuchtung gemacht worden sein. Es gibt verschiedene Arten von Gebäckstücken, die entweder in die Kategorie „fehlerfrei“ oder in eine bestimmte Fehlerklasse (wie „gebrochen“ oder „zu dunkel“) eingeteilt werden sollen. Die Annotation dieser Kategorien ist für den Trainingsdatensatz des KI-Modells notwendig. Für ein erfolgreiches Computer-Vision-Projekt ist bereits eine optimale Aufzeichnung der Daten in Hinblick auf Parameter wie Auflösung oder Belichtungszeit, aber auch eine korrekte Annotation der Trainingsdaten entscheidend.



## 2. DATA ENGINEERING & DATA PREPARATION

### Unverzichtbar in datengetriebenen Prozessen



#### Wie sammelt und annotiert man diese Daten kosteneffizient?

Die Datenerhebung kann kostspielig sein, da sie sorgfältige Planung und Bildaufnahme erfordert, um die notwendige Vielfalt an Daten aus der Produktivumgebung zu gewährleisten. Diese Aufnahmen müssen dann typischerweise manuell annotiert werden, um Trainingsdaten für das maschinelle Lernen zur Verfügung zu stellen. Im Fall der Firma Knusperkönig kann durch das Aufzeichnen des manuellen Qualitätssicherungsprozesses der Mitarbeitenden das Sammeln von Bilddaten aus der Produktivumgebung sowie deren Annotation automatisiert werden.

#### Techniken zur Reduzierung der nötigen Datenmengen

Um die notwendige Datenmenge zu reduzieren und somit Projektkosten zu senken, können Techniken wie Data Augmentation eingesetzt werden. Dabei werden künstliche Variationen der vorhandenen Daten erzeugt, um die Modellleistung zu steigern. **Transfer Learning sowie Methoden der Domain Adaptation erlauben** häufig das Anpassen öffentlich verfügbarer Modelle an den konkreten Use Case. Semi-Supervised-Verfahren machen nicht annotierte Bilddaten ebenfalls nutzbar und ermöglichen so das Training performanter Modelle mit einer drastisch reduzierten Anzahl an annotierten Daten. **Defekt- und Anomalieerkennung** sind häufig sogar ganz ohne Annotationen möglich, da die Erkennung über die visuelle Abweichung zu einem erlernten Normalzustand möglich ist.

#### Verwaltung der Daten

Ein effizientes Datenmanagement reduziert die Komplexität der Nutzung und sichert durch **Data Version Control** die Reproduzierbarkeit von Ergebnissen. Erfahrene Data Engineers integrieren gesammelte Daten durch **Data Pipelines** automatisiert in **Datenbanken, Datalakes, Data Meshes** oder **Data Marketplaces** und entwickeln eine maßgeschneiderte projektspezifische Dateninfrastruktur.

## 3. ML MODEL ENGINEERING

### Das Herz einer jeden KI-Anwendung



#### Welches Modell für welchen Use Case?

Die Auswahl des richtigen Modells ist entscheidend für den Erfolg des Projekts. Das am besten funktionierende Modell ist nicht brauchbar, wenn es durch Hardware-Limitationen am Einsatzort nicht verwendet werden kann. Beim Einsatz von Computer Vision in Produktionsketten muss die Analyse der Bilddaten häufig in Echtzeit stattfinden. Daher eignen sich hier meist kleinere Modelle, die auf Edge-Geräten direkt am Produktionsband ausgeführt werden können. Für den Anwendungsfall bei Firma Knusperkönig bieten sich Convolutional Neural Networks (CNNs) für Objektdetektion und Klassifikation an. Die Echtzeitfähigkeit kann beispielsweise über eine reduzierte Anzahl an Modellparametern sowie über Modellquantisierung, also die Konvertierung der Modellparameter zu einem Datentyp niedrigerer Bit-Zahl, sichergestellt werden.

#### Hardware

Je nach Anwendungsfall kann das Training von Convolutional Neural Networks eine hohe Rechenleistung erfordern. Besonders für große Modelle müssen leistungsstarke GPUs verwendet werden, um Trainingszeiten und -kosten möglichst gering zu halten. Für Firma Knusperkönig wird eher weniger aufwendige Trainingsarchitektur benötigt. Das Modell soll für mehrere verschiedene Kekssorten, aber unter kontrollierten Bildverhältnissen (gleicher Winkel, gleiche Belichtung) funktionieren. Das reduziert die benötigten Trainingsdaten und erlaubt den Einsatz preiswerterer Hardware für das Modelltraining.

Ein kontinuierliches Re-Training des Modells ist nur erforderlich, wenn sich die Eigenschaften der Bilddaten ändern (Kekssorten, Belichtung, Abstand, Winkel, etc.). Die Anschaffung eigener Hardware für das Modelltraining wäre daher für Firma Knusperkönig nicht rentabel. Entsprechende Hardware kann günstiger bei Cloud-Anbietern wie AWS und Microsoft Azure gemietet werden. Für die Inferenz, also den Einsatz des Modells in der Produktionslinie zur Detektion von defekten Keksen, ist dann typischerweise deutlich günstigere Hardware als für das Training ausreichend.

## 4. QUALITY ASSURANCE FOR MACHINE LEARNING APPLICATIONS

### Qualitätsbewertung und -sicherung auf allen Ebenen



#### Performance-Messung und Kalibrierung

Nach Auswahl und Entwicklung des geeigneten Modells für die Firma Knusperkönig sind einige wichtige Qualitätssicherungsschritte durchzuführen, um die erwartete Leistung des Zielprogramms zu gewährleisten. Dabei werden die Zuverlässigkeit, Genauigkeit und Effektivität des entwickelten Machine-Learning-Modells überprüft. Das Hauptziel besteht darin, sicherzustellen, dass das Modell die erwarteten Genauigkeitsstandards erfüllt. Hierzu wird es mit Evaluationsmetriken wie Precision, Recall oder ROC-AUC auf unabhängigen Testdaten überprüft. Ferner wird die Robustheit des Modells unter verschiedenen Szenarien wie ausgefallener Beleuchtung getestet und Maßnahmen ergriffen, um das Modell zu härten. Konfusionsmatrizen, ROC-Kurven und Precision-Recall-Kurven veranschaulichen die Testergebnisse und erlauben die Kalibrierung des entwickelten Modells.

#### Evaluation im Produktivbetrieb

Der Betrieb eines neuen Modells „im Schatten“ erlaubt das risikofreie Testen in der realen Umgebung, was bedeutet, dass das Modell zusätzlich zum aktuellen Verfahren im Produktivbetrieb installiert wird. Dabei lassen sich Abweichungen zu den Entscheidungen des aktuellen Verfahrens identifizieren und analysieren. Bei Firma Knusperkönig wird die erste Version des entwickelten Modells parallel zum existierenden manuellen Prozess installiert und kann so direkt mit einem menschlichen Prüfer verglichen werden. Das Schattenmodell hat während dieser Phase keinen Einfluss auf den Produktionsbetrieb. Der Einsatz dient nur der Validierung der neuen Modellversion. Nach erfolgreichem Test kann das Modell dann produktiv gestellt werden.

Die Analyse von Fehlentscheidungen mithilfe von Explainable-AI-Methoden wie GradCam und Lime erlaubt Rückschlüsse auf systematische Fehler in den Entscheidungen des Modells. Die Erkenntnisse können in der Entwicklung der nächsten Modelliteration nutzbar gemacht werden.



## 5. DEPLOYMENT

### Einsatz in der Produktivumgebung



#### Integration & Einsatztests


In der Deployment-Phase wird das trainierte Computer-Vision-Modell in betriebliche Systeme eingebunden. Da das Modell für den Einsatz in einer Produktionsumgebung vorgesehen ist, wird ein Einsatztest durchgeführt, um sicherzustellen, dass es sich reibungslos in bestehende Systeme integrieren lässt und unter Betriebsbedingungen einwandfrei funktioniert. Hier geht es primär darum zu testen, ob fehlerhafte Backwaren auch tatsächlich erkannt und dann aussortiert werden können. Außerdem wird ein Regressionstest durchgeführt, der sich auf eine regelmäßige Neubewertung des Modells bezieht, um sicherzustellen, dass es seine Leistung im Laufe der Zeit beibehält, insbesondere wenn neue Bedingungen auftauchen.

#### Inbetriebnahme

Nach Ausschluss etwaiger Schwachstellen kann das Modell in Betrieb genommen werden. In Absprache mit dem Kunden wird die bevorzugte Bereitstellungsinfrastruktur festgelegt, beispielsweise über Cloud-Plattformen wie AWS oder Microsoft Azure oder lokal auf firmeneigener Hardware. Containerisierungstools wie Docker werden häufig verwendet, um Machine-Learning-Modelle und deren Abhängigkeiten effizient und plattformunabhängig bereitzustellen. Container-Orchestrierungstools wie Kubernetes oder Docker Swarm helfen bei der Verwaltung und Skalierung von containerisierten ML-Anwendungen. Dies erleichtert die Bereitstellung und Wartung des Modells in der Produktionsumgebung. Ein weiterer Schwerpunkt liegt auf Überlegungen zur Skalierbarkeit, einschließlich der Frage, wie das eingesetzte Modell mit erhöhten Lasten oder Datenverkehr umgehen kann. Model Versioning hilft dabei, das Modell im Notfall schnellstmöglich auf einen früheren funktionierenden Zustand zurückzusetzen und den Betrieb ohne Einschränkungen aufrechtzuerhalten. Zusätzlich soll das System im Notfall auch ohne Verbindung zum Unternehmensnetzwerk sowie zum Internet funktionsfähig bleiben. Daher wird das entwickelte Modell „on the edge“ eingesetzt, das heißt, dass Berechnungen vor Ort durch kostengünstige Hardware direkt an der Maschine durchgeführt werden.

## 6. MONITORING & MAINTENANCE

### Qualitätssicherung und kontinuierliche Verbesserung



Ziel dieser Phase ist es, das eingesetzte Computer-Vision-Modell genau zu beobachten, um Probleme zu erkennen, Leistung zu überwachen und sicherzustellen, dass es weiterhin genaue Ergebnisse liefert. Dazu gehören kontinuierliche Re-Trainings, die Aktualisierung von Abhängigkeiten und die Durchführung notwendiger Verbesserungen. Tools wie der **ELK-Stack (Elasticsearch, Logstash, Kibana)** können verwendet werden, um Leistungsmatrizen zu erhalten.

#### Automatische Überwachung

Ein weiteres wichtiges Element in dieser Phase ist die Erkennung von **Data Drift**. Hierfür werden statistische Kennzahlen mit Tools wie **Grafana** auf übersichtlichen **Dashboards** dargestellt und automatisch überwacht. Methoden aus dem Bereich des **Active Learnings** erlauben die Identifikation von unbekanntem beziehungsweise schwierigen Situationen sowie die Integration dieser in die nächste Iteration der Daten. Bei Firma Knusperkönig kann eine Änderung der Fehlererkennungsrate ein Hinweis auf Änderungen im Produktionsablauf sein. Geringere Raten können durch Optimierungen der Produktion aber auch auf dadurch ausgelöste Veränderungen in den Bilddaten hindeuten. In Kombination mit anderen Informationen wie der Konfidenz des entwickelten Modells können relevante Änderungen in der Verteilung der Eingabedaten erkannt werden. Das Modell wird dann gegebenenfalls neu trainiert, um sicherzustellen, dass die Erkennungsleistung auch bei geänderten Bedingungen aufrechterhalten bleibt.

Zur Einhaltung der Wartungsvorschriften können **Shadow Tests** sowie **A/B-Tests** durchgeführt werden. Ebenso ist die **Überwachung der Nutzung von Ressourcen wie CPU, Speicher oder GPU** ein wichtiger Faktor, um Projektkosten im Blick zu behalten. Zu guter Letzt werden Mechanismen entwickelt, um Rückmeldungen von Benutzern oder Anwendungen, die mit dem Modell interagieren, zu sammeln, was eine kontinuierliche Verbesserung auf Grundlage der realen Leistung ermöglicht. So kann das gesammelte Feedback zur Feinabstimmung des Modells genutzt werden. **Monitoring und Maintenance** sind laufende Prozesse, die dazu beitragen, die Genauigkeit, Zuverlässigkeit und Relevanz des Modells in der Produktion aufrechtzuerhalten und zu verbessern.

# WARUM PROCON IT?

## Mit System zum erfolgreichen Computer-Vision-Projekt

Ein koordiniertes und standardisiertes Vorgehen ist essenziell für jedes Machine-Learning-Projekt, insbesondere in Computer-Vision-Projekten, in denen die Erhebung und Verarbeitung der Bilddaten teuer sein kann. Das vorgestellte Prozessmodell CRISP-ML(Q) setzt hierbei neue Maßstäbe und entwirft einen neuen Industriestandard, mit dem sich insbesondere Computer-Vision-Projekte schnell, in beliebig großen Teams und mit qualitativ hochwertigen Ergebnissen zum Erfolg bringen lassen.


PROCON IT unterstützt Sie gerne bei der Umsetzung Ihres Projekts!

Wir erarbeiten mit Ihnen die Strategie und das Vorgehensmodell und schöpfen den Wert aus Ihren Daten. Gemeinsam führen wir Ihr Computer-Vision-Projekt zum Erfolg!

**Kontaktieren Sie uns! Wir beraten Sie gerne!**



### Ihr Ansprechpartner



### Christoph Hoffmann

Head of Data Solutions & AI

+49 151 6711 1716

christoph.hoffmann@procon-it.de