

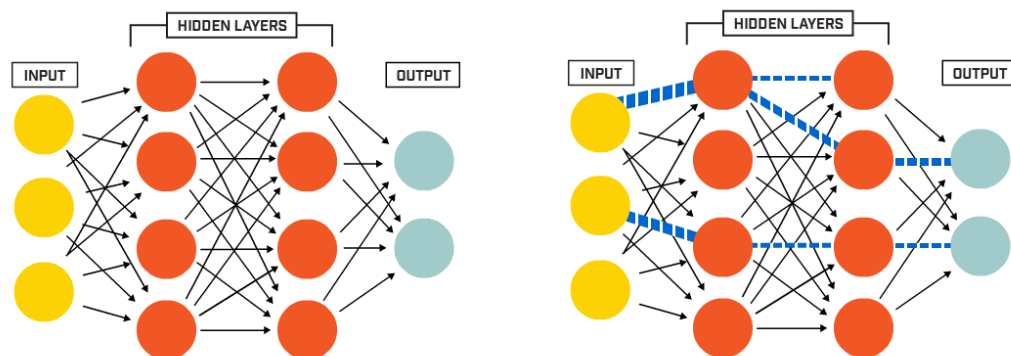
Deep Learning in Machine Vision- Systemen benutzen

- Was ist Deep Learning?
- Warum ist Deep Learning derzeit so beliebt?
- Viele Anwendungen
- Implementieren eines Systems
- Bereitstellung in einem eingebetteten System

Es wird von Machine Vision-Systemen immer mehr erwartet, dass sie automatische Entscheidungen basierend auf variablen Bedingungen treffen. Die Entwicklung dieser Systeme kann sehr zeit- und arbeitsintensiv sein. Mit der Einführung von Deep Learning wird Automatisierung für viele zugänglich gemacht. Ressourcen wie Open-Source-Bibliotheken, Nvidia-Hardware und FLIR-Kameras machen dies möglich. FLIR-Kameras verfügen über fortgeschrittene Funktionen, die die nötige Bildvorverarbeitung für das neuronale Netzwerktraining auf ein Minimum begrenzen. Sie ermöglichen eine nahtlose Zusammenarbeit mit Plattformen wie Nvidia Jetson TX-2 und Drive PX 2 und bieten ununterbrochene Zuverlässigkeit für den reibungslosen Einsatz.

Was ist Deep Learning?

Deep Learning ist eine Form des maschinellen Lernens, bei der neuronale Netze mit zahlreichen tiefer liegenden Schichten zwischen den Eingabe- und Ausgabeknoten genutzt werden. Nachdem ein Netzwerk das Training mit einem großen Datensatz durchlaufen hat, wird ein Modell erstellt, mit dem basierend auf den Eingabedaten genaue Vorhersagen getroffen werden können. In den neuronalen Netzen, die beim Deep Learning eingesetzt werden, wird die Ausgabe einer Schicht als Eingabe an die nächste Schicht übertragen. Die Optimierung des Modells erfolgt stufenweise, indem die Gewichtung der Verbindungen zwischen den Schichten geändert wird. In jedem Zyklus wird das Feedback zur Vorhersagegenauigkeit des Modells genutzt, um die Änderungen an der Verbindungsgewichtung zu steuern.



*Neuronales Netz mit tiefer liegenden Zwischenlagen zwischen Eingabe und Ausgabe.
Änderung der relativen Gewichtung der Eingaben*

Deep Learning sorgt durch die Automatisierung von Prozessen, die für herkömmliche Bildverarbeitungsanwendungen bisher zu komplex waren, für einen Wandel in der Industrie. Dank der benutzerfreundlichen Frameworks, der erschwinglichen, beschleunigten GPU-Hardware (Graphics Processing Unit) und Cloud-Computing-Plattformen kann heute jedermann die Vorteile von Deep Learning nutzen.

Beispiel: Gurkensortierung

Ein Beispiel für die einfache Anwendung von Deep Learning zeigt ein japanischer Landwirt, der das TensorFlow-Framework von Google und Cloud ML konfiguriert hat, um seine Gurken einzustufen. Mithilfe von TensorFlow trainierte er ein neuronales Netzwerk mit Beispielbildern für die einzelnen Qualitätsgrade von Gurken. Das System lernte, die Gurkengrade anhand von Merkmalen der Beispielbilder zu unterscheiden. Während die Gurken die Sortiermaschine des Bauern durchlaufen, werden sie erfasst und das neuronale Netzwerk klassifiziert sie. Anschließend weist es die Sortiermaschine an, die Gurken in die richtigen Behälter zu sortieren.

Warum ist Deep Learning derzeit so beliebt?

GPU-beschleunigte Hardware: mehr Leistung, geringere Kosten

Die Architektur von GPUs, die mithilfe einer großen Anzahl von Prozessoren koordinierte parallele Berechnungen („massively parallel architecture“) durchführen können, eignet sich ideal für Deep-Learning-Systeme. Dank der ständigen Weiterentwicklung durch Nvidia sind GPU-beschleunigte Computing-Plattformen heute viel leistungsstärker, effizienter und kostengünstiger geworden. Diese Technologie ist in verschiedenen Formfaktoren verfügbar, von kompakten eingebetteten Systemen, die auf Jetson TX1 und TX2 basieren, über PC-GPUs wie den Grafikprozessor GTX 1080 bis hin zu speziellen KI-Plattformen wie DGX-1 und Drive PX 2 von Nvidia.

Demokratisierung von Deep-Learning-Frameworks

Neben der Entwicklung benutzerfreundlicher Frameworks trägt auch die breite Verfügbarkeit von Tutorien und Onlinekursen zur größeren Verbreitung von Deep Learning bei. Mithilfe von C++-Wrappen wie TensorFlow von Google und Open-Source-Software wie Caffe, Torch und Theano geht das Erstellen und Trainieren eigener DNNs (Deep Neural Networks) schnell. Dank seiner Vielseitigkeit liegen Sie mit TensorFlow am Anfang immer richtig. Durch die GPU-Optimierung von Caffe eignet sich dieses Framework perfekt für eine Kombination mit dem Jetson TX1 und TX2.

Die Bibliothek Nvidia CUDA Deep Neural Network (cuDNN) bietet Entwicklern ausgereifte Implementierungen häufig genutzter Deep-Learning-Funktionen, mit denen die Lösungen für diese Plattformen weiter optimiert werden können.

Bessere Preise, kürzere Vorlaufzeiten

Die Verfügbarkeit diskreter, einsatzbereiter Kameras und eingebetteter Plattformen bietet Entwicklern von Verkehrssystemen die Flexibilität, die Systeme an ihre Projekte anzupassen. Separate Kameras und Verarbeitungshardware ermöglichen eine einfache und unabhängige Aktualisierung der einzelnen Komponenten. Diese Umgebung führt zu besseren Preisen und kürzeren Vorlaufzeiten als bei speziellen Smart-Kameras.

Viele Anwendungen

Auch wenn die Entwicklung selbst fahrender Autos viel Medienaufmerksamkeit auf sich zieht, gibt es noch eine ganze Reihe weiterer Anwendungen für Deep Learning. Die Anwendung von Deep Learning dient zur Lösung zahlreicher Probleme, wie etwa zur akkuraten Interpretation von CT-Untersuchungen, zur automatischen Übersetzung von Texten bis hin zur Optimierung des Verkehrsablaufs in Städten.

Deep Learning ist ein leistungsfähiges Tool für Entwickler von Automatischen Optischen Inspektion-Systemen (AOI). Deep Learning betriebene AOI-Software wie ViDi Red lernt von den Segmenten, die als gut gelten und kann sowohl Defekte erkennen als auch akzeptable Variationen erkennen lernen.

Das fortlaufende Training von Deep-Learning-Systemen erlaubt diesen auch die Reaktion auf wechselnde Bedingungen. Das Unternehmen HERE arbeitet an der Implementierung seines Kartensystems auf Grundlage von Deep Learning in selbst fahrende Autos. Die Technologie soll fortlaufend aktualisierte Karten mit einer Auflösung von 10–20 cm erstellen. Mithilfe von Deep Learning erstellt HERE Karten, die den genauen Standort von festen Objekten wie Signalen und vorübergehende Behinderungen wie Baustellen enthalten.

Implementieren eines Systems

Erfassung von Trainingsdaten

Die Entwickler müssen ein Deep-Learning-Modell trainieren, bevor sie es einsetzen können. Hochwertige Trainingsdaten sind besonders wichtig für akkurate Ergebnisse. Höchstleistungskameras stellen die besten Bilder für das Training von Systemen bereit, die Entscheidungen auf Grundlage von visuellen Eingaben treffen.

Eine in die Kamera integrierte Bildverarbeitung vereinfacht die Datennormalisierung, die vor dem Training notwendig ist. Kamerafunktionen wie die präzise Steuerung von automatischen Algorithmen, Schärfekorrektur, Pixelformat-Konvertierung, fortgeschrittene Farbinterpolierung von FLIR sowie die Farbkorrekturmatrix (CCM) dienen der Bildoptimierung. Die strengen Qualitätskontrollen von FLIR während der

Herstellung minimieren Abweichungen bei der Kameraleistung und reduzieren somit auch den Aufwand zur Normalisierung vor dem Training.

Bei Anwendungen, die Aufnahmen von fahrenden Fahrzeugen machen, lesen globale Verschlussensoren alle Pixel gleichzeitig. Damit werden Verzerrungen durch die Bewegung des Objekts während des Lesevorgangs verhindert. Viele der Machine Vision-Kameras von FLIR nutzen die globalen CMOS-Verschlussensoren Sony Pregius. Sie haben einen Dynamikbereich von 72 dB bei einem Ausleserauschen von weniger als 3e- und können damit gleichzeitig Details in hellen und verschatteten Bereichen erfassen. Und selbst bei schlechten Lichtverhältnissen machen sie exzellente Bilder.

Anwendungen mit wenig Licht wie der Nachtsicherheitsdienst und die Fluoreszenzmikroskopie profitieren von der Pixelstruktur der Sony-Sensoren Exmor R und Starvis mit Hintergrundbeleuchtung. Diese Geräte gehen einen Kompromiss bei der Auslesegeschwindigkeit ein, um die Quanteneffizienz zu steigern – dadurch können diese Sensoren kleiner und kostengünstiger gemacht werden und trotzdem eine großartige Leistung bei wenig Licht liefern.

Training auf spezialisierter Hardware

Wenn genügend Trainingsdaten gesammelt wurden, können Sie mit dem Training Ihres Modells beginnen. Zur Beschleunigung dieses Vorgangs können Sie einen PC mit einer oder mehreren CUDA-fähigen GPUs oder spezielle KI-Trainingshardware wie Nvidia DGX-1 verwenden. Es gibt auch Cloud-Computing-Plattformen, die auf Deep Learning spezialisiert sind.



GPU-beschleunigtes Training von Deep-Learning-Systemen geht viel schneller als CPU

Bereitstellung in einem eingebetteten System

Nach Abschluss des Trainings Ihres Deep-Learning-Modells können Sie es in der Realität anwenden. Kompakte und leistungsstarke GPU-beschleunigte, eingebettete Plattformen ermöglichen Anwendungen, in denen die Platz- oder Leistungsanforderungen durch herkömmliche PCs nicht erfüllt werden können und eine begrenzte Internetverbindung eine herausragende Computing-Leistung notwendig macht. Diese Systeme basieren auf der ARM-Prozessorarchitektur und werden meistens auf Linux-basierten Betriebssystemen ausgeführt. Informationen zur Verwendung des FlyCapture-SDK von FLIR auf einem ARM-Gerät in einer Linux-Umgebung finden Sie hier.

Viele Industrie-Anwendungen stützen sich auf Systeme mit mehreren Kameras. Mit Machine Vision-Kameras von FLIR haben Systementwickler die Flexibilität, mehrere Kameras per GPIO oder softwaregesteuert auszulösen. Das Precision Time Protocol nach IEEE 1588 (PTP) ermöglicht die Synchronisierung der Kamerauhr mit einer gemeinsamen Zeitbasis oder einem GPS-Zeitsignal – ohne Nutzereingriff. Der mittlere Störabstand (MTBF) von Mehr-Kamera-Systemen sinkt mit jeder zusätzlichen Kamera, deshalb sind zuverlässige Kameras für die Implementierung stabiler Systeme von besonderer Bedeutung. Entwicklung und Tests von Machine Vision-Kameras von FLIR sorgen für eine ununterbrochene Zuverlässigkeit und damit für weniger Ausfälle und Wartungsunterbrechungen.

Nvidia Jetson TX1 und TX2 sind leistungsstarke und effiziente GPU-beschleunigte, eingebettete Plattformen, die USB 3.1 Gen 1 und GigE Vision-Kameras unterstützen. Spezielle Jetson-Trägerplatten stellen die E/A-Verbindungen und anwendungsspezifische Funktionen bereit. SmartCow TERA+ unterstützt bis zu 8 GigE-Kameras nativ über einen verwalteten Switch und unterstützt die serielle Kommunikation mit RS-232 und RS-485. SmartCow stellt auch einen Caffe-Wrapper bereit, der die Entwicklung und Bereitstellung von Anwendungen Bildverarbeitung auf Basis von Deep Learning auf der TERA+-Hardware vereinfacht. Der Connect Tech Cogswell Carrier unterstützt sowohl USB 3.1 Gen 1 als auch GigE-Kameras mit Power Over Ethernet (PoE). Informationen zu den ersten Schritten mit FLIR-Kameras mit Nvidia TX 1 und TX 2 finden Sie hier.

Nvidia Drive PX 2 ist eine offene Automotive-KI-Plattform auf Grundlage von zwei Pascal-GPU-Kernen. Die Drive PX 2 erreicht bis zu acht TFLOPS und hat damit die Rechenleistung von 150 Macbooks Pro. Die Drive PX 2 wurde speziell für Deep-Learning-Anwendungen bei selbst fahrenden Autos entwickelt. Neben USB 3.1 Gen 1- und GigE-Kameras zur Bildverarbeitung verfügt sie auch über Eingänge für Kameras, die die Automotive GMSL-Kameraschnittstelle verwenden. Informationen zu den ersten Schritten mit der Drive PX 2 finden Sie hier.

Erste Schritte beim Deep Learning – einfacher als Sie denken!

Tauchen Sie mit diesen großartigen Tutorien in die Welt von Deep Learning ein:

<https://developer.nvidia.com/embedded/twodaystoademo>

<http://blog.udacity.com/2017/01/siraj-raval-deep-learning-nanodegree-foundation-program.html>

<http://www.flir.com/deeplearning>