

06 | GPU-Computing für KI



20

KI für jedermann

Automatische Generierung von
Deep-Learning-Modellen

22

Objekterkennung

Echtzeitlernende KI zur
automatischen Objektinspektion

42

Smart Super FPGA

Heterogeneous Acceleration
Platform for AI Applications

SPEED UP YOUR VISION.

**DEEP LEARNING
FOR PRODUCTION**

VISUAL APPLETS



modern. Deep Learning direkt auf dem Framegrabber-FPGA.
industriell. Lange Hardware-Verfügbarkeit, Echtzeitverhalten mit geringen Latenzen.
performant. Ausführung der Inference mit sehr hoher Genauigkeit und über 250MB/s.
kompatibel. „CNN ready“ Framegrabber mit CameraLink Schnittstelle verfügbar.
bewährt. Integration in VisualApplets mit Bildvor- und -nachverarbeitung.
einfach. Wir begleiten Sie zu Ihrem Erfolg.

Steigen Sie jetzt ein. Rufen Sie uns an.

SiliconSoftware | 0621-789507 0 | silicon.software | info@silicon.software



Der Blick nach vorne



DR.-ING. PETER EBERT | CHEFREDAKTEUR INVISION

Herzlich willkommen zu unserem inVISION Sonderheft 'Embedded Vision & Deep Learning'. Da in den letzten Jahren vieles über beide Themen diskutiert wurde, haben wir eine Vielzahl an interessanten Beiträgen in dieser Ausgabe zusammengefasst.

Vor allem um Deep Learning, KI, AI, Machine Learning (oder wie auch immer sie das Thema nennen wollen) hat sich ein Hype entwickelt. Kein Bereich – auch außerhalb von Vision-Technologien – scheint derzeit ohne die neuen Algorithmen auskommen zu können. Aber wo stehen wir derzeit und was kommt als nächstes? Erfahren Sie mehr in den ent-

sprechenden Beiträgen dieser Ausgabe. Auch im Kamerabereich tut sich derzeit einiges dank/mit Embedded Vision. Dabei meine ich nicht alleine intelligente Kameras, die bereits seit Jahr(-zehnten) sehr erfolgreich im Einsatz sind, sondern eher die extrem kleinen und kostengünstigen intelligenten Kameramodule, die erstmals – dank ihrer geringen Kosten und Größe – völlig neue Einsatzbereiche von Vision-Technologien (egal ob Machine, Computer oder Embedded Vision) ermöglichen. Des Weiteren haben neue Prozessoren, Boards und FPGAs einen Technologieschub ermöglicht, dass mittlerweile auch Deep Learning auf einem klassischen Industrie-PC läuft und nicht länger teure Großrechner hierfür nötig sind. Interessant ist, dass durch alle diese Technologien sich nicht nur neue Einsatzgebiete für Vision ergeben, sondern auch neue

Bedienkonzepte. Die Usability von Vision Systemen war in der Vergangenheit die Achillesferse der Bildverarbeitung. Wenn zukünftig neben den bisherigen Vision-Experten auch Bildverarbeitungsanfänger Vision-Technologien so einfach wie auf ihrem Smartphone einsetzen können, steht der Bildverarbeitung eine sehr erfolgreiche Zukunft bevor. Welche Auswirkungen dieses Wachstum auf die bisherige Vision Community haben könnte, diskutieren wir ein anderes Mal.

Viel Spaß beim Lesen.

Dr.-Ing. Peter Ebert
Chefredakteur inVISION
pebert@invision-news.de

Anzeige

 **Dream CHIP**



Visit us
at Hall
3A-440

accelerates
your product
innovation

Für unsere Kunden entwickeln und liefern wir:

- Intelligente Kameras
- Bildverarbeitungs-Systeme
- Bildverarbeitungs-Algorithmen
- Sensorbasierte Mess- und Regelsysteme

in ASIC-, FPGA- und Embedded Software-Technologien.

Dream Chip Technologies GmbH
Steinriede 10 · 30827 Garbsen, Germany

For our customers we develop and deliver:

- Intelligent cameras
- Custom imaging systems
- Custom imaging algorithms
- Sensor based measurement and control systems

utilizing latest ASIC, FPGA and embedded software technologies.

Fon +49 (0)5131 / 908 05-0
info@dreamchip.de · www.dreamchip.de



06 | TITELSTORY

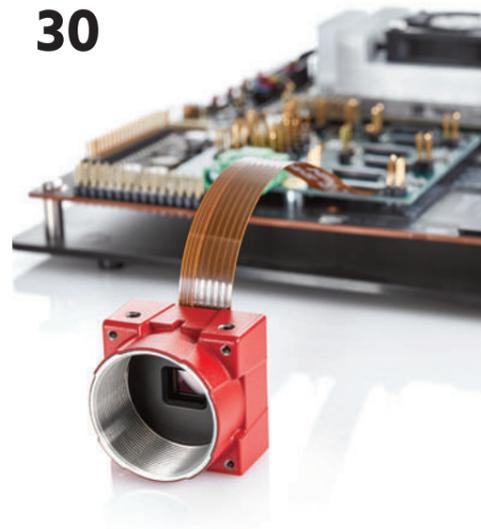


Bilder: S. 6, Vecow Co. Ltd.; S22, Gestalt Robotics GmbH; S30 Allied Vision Technologies GmbH

22



30



INHALT

AKTUELL

Titel: GPU-Computing für KI-Anwendungen	06
Messevorschau Embedded World 2019, Nürnberg	08
Embedded Vision Europe Conference 2019, Stuttgart	09
Revolutioniert Embedded Vision die Bildverarbeitung?	10
Impressum/Index	51

Deep Learning

Deep-Learning Science-Fiction or Reality?	12
CNN auf FPGAs erobern die Bildverarbeitung	15
Automatische Generierung von Deep-Learning-Modellen	20
Lernende KI zur automatischen Objektinspektion	22
Deep-Learning-Inferenz auf Intel-kompatiblen x86-CPU's	24
Neue Art von Beschleunigungs-SoCs für neuronale Netze	26
Automatisierte Risserkennung mit KI im Audi-Presswerk	28
Neuheiten: Deep Learning	29

Intelligente Kameras

Industrielle Kameramodule mit SoC für Embedded Vision	30
Marktübersicht: Board-Level-Kameras	32
Kostengünstige Smart-Kamera auf Raspberry-Pi-Basis	34
Programmierbare (Zeilen-)Kamera mit ARM-Prozessoren	36
Neuheiten: Intelligente Kameras	38
Künstliche Intelligenz als App für Industriekameras	39

IPC, Boards & FPGAs

Heterogeneous Acceleration Platform for AI Applications	42
NXP-Prozessoren mit leistungsfähigen Imaging-Features	44
Schnellere FPGA-Anbindung für neue Sony CMOS-Sensoren	46
Lüfterlose High-End- sowie Mini-PCs für Machine Vision	48
Einstiegsplattform für High-End Embedded Computing	49
Neuheiten: IPC, Boards & FPGAs	50

BE VISIONARY

Auf Wiedersehen zur
VISION 2020!

10. – 12. November 2020
Messe Stuttgart

www.vision-messe.de

VISION
Weltleitmesse für
Bildverarbeitung

Titelstory: Leistungsstarke Embedded-PCs für Deep Learning

GPU-Computing für KI

Die GPU-Computing-Systeme der ECX-1400/1200-Serie sind derzeit eine der stärksten Lösungen für KI-orientierte Embedded-Computing-Anwendungen auf dem Markt.

AUTOR: MICHAELA PILLAY, TECHNISCHE REDAKTEURIN, PLUG-IN ELECTRONIC GMBH | BILDER: VECOW CO. LTD.



Grundvoraussetzung für die Weiterentwicklung von Anwendungen wie selbstlernende Computer, Gesichtserkennung und fahrerlose Antriebssysteme ist Deep Learning. Um diese Visionen zu realisieren, sind Technologien zur Untersuchung großer Datenmuster von Nöten und eine zuverlässige Hardware, die den hohen Anforderungen standhält. Vecow ist spezialisiert auf die Entwicklung industrieller, lüfterloser Systeme für die Bereiche Machine Vision und High-End-Computing. Neuerdings bietet die Firma, deren Industrie-PCs von Plug-In Electronic in der DACH-Region vertrieben werden, auch GPU-Computing-Systeme an, die mit performanten Nvidia Grafikkarten ausgestattet sind, um die Rechenleistung, die für Deep-Learning benötigt wird, zu liefern. Weitere KI-orientierte

Eigenschaften der Embedded-PCs, sind beispielsweise ein weiter Betriebstemperaturbereich, eine kompakte Bauweise, flexible Anpassungsmöglichkeiten und selbstverständlich der Datentransfer in Echtzeit.

GPU-Computing mit Nvidia Grafikkarten

Die GPU-Computing-Systeme der ECX-1400/1200-Serie überzeugen durch eine Leistungssteigerung von

zehn Prozent gegenüber der vorangegangenen Generation und sind somit die derzeit stärkste Lösung für KI-orientierte Embedded-Computing-Anwendungen auf dem Markt. Ausgestattet mit der 8th Generation Intel-Coffee-Lake-Plattform und der fortschrittlichen Nvidia-GPU-Technologie bietet die neue Serie nicht nur die Systemleistung einer Workstation, sondern auch eine hohe Zuverlässigkeit. Je nach Modell sind unterschiedliche Grafik-Engines der Nvidia GeForce GTX-10-Serie verbaut, die bis zu sieben unabhängige

HD-Displays und 8K-Auflösung unterstützen und somit für eine exzellente Systemleistung sorgen. Durch eine Vielzahl an integrierten Schnittstellen und drahtlosen Verbindungen wird zudem ein nahtloser High-Speed-Datenaustausch ermöglicht. Das kompakte Design und der große Eingangsspannungsbereich von 12 bis 36V mit einem

der 6-Kern 8th Generation Intel Xeon/Core i7/i5/i3 Prozessor (Coffee Lake-S) mit dem Intel C246-Chipsatz sorgt für eine sehr hohe Systemleistung, sondern auch die UHD Graphics P630/630. Diese Grafikkarte unterstützt 4K-Auflösung über DisplayPort, VGA und DVI-D Schnittstellen. Die Geräteserie stellt bis zu 64GB von zwei DDR4-Speicher bereit und bietet verschiedene Anschlussmöglichkeiten, wie beispielsweise USB 3.1 Gen 2, der eine Übertragungsgeschwindigkeit von bis zu 10Gbit/s ermöglicht.

KI-Systeme in der Praxis

Ein erfolgreiches Anwendungsbeispiel dieser KI-Systeme, ist im Bereich der Intelligent Surveillance (intelligente Überwachung) zu finden. Bei einem Straßenbauprojekt in Taipei City sind mehr als 2.000 hochauflösende Netzwerkkameras mit über 200 Kennzeichen-Identifikationskameras im Einsatz. Die Embedded-PCs, zur Auswertung der gelieferten Daten, befinden sich in Schaltschränken am Straßenrand, wo sie gerade während der heißen Sommermonate sehr hohen Temperaturen ausgesetzt sind. Das perfekte Zusammenspiel aus der Anwendungssoftware, dem integrierten KI-Algorithmus, der mit einem Fahrzeugüberwachungssystem und einer Datenbank der Polizei zur Analyse großer Datenmengen gekoppelt ist, erleichtert die Erfassung von Verkehrsunfällen und Regelverstößen. Die Anwendung intelligenter Dienste, die äußerst leistungsstarke Computing-Systeme voraussetzen, ist vielfältig. Weitere Einsatzgebiete sind beispielsweise die Logistik, intelligente Landwirtschaft und die Sicherheitsüberwachung. Länder wie die USA, Europa, Japan, Südkorea und China zählen die KI-Technologie mittlerweile zu ihrer nationalen Strategie mit erheblichen potenziellen Geschäftsmöglichkeiten und diversifizierten Anwendungsmärkten.

www.plug-in.de





Auf der Embedded World stehen dieses Jahr u.a. die Themen autonomes Fahren, Deep Learning und Embedded Vision im Fokus.

Branchentreff

Messevorschau Embedded World 2019, Nürnberg

TEXT UND BILD: NÜRNBERGMESSE GMBH

Die Embedded World ist eine echte Erfolgsgeschichte. Fachmesse und Konferenzen wachsen seit Anbeginn kontinuierlich. Dieses Jahr findet sie vom 26. bis 28. Februar auf dem Nürnberger Messegelände statt.

Mehr als 1.000 Aussteller werden den mehr als 30.000 erwarteten Besuchern auch dieses Jahr in sechs Hallen die neuesten Trends und Produkte zu eingebetteten Systemen rund um Hard- und Software zeigen. Zu den Themen der Messe gehören natürlich auch Embedded Vision und Deep Learning. Auf dem Ausstellerforum in Halle 2 wird am Mittwoch (27.02.) ab 10:30 Uhr eine Podiumsdiskussion zum Thema 'Embedded Vision & Deep learning' stattfinden, an deren Organisation der VDMA IBV mitgewirkt hat.

Embedded Vision ist auch Teil des umfangreichen Kongressprogramms. So finden am Dienstag (26.02.) zwei Embedded Vision Sessions (09:30-12.30 und 14:30-17:30) während der Embedded World Conference statt, bei denen zehn jeweils 30-minütige Präsentationen zum Thema geboten werden. Auf der Start-up Area in Halle 3A können sich junge Unternehmen aus der Embedded-Technologie-Branche der internationalen Embedded-

Community präsentieren. Erstmals wird es auch einen Eingang in Halle 3A geben. Der neue Eingang ist von den Parkplätzen gut zu erreichen und wird von den Shuttle-Bussen regelmäßig angefahren. Alle Informationen rund um die Embedded World 2019 wie z.B. Hallenpläne, Kongressprogramme, Aussteller- und Produktverzeichnis oder Tipps zur Anreise finden Sie auch online unter...

www.embedded-world.de

Kostenfreier Zutritt zur Embedded World 2019

Mit dem **Gutscheincode ew19TeDo** können sich Messebesucher schon vorab ihre kostenfreie Eintrittskarte zur Embedded World 2019 sichern. Der Code kann auf der Homepage eingelöst werden. Sie erhalten nach Registrierung umgehend ein elektronisches Ticket für den direkten Zugang auf die Messe.

www.embedded-world.de/gutschein



Neue Autonomie

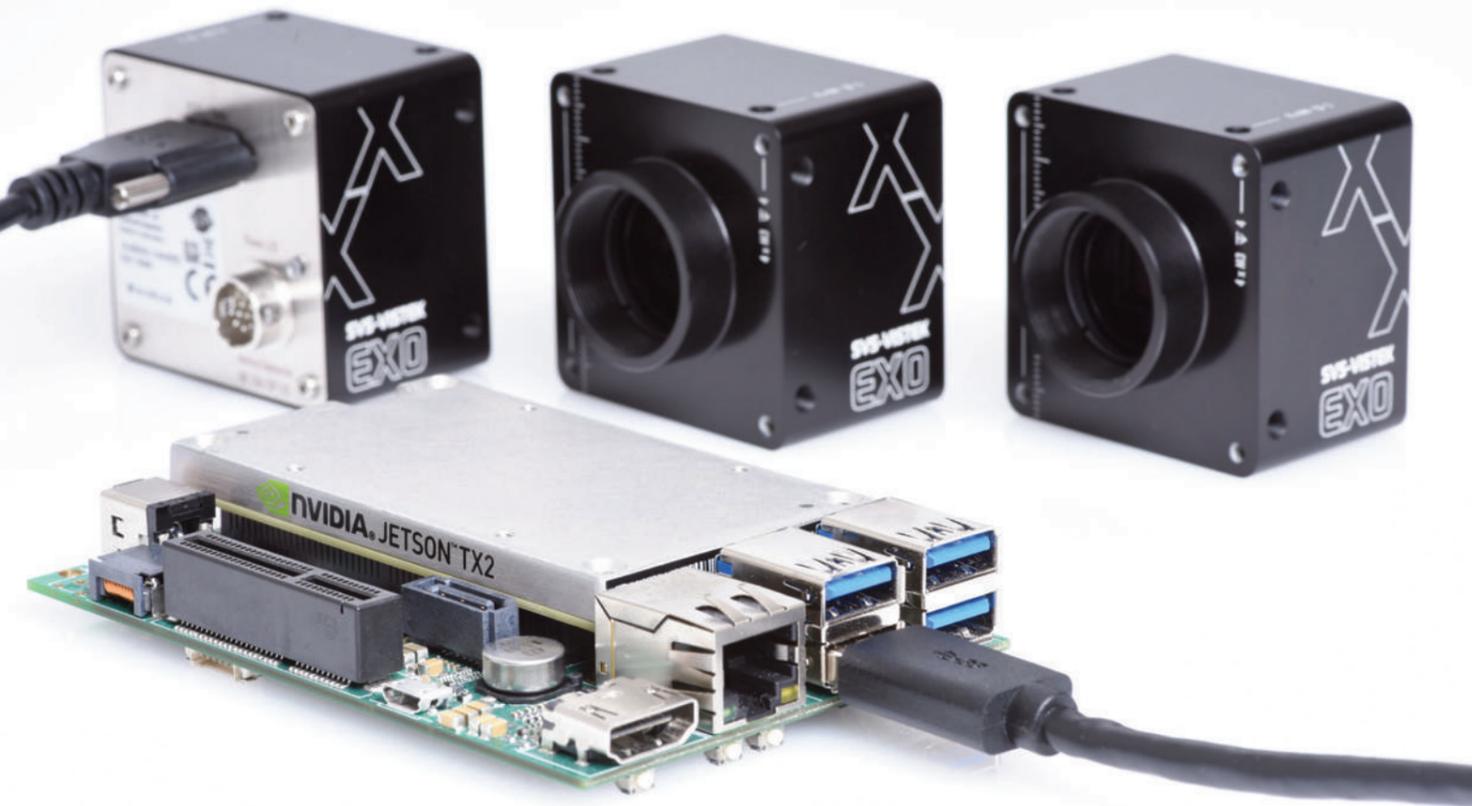
Embedded Vision Europe Conference 2019

EMVA und Messe Vision organisieren vom 24. bis 25. Oktober die 2. European Conference on Embedded Vision, die Embedded Vision Europe, die im ICS direkt am Stuttgarter Flughafen stattfindet.

AUTOR: HENNING STAERK, MARKETING MANAGER, EMVA
BILD: EMVA – EUROPEAN MACHINE VISION ASSOCIATION

Durch die Entwicklung leistungsstarker, kostengünstiger und energieeffizienter Prozessoren ist es möglich geworden, Bildverarbeitungsfunktionen in Embedded Systeme, mobile Geräte, PCs und die Cloud zu integrieren. In den nächsten Jahren wird es daher zu einer raschen Verbreitung der Embedded-Vision-Technologie in vielen Arten von Anwendungen kommen. Embedded-Vision-Systeme, die sich in eine 4.0-Umgebung integrieren lassen, für die Steuerung autonomer Fahrzeuge, portable Diagnosegeräte für die Medizin oder intelligente Bildverarbeitung in Sport und Entertainment sind nur einige Beispiele von vielen. Die Embedded Vision Europe 2019 ist die führende Konferenz in Europa zu diesem Thema. Bereits die erste Konferenz 2017 war ein großer Erfolg, so dass in diesem Jahr ein starkes Wachstum von Besuchern und Ausstellern erwartet wird. Hochkarätige Präsentationen geben Einblicke in modernste Hardware und Softwareplattformen, neue Produkte und kommende Standards. Anwendungen und Märkte für Embedded Vision werden mit einer Vielzahl von Fallstudien vorgestellt. Die Konferenz schafft eine Plattform für den Informationsaustausch und Peer-to-Peer-Netzwerke. Die Veranstaltung findet in englischer Sprache statt und wird gemeinsam von EMVA und Messe Stuttgart organisiert, dem Veranstalter der Messe Vision. Die Embedded Vision Europe 2019 richtet sich an Entwickler und Anwender von Embedded (Vision) Systemen aus allen Branchen und wird begleitet von einer Ausstellung technologisch führender Unternehmen, die vor Ort ihre Embedded-Vision-Kompetenz mit innovativen Produkten, Anwendungen und Dienstleistungen präsentieren.

www.embedded-vision-emva.org



Mit einem GenCam GenTL-Treiber kann auch auf einem SoC mit dem Nvidia Jetson eine hervorragende Leistung im Bildeinzug bereitgestellt werden.

Embedded (R-)Evolution

Revolutioniert Embedded Vision die Bildverarbeitung?

AUTOR: DIPL. ING. STEFAN WAIZMANN, SVS-VISTEK | BILD: SVS-VISTEK GMBH

Embedded Vision ist in aller Munde. Führt die 'neue' Technologie zu einem Umbruch in der Bildverarbeitung und wie wichtig sind dabei Vision-standards wie z.B. GenICam?

Embedded Entwicklungen mit eigenem Board Design und DSPs gibt es bereits seit über 20 Jahren. Heutige Embedded Lösungen erweitern jedoch diesen Begriff. Bereits bei der Begriffsklärung von Embedded Vision erhält man unterschiedliche Antworten. Einige Merkmale werden aber durchgängig genannt:

- Die Bildverarbeitungseinheit enthält alle Komponenten des Bildeinzugs On-Board,
- Embedded bedeutet eine kleine, kompakte Lösung mit geringem Platzbedarf der Komponenten, wie z. B. die Kombination von Kamera und Strobe Controller in einem Produkt.
- intelligentere Komponenten

In manchen hoch spezialisierten Disziplinen wie z. B. Deep Learning können embedded Boards in der Leistung großen PCs durchaus ebenbürtig sein. Embedded Projekte stehen dabei im Spannungsfeld der ökonomischen Vernunft: Hohe Projektvielfalt versus Stückzahlen,

d.h. Embedded Entwicklungen sind meist aufwändig und teuer und daher erst bei hohen Volumina wirtschaftlich sinnvoll. Auch lüfterlose Industrie-PCs werden immer kleiner und ermöglichen mit hohen CPU-Leistungen sowie USB3 und GigE Vision ebenfalls sehr leistungsfähige Embedded Vision Lösungen. Die lange Zeit übliche Version einer Embedded Vision Lösung enthält dabei alle Bildverarbeitungskomponenten in einem einzigen Gehäuse: Beleuchtung, Objektiv, integrierte Kamera, Prozessor und Software. Allerdings limitiert die hoch spezialisierte Software die Anwendungsmöglichkeiten der Systeme.

Intelligente Kameras werden zwar immer mit speziellen parametrierbaren Fähigkeiten angeboten, sind aber vom Kunden nicht frei programmierbar. Es kommen zudem immer neue Komponenten auf den Markt, die bereits in der Kamera eine Teilauswertung der Bilder vornehmen. Intel hat z.B. mit Real Sense eine neue Kategorie an 3D-Systemen geschaffen. Allgemein geht die Leistung heutiger embedded 3D-Visionssysteme deutlich über das hinaus, was bisher möglich war. So ist mittlerweile die Erzeugung einer 3D-Punktwolke in die FPGAs der Bilderfassung bzw. Kamera(s) ausgelagert.

Der Nachteil von SoCs

SoCs (System on a Chip) sind eine wichtige Basis für Embedded Vision. Die kleinen Rechereinheiten konnten in den letzten Jahren einen enormen Leistungszuwachs verzeichnen. Es gibt sie mittlerweile sogar mit USB3, GigE Vision oder CSI-Schnittstelle. Zusätzlich bieten sie oftmals Pins zur freien Verwendung in Steuerungen an. Dennoch erreichen sie in Bezug auf die CPU-Rechenleistung noch lange nicht das Niveau eines PCs. Die Kombination von Kleinstrechner und einer leistungsfähigen GPU wie dem Nvidia Jetson TX1 ist jedoch neu und birgt vielfältige Mög-

lichkeiten (s. Kasten). Der Vorteil ist, dass es die kleinen Rechner von der Stange gibt, was die Entwicklungs-Kosten erheblich senkt. Die GPU übernimmt dabei die Aufgaben bisheriger DSPs. Ein Treiber des SoC-Aufschwungs mit integrierter GPU ist sicherlich Deep Learning. Der Erfolg der neuen Algorithmen basiert auf der hohen GPU-Leistung. Allerdings gibt es bei SoCs auch einen Nachteil: Der Bildeinzug der Kamera über die Schnittstelle muss immer noch mit einer normalen, sequentiell arbeitenden CPU bewältigt werden, da SoCs - wie bereits angesprochen - einer großen CPU leistungsmäßig nicht ebenbürtig und daher noch für viele Anwendungsfälle zu langsam sind. Derzeit wird mit sensor-nahen Hardware-Schnittstellen zur Kamera, wie z.B. CSI oder MIPI, versucht, dort höhere Leistungen zu erzielen. Das Problem für den industriellen Systemintegrator ist dabei aber, dass man sich mit diesen neuen Ansätzen jenseits der etablierten Visionstandards bewegt. Zudem bezahlt der Integrator dies mit einem Verlust an Flexibilität bei der

» Die Verwendung etablierter Standards wie GenICam gibt dem Anwender die Planungssicherheit, auch langfristig auf ändernde Anforderungen oder Liefersituationen flexibel reagieren zu können «

Stefan Waizmann, SVS-Vistek

Wahl der Kamera, Software und Hardware, was sich oft erst gegen Ende des Lebenszyklus der Applikation als Problem herausstellt. Gerade die Verwendung etablierter Standards wie GenICam gibt dem Anwender die Planungssicherheit, auch langfristig auf ändernde Anforderungen oder Liefersituationen flexibel reagieren zu können. Natürlich gibt es Applikationen, bei denen es weiterhin ausreicht, Board Level Kameras per Flachbandkabel und MIPI an einen Kleinstrechner anzuschließen. Das befürchtete Schnittstellenchaos im sehr agilen Bildverarbeitungsmarkt scheint zum Glück jedoch auszubleiben. GenICam-basierende Kamertechnik und Schnittstellen bieten hier enorme Vorteile. Diese behalten sie auch bei der Auswertung mit Hilfe von Deep Learning.

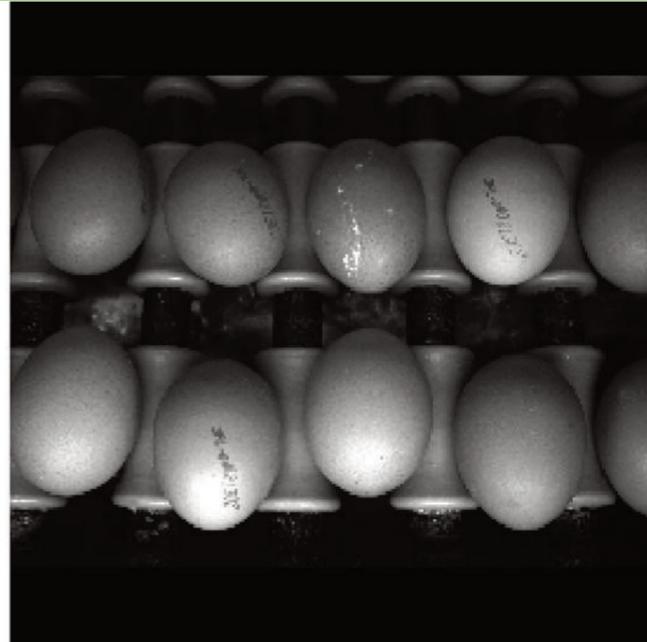
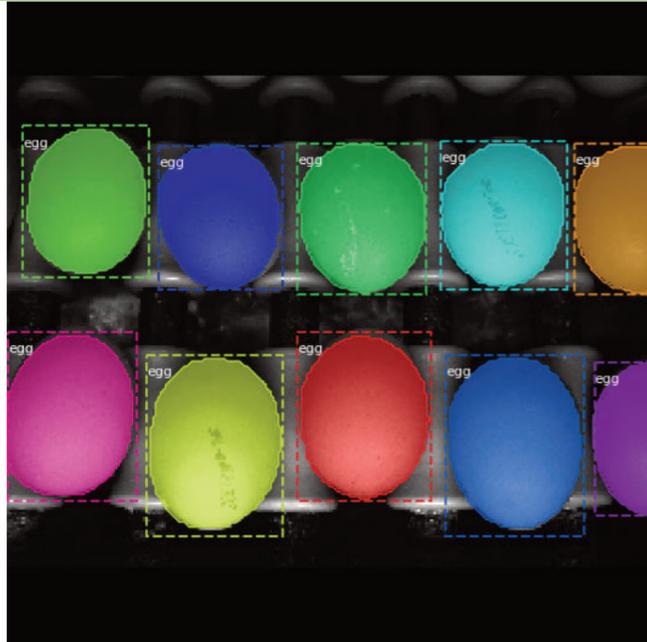
Fazit

Auf Vision-Standards (wie z.B. GenICam) basierte Embedded Vision Lösungen helfen Entwicklern bei kleinen und mittleren Stückzahlen, eine gewünschte Verschlankeung der Hardware zu erzielen, ohne auf die Flexibilität vertrauter Standardbaukästen verzichten zu müssen. Viele Bildverarbeitungsaufgaben lassen sich mit Deep Learning und den neuen Embedded Vision Lösungen einfacher bzw. überhaupt erstmalig lösen. Embedded Vision ist aber im Gesamtkonzept der industriellen Bildverarbeitung keine Revolution, sondern eher eine Evolution.

GenTL-Treiber für ARM-Plattformen

SVS-Vistek hat auf der Vision 2018 gezeigt, dass ein GenCam GenTL Treiber auch auf einem SoC mit dem Nvidia Jetson eine hervorragende Leistung im Bildeinzug bereitstellen kann, dies mit einer niedrigen Latenz und hohen Übertragungsraten bei GigE Vision und USB3. Das SDK von SVS-Vistek basiert seit Version 2.5.1 auf GenTL (GenCam Transport Layer). Es bietet eine einheitliche Schnittstelle für Hardware Interfaces. Anwender profitieren bei der Portierung auf ARM-Plattformen von der effizienten Programmierung, da auch bei einem Jetson-Board der Bildeinzug von dem in der Leistung begrenzten Kleinstrechner-Prozessor des Carrier-Boards erfolgen muss. Limitierender Faktor ist die USB-Hardware Anbindung der Schnittstelle auf dem Carrier-Board. Dennoch können bei USB3 bis zu 300MB/s Bilddaten-Transfer auf der ARM-Plattform realisiert werden.

www.svs-vistek.com



Images 1 + 2 | Modern deep learning networks can be trained with typically 20 to 50 training images within five to ten minutes on a modern GPU platform, e.g. object classification of sushi meals.

Ready or Not?

Deep Learning Science-Fiction or Reality?

AUTHOR: MICHAŁ CZARDYBON, GENERAL MANAGER, ADAPTIVE VISION | IMAGES: ADAPTIVE VISION - FUTURE PROCESSING SP. Z O.O.

There is no need to learn e.g. TensorFlow to successfully apply deep learning. But how complex are actual deep learning solutions for machine vision and which applications are they good for?

From the point of view of a regular user of machine vision systems the topic of deep learning might be confusing. This highly disruptive technology is relatively young and different experts of the field provide contradictory explanations of the subject. Some say that deep learning can behave like a human being, some say it is just sophisticated classification. There is also a question of the skills required for the user to effectively take advantage of it. Does it require a PhD diploma in machine learning or is it suitable just for every regular production worker? In short, each of the answers may be correct depending on the context the speaker has in mind. In this article I will explain it from the point of view of vision-based inspection systems.

The first time I met deep learning in reality was when a colleague of mine showed me how well his brand new phone could translate his voice into written notes. It was a time when I had only seen some early voice recognition systems for cars which had real trouble understanding a simple command such as 'home'. Then the progress was fast and remarkable. Soon after we heard about deep learning being successfully used in recognition of hand-written letters, in classification of objects on images or in programs that played chess better than any program had played before. Today the most interesting commercial topics became medical diagnosis, driving autonomous vehicles, automated harvesting and industrial quality inspection.

Deep learning for industrial vision

To efficiently discuss these applications we must not confuse the underlying theory and technology with real-world products. This is like discussing software

in 80' or early 90'. Some notable people were thinking at that time that everyone would be coding in the future. This was not true. What we needed were software programs that could be learned by everyone, such as office suites or CAD. It is now similar with deep learning. We cannot expect industrial engineers to learn deep learning frameworks such as TensorFlow or Caffe, or to learn Python programming language. These are tools for specialists who use them to develop software tools for specific applications. One application is recognition of roads and traffic in autonomous vehicles, another is software that recognizes cancer on x-ray images of lungs. For industrial quality inspection application it becomes a bit more complicated as each of these applications may be totally different from another. Nevertheless, we concluded - and our findings here are consistent with other key software suppliers - that we can identify several classes of tools that may cover a large variety of cases.



Image 3 | Another important class of deep learning tools are those for defect detection.

Object classification

The most basic class of tools that introduce deep learning to industrial vision systems is Object Classification. It is well known from easily available open-source networks that accept an entire image on the input and produce the name of the most prominent object on that image. It can be used to classify different types of fruit or meat, and can also be used as a post-processing step in defect detection applications (to identify the type of defect). It can be fast and very reliable, but the number of real-world applications is rather limited.

Instance segmentation

A significantly more interesting class of tools in industrial vision systems are Location and Instance Segmentation. The former find object coordinates or bounding rectangles, while the latter also produce the precise outline or region. This is very similar in the general goals to traditional Template Matching algorithms which we know from major software libraries. By comparing edges or feature points extracted from one training template with what is found on an input image these traditional tools were able to identify locations of the interesting objects. We were happy to claim that our tools were rotation or scale invariant, and could even handle a lot of background clutter and shape incompleteness. However, we were still limited to working with reasonably rigid and well-defined shapes such as automotive parts or electrical components in a controlled environment. What deep learning brings to this field is the ability to locate highly variable objects, ones that come in a variety of poses or those which are not uniformly illuminated. Notable examples include location of fruits on trees, counting spermatozooids for medical purposes or picking packed pieces of cloths from a container by a robot. Even if we take into account automotive parts which could be effectively detected with traditional template matching tools, today we can extend these applications to cases with imperfect illumination or not repeatable positioning.

Klare Sicht auch nach der dritten Flasche.

Etikettenkontrolle mit der x86.



Mehr Anwendungsbeispiele unter notavis.com/x86

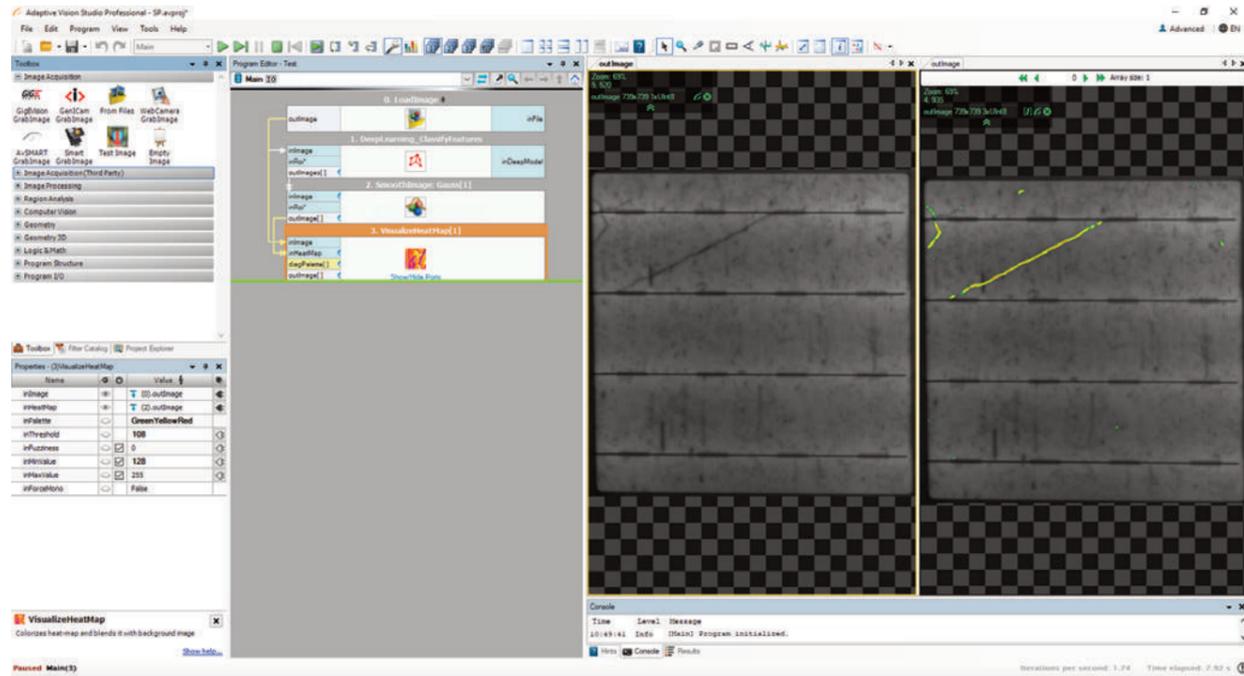


Image 4 | Customers are expected to use the right tool for each application and provide training images representing all different product cases.

Defect detection

Another important class of tools are those for defect detection. There are two very different approaches to that subject, each of which has its own unique advantages. We call them Feature Detection and Anomaly Detection respectively (they are also known under the terms of supervised and semi-supervised training modes). The former requires to prepare a set of training images with carefully marked pixels that correspond to defects (or features) that we want to detect. The task of the neural network is then to learn to reproduce those results on incoming input images. It is called supervised mode because the network is trained with explicit outputs that it is expected to produce for specific inputs. The latter tool is different in that its training is focused on good samples and it is expected to detect any deviations of shape, surface, color etc. It may look more attractive to many as it does not require any definition of defects and data labeling is

much easier. The drawback, however, is that it is not a strictly defined task and it is not as effective in detecting tiny or weak defects as in the supervised mode.

20 to 50 training images

What is very important is that we can have a very limited set of tools to cover a wide variety of industrial applications without the need to design custom neural network architectures for each particular case. There is no need to learn TensorFlow to successfully apply deep learning. Customers are just expected to use the right tool for each application and provide training images representing all different product cases. Contrary to a popular belief, it is also not required to provide hundreds or thousands of object samples. The most advanced software manufacturers provide highly sophisticated solutions that can be trained with typically 20 to 50 training images within five to ten minutes on a modern GPU platform. This is possible due to techniques such as usage of pre-trained net-

works, advanced preprocessing and artificial generation of raw training data from just a few initial samples. Details of these solutions are technical secrets of each of the supplier that required quite a lot of effort to bring it into reality, but for a regular user this are just out-of-the-shelf solutions that can be instantly applied in a huge variety of applications.

Conclusion

Everything I have described is not just research topics or ideas for next generations. These are ready products that are getting into practical use in an unprecedented pace. A major challenge now appears to be in our ability to change our mindsets in a fast way to keep up with that progress. This may be particularly difficult to more traditional industries where major revolutions took decades in the past, while today those who are not progressive enough may become obsolete in a matter of two or three years. ■

www.adaptive-vision.com

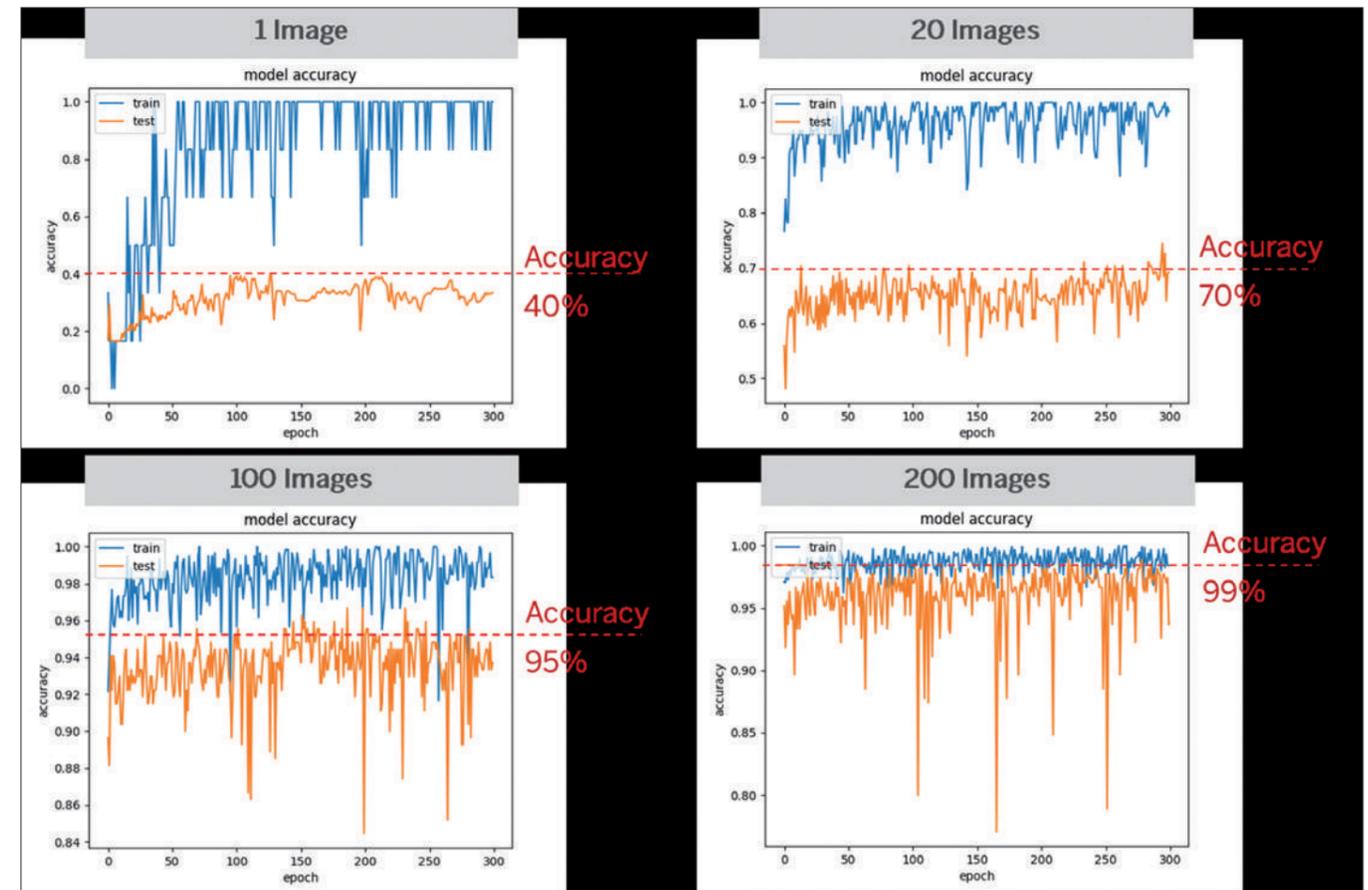


Bild 1 | Die Grafiken zeigen eine deutliche Zunahme der Vorhersage-Genauigkeit bei Deep-Learning-Anwendungen durch das Erhöhen der Anzahl der Trainingsdaten.

CNN auf FPGAs

Tiefe neuronale Netze erobern die Bildverarbeitung

AUTOR: MARTIN CASSEL, REDAKTEUR, SILICON SOFTWARE GMBH | BILDER: SILICON SOFTWARE GMBH

Der Beitrag erläutert aktuelle Deep-Learning-Technologien für die Verarbeitung von Bildern und Videos als 2D- und 3D-Daten sowie daraus resultierende Vision-Anwendungen, für die sich tiefe neuronale Netze wie CNN sehr gut eignen.

Bei der Bildklassifikation wird Deep Learning immer wichtiger, während ergänzend dazu die Bildvorverarbeitung, -nachbearbeitung und Signalverarbeitung weiterhin mit den bisherigen Me-

thoden ausgeführt werden. Deep Learning kommt insbesondere bei Applikationen wie reflektierende Oberflächen, schlecht ausgeleuchtete Umgebungen, variierende Beleuchtung oder bewegende Objekte zum Einsatz. Klassische Algorithmen eignen sich aber weiterhin, wenn eine Lokalisierung von Objekten oder Fehlern in einem Bild, das maßliche Prüfen, Codelesen oder Post-Processing benötigt werden. Deep Learning besticht dagegen durch eine hohe Zuverlässigkeit bei den Erkennungsraten. Im Wettbewerb um die bessere Lösung stehen somit die Aufwände für

eine algorithmische Umsetzung gegen die Zeit für Training und Vorklassifizierung anhand von Trainingsbildern. Dabei unterscheidet man zwischen dem Training zum Anlernen des neuronalen Netzes, der Implementierung des Netzes und der Inference, d.h. dem Ausführen der CNN-Algorithmik (Convolutional Neural Networks) des Netzes auf Bilder mit der Ausgabe eines Klassifizierungsergebnisses. Beim Training wird das Netz über die Parameter so lange angepasst, bis das erwartete Klassifizierungsergebnis vorliegt. Dies ist zeitaufwändig und setzt eine hohe Expertise voraus.

	Frame grabber	GPU
Model	marathon VCL (Kintex7)	NVIDIA GTX1080
Availability	15 years +	~ 3 years
Max. TDP	15W	180W
Resolution	8bit Fixed-Point	32bit Floating-Point
Accuracy	98.7%	99.0%
Time per Image	0.128ms	0.94ms
Inferences per Sec.	7812	1063

Bild 2 | Die FPGA-Leistung ist zwar 7,3-mal höher als die einer GPU, der Verlust an der Vorhersagegenauigkeit liegt aber bei 0,3 Prozent, was 30 Prozent mehr inkorrekt klassifizierten Bildern ent-

Deep Learning benötigt zudem eine große Mengen vorklassifizierter Daten und eine hohe Rechenleistung. Je mehr Daten für das Antrainieren verwendet werden, desto höher ist die Vorhersagegenauigkeit bei der Klassifikation.

Geschwindigkeit vs. Treffgenauigkeit

Die Defekt- und Objekt-Klassifikation anhand von Deep Learning ist derzeit ein viel diskutiertes Thema. Eignen sich aber die verschiedenen Machine Vision Prozesstechnologien mit ihren speziellen Voraussetzungen hinsichtlich eines schnellen Ausführens (Inference) von CNNs mit sehr geringen Latenzen? Neben Geschwindigkeit und Echtzeit-Anforderungen sind hier hohe Bandbreiten, geringe Wärmeleistung und Langzeitverfügbarkeit gefragt, wofür sich herkömmliche CPUs oder GPUs kaum eignen. Diese stellen eher eine geeignete Lösung für Bildverarbeitungsaufgaben im nicht-industriellen Umfeld dar, wo eine geringere Performanz oder Treffgenauigkeit manchmal ausreichend sind. Zudem zeigen beim Vergleich der technischen Aspekte die Technologieplattformen unterschiedliche Leistungswerte, die ihren Einsatz bei Anwendungen mit hohen Anforderungen ausschließen. So ist die Inference-Zeit einer GPU als Performanz-Indikator bei einer angenommenen Bildgröße von 400x400

Pixeln im Schnitt geringer als 8MB/s und die Bildrate kaum höher als 50fps. Allerdings sind GPUs die richtige Wahl für das Training von neuronalen Netzen aufgrund der sehr hohen Datenmengen. Da für das Training meistens nur eine GPU benötigt wird, wirkt sich die Hardwareumgebung wenig auf die Systemkosten aus. Hier haben sich mittlerweile kommerzielle GPUs durchgesetzt und werden von fast jeder Trainingssoftware unterstützt. Bei der Auswahl eines geeigneten Netzes genügen für typische Visionanwendungen oftmals mittelgroße Netze, wenn nur wenige Merkmale zu klassifizieren sind. Diese sind ausreichend für hohe Geschwindigkeiten bei geringen Abstrichen in der Treffgenauigkeit. Schwerpunkt sind immer größere, aber auch langsamere Netze, die eine breite Erkennung unterschiedlichster Objekte ermöglichen. Gleichzeitig entstanden aber auch kleinere, sehr effiziente Netze für Klassifi-

	FPGA	Software	Industrial	Non-Industrial
System Cost	😊	😞	😊	😊😊
Frame grabber	😞	😊	😊	😊
GPU	😊😊	😞😞	😞	😊
IPC	😊	😞	😞	😊
Software license	😊😊	😞😞	😊😊	😊😊

Bild 3 | Systemkostenvergleich für eine Deep-Learning-Anwendung.

kationsaufgaben, die typisch für die Bildverarbeitung sind.

FPGAs und SoCs für Inference

Die Anforderungen an die Inference vieler Bildverarbeitungsaufgaben erfüllen FPGAs als eigenständiger Prozessor bzw. SoC (System on Chip) im Verbund mit ARM-Prozessoren am besten. FPGAs zeichnen sich durch eine hohe Parallelität der Datenberechnung, einen garantiert robusten Bildeintrag und – im Vergleich zu CPUs und GPUs – eine hohe Rechenleistung, Bildrate und Bandbreite aus. Dadurch klassifizieren CNNs auf FPGAs mit einem hohem Datendurchsatz, was ideal für die anspruchsvollen zeitlichen Anforderungen einer Inline-Inspektion ist. Der FPGA ermöglicht eine Verarbeitung der Bilddaten – von der Bildaufnahme bis zur Bildausgabe – direkt auf einem Framegrabber oder eingebetteten Visiongerät, ohne die CPU zu belasten, was besonders für rechenintensive Anwendungen wie CNNs geeignet ist. Dadurch sind kleinere PCs ohne GPU einsetzbar, was die Kosten des gesamten Bildverarbeitungssystems deutlich verringert. Die Energieeffizienz von FPGAs im industriellen Temperaturbereich ist zudem zehnmal höher im Vergleich zu GPUs, was für Embedded Systeme ideal ist. Dies ermöglicht den Einsatz von Deep Learning in Hinblick auf Industrie 4.0, Drohnen oder autonomes Fahren. Für einen FPGA führt die Verlagerung in den Fixed Point Bereich lediglich zu einer zu vernachlässigenden Reduzierung der Treffgenauigkeit im Vergleich zu GPUs, während die gewonnenen

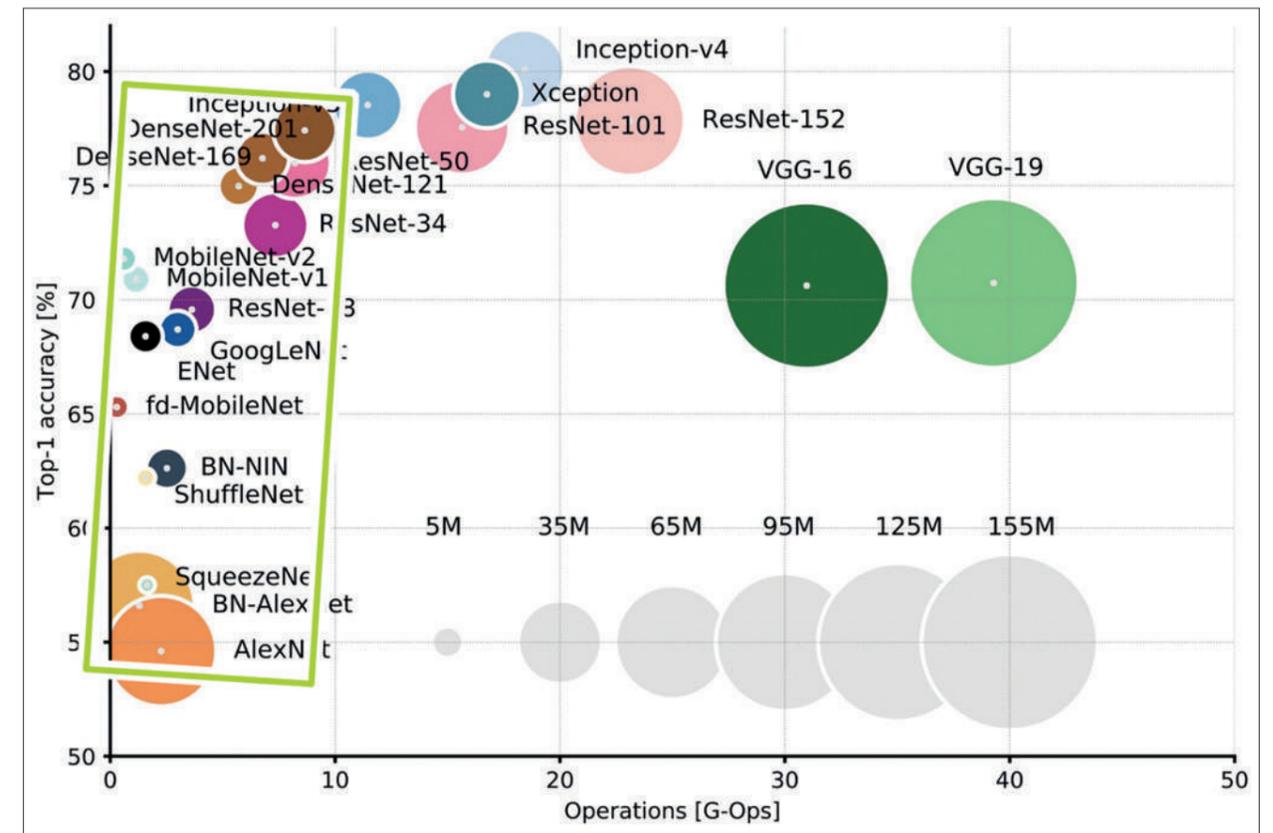


Bild 4 | An analysis of Deep Neural Network Models for Pratical Applications (Alfredo Canziani, Adam Paszke, Eugenio Culurciello, 2017).

Ressourcen für größere Netzarchitekturen oder einen höheren Datendurchsatz zur Verfügung stehen. Dadurch ist es möglich, die Produktionsgeschwindigkeit etwa bei der Schweißnaht-Inspektion oder Robotik zu steigern. Eine datenreduzierende Bildvorverarbeitung ermöglicht es darüber hinaus, kleinere Netze oder FPGAs einzusetzen. Diese reichen oftmals für einfache Klassifizierungsaufgaben mit wenigen Merkmalen aus.

Vergleich FPGA vs. GPU

Für hohe Bandbreiten kommen nur FPGAs oder GPUs als Technologie in Betracht. Eine Gegenüberstellung der jeweiligen Schwächen und Stärken zeigt, dass die höhere Rechengenauigkeit von GPUs und damit auch höhere Genauigkeit durch deutlich kürzere Verfügbarkeiten, höhere Leistungsaufnahme aber auch durch eine geringeren Datendurchsatz

erkauft wird. Die Leistung der Datenbearbeitung liegt bei den FPGAs um den Faktor 7,3 höher als bei vergleichbaren GPUs. Der Gewinn bei der Genauigkeit liegt bei 0,3 Prozent, bedeutet aber eine 30 Prozent höhere Anzahl falsch klassifizierter Bilder. Im Vergleich der Systemkosten für eine Inferenz wurden Rechensysteme basierend auf einem programmierbaren FPGA-Framegrabber, einer speziellen Branchensoftwarelösung mit zwei GPUs und zwei Standardsystemen mit einer industriellen und kommerziellen GPU herangezogen. Die Kosten wurden über die Komponenten für einen Framegrabber (hier eine industrielle Camera Link Lösung), eine oder mehrere GPUs, einen industriellen Rechner und anfallende Softwarelizenzen ermittelt. Nicht berücksichtigt wurde bei der Gegenüberstellung die Leistungswerte für Datendurchsatz, Bandbreite und Energieeffizienz. Die Kehrseite vermeintlich preis-

günstiger Systeme sind eine geringe Lieferbarkeit und schlechtere Performance. Ein Upgrade zu industriellen Produkten (auch GPUs) führt sofort zu höheren Preisen als FPGA-basierte Systeme. Branchenlösungen können dagegen durch unterschiedliche Lizenzmodelle (Jahreslizenz, Arbeitsplatzlizenz oder Koppelung) hohe Kosten erzeugen, welche die Hardwarekosten schnell übersteigen.

Implementierung auf FPGAs

Die Rechenleistung von FPGAs hat sich in einem Maße entwickelt, die das Wachstum von herkömmlichen Prozessoren deutlich überflügelt. Der Produktionsprozess von FPGAs wird aktuell von 16 auf 7nm umgestellt, das heißt eine Vervielfachung der Logikreserven um den Faktor 10. Mit der Umstellung auf 3nm in ca. fünf Jahren wird sogar ein Faktor 100 im Vergleich zu heute erreicht. Dadurch lassen

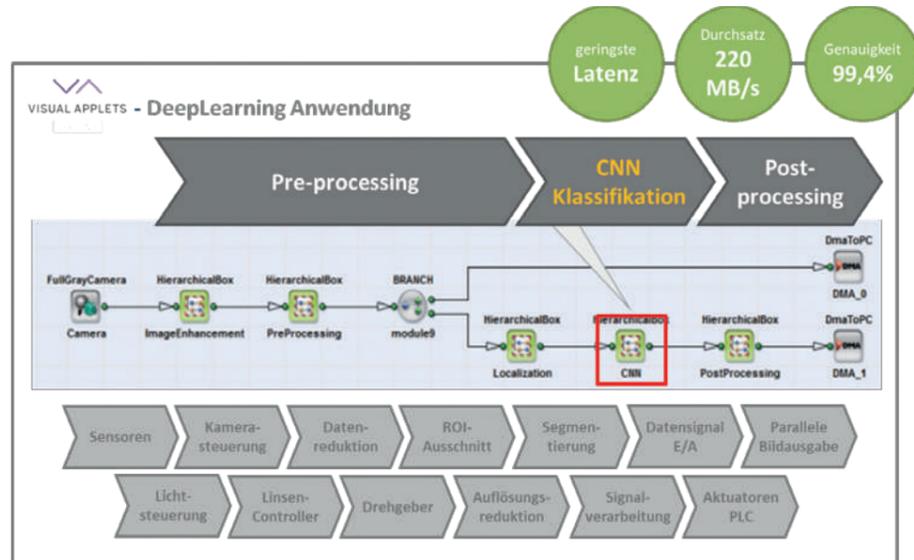


Bild 5 | Verarbeitung von Gesamtbildern, Videos und Signalen in Echtzeit mit FPGAs unter Visual Applets.

sich komplexe Algorithmen implementieren und Objekte in einem Bild automatisch klassifizieren. Um die bei vielen Deep-Learning-Anwendungen geforderte hohe Rechengeschwindigkeit zusammen mit einer hohen Durchsatzrate und Treffgenauigkeit zu erzielen sowie für die Implementierung großer Netze sind allerdings auch leistungsfähigere FPGAs notwendig. Für die in der Produktion erforderlichen Verarbeitungsgeschwindigkeiten stehen bereits Hochleistungs-Framegrabber und eingebettete Bildverarbeitungsgeräte wie Kameras und Sensoren mit größeren FPGAs zur Verfügung. Mit umfangreicheren FPGA-Ressourcen lassen sich komplexere Architekturen und damit auch Anwendungen verarbeiten. Die höhere Datenbandbreite ermöglicht eine Verarbeitung eines Gesamtbildes oder zusätzliche Bildvor- und -nachverarbeitung auf dem FPGA. Sie ist ausreichend hoch, um z.B. den kompletten Datenausgang einer GigE Vision Kamera mit Deep Learning zu analysieren.

FPGA-Ressourcen optimieren

Die Bearbeitungsmöglichkeiten im FPGA stehen im direkten Zusammenhang mit den verfügbaren Logikressourcen. Diese können für die algorithmische Beschreibung, aber auch für aufwändige Implementierungsmethoden, Rechentiefen

oder höhere Bandbreiten über die Vielfachung des Rechenkerns eingesetzt werden. Für Deep Learning gibt es unterschiedliche Methoden, Ressourcen einzusparen ohne die Qualität der Klassifizierung zu beeinträchtigen. Eine Methode ist die Skalierung der Bilder, die den internen Datendurchfluss reduziert. Erfahrungswerte haben gezeigt, dass die Rechentiefe sich nur marginal auf die spätere Erkennungsgenauigkeit durchschlägt. Die Reduktion von 32Bit auf 8Bit und von Floating Point auf Fixed Point / Integer ermöglicht dem FPGA, seine stark eingesparten Ressourcen in größere Netzarchitekturen zu investieren. Die höhere Rechengenauigkeit einer 32Bit Floating Point GPU ist für die Deep Learning

	Frame grabber	GPU
Model	marathon VCL (Kintex7)	NVIDIA GTX1080
Availability	15 years +	~ 3 years
Max. TDP	15W	180W
Resolution	8bit Fixed-Point	32bit Floating-Point
Accuracy	98,7%	99,0%
Time per Image	0,128ms	0,94ms
Inferences per Sec.	7812	1063

Bild 6 | Die FPGA-Leistung ist 7,3-mal höher als diejenige der GPU.

Inferenz von geringer Bedeutung, erreichen doch 8Bit Fixed Point FPGAs eine ausreichend präzise Erkennungsgenauigkeit für die meisten Deep-Learning-Anwendungen bei zu vernachlässigender Fehlertoleranz. Bei Anforderungen nach besonders präziser Rechengenauigkeit lässt sich auf einem größeren FPGA als Ressourcenkompromiss auch 16Bit Fixed Point implementieren. Typische Aufgabenstellung in der Bildverarbeitung ist die Erkennung von Defekten. Sind die Fehlerklassen bekannt, lassen sie sich anhand von Defektbildern aus der Produktion antrainieren. Hingegen bei unbekanntem Bildern und der Anforderung, jede Abweichung zu erkennen, werden die Prüfstücke mit einem Golden Master verglichen. In jedem dieser Fälle sind meist kleine Netze einzusetzen, die Fehlerklassen und deren Varianten detektieren. AlexNet, SqueezeNet oder MobileNet sind typische Vertreter hierfür. Diese sind als Basis für spezifische Anpassungen und Verbesserungen der Netzarchitektur für die individuelle Anwendung einsetzbar. Nach dem Training folgt die FPGA-Implementierung für die Inferenz, das heißt eine weitere Möglichkeit, Ressourcen zu optimieren und die Klassifizierungsqualität zu erhöhen. Im Verhältnis zwischen Erkennungsgenauigkeit, Implementierungsgröße und Rechengeschwindigkeit bzw. Bandbreite werden bei Machine Vision vorrangig kleine, schnelle Netze eingesetzt.

	FP-32	INT16	INT8	Diff. vs FP32
VGG-16	86,6%	86,6%	86,4%	(0,2%)
GoogLeNet	88,6%	88,5%	85,7%	(2,9%)
SqueezeNet	81,4%	81,4%	80,3%	(1,1%)

Bild 7 | Treffgenauigkeit von Prozessoren mit unterschiedlicher Rechentiefe (Floating Point 32bit vs. Fixed Point bzw. Integer 16bit und 8bit)

Deep Learning mit VisualApplets

Die gesamte Bildverarbeitung führen Framegrabber oder Embedded Vision Geräte als zentrale Elemente des Bildverarbeitungssystems aus, inklusive Vor- und Nachverarbeitung, die eigentliche CNN-Bildklassifikation sowie die Synchronisierung der Peripheriegeräte (Beleuchtung, Sensoren und Aktoren) durch eine Signalsteuerung in Echtzeit. Mit der grafischen FPGA-Entwicklungsumgebung VisualApplets sind Anwender in der Lage, Deep-Learning-Anwendungen und die Visionperipherie selbstständig im FPGA per Drag&Drop zu konfigurieren, auch ohne Hardware-Programmierkenntnisse. Sie sehen die Abbildung und Konfiguration des neuronalen Netzes als einen CNN-Operator innerhalb eines Datenfluss-Diagramms. Das spezifische CNN wird zwischen dem Kamera-Operator als Bildquelle und dem DMA-Operator als Datenübergabe an den PC eingebunden. Das gesamte Anwendungsdesign lässt sich fortlaufend simulieren sowie abschließend synthetisieren und läuft immer als Echtzeitbetrieb in der definierten Geschwindigkeit mit geringsten Latenzen ab. Werden Bilder vor dem Training über eine Bildverarbeitung optimiert, muss dieser Vorgang während der Inferenz ebenfalls durchgeführt werden. Der modulare Aufbau der Deep-Learning-Lösung in VisualApplets ermöglicht die Kombination von Vorverarbeitungen zur Bildoptimierung, Vorselektion von Bildausschnitten oder auch Auflösungsänderungen mit dem CNN-Verarbei-

tungskern und einer Bildnachbearbeitung für Ausschleusungen von NIO-Teilen. Der CNN-Operator wird hierbei nur mit Informationen über die Netzarchitektur und deren Gewichte konfiguriert. Über den CNN-Operator lassen sich passende Netzarchitekturen unterschiedlicher Größe und Komplexität integrieren sowie vortrainierte Konfigurationsparameter für die Gewichte der Netze für eine Vielzahl von Vision-Anwendungen laden. Dabei werden auch Informationen über Netze und deren Parameter aus Drittsoftware wie die Deep-Learning-Frameworks TensorFlow oder Caffe importiert. Neue Gewichte sind leicht zu laden, solange das Netz unverändert bleibt. Ein Nachtrainieren, z.B. für ein neues Werkstück in der Fertigung, geht mit relativ wenig Aufwand. Ändern sich Testumgebung oder -objekte, können die nachtrainierten Bilder über einen neuen Parametersatz der Gewichte oder als neues Netz nachgeladen werden. Die Implementierung von Deep-Learning-Anwendungen auf einem FPGA ist mit VisualApplets einfach zu handhaben und in kurzer Zeit umzusetzen - und dies als hardwareprogrammierte Echtzeitanwendung. Für die Inspektion von reflektierenden Oberflächen wie Lack und Metall mit Deep Learning wurde innerhalb von zwei bis drei Wochen eine Bildverarbeitungslösung aus dem Camera Link Framegrabber microEnable 5 marathon deepVCL und VisualApplets aufgebaut. Die Summe aller Optimierungen und das modu-

lare Konzept der Inferenz mit Pre-Processing, Deep-Learning-Ausführung und Post-Processing ermöglichen Verbesserungen der Klassifikation ohne Abstriche bei der Performance. Anwender verwenden ihr bereits vorhandenes Bildverarbeitungssystem einfach weiter.

Fazit

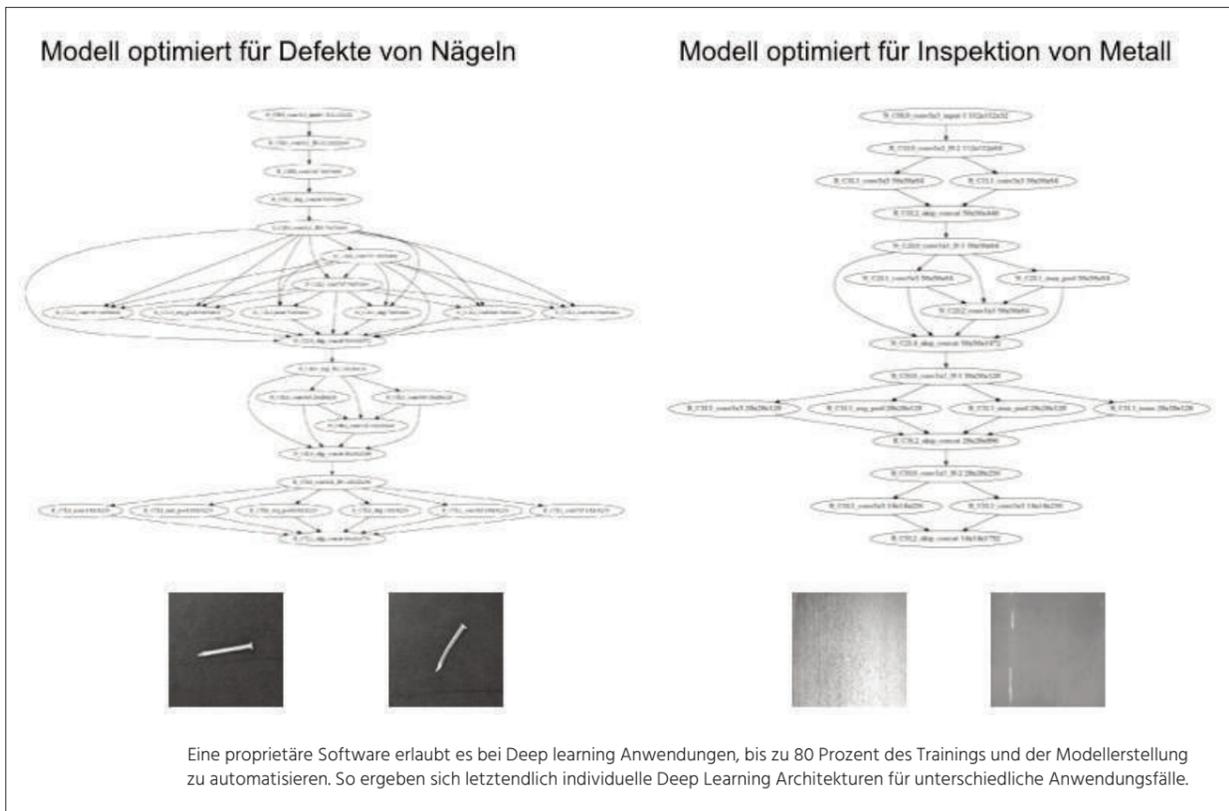
Für die Objekt- und Merkmalsklassifikation setzen sich in der Bildverarbeitung immer mehr neuronale Netze durch, insbesondere bei Aufgaben mit vielen Merkmals- oder Umgebungsvariablen oder solchen die algorithmisch schwierig zu beschreiben sind. Die Stärken von Deep Learning überwiegen bei weitem die Schwächen. Ein relativ hoher Trainingsaufwand wird durch Zuverlässigkeit, Schnelligkeit und Transfermöglichkeit der Ergebnisse mehr als aufgewogen. Im industriellen Umfeld sind FPGAs die beste Wahl aufgrund ihrer hohen Rechenleistung, geringen Latenzen und Leistungsaufnahme sowie der Langzeitverfügbarkeit und weiten Verbreitung auch in Embedded-Geräten. Somit werden FPGAs auch unter dem Aspekt des Return on Investment zu einer interessanten Alternative, wenn man die Gesamtkosten eines Bildverarbeitungssystems zugrunde legt. ■

silicon.software

- Anzeige -

Kameraschutzgehäuse
Montagelösungen
Zubehör

www.autoVimation.com



chen will, wird es ihm sehr schwer fallen, das zu schaffen, da er weder Data Scientist noch Experte für Deep-Learning-Anwendungen ist. Um in einem Anwendungsfall eine Genauigkeit zu erreichen, die in einer Produktion erwartet wird, kann man sich nicht alleine auf ein Werkzeug verlassen, sondern benötigt entsprechende Experten im Bereich Data Science.

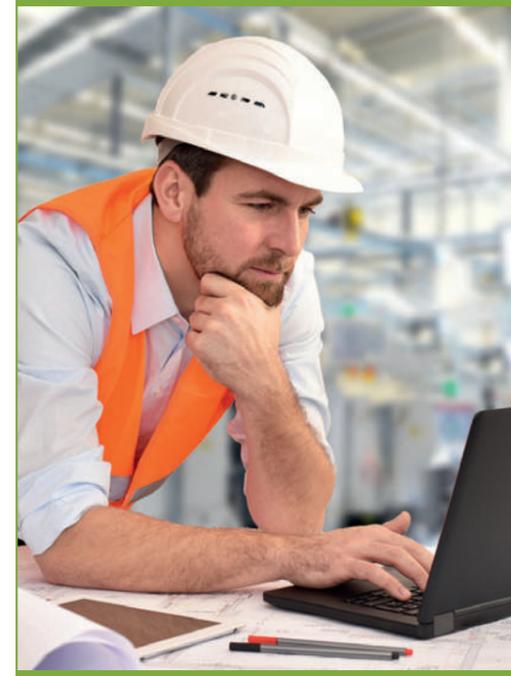
Erstellung von DL-Modellen

Das Geschäftsmodell von Deevio beruht auf der vollständigen Übernahme der Verantwortung für die Erstellung und Implementierung der Deep-Learning-Modelle für den Anwender. Anstatt selbst mit einem Werkzeug zu arbeiten, stellt der Anwender Bilddaten zur Verfügung und bekommt dafür von dem Team aus Data Scientists ein maßgeschneidertes Modell für die Inspektion seiner Produkte. Dabei ist es unerheblich, ob es sich um s/w, Farbbilder oder 3D-Daten handelt. Um loszulegen, werden ca. 100 Bilder pro Kategorie für die Erstellung eines ersten Modells benötigt, so dass eine Einschätzung der Machbarkeit des Anwendungsfalls möglich ist. Im Anschluss daran erfolgt die Installation eines Kamerasystems in der Produktion, erste Modelltests und die Aufnahme weiterer Produktionsbilder zur Optimierung. Sobald die Genauigkeit im 99 Prozent Bereich liegt, beginnt die Pilotphase mit dem Ziel, das Modell unter realen Bedingungen zu testen und zu industrialisieren. Zusätzlich zum Bildverarbeitungssystem wird eine Analysesoftware angeboten, mit der die Produktivität auf der Linie und die häufigsten Defekte einsehbar sind. Die Klassifizierung jedes Produkts wird gespeichert und somit dokumentiert und nachverfolgbar.

Automatische Modell-Generierung

Aus dem Ansatz der individuellen Erstellung von anwenderspezifischen Deep-Learning-Modellen stellt sich die Frage, wie man dieses Geschäftsmodell skalieren und mit möglichst vielen Kunden arbeiten

kann. Die Antwort ist eine automatische Generierung der Deep-Learning-Modelle. Eine proprietäre Software erlaubt es, bis zu 80 Prozent des Trainings und der Modellerstellung zu automatisieren. Dadurch bekommen die Data Scientists die bestmögliche Architektur für das vorhandene Datenset angezeigt und haben die Aufgabe, lediglich die restlichen 20 Prozent des Prozesses manuell zu optimieren. Genau in der Optimierung dieser 20 Prozent liegt aber der Mehrwert des Deevio-Teams, die mit ihrer Expertise so die höchstmögliche Genauigkeit des Modells für den jeweiligen Anwendungsfall erreichen. Durch die Kombination von automatischer Modellgenerierung und manueller Optimierung sind die Modelle genauer und benötigen weniger Speicherplatz. Das Beispiel im Aufmacher zeigt einen echten Anwendungsfall mit Nägeln auf der linken und Metallplatten auf der rechten Seite. Für verschiedene Anwendungsfälle sehen die Deep-Learning-Modelle entsprechend unterschiedlich aus. Das liegt daran, dass keine Standardarchitekturen zum Einsatz kommen, sondern jeweils die am besten geeignete, automatisch generierten Modelle. Da diese auch weniger Speicherplatz und somit auch keine teuren GPUs benötigen, werden sie in Zukunft auf FPGAs laufen, die in Kameras integriert sind. Das Geschäftsmodell ist auch perfekt für eine Zusammenarbeit mit Distributoren und Systemintegratoren geeignet, da die Deevio-Expertise primär in der Modellgenerierung liegt. Derzeit finden bereits erste Zusammenarbeiten mit einigen ausgewählten Partnern statt, die bei Bildakquise und Installation des kompletten Bildverarbeitungssystems für den Endanwender helfen.



Informationsportal für die Industrie

- ✓ Passende Produkte finden
- ✓ Marktüberblick gewinnen
- ✓ Kompetent entscheiden

Nicht suchen, sondern finden!

www.deevio.ai

Gleich ausprobieren!
www.i-need.de



KI für jedermann

Automatische Generierung von Deep-Learning-Modellen

AUTOR: DAMIAN HEIMEL, COO, DEEVIO GMBH | BILD: DEEVIO GMBH & DONATO MONTANARI, CEO, DEEVIO GMBH

Die Bildverarbeitungsindustrie adaptiert Deep Learning eher langsam. Ein Punkt, der eine großflächige Adaption verhindert, ist die Zuständigkeit und Verantwortung für die Erstellung und Implementierung der Deep-Learning-Modelle, die bisher beim Anwender lag.

Was Machine-Vision-Unternehmen derzeit verkaufen, sind Softwarebibliotheken, also ein Werkzeug zur Erstellung von Deep-Learning-Modellen. Für die richtige Nutzung dieses Werkzeugs und die Genauigkeit der damit generierten Modelle ist aber immer noch der Anwender selbst verantwortlich. Wenn ein Automatisierungsingenieur mit einem existierenden Werkzeug eine Genauigkeit im Bereich von 99 Prozent errei-



Bild 1 | Echtzeitlernende Objekterkennung: ein unbekanntes Objekt liegt vor (l), der Nutzer macht drei bis fünf Fotos vom neuen Objekt mit einem Tablet oder Smartphone (m) und wenige Sekunden später ist das System in der Lage das neue Objekt zu erkennen.

Echtzeitlernende Objekterkennung

Lernende KI zur automatischen Objektinspektion

AUTOR: DR. EUGEN FUNK, GESCHÄFTSFÜHRER, GESTALT ROBOTICS GMBH | BILDER: GESTALT ROBOTICS GMBH

Inspektionssysteme sind auf wenige, akkurat justierte Objekttypen herstellerseitig justiert. Kommen neue Produkte hinzu, müssen sie zeit- aufwendig neu justiert werden. Die KI-Inspektionsplattform beseitigt diese Hürden.

Auf Basis eines neuronalen Netzes werden hochflexible Systeme zur Wareneingangsprüfung und Qualitätssicherung im laufenden Betrieb aufgebaut. Dadurch werden metrische Messungen mit einfachsten Kameras ermöglicht und jeder Benutzer kann über eine App neue Produkte in wenigen Sekunden anlernen. Durch die Kombination der Künstlichen

Intelligenz (KI) und Maschinellem Wahrnehmung kann flexibel eine breite Masse an Objekten inspiziert und vermessen werden. Das Gedächtnis der KI kann auf neue Produkttypen mit nur wenigen Fotos von jedem Mitarbeiter erweitert werden. So kann eine schier unbegrenzte Anzahl von Objektklassen erkannt und verwaltet werden. Das Verfahren basiert

auf aktuellen Forschungsergebnissen zur Gesichtserkennung, wo Millionen verschiedene Gesichter gelernt und wiedererkannt werden müssen. Hat das KI-System ein Objekt erfolgreich im Bild detektiert, kann das Objekt metrisch vermessen werden.

Dank dieser Besonderheit des neuen Ansatzes von Gestalt Robotics ist keine kostspielige 3D-Kamera erforderlich. Informationen über die Umgebung der Aufnahme und die KI-Analyse sind für eine präzise Vermessung eines

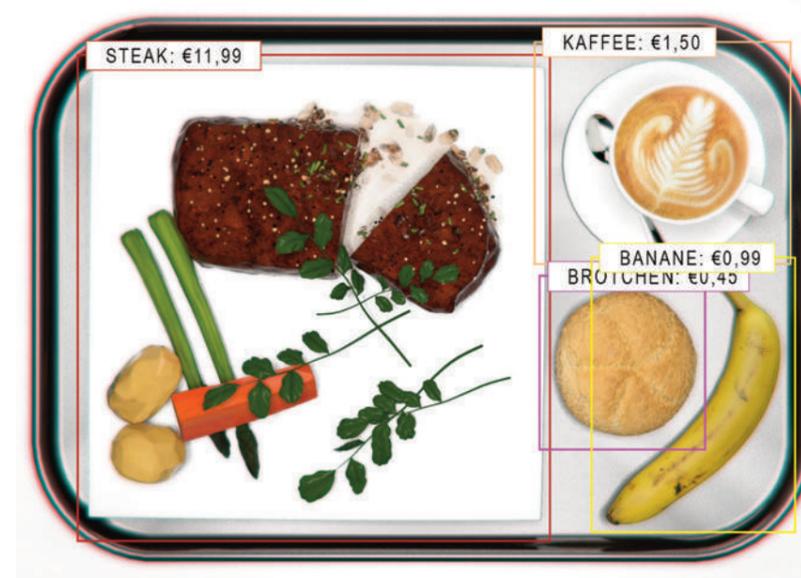


Bild 2 | Erkennung von gekauften Produkten in der individuellen Gastronomie

Objektes ausreichend. Die KI-Inspektions-Plattform ist in der Lage, in unterschiedlichen Architekturen zu operieren, beispielsweise auf den neuen Embedded-Kamerasystemen von Adlink (Neon) und Flir (Firefly) sowie Server-Client-Architekturen, die sogar in Echtzeit über LTE/4G betrieben werden können. Die Wartung kann dank der Web-App-Oberfläche mit Laptops, Desktop-Rechnern oder Mobiltelefonen erfolgen. Jeder beliebiger Bildsensor ist nutzbar. Als Bildgeber können alle Quellen von RGB-Kameras bis X-Ray-Sensoren genutzt werden.

Einsatzgebiete

Wareneingangsprüfung: Üblicherweise wird die eingehende Ware manuell anhand der Rechnungsbeschreibungen und Artikelnummern in den Bestand aufgenommen. Diese Art der Prüfung ist zeitaufwendig und ermüdend. KI-Inspekt identifiziert das Objekt anhand des Fotos und ermöglicht so eine automatisierte Wareneingangskontrolle. Die Erkennung eingehender Objekte erlaubt es bei automatisierten Hochregalen, Waren und Bauteile voll automatisch einzusortieren und mithilfe von Fotos ('Finde mir dieses Objekt') zu suchen.

Qualitätsprüfung: Die Vermessung der Objekte mit nur einer Kamera erlaubt es Objekte nicht nur auf optische Stimmigkeit zu prüfen, sondern auch auf geometrische Abweichungen vom Sollwert. Als modulares System ist es KI-Inspekt möglich die Kamerahardware an die Präzisionsanforderungen anzupassen, sowie weitere Informationsquellen, wie Gewicht und Text-Scan (OCR) zu integrieren.

Automatisierter Check-Out: Anstatt auf Barcodes angewiesen zu sein, können Produkte in jeder Lage z.B. auf einem Förderband erkannt werden und ermöglichen auch das Bepreisen von selbstzusammengestellten Menüs in Kantinen. ■

www.gestalt-robotics.com

KI auf Intel CPUs

Deep-Learning-Inferenz auf Intel-kompatiblen x86-CPUs

AUTOR: JOHANNES HILTNER, PRODUKTMANAGER HALCON, MVTEC SOFTWARE GMBH | BILDER: MVTEC SOFTWARE GMBH

Mit der Halcon-Version 18.11 kann die Deep-Learning-Inferenz, also die Anwendung eines trainierten Netzes auf neue Daten, auch auf Intel-kompatiblen x86-CPUs ausgeführt werden und das annähernd mit der Geschwindigkeit einer Mittelklasse-GPU.

KI-basierte Technologien wie Deep Learning und Convolutional Neural Networks (CNNs) bieten viele Vorteile und sind damit für den Einsatz in Vision-Systemen geradezu prädestiniert: Dank selbstlernender Algorithmen können die

Verfahren mittels Analyse großer Mengen an digitalen Bildinformationen verschiedene Objekte eigenständig kategorisieren. Im Rahmen eines Trainingsprozesses werden dabei spezifische Muster gelernt, die typisch für bestimmte Merk-

male und damit für die Einordnung in eine entsprechende Objektklasse sind. Die Bilddaten von verschiedenen, zu erkennenden Gegenständen werden dazu sortiert (gelabelt) und einer Identität bzw. Klasse zugewiesen. Mit den so trainierten Modellen, auch Klassifikatoren genannt, lassen sich dann problemlos neu aufgenommene Bilder in die zuvor gelernten Klassen einordnen. Die Vorteile dieser Methodik liegen auf der Hand: Durch die große Trainings-Datenmenge werden nicht nur äußerst treffsi-

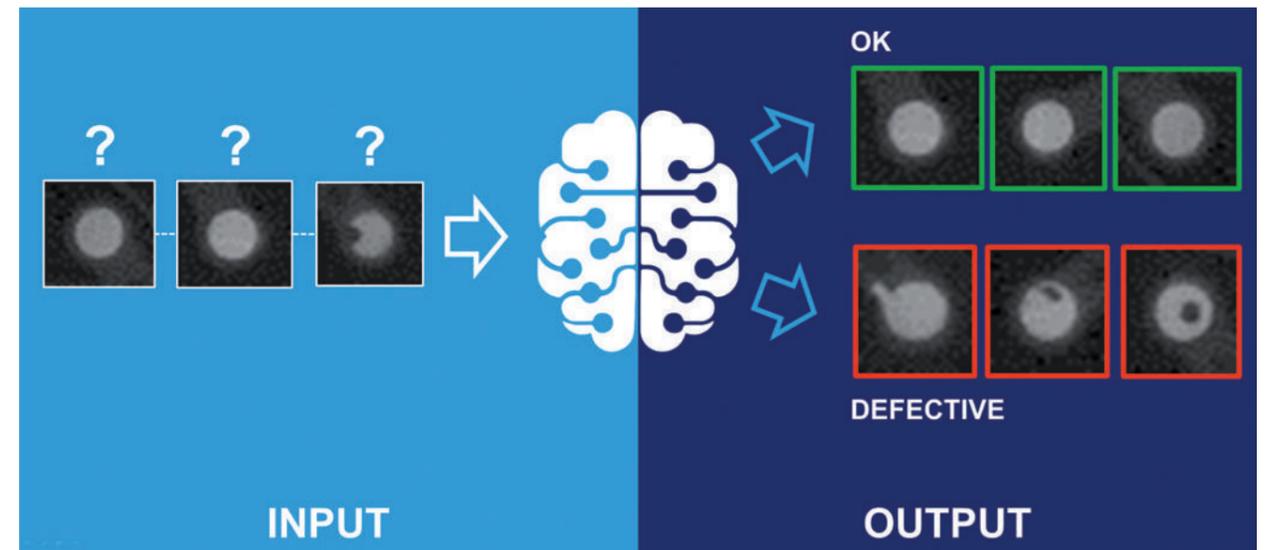


Bild 2 | Mit Halcon 18.11 können konventionelle IPCs ohne Einsatz einer GPU problemlos für Klassifikationsaufgaben auf Basis von Deep Learning genutzt werden.

chere Ergebnisse bei der Identifikation verschiedenster Objekte erzielt. Auch werden durch den ständigen Lernprozess der Aufwand und die Komplexität für das Training von Deep-Learning-Netzen reduziert. Wie können aber die Anwender davon profitieren? Eine Möglichkeit besteht darin, in eigener Regie ein entsprechendes Netz zu erstellen. Hierfür werden jedoch mehrere hunderttausend rechtlich einwandfreier Vergleichsbilder benötigt, um beispielsweise eine hohe Trefferquote bei der Erkennung von Defekten zu realisieren. Zudem ist die Entwicklung von CNNs äußerst komplex und setzt profundes Know-how voraus. Dieser Aufwand ist wohl für die meisten Unternehmen kaum zu stemmen.

Weniger Beispielbilder

Daher empfiehlt sich die Nutzung bereits vortrainierter Netze. MVTEC nutzt für das Vortrainieren von Deep-Learning-Netzen einen Fundus von rund drei Millionen selbst erstellten, lizenzfreien Bildern aus dem industriellen Umfeld. Pro Klasse braucht der User zusätzlich nur etwa 300 bis 500 eigene Beispielbilder, anhand derer sich fehlerhafte Produkte trainieren und zuverlässig erkennen lassen. Zudem steckt in den vortrainierten Netzen bereits ein hohes Maß an Kompetenz, Expertise und Erfahrung, sodass dem Kunden damit viel Aufwand für das eigene Training abgenommen wird. Wichtig ist es nun, dass sich die Deep-Learning-basierten Machine-Vision-Funktionen nicht nur auf performanten, stationären Standard-PCs, sondern auch auf Embedded-Plattformen nutzen lassen. Denn kompakte Devices mit integrierter Embedded-Software finden im industriellen Umfeld immer mehr Verbreitung. Dazu zählen z.B. intelligente Kameras,

Vision-Sensoren, Smartphones, Tablets oder Handhelds. Halcon bietet nun Deep-Learning-Algorithmen an, die auch auf Embedded-Boards auf Basis der weit verbreiteten Arm-Architektur laufen. Bereits für die Halcon-Version 17.12 wurde die Deep-Learning-Inferenz, also die Verwendung eines vortrainierten CNNs erfolgreich auf den Nvidia Jetson TX2 Boards, basierend auf 64-Bit-Arm-Prozessoren, getestet. Dabei stellt MVTEC seinen Kunden auf Anfrage auch die für diese Architektur optimierte Halcon-Bibliothek zur Verfügung.

Standard-CPU statt Mittelklasse-GPU

Das Besondere: Die Deep-Learning-Inferenz erreichte mit fünf Millisekunden annähernd die Geschwindigkeit einer herkömmlichen Laptop-GPU, was eine ungewöhnlich hohe Ablauf-Performance auf einem Embedded-Device bedeutet - verglichen mit einem Standard-PC. Anwender sind damit in der Lage, alle Vorteile des Deep Learnings auch auf dem gängigen Embedded-Board Nvidia Jetson TX2 zu nutzen. Dennoch verfügt nicht jedes Device über eine leistungsfähige GPU. Daher geht MVTEC noch einen Schritt weiter: Mit Halcon kann erstmalig die Deep-Learning-Inferenz auch auf Intel-kompatiblen x86-CPUs ausgeführt werden. Damit lässt sich mit einer Laufzeit von etwa zwei Millisekunden auf einer Standard-Intel-CPU die Performance einer Mittelklasse-GPU erreichen, was die operative Flexibilität von Systemen entscheidend erhöht. So können konventionelle Industrie-PCs, die üblicherweise über keine performanten GPUs verfügen, nun problemlos für Klassifikationsaufgaben auf Basis von Deep Learning genutzt werden. ■

www.mvtec.com



Bild 1 | Jeder Akida NSoC weist 1,2Mio. Neuronen und 10Mrd. Synapsen auf, was eine 100-mal bessere Effizienz mit sich bringt, als bei neuromorphen Testchips von Intel und IBM. Der NSoC wurde für den Einsatz als eigenständiger Embedded-Beschleuniger oder Co-Prozessor entwickelt.

Neuromorpher SoC

Neue Art von Beschleunigungs-SoCs für neuronale Netze

AUTOR: ROBERT BEACHLER, MARKETING AND BUSINESS DEVELOPMENT, BRAINCHIP HOLDINGS LTD. | BILDER: BRAINCHIP HOLDINGS LTD.

Der neuromorphe System-on-Chip-Baustein (NSoC) Akida ermöglicht erstmals eine gepulste neuronale Netzwerk-Architektur (SNN: Spiking Neural Network) in Serie.

Laut Daten des Marktforschungsunternehmens Tractica wird der Markt für KI-Beschleuniger-ICs bis zum Jahr 2025 die 60Mrd. US-\$ überschreiten, Neuromorphe Computer versprechen dabei eine schnellere KI, insbesondere bei stromsparenden Anwendungen. Akida, griechisch für 'Puls bzw. Spitze', ist der erste Baustein einer neuen Generation von KI-Hardwarelösungen. Der NSoC ist klein, kostengünstig, stromsparend und eignet sich für Edge-Anwendungen wie Fahrerassistenzsysteme (ADAS), autonome Fahrzeuge, Drohnen, bildgesteuerte Robotik, Überwachungs- und Bildverarbeitungssysteme. Da er skalierbar ist, lassen sich zudem mehrere NSoCs miteinander verknüpfen.

Der Akida NSoC

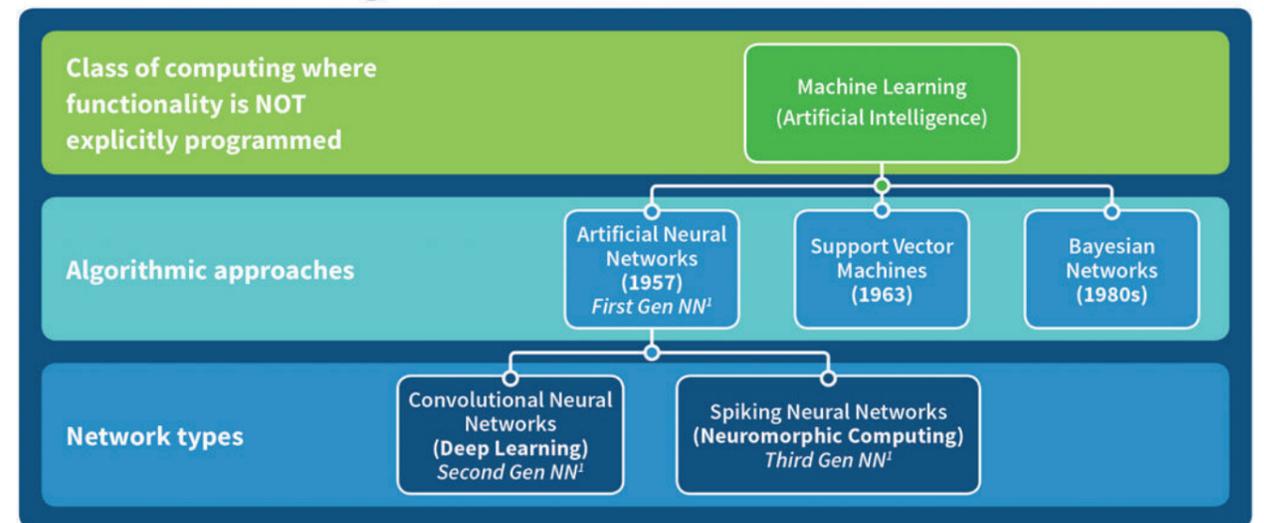
Der Akida NSoC basiert auf einem reinen CMOS-Logikprozess. Gepulste neuronale Netze (SNNs) sind von Natur aus weniger leistungsfähig als herkömmliche faltungsneuronale Netze (CNN), da sie die rechenintensiven Faltungen und Fehlerfortpflanzungs-Trainingsmethoden durch biologisch inspirierte Neuronenfunktionen und Feed-Forward-Trainingsmethoden ersetzen. Brain-Chips Forschung hat das optimale Neuronenmodell und die besten Trainingsmethoden ermittelt. Jeder Akida NSoC weist effektiv 1,2Mio. Neuronen und 10Mrd. Synapsen auf, was eine 100-mal bessere Effizienz mit sich bringt, als bei neuromorphen Testchips von Intel und IBM. Vergleiche mit führenden CNN-Beschleunigern zeigen Leistungszuwächse um mehr als eine Größenordnung bei Bild-/Sekunden-/Watt-Benchmarks wie CIFAR-10 mit vergleichbarer Genauigkeit. „SNNs gelten als die dritte Generation neuronaler Netze“, so Peter van der Made, Gründer

und CTO von BrainChip. „Der Akida NSoC ist das Ergebnis jahrzehntelanger Forschung, um das optimale Neuronenmodell und innovative Trainingsmethoden zu ermitteln.“ Der Akida NSoC wurde für den Einsatz als eigenständiger Embedded-Beschleuniger oder Co-Prozessor entwickelt. Er enthält Sensorschnittstellen für die pixelbasierte Bildgebung, dynamische Bildsensoren (DVS), Lidar, Audio und Analogsignale. Es verfügt zudem über Hochgeschwindigkeits-Datenschnittstellen wie PCI-Express, USB und Ethernet. Im NSoC finden sich Daten-zu-Puls-Wandler, die gängige Datenformate optimal in Pulse/Spikes umwandeln, um von der Akida-Neuronen-Fabric trainiert und verarbeitet zu werden.

Innovative Trainingsmethoden

SNNs sind von Grund auf Feed-Forward-Datenflüsse für das Training und Inferencing. Das Akida-Neuronenmodell deckt innovative Trainingsmethoden für das über-

AI Taxonomy



1. Maass, Wolfgang. 1997. "Networks of Spiking Neurons: The Third Generation of Neural Network Models". Bild 2 | Gepulste neuronale Netze (SNN) gelten als die dritte Generation neuronaler Netze.

wachte und unbeaufsichtigte Training ab. Im überwachten Modus trainieren sich die ersten Ebenen des Netzwerks selbstständig, während in den letzten vollständig vernetzten Ebenen Label angewendet werden können. Damit dienen diese Netzwerke als Klassifizierungsnetzwerke. Der NSoC ist so konzipiert, dass er in der Akida-Entwicklungsumgebung ein Off-Chip-Training ermöglicht – oder ein On-Chip-Training. Eine integrierte CPU steuert die

Konfiguration der Akida-Neuronen-Fabric sowie die Off-Chip-Kommunikation von Metadaten. Die Entwicklungsumgebung ist ab sofort für Early-Access-Kunden erhältlich, die mit dem Erstellen, Training und Testen von Akida-NSoC-basierter SNNs beginnen wollen. Der Akida NSoC wird voraussichtlich im dritten Quartal 2019 als Muster zur Verfügung stehen.

www.brainchip.ai

Anzeige

2ew19P
E-Code für freien Eintritt
embedded-world.de/gutschein

Nürnberg, Germany
26.–28.2.2019

embeddedworld
Exhibition & Conference
... it's a smarter world

INNOVATIONEN ENTDECKEN

Tauchen Sie ein in die Welt der Embedded-Systeme und entdecken Sie Innovationen für Ihren Erfolg.

embedded-world.de

Medienpartner

Fachmedium für elektronische Bauelemente und Baugruppen

Fachmedium für elektronische Bauelemente und Baugruppen

Fachmedium der Automatisierungstechnik

Fachmedium für Elektronik in der Medizintechnik

KNOW-HOW FÜR ENTWICKLER

Fachmedium für professionelle Automobilelektronik

Solutions for a Smarter World

Veranstalter Fachmesse
NürnbergMesse GmbH
T +49 911 8606-49 12
F +49 911 8606-49 13
besucherservice@nuernbergmesse.de

Veranstalter Konferenzen
WEKA FACHMEDIEN GmbH
T +49 89 255 56-13 49
F +49 89 255 56-03 49
info@embedded-world.de

NÜRNBERG MESSE



Eine Deep-Learning-Software erkennt bei Audi automatisch mit höchster Präzision feinste Risse in Blechen im Presswerk und markiert die Stelle zuverlässig.

KI bei Audi

Automatisierte Risserkennung mit KI im Audi-Presswerk

TEXT UND BILD: AUDI AG

Audi wird zukünftig Deep Learning in der Serienproduktion einsetzen. Die selbst entwickelte Software erkennt und markiert im Presswerk automatisch feinste Risse in Blechteilen in Sekunden.

Aufgrund des immer anspruchsvolleren Designs der Autos und der hohen Qualitätsstandards überprüft Audi alle Bauteile direkt nach der Herstellung im Presswerk. Neben der Sichtprüfung durch Mitarbeiter sind dazu mehrere kleine Kameras direkt in den Pressen verbaut. Diese werten die aufgenommenen Bilder mit Hilfe von Bilderkennungs-Software aus. Dieser Vorgang soll durch ein Deep-Learning-Verfahren abgelöst werden. Im Hintergrund des Verfahrens

arbeitet eine Software, deren Basis ein komplexes künstliches neuronales Netz ist. Die Software erkennt feinste Risse in Blechen und markiert die Stelle zuverlässig. „Unsere automatisierte Bauteilprüfung erproben wir derzeit in unserem Ingolstädter Presswerk für den Serieneinsatz“, sagt Jörg Spindler, Leiter des Kompetenzzenters Anlagen- und Umformtechnik. Mit mehreren Millionen Prüfbildern hat das Team über Monate das künstliche neuronale Netz trainiert. Die größten Herausforderungen waren zum einen das Aufbauen einer ausreichend großen Datenbasis und zum anderen das Labeln der Bilder. Dabei markierte das Team pixelgenau Risse in den Beispielbildern. Der Aufwand hat sich gelohnt, denn anhand der Beispiele lernt das neuronale Netz nun selbstständig und erkennt Risse auch bei neuen, bis-

lang unbekanntem Bildern. Mehrere Terabyte an Prüfbildern aus sieben Pressen am Audi-Standort Ingolstadt und von mehreren Volkswagen-Standorten bilden die Datenbasis. Die Software entstand überwiegend in-house. So arbeitet die Innovationsabteilung der Audi IT seit Mitte 2016 mit dem Bereich Produktionstechnologie aus dem Kompetenzzentrum für Anlagen- und Umformtechnik. In Zukunft soll die neue Qualitätsprüfung die bisher eingesetzte optische Risserkennung mit Smart-Kameras ablösen. Der ML-Ansatz lässt sich künftig auch bei anderen optischen Qualitätsprüfungen einsetzen. Liegt eine ausreichend große Zahl gelabelter Datensätze vor, kann die Lösung z.B. auch in Lackiererei oder Montage unterstützen. ■

www.audi-mediacycenter.com

DEEP LEARNING

Oberflächenerkennung mittels AI

Moonvision automatisiert dank AI die Oberflächenerkennung unterschiedlichster Materialien. Was bislang über 50 Bilder erfordert hat, gelingt dem Wiener Startup mit nur elf Bildern. Nach einem kurzen Trainingsverfahren erkennt das System bereits kleinste Schwachstellen an verschiedensten

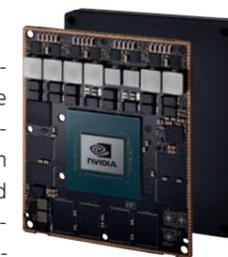
Oberflächen (von Metall bis hin zu Kunststoff, Textilien oder Holz) vollkommen automatisiert. Die intelligente Plattform eruiert Kratzer und typisiert sie, damit selbst Laien erforderliche Aktionen augenblicklich ableiten können.

The Moon Vision GmbH
www.moonvision.io



KI-Plattform für autonome Maschinen

Eine Embedded-Lösung für KI-Entwickler wird nun als eigenständige Produktionsmodule von Nvidia ausgeliefert. Als neueste Generation Jetson AGX-Familie von Embedded Linux-Hochleistungscomputern bietet der Jetson AGX Xavier 32 TeraOPS für Spitzenberechnungen und 750Gbps für Hochgeschwindigkeits-I/O in einem kompakten 100x87mm-Formfaktor. Benutzer können die Betriebsarten für 10W, 15W und 30W konfigurieren. Die Plattform umfasst eine integrierte 512-Core Volta GPU mit 64 Tensor-Kernen und 16GB 256Bit-LPDDR4x. Intelligente Maschinen auf Basis des Systems sollen die Fähigkeit erlangen, in ihrer Umgebung autonom zu navigieren.



Nvidia GmbH
www.nvidia.de

Panel-PC für KI-Anwendungen

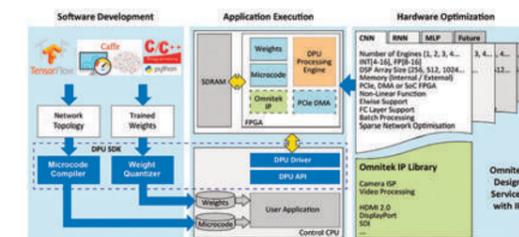
Mit dem Modell Flex-BX200 bietet Comp-Mall eine Hardwarelösung für künstliche Intelligenz und Deep Learning. Das Modell basiert auf dem Intel Q370-Chipsatz, Intel Core i7/i5/i3, Celeron- oder Pentium-Prozessor der 8. Generation, mehreren PCIe3.0-Steckplätzen und vier hot-swap-fähigen Festplattenlaufwerkschächten. Darüber hinaus werden verschiedene I/O-Schnittstellen bereitgestellt, um Kameras, Sensoren und Bewegungssteuerungsgeräte zu integrieren. Das Modell unterstützt Grafikkarten, Intel FPGA- und VPU-Beschleunigungskarten.



Comp-Mall GmbH
www.comp-mall.de

FPGA-based Engine for DNNs

The Omnitek DPU (Deep Learning Processing Unit) is a configurable IP core built from a suite of FPGA IP comprising the key components needed to construct inference engines suitable for running DNNs used for a wide range of Machine Learning applications, plus an SDK supporting the development of applications which integrate the DPU functionality. These can be targeted for a range of devices including small FPGAs with an embedded processor control for edge devices, or a PCI Express card with a large FPGA for data centre applications. The DPU can be programmed by creating a model of a chosen neural network in C/C++ or Python using standard frameworks



such as TensorFlow. The DPU SDK Compiler converts the model into microcode for execution by the DPU. A quantizer optimally converts the weights and biases into the selected reduced precision processing format.

Omnitek
www.omnitek.tv

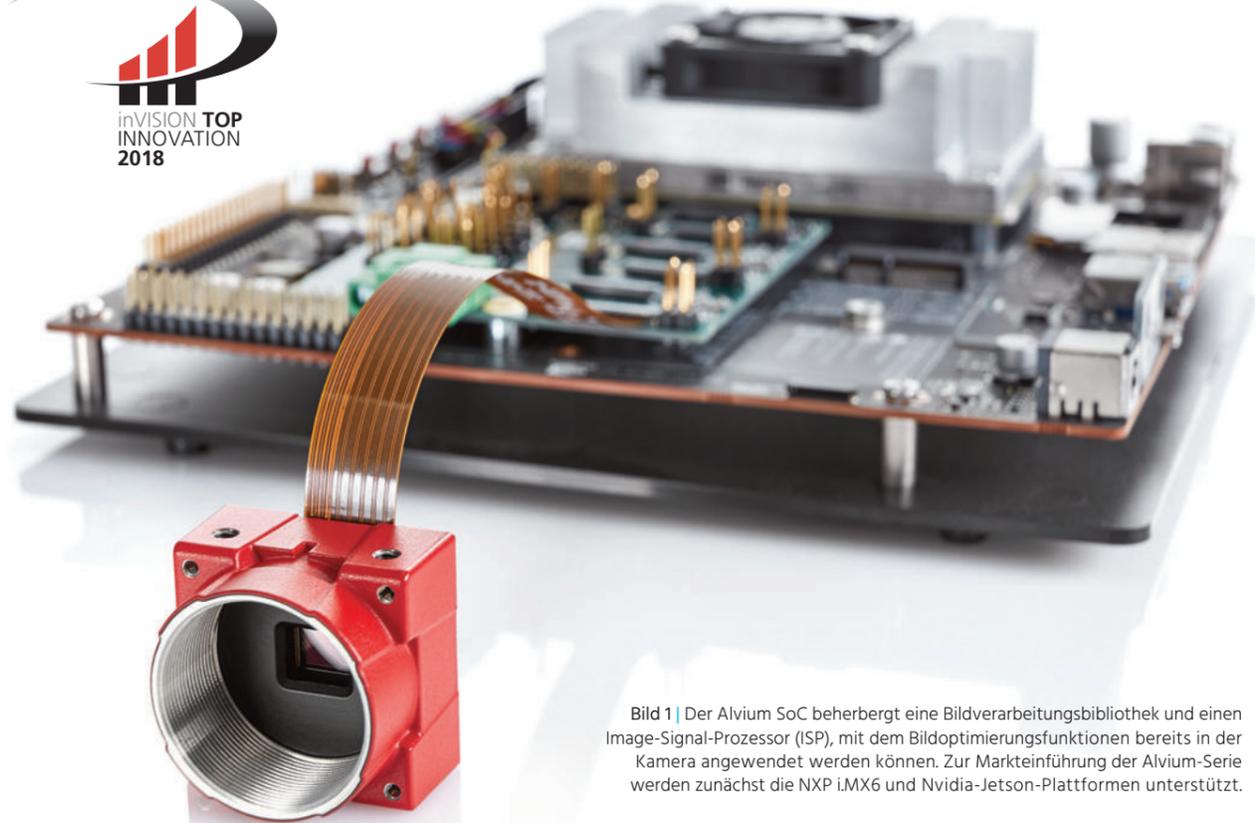


Bild 1 | Der Alvim SoC beherbergt eine Bildverarbeitungsbibliothek und einen Image-Signal-Prozessor (ISP), mit dem Bildoptimierungsfunktionen bereits in der Kamera angewendet werden können. Zur Markteinführung der Alvim-Serie werden zunächst die NXP i.MX6 und Nvidia-Jetson-Plattformen unterstützt.

Brückenschlag

Industrielle Kameramodule mit SoC für Embedded Vision

AUTOR: PAUL MARIA ZALEWSKI, STRATEGIC PRODUCT MANAGEMENT, ALLIED VISION TECHNOLOGIES GMBH
BILDER: ALLIED VISION TECHNOLOGIES GMBH

Die Alvim-Technologie setzt sich aus einem SoC und einer Bildverarbeitungsbibliothek zusammen. Dies ermöglicht eine einfache Integration, geringe Systemkosten und hohe Flexibilität für Embedded-Vision-Systeme.

Im Embedded-Markt werden bisher so genannte Sensormodule für die Bilderfassung eingesetzt. Diese beinhalten in der Regel lediglich einen Sensor auf der Pla-

tine inklusive fest verbauter Optik. Bildverarbeitung direkt auf dem Modul wird gar nicht oder nur sehr eingeschränkt unterstützt. Stattdessen führen Ingenieure die meiste Bildverarbeitung auf dem Host Prozessor aus. Ein wesentlicher Unterschied zwischen diesen Sensormodulen und der Alvim Kameraserie ist ein eigen dafür entwickelter SoC (System on Chip). Der Alvim SoC beherbergt einen Image Signal Prozessor (ISP), mit dem Bildoptimierungsfunktionen bereits in der Kamera angewendet werden können. Somit eröffnet die Alvim Technologie

Systementwicklern neue Möglichkeiten: Durch das Auslagern von Bildbearbeitungsschritten in das Alvim Kameramodul wird die Host-CPU entlastet. So kommt das System mit einem kleineren, kostengünstigeren Prozessor zurecht, was die Gesamtsystemkosten reduziert. Die freigewordene Rechenleistung kann für zusätzliche Aufgaben verwendet werden. Ein weiterer Vorteil für Embedded Systementwickler ist, dass der im Alvim SoC integrierte ISP und seine Bildverarbeitungsbibliothek es leichter machen, Kamera und Bildverarbeitung zu

konfigurieren. Statt wie früher auf dem Host-Prozessor mühsam zu programmieren, muss der Anwender lediglich die vorhandenen Funktionen aktivieren und parametrieren. Dieser Punkt ist wichtig, da Embedded Systemintegratoren oft keine Bildverarbeitungsexperten sind.

Ein Treiber für alle

Wesentlicher Unterschied zwischen den neuen Sensormodulen und klassischen Machine Vision Kameras ist, dass jedes Embedded Sensormodul seinen eigenen Treiber braucht. Der Alvim SoC unterstützt alle gängigen Sensorschnittstellen und ist für eine breite Auswahl an heutigen und zukünftigen Bildsensoren mit Auflösungen von VGA bis 21MP ausgelegt. Damit ergibt sich ein weiterer Vorteil der neuen Technologie für Embedded Systemintegratoren: eine noch nie da gewesene Flexibilität. Mussten sie bisher für jedes Sensormodul einen neuen Treiber programmieren und in ihr System implementieren, deckt mit der Alvim Technologie ein einziger Treiber sämtliche Sensorvarianten der Kameraserie ab. So lassen sich mit minimalem Entwicklungsaufwand unterschiedliche Sensoren testen, verschiedene Auflösungsvarianten eines Systems entwickeln oder bestehende Systeme auf neue Sensoren umstellen. Allied Vision wird kostenlos Treiberpakete für verschiedene Embedded Board SoCs als Open Source zur Verfügung stellen, damit diese auch von der Embedded Community weiterentwickelt und für besondere Anforderungen angepasst werden können. Zur Markteinführung der Alvim Serie werden zunächst die NXP i.MX6 und Nvidia Jetson Plattformen unterstützt. Später wird die Unterstützung auf i.MX8 und i.MX8M ausgeweitet. Allied Vision wird einer der ersten Kamerahersteller weltweit sein, der einen Kamertreiber für das Nvidia Jetson AGX Xavier anbietet, dank einer Kooperation mit dem polnischen Embedded Spezialisten Antmicro.

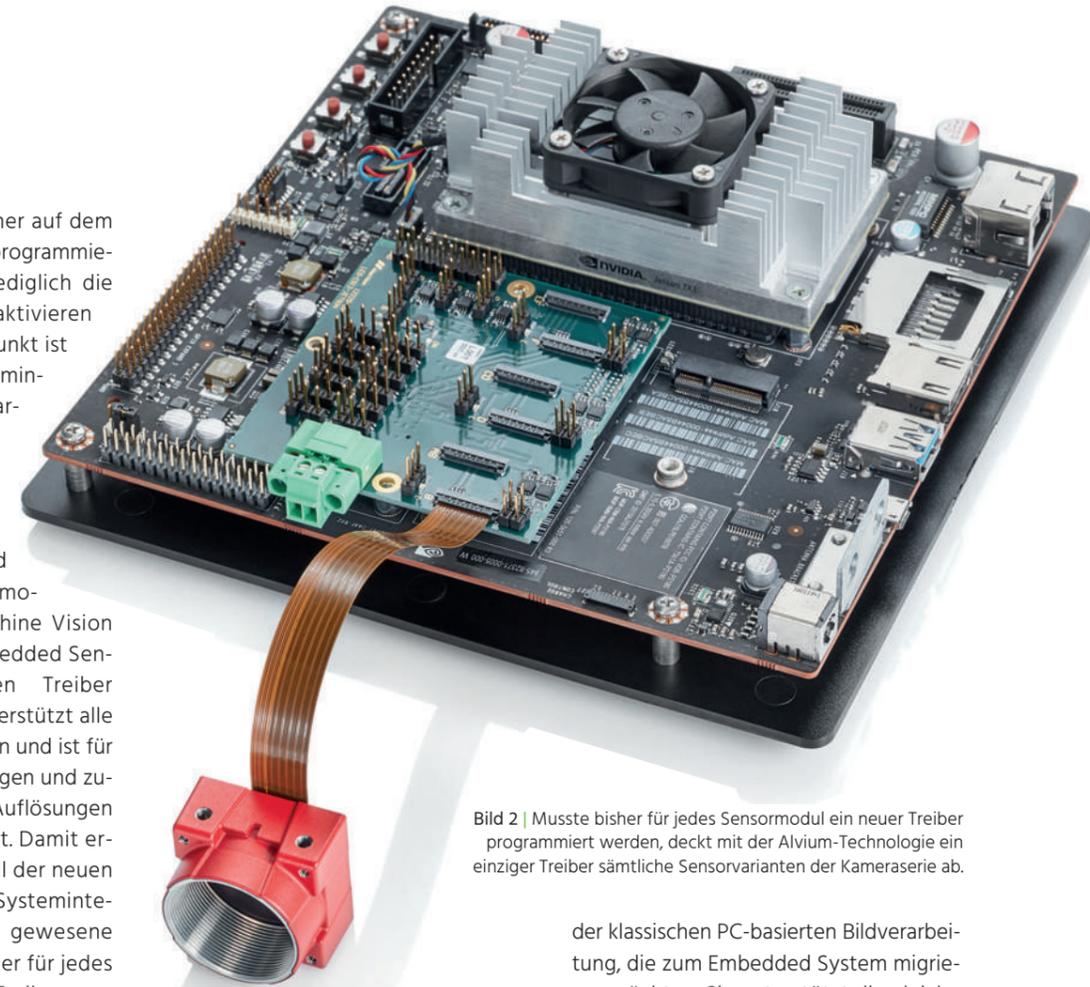


Bild 2 | Musste bisher für jedes Sensormodul ein neuer Treiber programmiert werden, deckt mit der Alvim-Technologie ein einziger Treiber sämtliche Sensorvarianten der Kameraserie ab.

Einfache Softwareintegration

Die Alvim Technologie bietet Systemintegratoren vielfältige Steuerungsmöglichkeiten für unterschiedliche Anwenderprofile. Embedded Systementwickler setzen in der Regel keine hohen Ansprüche an integrierte Bildverarbeitungsfunktionen. Die Alvim 1500 Serie ist genau für dieses Anwenderprofil zugeschnitten. Die Kamera besitzt eine CSI-2 Schnittstelle und lässt sich per Video4Linux2 (V4L2) bzw. GStreamer anbinden, die derzeit gängigsten Softwareschnittstellen für Embedded Applikationen. Mit diesen Protokollen können die Grundeinstellungen des ISPs im Alvim SoC konfiguriert werden. Darüber hinaus erhalten anspruchsvollere Anwender den vollen Zugriff auf die Kamerafunktionalitäten per Direct Register Access (DRA). Die Alvim 1800 Serie richtet sich dagegen an Entwickler von anspruchsvolleren Embedded Vision Anwendungen oder Systemintegratoren aus

der klassischen PC-basierten Bildverarbeitung, die zum Embedded System migrieren möchten. Sie unterstützt die gleiche Softwareanbindung wie die Alvim 1500 und zusätzlich das Generic Control Protocol des GenICam Standards.

GenICam für Embedded

GenICam macht nicht nur die Migration von PC-basierten zu Embedded Systemen einfacher, sondern eröffnet für Embedded Anwender die Möglichkeit, auf GenICam-kompatible Visionbibliotheken wie z.B. Halcon oder Matlab zurückzugreifen. Die Zeiten, in denen Embedded Systementwickler ihre Anwendung komplett selbst programmieren mussten, sind damit vorbei. Von nun an stehen ihnen auch leistungsstarke Bildverarbeitungssoftware zur Verfügung. GenICam wird in der Alvim Serie vorerst im Zusammenspiel mit USB 3.1 Gen. 1 bereitgestellt. Die EMVA hat jedoch einen GenICam Standardisierungskomitee für MIPI CSI-2 ins Leben gerufen, dessen Vorsitz Allied Vision inne hat. Bald werden also auch CSI-2 Kameramodule GenICam unterstützen können. ■

www.alliedvision.com

Board-Level-Kameras

Der Trend zu Embedded Vision ist weiterhin ungebrochen und so bekommen auch Board-Level-Kameras ein immer größeres Interesse. Allerdings herrscht noch Unklarheit, wie die Kameras an die Embedded Systeme angeschlossen werden sollen.

Während in der Bildverarbeitung bereits zahlreiche Schnittstellen wie z.B. USB, GigE, CoaXPress usw. zur Verfügung stehen (und ständig weitere Interfaces hinzukommen), spielen bei Embedded Vision-Systemen auch völlig andere Schnittstellen eine Rolle. Vor allem das MIPI-Interface wird hier des öfteren genannt. Mittlerweile haben bereits zahlreiche Kamerahersteller entsprechende MIPI-Kameras im Programm, wie z.B. Allied Vision, Basler, Phytex, Vision Components... Vor allem die Firmen, die auf der Embedded World (26. bis 28.02., Nürnberg) ausstellen, kommen nicht um das MIPI-Interface herum. Aber auch auf den Standardisierungstreffen der Vision-Community spielt MIPI inzwischen eine Rolle. (peb) ■

Vertrieb	Allied Vision Technologies GmbH
Produkt-ID	1086
Ort	Stadroda
Telefon	036428/ 667-230
Internet-Adresse	www.alliedvision.com
Produktname	Manta
Branchenschwerpunkte	Industrielle und wissenschaftliche Bildverarbeitung
Anwendungsfeld	Produktionsüberwachung, Qualitätssicherung, Montage, Robotik
Aufgabenstellung	Oberflächeninspektion, Vollständigkeit, Messte., Identifikation, Positionserkennung
Sensortyp	
SIW-Kamera	✓
Farb-Kamera	✓
Zeilen-Kamera	Nein
Matrix-Kamera	✓
Progressive Scan-Kamera	✓
Auflösung des Sensors (Pixelfläche)	VGA - 12 Megapixel
Pixel-synchroner Betrieb für subpixelgenaue Vermessungsaufgaben	✓
Besonderheiten bei Flächenkameras	GigE Vision-Kamera mit 3 LUTs, Farbkorrektur, PoE, PTP, Modularoptionen
Auflösung des Sensors Pixel pro Zeile	
Erfasster Durchsatz: Messwerte oder Teile bzw. Stück / Sek.	bis zu 125 fps bei VGA Auflösung
Erfasster Durchsatz: Geschwindigkeit (m/s)	
Bildverbesserungen und -vorverarbeitung per Hardware-/Software	
Datenreduktion	AOI (Area of Interest) mit Speed Increase
Anzahl und Art der Digitaleingänge / Digitalausgänge	2 in, opto-coupled / 2 out, opto-coupled
Anzahl der darstellbaren Grauwerte	
Anzahl der darstellbaren Farben	
Power-over-Ethernet PoE bzw. PoE plus	PoE optional erhältlich



 Basler AG 22693 Ahrensburg 04102/ 463-500 www.baslerweb.com Basler dart Serie Elektro, Maschinenb., Automobil., Pharma, Medizinte., Lebensmittel, Kunststoff, Holz Produktionsüberwa., QS, Sicherheitste., Verkehr, Montage, Robotik, Verpackung Oberflächeninspektion, Vollständigkeitsprüfung, Identifikation, Positionserkennung CMOS-Sensor ✓ ✓ Nein ✓ ✓ 1,2 bis 5 MP (1280 x 960, 2592 x 1944) Nein Image Pre-Processing, Image Enhancement Algorithms 60 Bilder pro Sekunde 5x5 Debayering, Color-Anti-Alias., Denois., Image Adjust., Sharpness, Anti-Flicker, uvm 2 x GPIO/ 2 x GPIO 12 Bit RGB 12 Bit	 Baumer GmbH 16718 Friedberg 06031/ 6007-0 www.baumer.com Baumer MX-Serie Automobil., Maschinenbau, Sonderma., Elektro, Kunststoff, Lebensmittel, Pharma Produktionsüberwachung, QS, Montage, Verpackung, Abfülltechnik, Robotik Oberflächeninspektion, Vollständigkeitsprüfung, Messte., Identifikation, Position ✓ ✓ Nein ✓ ✓ VGA bis 4 MP ✓ Einfache, flexible Integration durch abgesetzten Sensorkopf 27 bis 376 Bilder/s applikationsabhängig Look-Up Tabellen, YUV, RGB Farbrechnung, Gamma Partial Scan (ROI), Binning 1 Eingang (Trigger) / 3 Ausgänge 8 Bit / 12 Bit 3x 8 Bit / 3x 12 Bit PoE	 Flir Integrated Imaging Solutions GmbH 23665 Ludwigsburg 07141/ 488817-0 www.ptgrey.com Chameleon3 USB3 Vision CMOS Automobilindustrie, Maschinenbau, Lebensmittel, Pharma, Elektro industrielle Anwendungen, Inspektion, 3D, Eye Tracking, Prosumer CMOS-Sensor ✓ ✓ Nein ✓ ✓ 1,3 to 5 MP (1280x1024 to 2448 x 2048) ✓ bis zu 149 FPS	 IDS Imaging Development Systems GmbH 31396 Obersulm 07134/ 96196-0 www.ids-imaging.de uEye LE USB 3.1 Gen 1 Kameraserie Maschinenbau; Automobilindustrie, Sonderma., Elektro, Pharma, Medizinte., ITS; QS, Embedded Systeme, Mikroskopie, Machine Vision, Medizintechnik Oberflächeninspektion; Vollständigkeit; Messte., Identifikation; Positionserkennung CMOS-Sensor ✓ ✓ Nein ✓ ✓ 808x608, 1936x1096, ..., 3088x2076 ✓ 10-poliger Molex-Steckverbinder	 Matrix Vision GmbH 26497 Oppenweiler 07191/ 9432-0 www.matrix-vision.de mvBlueFOX3-M2 (USB 3.0) Automobil.; Maschinenbau; Sonderma.; Elektro; Holz; Kunststoff; Pharma; Alle Produktionsüberwa., Förderte.; QS; Montage; Verpack.; Abfüllte.; Robotik; Sicherh. Oberflächeninspektion; Vollständigkeit; Messte.; Identifikation; Positionserkennung CMOS-Sensor ✓ ✓ Nein ✓ ✓ bis 4112 x 3008 ✓ 2 / 4	 NET New Electronic Technology GmbH 30492 Finning 08806/ 9234-0 www.net-gmbh.com HDselect Endoskopie; Dental; Robotik CMOS-Sensor ✓ ✓ ✓ ✓ /
--	--	---	---	---	--

Alle Einträge basieren auf Angaben der jeweiligen Firmen. Stand 20.12.2018

i-need.de
 PRODUCT FINDER
 Direkt zur Marktübersicht:
www.i-need.de/134



Vertrieb	Photonfocus AG	Phytex Messtechnik GmbH	Sensor to Image GmbH	The Imaging Source Europe GmbH	Vision Components GmbH
Produkt-ID	26521	30500	985	32867	32010
Ort	Lachen	Mainz	Schongau	Bremen	Ettlingen
Telefon	0041 55/ 451 00 03	06131/ 9221-0	08861/ 2369-0	0421/ 004942133591-0	07243/ 2167-16
Internet-Adresse	www.photonfocus.com	www.phytex.de	www.sensor-to-image.de	www.theimaging-source.com	www.vision-components.de
Produktname	OEM-D4096-960-LC	VM-012	CANCam-GigE	DFM 37UX287-ML	VCSCBnano Z-RH-0022 Embedded Syst.
Branchenschwerpunkte	Automobilindustrie, Maschinenbau, Sondermaschinenbau, Security&Surveillance.	Automobilindustrie, Maschinenbau, Elektro	Automobilindustrie, Maschinenbau, Sondermaschinenbau	Automobilindustrie; Maschinenbau; Elektro; Kunststoff; Lebensmittel	Automobil.; Maschinenbau; Sondermaschinenbau; Elektro; Holz; Kunststoff; usw.
Anwendungsfeld	Produktionsüberwachung, Fördertechnik, QS, Montage, Abfülltechnik, Robotik	Produktionsüberwachung, Qualitätssicherung, Robotik, Sicherheitstechnik	Produktionsüberwachung, Qualitätssicherung, Robotik	Produktionsüberwachung; Robotik	Produktionsüb.; Förderte.; QS; Montage; Verpack.; Abfüllte.; Robotik; Sicherheitste.
Aufgabenstellung		Oberflächeninspektion, Vollständigkeitsprüfung, Messte., Identifikation, Position	Oberflächeninspektion, Vollständigkeit, Messte., Identifikation, Positionserkennung	Messtechnik, Identifikation	Oberflächeninspektion; Vollständigkeit; Messte.; Identifikation; Positionserkennung
Sensortyp	CMOS-Sensor	CMOS-Sensor	CMOS-Sensor		CMOS-Sensor
SIW-Kamera	✓	✓	✓	✓	✓
Farb-Kamera	Nein	✓	✓	✓	✓
Zeilen-Kamera	Nein	Nein	Nein	Nein	✓
Matrix-Kamera	✓	✓	✓	✓	✓
Progressive Scan-Kamera	✓	✓	✓	✓	✓
Auflösung des Sensors (Pixelfläche)	4096 x 3072	1280 x 1024	Bildgröße max. 32 MByte	VGA bis 720x540 (0,4 MP)	2048 x 1536 Pixel
Pixel-syn. Betrieb für subpixelgenaue Vermessung	Nein	✓	✓	Nein	✓
Besonderheiten bei Flächenkameras	Global Shutter, Schwachlichtver., Skimming, Line Hop., Flip effect, Multiple ROI, ...	Anschl. an emb. Controller (z.B.: i.MX6, OMAP4,i.MX35,i.MX31,i.MX6,...),LED_Out			Sensor auf abgesetzter Platine sorgt für größtmögliche Flexibilität bei Integration.
Auflösung des Sensors Pixel pro Zeile					
Erf. Durchsatz: Messwerte o. Teile bzw. Stück / Sek.		37 fps (Vollbild), 130 (VGA)			
Erfasster Durchsatz: Geschwindigkeit (m/s)					
Bildverbesserungen und -vorverarbeitung per Hardware-/Software	Look-Up Tabelle, Großsignalverstärkung bei geringer Lichtintensität				✓, frei programmierbar
Datenreduktion	Multiple Region of Intrests				✓, frei programmierbar
Anzahl und Art der Digitaleingänge / -ausgänge	/	/	2 / 2	/	12 / 12
Anzahl der darstellbaren Grauwerte					8 bit - 12 bit optional
Anzahl der darstellbaren Farben					mind. 24 bit
Power-over-Ethernet PoE bzw. PoE plus					optional

MESSE FÜR OPTIK, ELEKTRONIK, MECHANIK UND HIGHTECH INNOVATIONEN

W3+FAIR
 CONVENTION
 WETZLAR

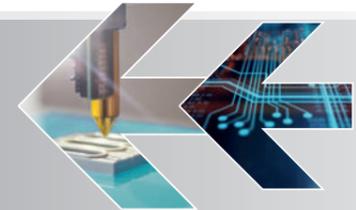
W3+FAIR
 CONVENTION
 RHEINTAL

25. + 26. FEBRUAR 2019
 RITTAL ARENA
 WETZLAR (GER)

18. + 19. SEPTEMBER 2019
 MESSEQUARTIER DORNBIRN
 RHEINTAL (A, CH, LI, GER)

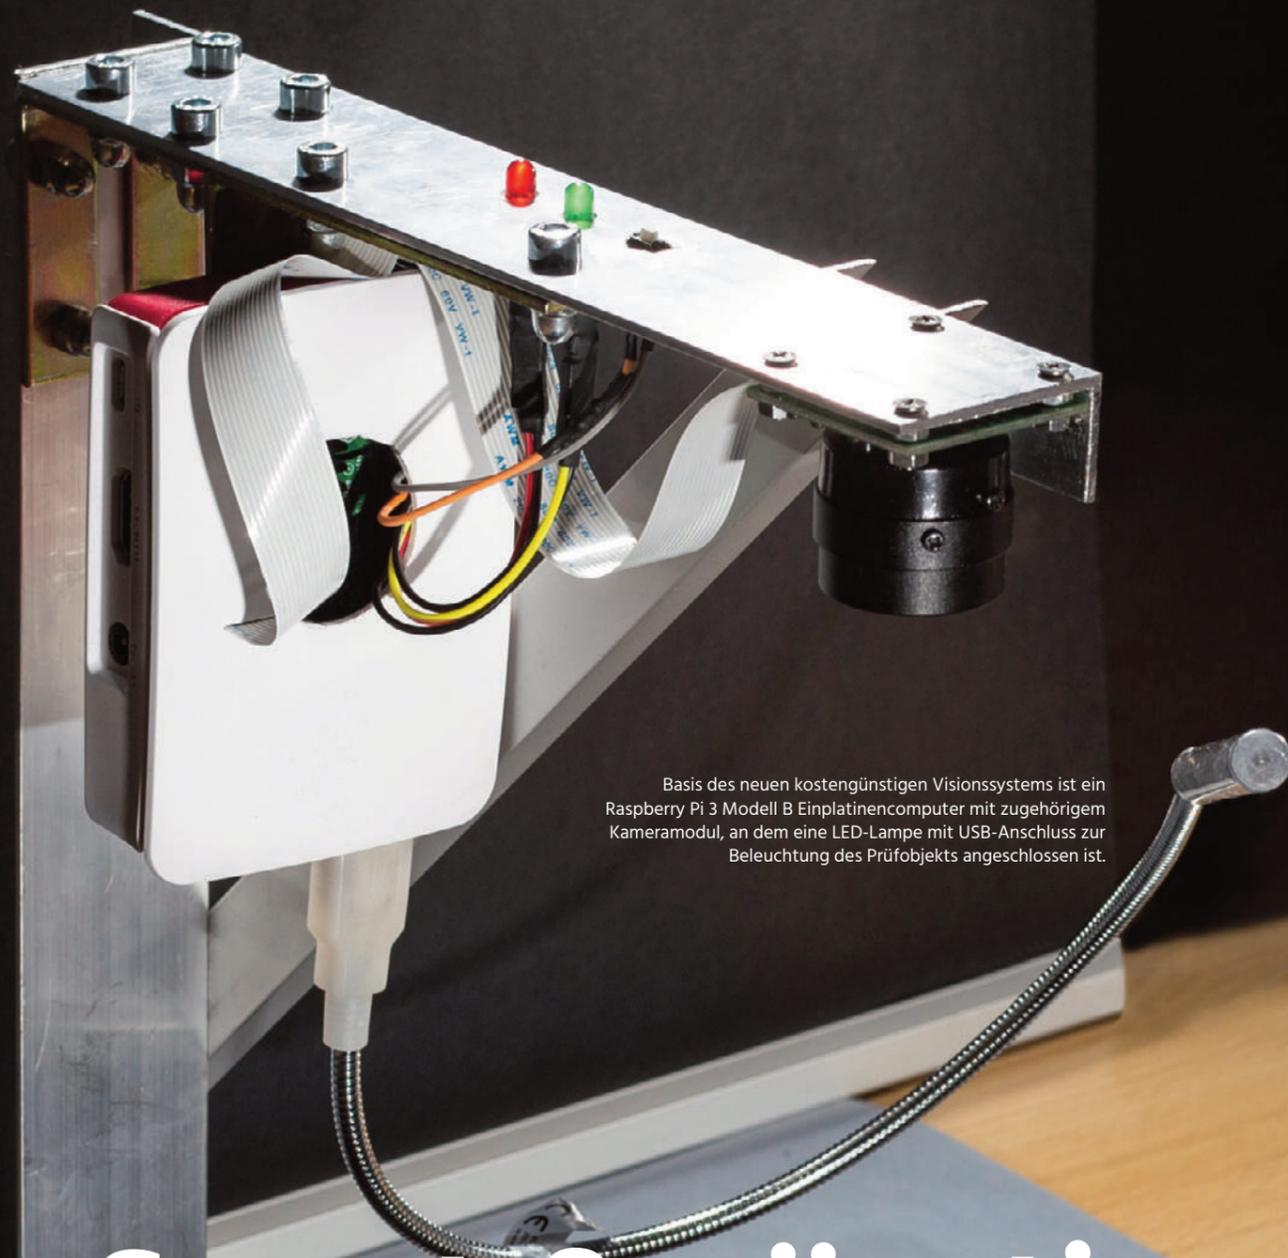
GOLD PARTNER   GOLD PARTNER  

Wir präsentieren Ihnen die neuen Sonderflächen 2019 in Wetzlar
3D-DRUCK | ADDITIVE FERTIGUNG
IVAM: MICROTECHNOLOGIES FOR OPTICAL DEVICES



TREFFPUNKT FÜR TOP-ENTSCHEIDER





Basis des neuen kostengünstigen Visionssystems ist ein Raspberry Pi 3 Modell B Einplatinencomputer mit zugehörigem Kameramodul, an dem eine LED-Lampe mit USB-Anschluss zur Beleuchtung des Prüfobjekts angeschlossen ist.

Smart & günstig

Kostengünstige, intelligente Kamera auf Raspberry-Pi-Basis

TEXT UND BILD: STEFAN WEISS, PROF. DR. MARTIN JOGWICH, THD-TECHNISCHE HOCHSCHULE DEGGENDORF

Preiswerte Einplatinencomputer haben ihr Bastler-Image längst abgelegt und werden bereits zur Maschinensteuerung eingesetzt. Im Rahmen einer Masterarbeit an der TH Deggendorf wurde nun ein kostengünstiges Smart-Kamera-System auf Basis eines Einplatinencomputers (Raspberry Pi 3) als Labormuster entwickelt.

Das neue System stellt Bildvorverarbeitungsfunktionen und -aufgaben zur Verfügung, die durch den Anwender zu einem individuellen Prüfprogramm zusammengesetzt und konfiguriert werden können. Als Basis dient ein Raspberry Pi 3 Modell B Einplatinencomputer mit zugehörigem Kamera-Modul, das über die integrierte CSI-Schnittstelle angesteuert wird. Die Kamera verfügt über einen CS-Mount-Objektivgewindeanschluss, der einen Wechsel des Objektivs ermöglicht. Zur Präsentation und Verwendung im Labor wurde das System an

eine Haltevorrichtung angebracht. Zur Simulation eines Linienlichts wurde eine handelsübliche preiswerte LED-Lampe mit USB-Anschluss zur Beleuchtung des Prüfobjekts angeschlossen. Die Anbindung an eine industrielle Produktionsanlage, z.B. zur Maschinensteuerung, wurde durch einfache Hardwaremaßnahmen simuliert. Ein Inputsignal zum Starten der Bildaufnahme mit darauffolgender Ausführung der Bildverarbeitungsfunktionen im konfigurierten Prüfprogramm kann durch Betätigung eines Tasters gesendet werden, wohingegen das Ergebnis der Prüfung im Output durch aufleuchtende LEDs verdeutlicht wird. Dies erfolgt im Prototyp über die GPIO-Pin-Leiste des Einplatinencomputers.

Offene Softwarearchitektur

Unter Verwendung quelloffener Bibliotheken wurde eine Software entwickelt, die per grafischer Oberfläche die Steuerung des Systems ermöglicht. Dies kann über die angeschlossene Peripherie oder per Fernzugriff im Netzwerk erfolgen. Das Programm wurde mittels Python implementiert und nutzt OpenCV 3.4.1 als Bildverarbeitungsbibliothek. Im Fokus der Entwicklung stand die einfache Bedienbarkeit und Erweiterbarkeit. Die Softwarearchitektur besteht aus Einzelkomponenten, deren Erweiterung mit geringem Aufwand getrennt voneinander anhand definierter Schnittstellen möglich ist. Dadurch kann das System auf individuelle Bedürfnisse angepasst und um zusätzliche Bildverarbeitungsfunktionen erweitert werden. Aktuell sind folgende konfigurierbare Bildverarbeitungsfunktionen implementiert:

- Maßkalibrierung
- Maßprüfung eines Objekts
- Blob-Analyse
- Dekodierung von Barcodes und QR-Codes
- Binarisierung
- Graufilter
- Box-Glättungsfilter
- Bildaddition/-subtraktion
- Bildspiegelung/-invertierung
- Grauwert-Histogramm
- Histogramm-Ebnung

Ergebnisse und Daten der Messung, wie beispielsweise Prüfdauer und Maße eines Objekts, werden in der grafischen Oberfläche angezeigt und können für statistische Zwecke mithilfe einer integrierten Logfunktion lokal protokolliert werden. Die Bildauflösung der Kamera kann in den Systemeinstellungen frei gewählt werden. Die maximale Auflösung beträgt 2.592x1.944 Pixel (5MP). Dadurch kann der Anwender wahlweise eine höhere Geschwindigkeit oder eine höhere Genauigkeit forcieren. Neben der Aufnahme von Bildern durch die Kamera und Erstellung von Prüfprogrammen können diese auch in das Programm importiert bzw. exportiert werden. Weiterhin können Arbeitsbereiche im Bild definiert werden, um die zu verarbeitende Datenmenge zu reduzieren, wodurch sich die Messdauer verringert.

100 Euro Hardwarekosten

Der Prototyp kann bereits für Oberflächenprüfungen, Barcode-Dekodierung oder Vollständigkeitsprüfungen eingesetzt werden. Weiterhin ist die Vermessung und Prüfung von Außenabmessungen von Objekten möglich, sofern die zulässige Toleranz mindestens im Bereich von 0,5mm liegt und die Geschwindigkeit zweitrangig ist. Alternativ wäre der Einsatz denkbar, wenn die Toleranzanforderungen niedriger sind, dafür die Geschwindigkeit aber wichtiger ist, wie z.B. bei einer Barcodeerkennung. Durch Erweiterung der Software und Verbesserung der Hardwarekomponenten ist eine Erhöhung des Toleranzbereiches, der Leistungsfähigkeit und eine Erweiterung der Anwendungsmöglichkeiten, z.B. Farbprüfung oder Mustererkennung, denkbar. Auch ist eine Kameraanbindung, sowie die Input- und Output-Funktionen z.B. über Ethernet- oder USB-Schnittstelle möglich. Die Hardwarekosten des Systems (ohne Monitor zur Darstellung und Peripherie) betragen lediglich ca. 100€. In Relation zu den Systemkosten ist die Leistung des entwickelten Prototyps sehr positiv zu bewerten. ■

www.th-deg.de

Die weltweit führende Plattform der Intralogistik



17. Internationale Fachmesse für Intralogistik-Lösungen und Prozessmanagement

19. – 21. Feb. 2019
Messe Stuttgart

INTRALOGISTIK
AUS ERSTER HAND

Intelligent • Effizient • Innovativ



Jetzt informieren
und dabei sein!

Tel. +49 (0)89 32391-259
www.logimat-messe.de

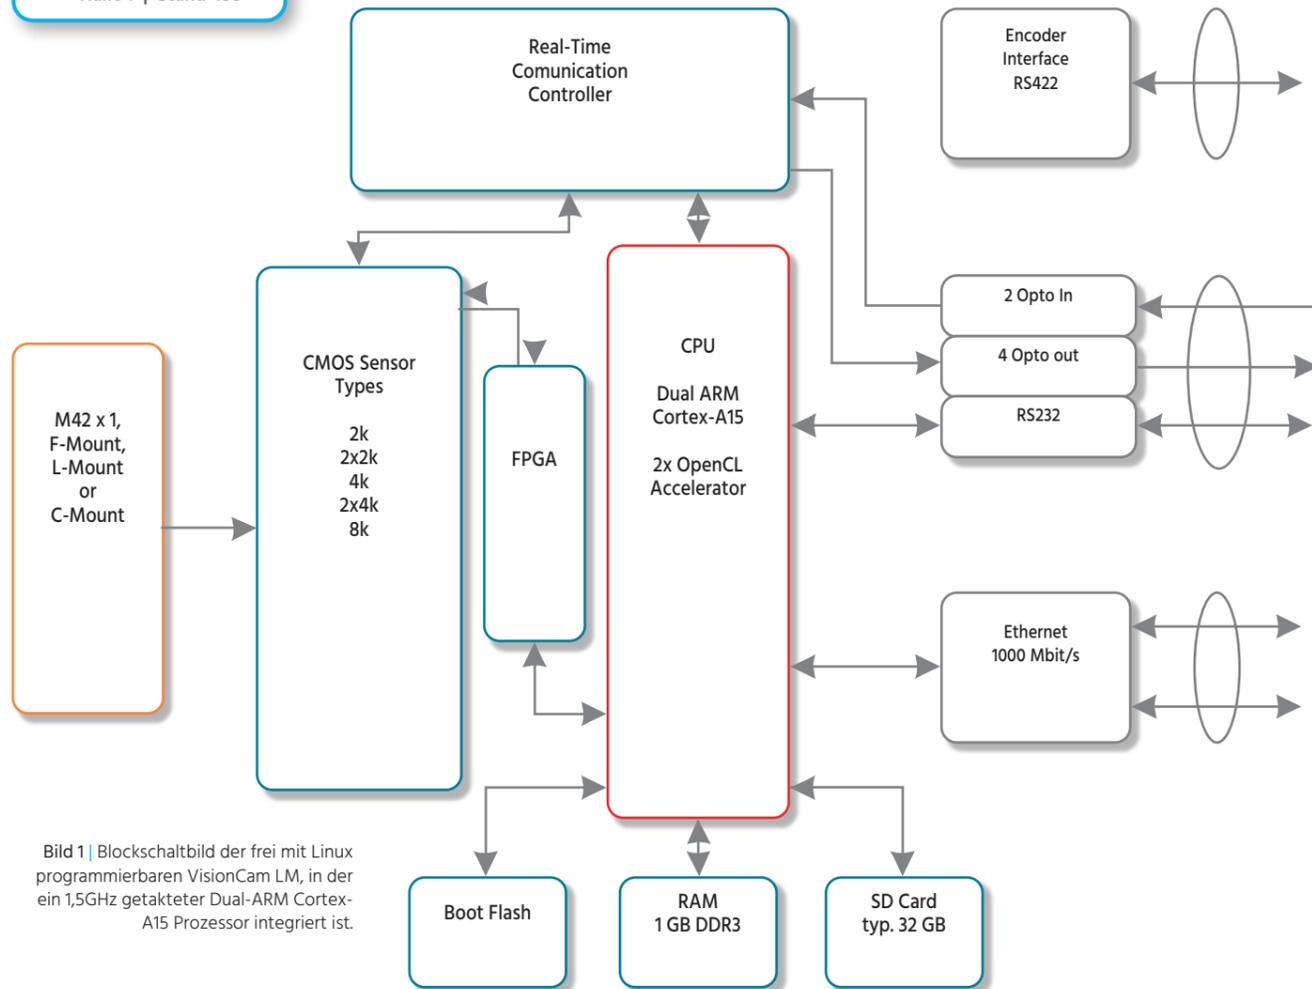


Bild 1 | Blockschaubild der frei mit Linux programmierbaren VisionCam LM, in der ein 1,5GHz getakteter Dual-ARM Cortex-A15 Prozessor integriert ist.

Intelligente Zeilenkamera

Programmierbare (Zeilen-)Kamera mit ARM-Prozessoren

AUTOREN: DIPL.-ING. CARSTEN STRAMPE, GESCHÄFTSFÜHRER, DIPL.-PHY. OLIVER BARZ, KEY ACCOUNT MANAGER, IMAGO TECHNOLOGIES GMBH
BILDER: IMAGO TECHNOLOGIES GMBH

Die VisionCam ist eine frei unter Linux programmierbare, intelligente Kamera. Die hohen Datenraten werden durch den mit 1,5GHz getakteten Dual-ARM Cortex-A15-Prozessor verarbeitet.

Die GigE-Flächenkamera kommt ohne Kühlkörper aus, kann mit Sensoren bis zu 5MP bestückt werden und erlaubt genaue Messungen, Codes auf größeren Labeln zu lesen oder mit Hilfe mehrerer AOIs trickreiche Applikationen zu realisieren. Die Rechenleistung näher an die Kamera zu bringen, ist bereits mehrfach

mit VisionBoxen umgesetzt worden. Voll integriert als frei programmierbare Kamera mit leistungsstarker CPU und Linux ist allerdings neu. Auflösungen von 2k bis zu 8k Pixeln sind mit Zeilenfrequenzen von bis zu 80kHz (2k) bis 25kHz (8k) möglich. Die gesamte Anwendung kann in der intelligenten Zei-

lenkamera VisionCam LM implementiert werden. Wird die Auswertung auf den ARM-Kernen zu komplex, so stehen zwei spezielle Coprozessoren (angesprochen in OpenCL) zur Verfügung. Oder – als Idee – man transferiert per Algorithmen bearbeitete Bildausschnitte per GigE zu einem übergeordneten embedded Rechner. Läuft die Anwendung komplett in der intelligenten Kamera, so wird diese via Switch mit einem Browser auf einem Tablet (oder Panel PC) verbunden, weitere Schaltschrankrechner und Bauraum sind nicht erforderlich.



Bild 2 | Auflösungen von 2k bis zu 8k Pixeln sind mit der VisionCam LM für Zeilenfrequenzen von bis zu 80kHz (2k) bis 25kHz (8k) möglich.

Entwicklungsumgebungen

Als Betriebssystem ist Linux in der Embedded-Welt gesetzt. Als Entwicklungsumgebung nutzt man dagegen das Microsoft Visual Studio sowohl als Editor sowie für das Debugging und bleibt so in der Windows-PC-Komfortzone. Auch eine Halcon-Bibliothek läuft auf den ARM-Rechnern. Was macht aber die 16-jährige rechnerinteressierte Tochter heutzutage in ihrem Zimmer? Ein Blick verrät, dass sie auf einem Raspberry Pi programmiert, einem günstigen (und gesponserten) Linux-Rechner. Auch der erfahrene 50-jährige Entwicklungsingenieur ist so clever in seinem Labor zu zeigen, dass eine Anwendung auf einem Raspberry Pi laufen kann. Die Rechenleistung und Industrietauglichkeit reichen zwar noch nicht ganz, aber in beiden Fällen zeigt sich: Linux ist etabliert, auch wird es in vielen Industrieanwendungen bereits verwendet.

Bedienoberflächen

Der Bedienmonitor vor Ort verschwindet mehr und mehr bzw. wird durch Ideen ersetzt, die auf die Bedienung und den Blick auf die Anwendung optimiert sind. Embedded Visionssysteme sind meist in die Maschinenbedienoberfläche eingebunden, die vom Maschinenhersteller definiert wird, d.h. Bilder werden geliefert und Daten z.B. per XML-Dateien kommuniziert. Andere Anwendungen erfordern dagegen eine webbasierte Oberfläche, ausgelegt für Bediener, Techniker und Entwickler. Hier gibt es bereits vorgefertigte Tools, in die man z.B. nur noch Verarbeitungs-Skripte einbinden muss. Bibliotheken, aber auch Tools, vereinfachen das Design von webbasierten Oberflächen, die automatisch skaliert auf Browser, Tablet oder Smartphone laufen. Für bis dato nicht realisierte Webinspektion steht demnächst auch ein Tool für die Oberflächenkontrolle zur Verfügung. Zahlreiche Klassifikatoren laufen bereits auf den ARM-basierten Plattformen.

www.imago-technologies.com

- Anzeige -



The **Art of M&A**
is in creating value.

Vision Ventures führt Ihren Unternehmensverkauf zum Erfolg.
Nach allen Regeln der Kunst.

VISION
VENTURES

www.vision-ventures.eu info@vision-ventures.eu

Programmierbare Kameras und Boxen

Embedded Deep Learning soll künstliche Intelligenz von der Cloud in das Gerät oder die Maschine bringen. Der erste Schritt zur Verkleinerung einer Serverfarm besteht laut Imago darin, ein leistungsstarkes GPU-Board in einer kompakten VisionBox einzusetzen. Der zweite Schritt ist eine lüfterlose VisionBox mit embedded GPU. Der dritte und letzte Schritt ist, Deep-Learning-Anwendungen auf eine VisionCam, die programmierbare Kamera des Herstellers, zu verkleinern und sowohl das Training als auch die Inferenz auf der ARM-Architektur laufen zu lassen. Programmierbare Vision-Senso-

ren sollen die Kombination kompakter Hardware mit verbesserter Programmierung erlauben, entsprechend den Anforderungen der Anwendung. Skalierbare Technologie soll es den Anwendern ermöglichen, die beste Kombination aus Rechenleistung, Kamerasensorik und Schnittstellen zu wählen.



Imago Technologies GmbH
www.imago-technologies.com

Software-Suite mit Deep Learning



Die Carrida-Software-Engine für die automatische Nummernschilderkennung (ALPR/ANPR) wurde jetzt um die neue Funktion Fahrzeugtypenerkennung er-

weitert, die mit Deep-Learning-Algorithmen umgesetzt wird. Das Tool kann allein- stehend verwendet werden oder zusammen mit der Nummernschilderkennung, um die Erkennungsgenauigkeit zu erhöhen. Vision Components hat seit 2014 ein Lösungsangebot für OEMs im Bereich Zufahrtskontrolle, Verkehrsüberwachung und Smart City auf die Beine gestellt. Dieses wird seit Kurzem federführend von der Tochterfirma Carrida Technologies vermarktet und weiterentwickelt. Das

Kernelement bildet die Software, die in- zwischen Kennzeichen aus über 50 Län- dern auf der ganzen Welt mit einer typi- schen Genauigkeit von 96% liest. Die Min- destzeichengröße beträgt nur 8 Pixel. Vi- deostreams können mit Bewegungsde- tektion verarbeitet werden, um Rechen- kapazität zu sparen. Die Hardware-un- abhängige Software läuft auf Windows-, Linux- und Android-Systemen.

Vision Components GmbH
www.vision-components.com

Embedded Vision für den Schaltschrank

Emsens ist eine Kombination aus einem Single-Board-Computer wie z.B. Odroid XU4 oder Pine und der Basler Dart Board Level USB3.0-Kamera. Dieses Embed- ded-Vision-System lässt sich im Hutschienengehäuse in einen Schaltschrank ein- bauen. Die Kamera Dart verfügt über ein CS-Mount- oder S-Mount-Gewinde und ist auch ohne Mount erhältlich. Der Anwender kann zwischen Graubild- und Farbsensoren und drei verschiedenen Auflösungen wählen. Die eingesetzte Eye- vision-Software hat vorgefertigte Befehle zur Lösung von Applikationen wie z.B. Messtechnik, Mustervergleich, Objektzählung (BLOB), Lesen (Barcode, DMC, QR, OCR/OCV), Farbprüfung, Oberflächenprüfung oder Vollständigkeitsprüfung. An- wender können per Drag&Drop Prüfprogramme erstellen.

EVT Eye Vision Technology GmbH
www.evt-web.com



Bild 1 | IDS zeigt auf der Vision einen funktionsfähigen Prototypen einer KI-basierten Objekterken- nung, die vollkommen eigenständig auf einer IDS NXT-Industriekamera läuft.

KI per Vision-App

Künstliche Intelligenz als App für Industriekameras

AUTOR: DIPL.-ING. (FH) HEIKO SEITZ, TECHNISCHER REDAKTEUR, IDS IMAGING DEVELOPMENT SYSTEMS GMBH
BILDER: IDS IMAGING DEVELOPMENT SYSTEMS GMBH

Vision-App-basierte Industrie- kameras der IDS NXT-Familien Rio und Rome sind bereit für künstliche Intelligenz (KI). Eine Vision-App macht sie zu ener- gieeffizienten und leistungs- starken Inferenzkameras mit integriertem KI-Beschleuniger.

Einmal programmiert, funktioniert die klassische Bildverarbeitung immer auf dieselbe Art und Weise – aber nur so- lange die zu identifizierenden Merkmale eindeutig sind und vorab definiert wur- den. Um Fehlerquoten immer weiter zu senken, müssen Produktionsfehler früh- zeitig erkannt und vermieden werden. Wo sich aber die komplette Vielfalt an möglichen Abweichungen und Fehlern

kaum vollständig vorhersagen lässt, liefern KI-basierte Verfahren neue Ansätze. Künstliche Neuronale Netze (KNN) interpretieren mittlerweile komplexe Bildinhalte mit unerreichter Genauigkeit und bieten Lösungen, die sich durch die manuelle Programmie- rung mit bisherigen Algorithmen selbst mit hohem Aufwand nicht realisieren ließen. Neben der Qualitätssicherung

Bild 2 | Die NXT-Industriekameras werden durch die KI-Vision-App zu universellen Inferenzkameran inklusive KNN-Beschleuniger. Mehrere vortrainierte Netze gängiger Architekturen können geladen und in wenigen Millisekunden zur Laufzeit umgeschaltet werden.



Inferenzzeiten von wenigen Millisekunden

Ein spezieller Interpreter sorgt dafür, dass die KNNs zusammen mit ihren trainierten Gewichten und definierten Ausgaben für die Verwendung mit dem NXT KI-Prozessor vorbereitet und bei Bedarf einer Optimierung (Pruning) unterzogen werden, wodurch die KNN-Geschwindigkeit für die gewünschte Anwendung nochmals verbessert wird. Durch die FPGA-basierte KI-Beschleunigung sind Inferenzzeiten von wenigen Millisekunden mit

verbreiteten Architekturen möglich. NXT-Kameras können damit, was Genauigkeit und Geschwindigkeit von KI-Aufgaben angeht, mit modernen Desktop CPUs Schritt halten – bei gleichzeitig wesentlich geringerem Platz- und Energieverbrauch. Durch die Wiederprogrammierbarkeit des KNN-Beschleunigers ergeben sich zudem Vorteile, was Zukunftssicherheit, geringe wiederkehrende Kosten und Time-to-Market betrifft. Die KI-Technik schreitet so rasant voran, dass monatlich neue Frameworks und Architekturen dazukommen, die dann sofort implementiert werden können, ohne die Hardware-Plattform zu ändern. Durch die schnelle Neukonfiguration des dedizierten Prozessors kann zur Laufzeit in wenigen Millisekunden zwischen mehreren geladenen KNNs umgeschaltet werden. Das ermöglicht die sequentielle Durchführung unterschiedlicher Klassifizierungen mit denselben Bilddaten innerhalb derselben Anwendung. Mit der flexiblen Vision-App-basierten Plattform werden Anwender ihre vorbereiteten neuronalen Netze als vollständiges KI-Bildverarbeitungssystem schnell und einfach an die Maschine bringen können. IDS zeigt auf der Vision einen funktionsfähigen Prototypen einer KI-basierten Objekterkennung, die vollkommen eigenständig auf einer NXT-Industriekamera läuft.

www.ids-imaging.de

oder Predictive Maintenance in der industriellen Produktion sind z.B. auch neue Einsatzgebiete in der medizinischen Diagnostik oder Lagerprüfungen in Einzelhandel und Logistik denkbar.

Embedded-Beschleuniger in der Kamera

Die Vielfalt von KNNs wird Anwendern durch ein breites Spektrum von Open-Source Frameworks, high-level-Software und Services zugänglich gemacht. Eine Vielzahl veröffentlichter KNN-Architekturen decken dabei bereits unterschiedliche Anforderungen an Komplexität, Genauigkeit oder Inferenzzeiten ab. Durch die Automatisierung und Überwachung industrieller Anlagen stehen zum Training dieser Architekturen immer mehr Daten zur Verfügung. Allerdings bedurfte der Einsatz von KNNs bisher häufig teurer und leistungshungrieriger Hardware. Spezielle Embedded-Beschleuniger, das heißt Hardware-Chips mit hoher Rechenleistung bei geringer Leistungsaufnahme, können hier Abhilfe schaffen. Dabei liegt es nahe, solche Beschleuniger direkt in die Kamera zu integrieren, sodass Bildanalysen dezentral stattfinden und Bandbreiten-Engpässe in der Übertragung vermieden werden.

Dem Anwender wird dadurch die Wahl gelassen, ob die künstliche Intelligenz klassisch auf einem PC, in der Cloud oder auf einer Embedded-Vision-Kamera ausgeführt wird, die sich damit neben der Bereitstellung der Bilddaten, auch direkt um deren Auswertung kümmert. Die Struktur und Arbeitsweise von KNNs hat gezeigt, dass für deren Beschleunigung bewährte Hardware neu überdacht werden muss. Zwar interpretieren sie Bilder mit vergleichsweise simplen Rechenoperationen, wie Additionen und Multiplikationen, allerdings müssen je nach Tiefe der Vernetzung Milliarden solcher Berechnungen durchgeführt werden, um die Bilddaten gegen alle trainierten Merkmale zu prüfen. Um hohe Inferenzraten bei geringer Latenz bzw. in Echtzeit zu realisieren, ist daher ein hohes Maß an paralleler Verarbeitung notwendig. Die Auswahl der richtigen Technologie (z.B. GPUs, DSPs oder FPGAs) zur KI-Beschleunigung ist somit eine weitere Variable, die bei der Konzeption des kompletten Bildverarbeitungssystems zu betrachten ist, dessen Umsetzung von Anforderungen wie Kosten, Baugröße, Performance, Qualität und Hardwarekompatibilität abhängt.

Kamera und KI-Plattform in einem

Die neuartigen Vision-App-basierten Industriekameras IDS NXT Rio und Rome sind mehr als reine Bildlieferanten, denn sie bringen KI "on the edge". Standard-Kamera-Funktionen können vom Anwender bequem um Bildverarbeitungsaufgaben in Form sogenannter Vision-Apps erweitert werden. Hardwareseitig wird die CPU durch einen zur Laufzeit programmierbaren, parallel arbeitenden FPGA unterstützt, wodurch der komplette Datenpfad flexibel nutzbar wird. Durch eine spezielle KI-Vision App wird dieser integrierte FPGA zum KI-Prozessor, der viele bereits bekannte Architekturen neuronaler Netze beschleunigt ausführen kann. Damit kann der Anwender seine eigenen neuronalen Netze bequem in der eigenständig arbeitenden Inferenzkamera für unterschiedliche Aufgaben bereitstellen: Anomalien erkennen, Früchte klassifizieren, Oberflächen prüfen, Leiterplatten und deren Bestückung verifizieren, usw. Die flexible Anpassungsfähigkeit der NXT-Plattform vereinfacht deren Integration in ein bestehendes System und die Anpassung an verschiedene Aufgaben.

Das exklusive Fachmagazin für Robotik-Systeme und Produktion

Jetzt Gratis-Heft anfordern:

aboservice@tedo-verlag.de

Es entstehen keine Kosten oder Verpflichtungen



Praxisnahe und aktuelle Berichterstattung über

- Robotik – Kinematiken, Greifer, Werkzeuge
- Lösungen – Montage, Handhabung, Integration
- Automation – Komponenten, Kommunikation, Konstruktion
- News und Normen

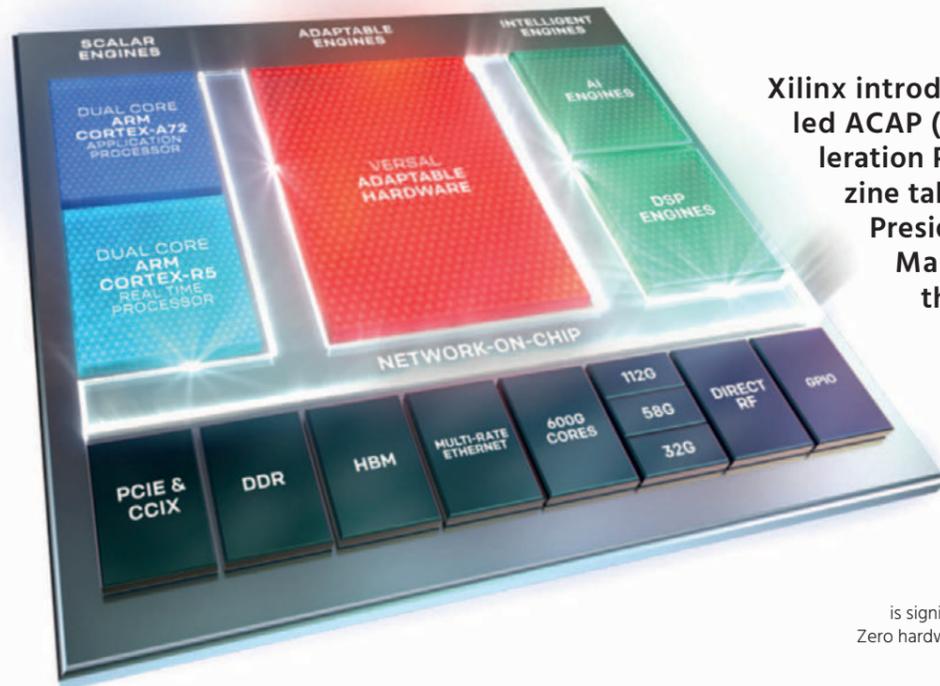
Mit dem Newsletter alle 14 Tage kostenlos das Neueste aus Robotik und Produktion erfahren

robotik-produktion.de/newsletter



Super FPGA

Heterogeneous Acceleration Platform for AI Applications



IMAGES: XILINX LTD

Xilinx introduced a new platform called ACAP (Adaptive Compute Acceleration Platform). inVISION magazine talked with Kirk Saban, Vice President, Product & Technical Marketing at Xilinx, about the advantages of the new platform and the first product series Versal.

Image 1 | A Versal ACAP (Adaptive Compute Acceleration Platform) is significantly different than a regular FPGA or SoC. Zero hardware expertise is required to boot the device.

inVISION What is an ACAP and for which applications does it work best?

Kirk Saban: An ACAP is a heterogeneous, hardware adaptable platform that is built from the ground up to be fully software programmable. An ACAP is fundamentally different from any multi-core architecture in that it provides hardware programmability but the developer does not have to understand any of the hardware detail. From a software standpoint, it includes tools, libraries, run-time stacks and everything you'd expect from a modern software driven product. The tool chain, however, takes into account every type of developer - from hardware developer, to embedded developer, to data scientist and framework developer.

inVISION What are the differences to a classic FPGA or SoC?

Saban: A Versal ACAP is significantly different than a regular FPGA or SoC. Zero hardware expertise is required to boot the device. Developers can connect to a host via CCIX or PCIe and get memory-mapped access to all peripherals (e.g. AI engines, DDR memory controllers). The Network-on-Chip is at the heart of what makes this possible. It provides ease-of-use and makes the ACAP inherently SW programmable—available at boot and without any traditional FPGA place-and-route or bit stream. No programmable logic experience is required to get started, but designers can design their own IP or add from the Xilinx ecosystem.

With regard to Xilinx's hardware programmable SoCs (Zynq-7000 and Zynq UltraScale+ SoCs), the Zynq platform partially integrated two out of the three engine types (Scalar Engines and Adaptable Hardware Engines). Versal devices add a third engine type (Intelligent Engines), but more importantly, the ACAP architecture tightly couples them together via the Network on Chip (NOC) to enable each engine type to deliver 2-3x the computational efficiency of a single engine architecture, such as a SIMT GPU.

inVISION Does this mean, Xilinx will address, besides the classic hardware designers, also application engineers in the future?

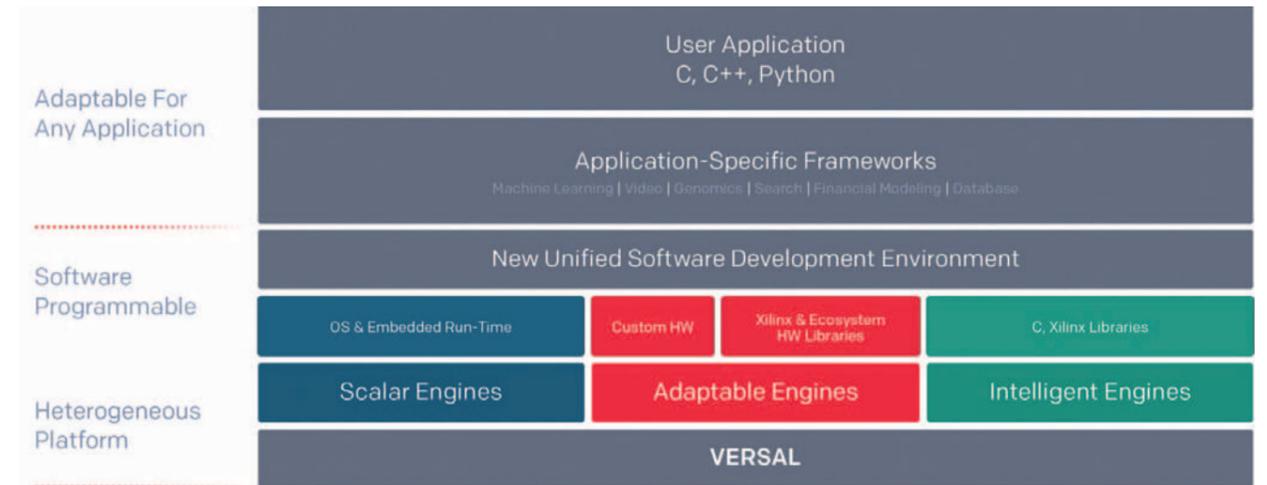


Image 2 | No programmable logic experience is required to get started with ACAP, but designers can design their own IP or add from the Xilinx ecosystem.

Saban: Xilinx has been addressing SW developers with design abstraction tools as well as its HW programmable SoC devices (Zynq-7000 and Zynq UltraScale+) for multiple generations. However, with ACAP, SW programmability is inherently designed into the architecture itself for the entire platform including its HW adaptable engines and peripherals.

inVISION Can you tell me a little bit about the use of ACAPs for artificial intelligence applications?

Saban: Among Versal's intelligent engines is the AI engine, a key enabler for many of Versal's target markets. The software programmable, hardware adaptable AI Engine addresses both the compute density and the memory bandwidth needed for high throughput

and AI/ML computation and suited for applications from cloud, to network, to edge and endpoint. AI Engine is tightly coupled with adaptable hardware for custom compute and flexible memory hierarchy to maximize performance. Alongside these adaptable hardware engines and scalar engines, the AI engine is part of a complete heterogeneous compute platform where deep learning can be infused as an element of a larger application that has other pre/post processing requirements.

inVISION Are there already benchmarks available, to compare Versal with other devices?

Saban: Multiple performance projections for Machine Learning inference throughput for Versal VC1902 can be

found in the media presentation delivered at XDF San Jose 2018. Xilinx's initial benchmark ratings show the Versal VC1902 delivering 3.5X low-latency CNN throughput against Nvidia T4 in a 75W power envelope, and 4.2X low-latency CNN throughput against a high-end Volta V100 GPU. These Versal performance numbers assume 60 percent of the VC1902 device is reserved for user functions, such as network attach or video processing. 5X wireless compute versus UltraScale+ is also cited in the presentation. From the technology announcement in March 2018, 20X AI Compute performance is cited in a comparison to Virtex UltraScale+ (VU9P) for Machine Learning inference for image recognition.

inVISION What about ACAPs in the classic machine vision application?

Saban: Xilinx will be announcing Versal devices for edge applications such as machine vision some time in the future. These will leverage Versal's scalar engines, adaptable engines, intelligence engines, and high-throughput connectivity from highest-resolution image sensors to frame grabber cards or industrial networks. Versal will excel in enabling the next generation of smart machine vision for the most compact and capable solution on the market.

inVISION Which devices of the Versal series are already available, which will be added in the future?

Saban: Versal is comprised of multiple device series, including AI Core Series, AI RF series, AI Edge series, Prime, Premium, and HBM. Product details of AI Core and Prime have been announced. Details of other device series will be disclosed at a later date. (peb)

» The ACAP tool chain takes into account every type of developer – from hardware developer, to embedded developer, to data scientist and framework developer. «

Kirk Saban, Xilinx



and low latency Machine Learning. The massive array of interconnected VLIW SIMD high-performance processors with local memory offer up to 8X compute density for vector-based algorithms vs. programmable logic and at half the power. These engines are optimized for deterministic, real-time DSP

found in the media presentation delivered at XDF San Jose 2018. Xilinx's initial benchmark ratings show the Versal VC1902 delivering 3.5X low-latency CNN throughput against Nvidia T4 in a 75W power envelope, and 4.2X low-latency CNN throughput against a high-end Volta V100 GPU. These Versal perfor-

www.xilinx.com

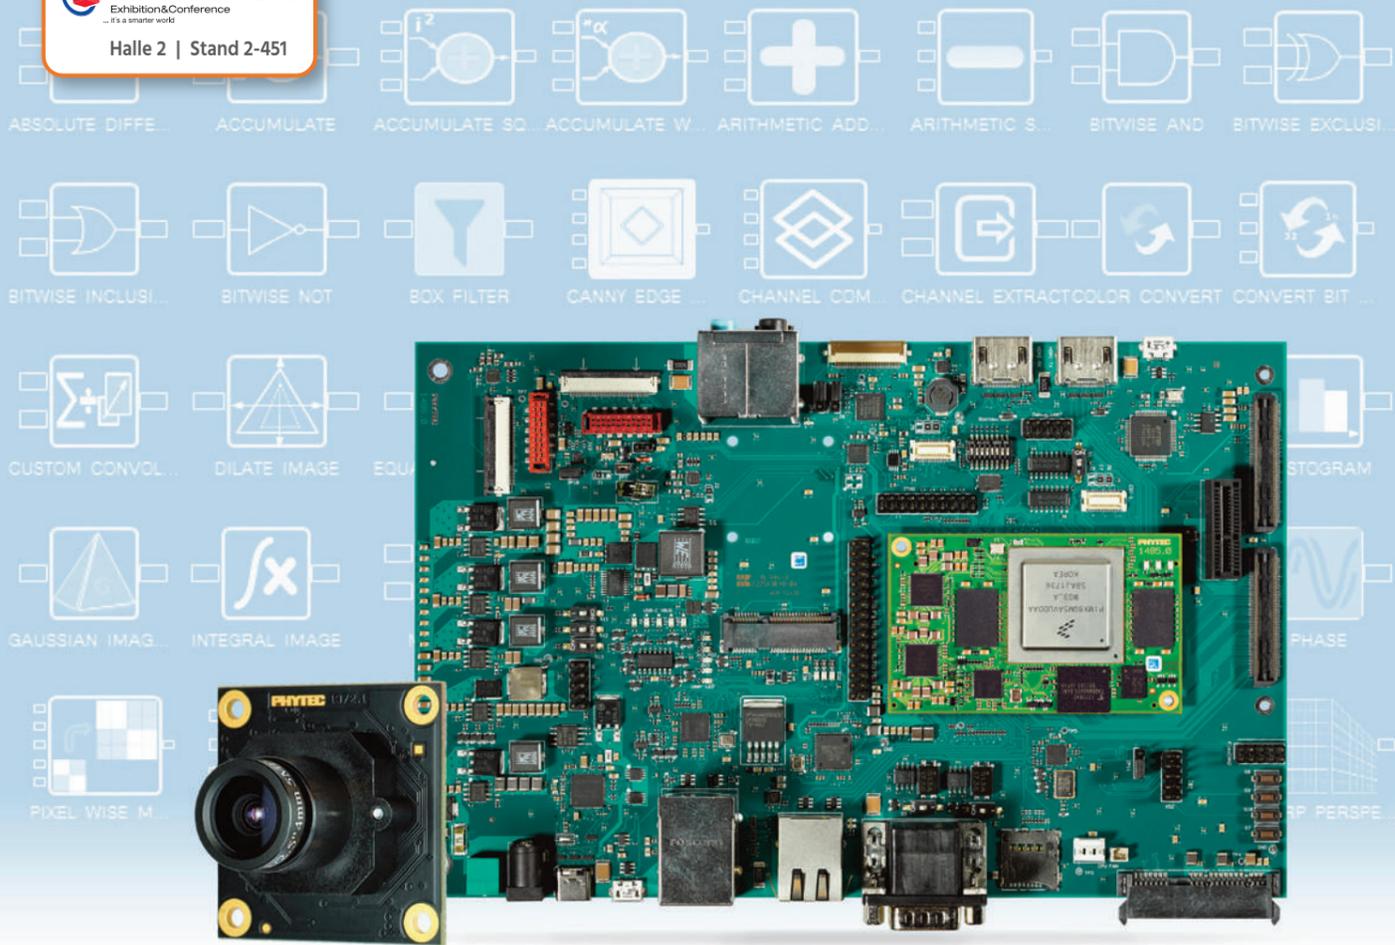


Bild 1 | Das Phytex-Entwicklungskit mit phyCORE-i.MX 8 System on Module.

Rechenpower

Neue NXP-Prozessorfamilie mit leistungsfähigen Imaging-Features

AUTOR: DIPL.-ING. (FH) MARTIN KLAHR, BEREICHSLEITER DIGITAL IMAGING, PHYTEC MESSTECHNIK GMBH | BILDER: PHYTEC MESSTECHNIK GMBH

Die i.MX-8 Prozessorfamilie von NXP punktet mit leistungsfähigen Bildverarbeitungsfeatures, Performance satt, zahlreichen Schnittstellen und einer Reihe integrierter Funktionseinheiten.

Wer sich mit dem neuen i.MX 8 beschäftigt, muss mehrdimensional denken. Denn der neue Prozessor-Clan ist auf den ersten Blick schwer zu überblicken. Er unter-

teilt sich in drei Familien: i.MX 8 mit maximaler Performance, i.MX 8M mit Fokus auf Multimedia und die kostenoptimierte i.MX 8X Familie. Alle drei Familien werden in verschiedenen, pinkompatiblen Derivaten erhältlich sein. Flaggschiff ist die i.MX 8-Familie, deren leistungstärkster Vertreter, der i.MX 8QuadMax mit zwei ARM Cortex-A72, vier ARM Cortex-A53 und zwei ARM Cortex-M4 Rechenkernen aufwartet. Er ist ab Mitte des Jahres in Serie verfügbar und damit nur wenig später als

der i.MX 8M. Für alle drei Familien entwickelt Phytex einsatzfertige Prozessormodule, Single Board Computer und Entwicklungskits. Im Bereich Embedded Imaging setzt das Unternehmen im ersten Schritt auf den i.MX 8QuadMax und den später erscheinenden i.MX 8X. Letzterer befindet sich in der gleichen Leistungsklasse wie der im Embedded Imaging-Bereich erfolgreich eingesetzte i.MX 6 und kann langfristig als dessen Nachfolger verstanden werden.

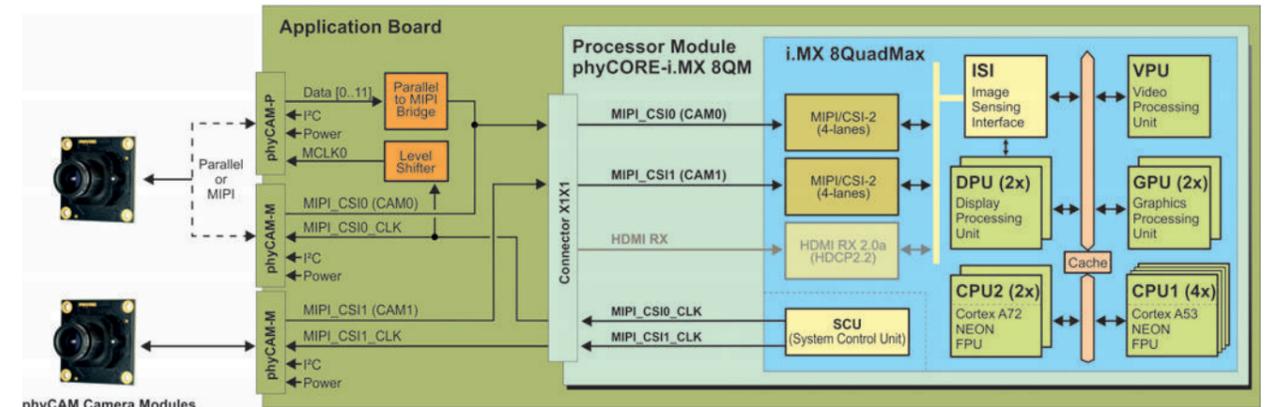


Bild 2 | Aufbau eines Embedded-Imaging-System mit dem i.MX 8QuadMax Prozessor.

28.650DMIPS Rechenleistung

Der i.MX 8QuadMax macht sich aufgrund seiner hohen Rechenleistung - NXP gibt bis zu 28.650DMIPS an - und seiner auf Bildverarbeitung abgestimmten Funktionseinheiten für Embedded Imaging besonders interessant. Dank der 64Bit RAM-Anbindung und bis zu 16GB LPDDR4-RAM können auch große Datenmengen schnell verarbeitet werden. In der i.MX 8 Familie sind aktuell noch zwei weitere Derivate geplant, der 8QuadPlus und 8Quad, die sich u.a. durch die Anzahl der ARM Cortex-A72-Kerne unterscheiden. Zahlreiche integrierte Funktionseinheiten des neuen Prozessors prädestinieren ihn für Imaging-Anwendungen. Der Bildeinzug von Kameras wird durch das ISI (Image Sensing Interface) durchgeführt, das acht Processing-Pipelines zur Verfügung stellt. Das ISI kann auch bereits einfache Vorverarbeitungen wie Farbraumkonvertierung, Scaling und Cropping oder Spiegelung durchführen. Kodierung und Dekodierung von Video-Streams erfolgt autark in der Video Processing Unit (VPU) von H.265 (4k60/2k60) und von/nach H.264 (1.080p60). Für die Verarbeitung von Bilddaten stehen den CPU-Kernen mehrere Funktionsblöcke zur Seite: Die jeweils den A72- und A53-

Cores zugeordneten Neon-Einheiten sind SIMD-Units (Single Instruction, Multiple Data), die z.B. Filterfunktionen effizient bearbeiten können.

Die zwei GC7000SXVX GPUs von Vivante für den i.MX 8 sind mit Dynamic VLIW-Architektur und dem Extended Vision Instruction Set (EVIS) speziell für die Bildverarbeitung optimiert. Sie leisten bis zu 128Gflops und können entweder einzeln oder zusammenschaltet als eine Einheit betrieben werden. Hinzu kommt die entsprechende Software-Unterstützung der Hardware-Funktionen, die NXP für ihr Board Support Package angekündigt hat. So werden zahlreiche Standards der Khronos Group unterstützt. Dazu gehören u.a. APIs für OpenCL, OpenGL und OpenVX, der Khronos-Variante von OpenCV. Die GC7000XS* GPU von Vivante wurde von Khronos für die Verwendung mit OpenGL ES 3.2 zertifiziert.

Erste Kameramodule

Als Kameraschnittstellen stellt der i.MX 8 zwei MIPI CSI-2 Interfaces zur Verfügung. Der Standard stammt zwar aus der Consumer-Welt, etabliert sich derzeit jedoch über den Automotive-Bereich zunehmend auch für industrielle

Anwendungen. Allerdings fehlt ihm eine definierte Hardware-Schnittstelle, welche die Austauschbarkeit der Komponenten und eine Hardware-Skalierbarkeit ermöglicht. Phytex hat dafür das phyCAM-M Schnittstellenkonzept entwickelt, das die genannten Kriterien berücksichtigt. Ein erstes Kameramodul mit phyCAM-M Interface für den industriellen Einsatz und mit dem langzeitverfügbaren Sensor AR0144 ist bereits erhältlich. Für die Verwendung von bewährten Kamerasensoren mit parallelem Interface hat Phytex zudem eine Ankopplung über eine Parallel-/MIPI-Bridge realisiert, die auf dem i.MX 8 Rapid Development Board ausgebaut und softwareseitig ins Board Support Package der Module integriert ist. Damit kann das Sortiment an phyCAM-P Kameramodulen auch mit dem i.MX 8 genutzt werden. Das phyCORE-i.MX 8 Rapid Development Board unterstützt alle Features des Prozessors und ermöglicht einen schnellen Einstieg in eigene Produktentwicklungen. Ein speziell auf Embedded-Imaging-Anwendungen abgestimmtes Entwicklungskit von Phytex ist für Q2/2019 angekündigt. ■

www.phytex.de

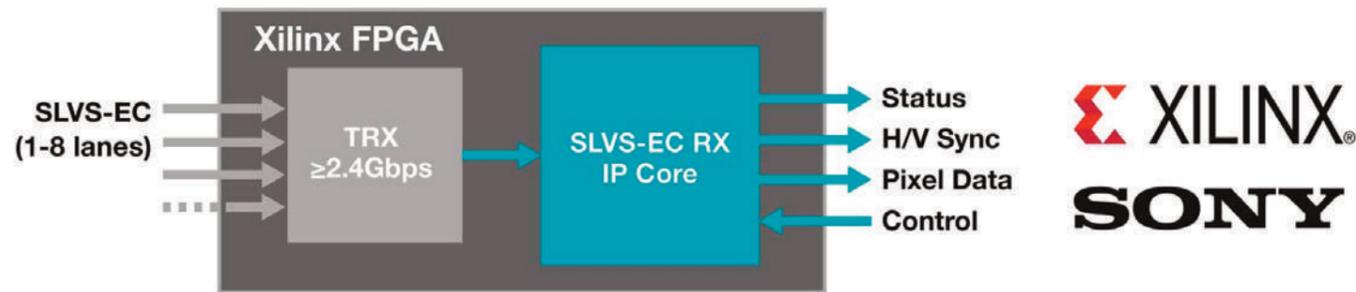


Bild 1 | Der SLVS-EC IP-Core erleichtert Anwendern die Verbindung zwischen Image-Sensor und FPGA.

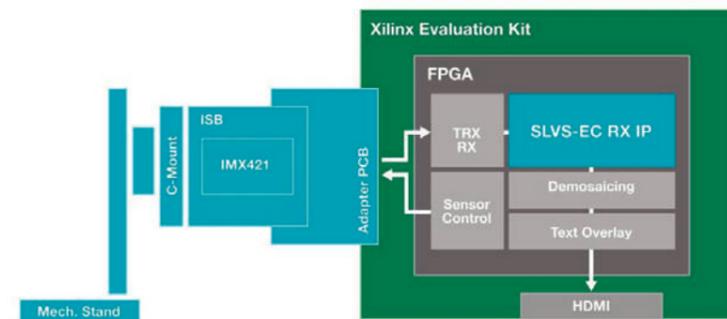


Bild 2 | Schema eines Kameradesigns mit einem Sensorauswertungs-Erweiterungspaket für ein Xilinx Ultrascale Evaluation Board.

Vereinfachter Anschluss

Schnellere FPGA-Anbindung für neue Sony CMOS-Sensoren

AUTOR: ANDRÉ BRELA, PRODUCT MANAGER, FRAMOS GMBH | BILDER: FRAMOS GMBH

Mit dem integrierbaren IP-Core für Sonys neue CMOS-Global-Shutter-Bildsensoren der dritten Generation mit SLVS-EC-Schnittstelle profitieren Anwender von einer verkürzten Time-to-Market und einer verbesserten Performance für die Vision-Entwicklung mit FPGAs von Xilinx.

Die Innovationen der neuen Sony Pregius-Bildsensoren der dritten Generation basieren vor allem auf deren Bildqualität und Geschwindigkeit. Angesichts der zahlreichen Qualitätsverbesserungen und der damit erreichten Sensorleistung ist allerdings eine Übertragung der Bild-daten, bei gleichzeitiger Steigerung der Übertragungsgeschwindigkeit, mit den bisherigen Sensorschnittstellen nicht möglich. Der SLVS-EC-Schnittstellenstandard wird als Hochgeschwindigkeitsschnittstelle der neuesten Bildsensoren eingesetzt und erlaubt einen hö-

heren Durchsatz, eine bessere Signalintegrität sowie einfachere Designs.

Acht Lanes mit je 2,376Gbps

Mit bis zu acht Lanes, die jeweils 2,376Gbps bieten, steht mit SLVS-EC (Scalable Low-Voltage Signaling with Embedded Clock) eine neue Sensorschnittstelle zur Verfügung, die den Anforderungen der Industrie hinsichtlich Auflösung und Geschwindigkeit gerecht wird. Die Ausgabegeschwindigkeit wurde gegenüber der zweiten CMOS-Generation von Sony auf 18,4Gbps fast verdoppelt. Es stehen damit mehr als dreimal höhere Bandbreiten pro Lane und höhere Auflösungen zur Verfügung, sowie ein einfacheres Systemdesign gegenüber den gängigen SubLVDS-Schnittstellen. Mit SLVS-EC können Anwender von schnelleren und leistungsfähigeren Sensoren sowie größeren Kabellängen, oder – wenn sie weniger Lanes nutzen – von einem vereinfachten und damit kleineren Hardware-Design profitieren. Mit ihrer integrierten Taktung (Em-

bedded Clock) ist die Schnittstelle robust gegenüber Taktversätzen, was eine höhere Bandbreite ermöglicht und dedizierte Clock-Lanes überflüssig macht.

Verbindung IP-Core mit FPGA

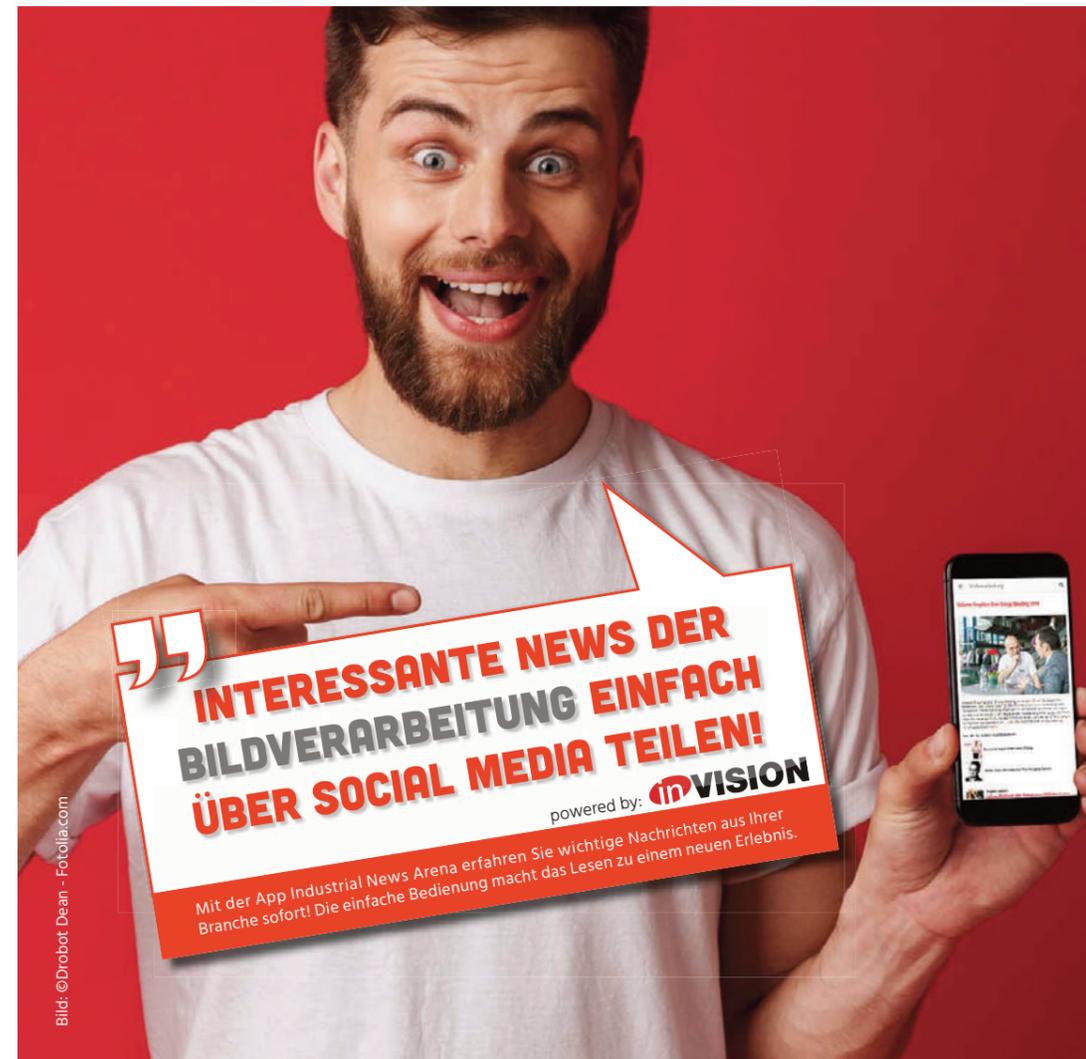
Um die neuen Bildsensoren mit einer leistungsfähigen Onboard-Verarbeitung zu kombinieren, sind für die FPGAs aber Spezialkenntnisse und erfahrene Entwickler vonnöten. Darüber hinaus bedeutet die komplexere SLVS-EC-Schnittstelle aufgrund der erforderlichen Byte-zu-Pixel-Konvertierung und korrekten Transceiver-Konfiguration einen höheren Aufwand und einen größeren Overhead für die allgemeine Sensorimplementierung. Entwickler, die an Lösungen mit Xilinx-FPGAs und SoCs arbeiten, können den SLVS-EC RX IP Core und das Evaluation Board von Framos sowie dezidierte Quellcodebeispiele nutzen. So können sich Anwender auf ihre Core-Spezialisierung bzw. USP-Anwendung fokussieren und die Entwicklungszyklen kurzhalten.

Um diese Ziele zu erreichen, stehen ihnen nun hilfreiche Entwicklungswerkzeuge und SDKs zur Verfügung. Spezielle IP-Cores haben die Aufgabe, die Signalumwandlung innerhalb des FPGA oder SoC zu übernehmen, indem sie die Sensordaten auf einer gut dokumentierten Schnittstelle empfangen und einen vorentwickelten Logikblock bereitstellen. Der SLVS-EC RX IP Core für Xilinx-FPGAs und SoCs ist eine bewährte Implementierung von SLVS-EC als Sonys bevorzugter Schnittstelle für deren Bildsensoren. Als On-Chip-Funktionsblock verbindet der IP Core die FPGA-Logik mit dem Datenstrom des Bildsensors, nimmt die Schnittstellendaten an und verwaltet die Byte-zu-Pixel-Konvertierung für alle verfügbaren Lane-Konfigurationen. Er bereitet damit einen optimalen und effizienten

Verarbeitungsablauf auf dem FPGA vor. Die Software unterstützt SLVS-EC v1.2 mit 1, 2, 4 oder 8 vom Nutzer konfigurierbaren Lanes und liefert Pixelformate zwischen 8 und 14Bit als Rohdaten. Der IP Core unterstützt dynamische Modusänderungen sowie eine AXI4-Kommunikations- und Control-Schnittstelle. Vorimplementierte IPC Cores, die Anwender bei der Erreichung ihrer Ziele unterstützen, werden als Pakete angeboten, die sowohl Konstruktionsdateien, eine Simulationsumgebung (z.B. ModelSim) und als Referenz dienende Implementierungsbeispiele umfassen. Das dazugehörige EVB-Kit bietet Beispiele und Designs, die beim Implementieren und Testen eines SLVS-EC-basierten Sensors unterstützen (inkl. Hard- und Softwareumgebung), sowie dokumentierte Implementierungsbeispiele mit Quellcodes.

www.framos.com

- Anzeige -

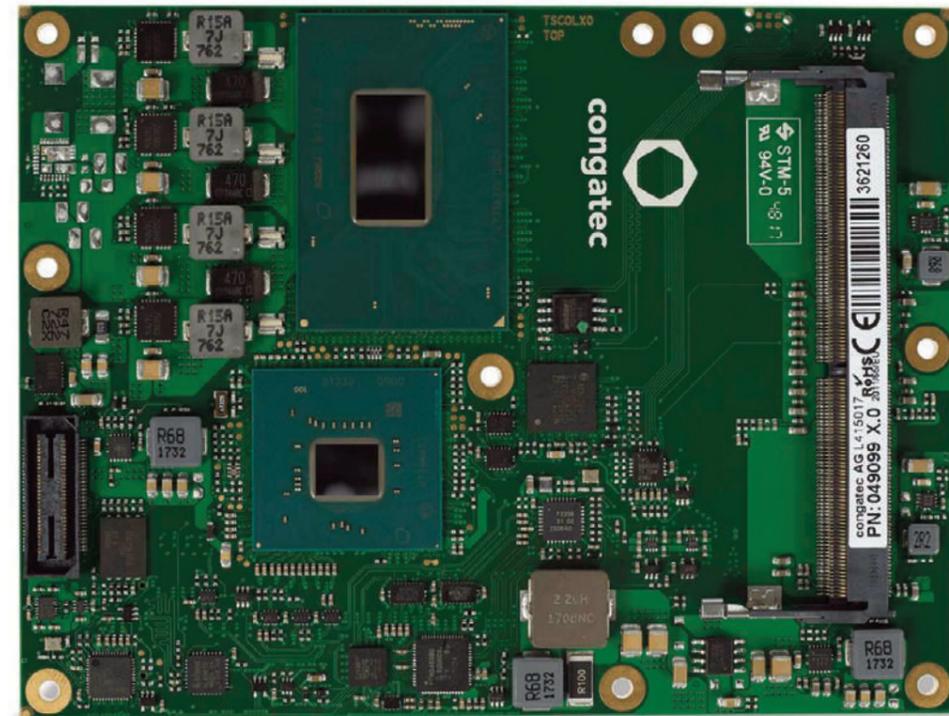


HIER KOSTENLOS DOWNLOADEN!





Die PowerBox 400-i7 BV bietet die technischen Möglichkeiten eines klassischen 19" Industrie-PC, benötigt allerdings weniger als ein Zehntel dessen Volumens.



Mit insgesamt 16 PCIe Gen 3.0 Lanes ist das conga-TS370 Computer-on-Module ideal für KI- und Machine-Learning-Applikationen, die mehrere GPUs für die parallele Datenverarbeitung benötigen.

Vision Power

Lüfterlose High-End- sowie Mini-PCs für Machine Vision

TEXT: SPECTRA GMBH & CO. KG | BILD: SPECTRA GMBH & CO. KG / ©SERGEYNIVENS/ISTOCKPHOTO.COM

Gleich zwei neue Industrie-PCs für die Bildverarbeitung stellt Spectra vor. Neben einer High-End-Version gibt es auch einen Mini-PC.

Die PowerBox 400-i7 BV ist ein lüfterloser Mini-PC, der in puncto Leistungsfähigkeit, modularer Erweiterungsmöglichkeiten und kompakter Bauform kaum Wünsche offen lässt. Der Mini-PC verfügt über eine Intel HD 630 Grafik-Engine der neunten Generation. Für höchste Performance sorgt ein hochmoderner Intel Core i7-7700T Desktop-Prozessor der Kaby Lake Familie. Es stehen ein Steckplatz für serielle Schnittstellenerweiterungen sowie zwei Sockel für LAN- oder PoE-Erweiterungen zur Verfügung.

Damit können sechs LAN sowie vier PoE Ports realisiert werden, die beispielsweise zum Anschluss von Kameras ideal geeignet sind. Zusätzliche Erweiterungen ermöglichen vier mPCIe-Steckplätze. Insgesamt lassen sich mehr als 100 Ausstattungsvarianten im Plug&Play-Prinzip zusammenstellen. Somit bietet die PowerBox die technischen Möglichkeiten eines klassischen 19" Industrie-PC, benötigt allerdings weniger als ein Zehntel dessen Volumens. Der Anwender hat die freie Wahl, ob er den Mini-PC fertig bestückt und getestet bezieht oder seine Anpassungen selbst vornimmt. Die PowerBox 4000 Serie verfolgt dagegen ein anderes Konzept. Sie basiert auf einem 340x330x133mm thermisch optimierten Aluminiumgehäuse mit ausgeklügeltem Wärmemanagementsystem, das sich flexibel als Tisch- oder Wandgehäuse verwenden lässt. Mit Zusatzwinkel ist es trotz seiner geringen Breite auch in einem 19" Schrank einsetzbar (Platzbedarf: 3HE). Im Inneren arbeitet ein Intel Xeon Silver Prozessor mit zehn Kernen. 64GB DDR4 Arbeitsspeicher und eine 500GB NVMe M.2 SSD sowie zwei 10GLAN und weitere vier GLAN ermöglichen Hochleistungsapplikationen. Zudem stehen zwei PCIe x16 Slots für den Einsatz von Profi-Grafikkarten oder Framegrabber zur Verfügung. Windows 10 Pro als Betriebssystem ist vorinstalliert, individuelle Ausstattungen sind möglich. ■

www.spectra.de

Preisbrecher

Einstiegsplattform für High-End Embedded Computing

TEXT UND BILD: CONGATEC AG

Das auf dem Intel Core i3-8100H Prozessor basierte conga-TS370 COM ist eine Plattform für High-End Embedded Computing.

Die COM Express Basic Plattform überzeugt durch kosten- und Performancepro-Watt-optimierten Quad Core Prozessor und energieeffizienten aber durchsatzstarken DDR4 RAM. Mit insgesamt 16 PCIe Gen 3.0 Lanes ist das Modul ideal für KI- und Machine-Learning-Applikationen, die mehrere GPUs für die parallele Datenverarbeitung benötigen. Die integrierte Intel HD Graphics UHD 630 ist hinsichtlich Taktrate und Treiber optimiert

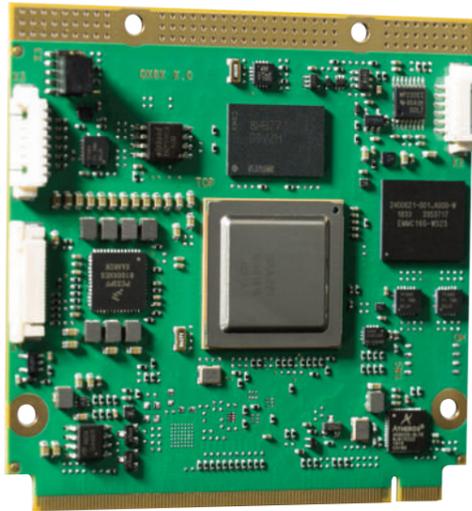
und bietet so zusätzlichen TDP-Spielraum für noch mehr GPGPU- oder 4k UHD Grafik-Performance. Bei Bedarf können die Module auch direkt mit ausgefeilten passiven oder aktiven Kühllösungen ausgeliefert werden. „Der neue 3 GHz Quad Core Intel Core i3 Prozessor und der neue HM370 Platform Controller Hub bieten eine besonders hohe Performance pro Watt“, erklärt Martin Danzer, Direktor Produktmanagement bei congatec. „Durch den deutlich gesunkenen Preis können Kunden nun sogar die rechenintensivsten KI-Applikationen zu einem erschwinglichen Kostenniveau bedienen.“ Das Type 6 Computer-on-Module mit Quad Core Intel Core i3 8100H Prozessor

unterstützt 6MB Cache und bis zu 32GB Dual-Channel DDR4 2400 RAM. Die gegenüber der vorherigen 7. Generation der Intel Core Prozessoren verbesserte Speicherbandbreite verhilft der integrierten Intel UHD630 Grafik auch zu mehr Grafik- und GPGPU-Performance. Zudem bietet sie mit 24 Execution Units auch einen dynamisch gesteuerten, höheren Grafiktakt von bis zu 1GHz. Unterstützt werden bis zu drei unabhängige 4k-Displays mit bis zu 60Hz via DP 1.4, HDMI, eDP und LVDS. Erstmals können Entwickler nun auch ohne Hardwareänderungen rein über Softwaremodifikation zwischen eDP und LVDS umschalten. ■

www.congatec.com

INDUSTRIE-PC FÜR VISION

Embedded Computing und Vision-Technologien



Congatec präsentiert drei applikationsfertige Lösungen als Embedded-Vision-Schwerpunkte: Die von Intel und Luxoft gemeinsam entwickelte Automotive Reference Platform – welche mit dem Conga-SA5 als erstes offiziell unterstütztes Modul auf den Markt kommt – macht Digital-Cockpit-Designs von Fahrzeugen der nächsten Generation smarter. Weiter zeigt Congatec in Kooperation mit AMD eine visionbasierte KI-Plattform, die auf den



neuen AMD Ryzen Embedded V1000-Prozessoren aufbauen. Diese sind auf GPGPU- und Gesamtleistung ausgelegt und nutzen das Open-Source-Ökosystem für Smart Vision. Abschließend wird die smarte Embedded-Bilderkennungsplattform präsentiert, die aus der Partnerschaft zwischen Congatec und Basler entstanden ist. Sie ist fokussiert auf Gesichtserkennung und basiert auf der Dart-Kamera-Serie mit USB3.0 sowie Conga-PA5 Pico-ITX Boards mit Intel Atom, Celeron und Pentium Prozessoren der 5. Generation.

Congatec AG
www.congatec.com

Künstliche Intelligenz in IoT-Umgebungen

Auf der Embedded World stellt Arrow eine Reihe von Systemen vor, mit denen Nutzer die Möglichkeiten der künstlichen Intelligenz in ihren Anwendungen, zum Beispiel in IoT-Applikationen, nutzen können. Das Unternehmen zeigt in Kooperation mit verschiedenen Herstellern entsprechende Technologien und bietet Support und Expertise für die Implementierung von KI-Funktionen in einer Vielzahl von Bereichen, wie Industrie, Gesundheitswesen und Transport/Logistik. Arrow unterstützt die Bereitstellung von KI-Funktionen von der Cloud bis zum Netzwerk-Edge und bietet Lösungen und Services für Smart Cities (Straßenbeleuchtung, Parken, öffentliche Sicherheit), Industrie, Robotik, autonome Maschinen und Landwirtschaft. In vielen Fällen bilden Embedded-Technologien die Grundlage für KI-Applikationen.

www.arrowce.com

Robuste KI-Inferenzplattform

Neosys kündigt die robuste KI-Inferenzplattform, die Nuvo-7164GC-Serie, an. Ein kompakter Embedded-Computer mit Nvidia Tesla P4/ T4 und Intel 8th-Gen Core i Prozessor, der für fortschrittliche Inferenzbeschleunigungsanwendungen wie Sprach-, Video-, Bild- und Empfehlungsdienste entwickelt wurde. Weiter verfügt die Serie über eine M.2 NVMe-Schnittstelle, die Lese-/Schreibgeschwindigkeiten von über 2000MB/s unterstützt und USB3.1 Gen2/ GbE-Ports für schnelle Datenübertragung, wie z.B. die Erfassung von

HD-VideoDaten. Darüber hinaus unterstützt Nuvo-7164GC das MezzIO Interface mit verschiedenen I/Os wie RS-232/422/485, USB3.1 Gen1 und GbE mit 802.3at PoE+.

Neosys Technology Inc.
www.neosys-tech.com



Robuster Embedded-PC

Die Industrial Computer Source stellt mit Nuvo-7160GC einen robusten Embedded PC vor, der auf Intels Core i Prozessoren der achten Generation basiert. Diese arbeiten mit 6 Kernen und 12 Threads und liefern somit eine um bis zu 50 Prozent gesteigerte CPU-Leistung gegenüber früheren Generationen. Das System soll für Robustheit und Vielseitigkeit stehen, u.a. durch das lüfterlose Design, die patentierte Erweiterungskassette und die proprietäre MezzIO-Schnittstelle. Der Embedded-PC verfügt über weitere I/O-Funktionen wie USB3.1 Gen2/Gen1, GbE und COM. Der PC nutzt überdies die M.2-NVMe-SSD-Technik für eine Lese- und Schreibgeschwindigkeit von über 2000MB/s oder Intel Optane Speicher für die Systembeschleunigung. Das System unterstützt GPUs mit bis zu 120W Verbrauch und liefert 4~6TFLOPS Rechenleistung.

Industrial Computer Source (Deutschland) GmbH
www.ics-d.de



Anzeigenindex

autoVimation GmbH.....	19	Landesmesse Stuttgart GmbH.....	5
Dream Chip Technologies GmbH.....	3	Vision Ventures GmbH & Co. KG.....	37
EUROEXPO Messe- und Kongress GmbH.....	35	Global Werbeagentur GmbH Nürnberg.....	27
NOTAVIS GmbH.....	13	Silicon Software GmbH.....	2
		Tanja Knott Kommunikation.....	33

Impressum

VERLAG/POSTANSCHRIFT:
Technik-Dokumentations-Verlag
TeDo Verlag GmbH®
Postfach 2140, 35009 Marburg
Tel.: 06421/3086-0, Fax: -180

info@invision-news.de
www.invision-news.de

LIEFERANSCHRIFT:
TeDo Verlag GmbH
Zu den Sandbeeten 2
35043 Marburg

VERLEGER & HERAUSGEBER:
Dipl.-Ing. Jamil Al-Badri +
Dipl.-Statist. B. Al-Scheikly (V.i.S.d.P.)

REDAKTION:
Dr.-Ing. Peter Ebert (peb),
Georg Hildebrand (Marktübersichten, ghi)

WEITERE MITARBEITER:
Bastian Fitz, Tamara Gerlach,
Pascal Jenke, Susan Jünger, Kristine Meier,
Melanie Novak, Sarah-Lena Schmitt,
Florian Streitenberger, Natalie Weigel,
Sabrina Werking

ANZEIGENLEITUNG:
Markus Lehnert

ANZEIGENDISPOSITION:
Michaela Preiß
Tel. 06421/3086-0
Es gilt die Preisliste der Mediadaten 2018

GRAFIK & SATZ:
Julia-Marie Dietrich, Tobias Götz, Fabienne Heßler, Melissa Hoffmann, Kathrin Hoß,
Ronja Kaledat, Moritz Klös, Patrick Kraicker,
Timo Lange, Ann-Christin Lölkes, Nadin Rühl

ERSCHEINUNGSWEISE:
6 Druckausgaben + 2 ePaper für das Jahr 2018

BANKVERBINDUNG:
Sparkasse Marburg/Biedenkopf
BLZ: 53350000 Konto: 1037305320
IBAN: DE 83 5335 0000 1037 3053 20
SWIFT-BIC: HELADEF1MAR

GESCHÄFTSZEITEN:
Mo.-Do. von 8.00 bis 18.00 Uhr
Fr. von 8.00 bis 16.00 Uhr

JAHRESABONNEMENT: (6 Ausgaben)
Inland: 36,00€ (inkl. MwSt. + Porto)
Ausland: 42,00€ (inkl. Porto)

EINZELBEZUG:
7,00€ pro Einzelheft (inkl. MwSt., zzgl. Porto)

ISSN 2199-8299
Vertriebskennzeichen 88742

Hinweise: Applikationsberichte, Praxisbeispiele, Schaltungen, Listings und Manuskripte werden von der Redaktion gerne angenommen. Sämtliche Veröffentlichungen in inVISION erfolgen ohne Berücksichtigung eines eventuellen Patentschutzes. Warennamen werden ohne Gewährleistung einer freien Verwendung benutzt. Alle in inVISION erschienenen Beiträge sind urheberrechtlich geschützt. Reproduktionen, gleich welcher Art, sind nur mit schriftlicher Genehmigung des TeDo Verlages erlaubt. Für unverlangt eingesandte Manuskripte u.ä. übernehmen wir keine Haftung. Namentlich nicht gekennzeichnete Beiträge sind Veröffentlichungen der Redaktion. Haftungsausschluss: Für die Richtigkeit und Brauchbarkeit der veröffentlichten Beiträge übernimmt der Verlag keine Haftung.

© Copyright by TeDo Verlag GmbH, Marburg.
Titelbild: Vecow Co. Ltd.

Embedded-Systeme mit integrierter KI

Der neue KI Embedded Computer von Syslogic eignet sich für alle Anwendungen, in denen Edge Computing und künstliche Intelligenz zusammentreffen. Typische Anwendungsgebiete sind die KI-Teilbereiche Machine Vision, Intelligent Control und Deep Learning. Als Basis setzt der Hersteller auf ein Jetson-TX2i-Modul von Nvidia. Herzstück des Systems ist ein ARM-SoC Tegra X2, das zwei Rechenkerne mit der von Nvidia selbst entwickelten Denver-2-Mikroarchitektur mit vier Cortex-A57-Kernen und einer Pascal-GPU vereint. Die Embedded-



PCs sind lüfterlos, wartungsfrei und eignen sich für den Temperaturbereich von -40 bis +70°C. Zur Systemanbindung verfügen sie über ein flexibles Schnittstellenlayout und es lassen sich WIFI-, GPS- sowie LTE-Funktionen ergänzen.

Syslogic GmbH
www.syslogic.de

Video-Rekorder-Board mit Display

X-Spex erweitert sein Produktangebot um das Diris Video-Rekorder-Board. Dieses ermöglicht Displays mit paralleler oder LVDS-Schnittstelle direkt anzusteuern. Kompatible Display sind erhältlich mit min. 650cd/m², wahlweise mit oder ohne kapazitive Touch-Funktion in 5, 7 oder 10". Das Board/Display-Bundle wird mit allen benötigten Anschlusskabeln geliefert. Eine optionale Schutzfolie verbessert die Haltbarkeit bei Belastung.

X-Spex GmbH
www.x-spex.de

