

IDA Classification

Vielseitiges Feature zur Dokumentenklassifikation

IDA Classification ist ein Feature für Aufgaben der Dokumentenklassifikation, das auf einem **regelfreien Ansatz mit wenigen notwendigen Lernschritten** (Few-Shot Learning) basiert. Dank **fortschrittlicher Machine-Learning-Fähigkeiten** wird die Einrichtung und Wartung von Workflows im Vergleich zu regelbasierten oder manuellen Ansätzen drastisch beschleunigt. In Kombination mit der **außergewöhnlichen OCR und ICR** von PLANET AI sinkt der Bedarf an manuellen Korrekturen erheblich, was zu einer verbesserten durchgehenden Datenverarbeitung (Straight Through Processing) führt.

HAUPTMERKMALE

Lernen mit wenigen Trainingsdaten

IDA Classification verfügt über fortschrittliches Few-Shot-Learning, das sowohl visuelle als auch textuelle Merkmale berücksichtigt. Dies verkürzt nicht nur die Zeit bis zur Wertschöpfung, sondern minimiert auch den Wartungsaufwand, wenn sich Dokumentenklassen ändern oder erweitern.

No-Code-Training

IDA ermöglicht es Benutzer:innen ohne technisches Fachwissen, Klassifikationsmodelle über eine browserbasierte grafische Oberfläche zu erstellen, zu trainieren und anzupassen.

Intelligente Dokumententrennung

Die automatische Trennung von Dokumenten mit 100 oder mehr aufeinanderfolgenden Formularen mag unmöglich erscheinen. Mit IDA Classification ist es jedoch möglich, ein neuronales Netz zu trainieren, das automatisch die Grenzen von Dokumenten in großen Dateien erkennt. Dadurch ist eine manuelle Trennung während des Scannens nicht mehr erforderlich.

SYSTEMVORAUSSETZUNGEN

Für 64-Bit-Systeme

Linux: Ubuntu 18.04 - 23.10, Debian 11, CentOS 8, Red Hat 8.x, LEAP 15.x, SLES 15 SP 4-5

Windows: 10, 11

Windows Server: 2012, 2012 R2, 2016, 2019, 2022

Docker

Mind. **9 GB Festplattenspeicher**
+ ca. 0.9 GB für volle Funktionalität
+ Unterschiedlicher Speicherbedarf der selbst trainierten Modelle je nach Einstellungen (bis zu ca. 1 GB für vollständiges Training)
+ up to 0.5 GB to store logging data

Das volle Potenzial unübertroffener OCR-Qualität

IDA Classification basiert auf **IDA Recognition**, einer optischen (OCR) und intelligenten (ICR) Zeichenerkennungs-Engine, die selbst in den schwierigsten Szenarien hervorragende Ergebnisse liefert. IDA Recognition erfasst maschinell gedruckten und handgeschriebenen Text, Kontrollkästchen, Tabellen und historische Schriften, selbst bei schlechter Scanqualität mit gedrehtem oder schiefem Druck. Bei einem nachgelagerten Prozess wie der Dokumentenklassifikation ist eine hohe Qualität der Eingabedaten von entscheidender Bedeutung, da sie sich direkt auf die Qualität der resultierenden Ausgabe auswirkt.

Einfache Bereitstellung und Integration

IDA wird entweder vor Ort (on-premises) oder in der Cloud als Java-Anwendung oder als Containerisierung mit Docker bereitgestellt. Die gRPC-API ermöglicht eine nahtlose und schnelle Integration.

METHODEN VON IDA CLASSIFICATION


Indem IDA mit einem kleinen Satz getaggtter Beispieldokumente gefüttert wird, die als Verzeichnisse bereitgestellt werden, erkennt das System automatisch signifikante Merkmale und lernt weiter. IDA bietet **zwei Klassifizierungsarten**, die sowohl für einseitige als auch für mehrseitige Dokumente anwendbar sind. Auf der Grundlage der sich ergebenden Klassen können Dokumente an verschiedene nachgelagerte Prozesse weitergeleitet werden, z. B. an eine Datenextraktion.

Die **Dokumentenklassifikation** ermöglicht die Klassifikation ganzer Dokumente durch Analyse des gesamten Textes innerhalb eines bestimmten Dokuments. Ein möglicher Anwendungsfall ist die Identifizierung eines E-Mail-Anhangs als Bewerbung.



application

Die **Seitenklassifikation** ermöglicht die Klassifikation einzelner Seiten innerhalb eines Dokuments durch Analyse des Textes der aktuellen Seite sowie der vorherigen und der nächsten Seite, sofern vorhanden. Ein möglicher Anwendungsfall ist die Analyse aller Abschnitte einer E-Mail-Bewerbung, z. B. die Sortierung der Seiten in Anschreiben und Lebenslauf.



Beide Klassifikationsmethoden basieren entweder auf einem trainierbaren neuronalen Netz oder einem Wörterbuch (Bag of Words-Modell).

DOKUMENTENTRENNUNG

Beim Scannen großer Dokumentenstapel kommt es häufig vor, dass PDF-Dateien 100 oder mehr aufeinanderfolgende Seiten enthalten. Mit dem IDA-Feature zur Aufteilung von Dokumenten ist es möglich, ein **neuronales Netz** zu trainieren,



IDA CLASSIFICATION

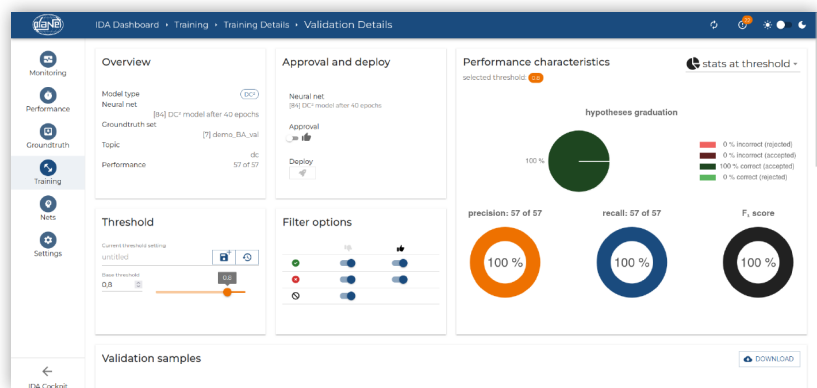
um Dokumentenstapel mit mehrseitigen Dokumenten automatisch zu trennen. Wenn die Anforderungen mit einer zuvor durchgeführten Seitenklassifikation übereinstimmen, können Sie das gleiche Modell für die Aufteilung von Dokumenten verwenden.

Alternativ können Dokumente nach einer festen Anzahl von Seiten **regelbasiert** getrennt werden, anstatt Machine Learning zu verwenden. Für die Aufteilung von Dokumenten, deren Layout sich nicht häufig ändert, müssen Sie nur ein leeres Dokument pro Klasse bereitstellen, z. B. ein leeres Formular. Bislang ist die Dokumententrennung auf Dokumente beschränkt, die in der richtigen Reihenfolge vorliegen.

MODELLTRAINING

IDA bietet eine benutzerfreundliche grafische Oberfläche, die ein einfaches Modelltraining ermöglicht, ohne dass Programmierkenntnisse erforderlich sind.

Rechts: IDA-Benutzeroberfläche für Training



Neuronales Netzwerk

Für die meisten Klassifikationsszenarien wird das **Training eines neuronalen Netzes empfohlen**. Es berücksichtigt sowohl visuelle als auch textuelle Merkmale, um ein Modell zu erstellen. Während des Trainings lernen die Attention-Mechanismen, sich auf die relevantesten Merkmale zu konzentrieren.

Für das Training sind **mindestens 20 Dokumente pro Klasse** und mindestens 10 Dokumente für die Validierung erforderlich. Um eine höhere Trainingsqualität zu erreichen, wird jedoch empfohlen, mindestens 100 Dokumente pro Klasse bereitzustellen. Bei der Klassifikation von strukturierten Dokumenten, deren Layout sich nicht häufig ändert, reicht es aus, nur ein leeres Dokument pro Klasse zur Verfügung zu stellen, z. B. ein leeres Formular.

Bag of Words (Wörterbuch)

Eine weitere Möglichkeit der Klassifikation beruht auf einem **Keyword-Spotting-Ansatz in Kombination mit der patentierten PerceptionMatrix**. Das Bag-of-Words-Modell berücksichtigt in erster Linie textuelle Merkmale, und ist dadurch für weniger komplexe Klassifikationsaufgaben geeignet. IDA führt eine **Suche innerhalb jedes Dokuments durch, die auf einer anpassbaren Liste von Wörtern** (inkl. Wortgruppen, Sätzen) basiert. Zusätzlich ist es möglich, innerhalb der PerceptionMatrix zu suchen, die alle möglichen Transkriptionen eines gegebenen Textes ohne Informationsverlust speichert.

Weitere Informationen sind in der [Software-Dokumentation](#) zu finden.