

20.11. 2015

Vortrag ArchivistaBox OCR-Cluster anlässlich linuxday.at am 21.11.2015

Von pfister2



Bild Rechte

Urs Pfister

(Egg) Am morgigen LinuxDay.at (21.11.2015) in Dornbirn (Dreiländereck Schweiz, Österreich und Deutschland) wird der ArchivistaBox OCR-Cluster (Rechnerverbund) im Rahmen des Vortrages 'ARM-Plattform reif für den Alltag?' präsentiert. Mit dem OCR-Cluster können Bilddaten vollautomatisiert mit Texterkennung (OCR) in durchsuchbare PDF- bzw. Text-Dateien umgewandelt werden. Dank skalierbarer Cluster-Technologie von 24 bis 1920 Prozessoren (CPU-Kerne) ist der ArchivistaBox OCR-Cluster in der Lage, zwischen 120'000 und 10 Millionen Bild-Dateien pro Tag in durchsuchbare Textdaten (OCR) umzuwandeln.

Der OCR-Cluster wird durch stromsparende ARM-Prozessoren (CPUs) angetrieben. So findet ein 48-CPU-Cluster Platz in einem 3-Liter mITX-Gehäuse und benötigt unter Last in etwa 75 Watt an Energie. Dabei werden pro Minute 180 Seiten verarbeitet. Dies ergibt eine Tagesleistung von 250'000 Seiten. Die Verwaltung des OCR-Clusters erfolgt webbasiert. Bei der Auslieferung sind die notwendigen IP-Adressen der Knoten

bereits eingetragen, die weitere Konfiguration wie gewünschte Sprachen, Textlayout, Scan-Profile und Netzlaufwerke werden ebenfalls per Web-Interface vorgenommen.

Um die Erkennung zu steuern, steht optional ein API (Application Programming Interface) mit HTTP-Aufrufen zur Verfügung. Ferner kann die Texterkennung direkt auf der Konsole gestartet und überwacht werden. Die zu verarbeitenden Dokumente können per FTP (Datei-Upload), SMB (Netzlaufwerk), HTTP bzw. HTTPS (Web) oder mittels angeschlossener Dokumenten-Scanner zur Verarbeitung herangezogen werden.

Bei der Texterkennung, die auf Tesseract 3.0x basiert, stehen mehr als 50 Sprachen zur Verfügung, darunter alte Zeichensätze wie Fraktur und/oder Gothik. Zusätzliche Sprachen und/oder spezielle Zeichensätze lassen sich jederzeit integrieren. Die Auslieferung der erkannten Texte erfolgt über das integrierte Dokumenten-Management-System ArchivistaDMS. Optional können durchsuchbare PDF-Dateien direkt auf externe Laufwerke exportiert werden.

Ausgeliefert werden die OCR-Cluster in Form von Mini-Rechnern (je ca. 100 Gramm schwer) oder (optional) montiert in klassischen Gehäusen bis hin zur Rack-Bauweise. Die Preisstruktur des OCR-Clusters richtet sich nach der Anzahl CPU-Kerne. Ein einzelner Knoten enthält acht CPU (Prozessoren) und entspricht einer ArchivistaBox mit dem gewünschten Leistungsumfang. So kostet z.B. ein OCR-Cluster mit 24 CPU-Kernen und einer Tagesleistung von 120'000 Seiten 981,18 EURO (3 x ArchivistaBox Dolder). Die für den OCR-Cluster notwendigen Knoten (ArchivistaBoxen) können unter <http://shop.archivista.ch> bestellt werden.

Über die Organisation:

Die Firma Archivista GmbH entwickelt und vertreibt seit 1998 die Dokumenten-Management-Software Archivista, seit dem Jahre 2005 in der Form von ArchivistaBox-Systemen. Vom Standort Egg bei Zürich werden sowohl Firmen- wie Privatkunden betreut.

Pressekontakt:

Archivista GmbH
Urs Pfister
Stegstr. 14
CH-8132 Egg

Telefon: 044 350 05 60

Homepage <http://archivista.ch>

Mail: webmaster@archivista.ch

Kategorie

IT & Software & Neue Medien

Source URL: <https://www.presseportal-schweiz.ch/pressemeldungen/vortrag-archivistabox-ocr-cluster-anlaesslich-linuxdayat-am-21112015>