


Living on the Edge

Edge-Analytics in der Praxis @ TamedAI GmbH

29.10.2020

Ole Meyer
ole.meyer@tamed.ai




Beyond Clouds - TamedAI

- Die TamedAI GmbH ist eine Forschungsausgründung der Universität Duisburg-Essen
- Aufgabengebiet:
 - Entwicklung von KI-basierten Speziallösungen und/oder kritischen Systemen
- Vorgehen:
 - Produktbasiert durch Verwendung von vorgebauten Komponenten
 - Hands-On: Weniger Consultancy, mehr Taten
- Ziel
 - Anpassbarkeit: Vollständige Kontrolle über alle KI-Module
 - Sicherheit: Keine externen Services, die Zielplattform ist frei wählbar
 - Forschungsnah: Lösungen auf dem aktuellen Stand der Forschung



Edge-Analytics - Entscheidungsgründe in der Praxis




Geschwindigkeit

- Zielgröße:
 - Antwortzeit im Bereich weniger Millisekunden
- Beispiel:
 - AR im Operationssaal
- Herausforderungen
 - Insbesondere State-of-the-Art-Modelle häufig nicht Echtzeitfähig ohne besondere Hardware
 - Beispiel GPT2: ca. 1.5 Milliarde Parameter, Ausführungszeit ohne Hochleistungs-GPUs/TPUs > 1 Minute
 - Hardware steht auf Edge-Devices oft nicht zur Verfügung oder ist ein wesentlicher Kostentreiber
- Lösungen
 - Knowledge Distillation
 - Wahl passender Netzwerkarchitekturen (z.B. MobileNet vs NASNet in der Bildverarbeitung)




Ausfallsicherheit

- Zielgröße:
 - Ausfalltoleranz <10 Minuten
- Beispiel:
 - Kraftwerksteuerung, Steuerung von Windkraftanlagen
- Herausforderungen
 - Viele Algorithmen sind stochastisch.
 - Abgleich bei redundanten Systemen ist deutlich komplexer
 - Korrupte Daten sind schwerer Erkennbar
- Lösungen
 - Integration von „Safety-Frames“: KI-basierte Steuerung wird auf einen sicheren Operationsbereich eingeschränkt
 - Integration von Anomaly Detection (bestimmt Verfahren wie AutoEncoder lassen dies direkt auf Modellebene zu)



Privacy

- Beispiel:
 - Schutz von medizinischen Daten
- Herausforderungen
 - Zusammenführung unterschiedlicher Daten ohne gegenseitiges Vertrauen
 - Gemixte Verwendung von Cloud- und Edge-Ressourcen
- Lösungen
 - Encoding in einen Latenten-Space auf den Edge-Devices
 - Verwendung von Federated-Learning bei mehreren Teilnehmern



5G - Eingrenzung der möglichen Anwendungen

- Hochsicherheitsanwendungen
 - z.B. Unmittelbare Steuersysteme für autonome Fahrzeuge
 - Verwendung von Funktechnologie stellt oftmals keine Alternative dar
- Hochkapazitive Algorithmen mit hoher Ausführungszeit
 - z.B. State-of-the-Art NLP / Image Processing mit GPT-2/NASNet
 - Ausführung möglich, häufig keine entscheidenden Geschwindigkeitsvorteile durch 5G (relativ)
- Mittlere Modellgrößen mit Echtzeitanforderungen ohne hohe Sicherheitsanforderungen
 - z.B. AR Anwendungen oder Live-Übersetzungen
 - Einsatz von 5G ist optimal
 - Schnelle Modellausführung macht Geschwindigkeitsunterschiede sichtbar
 - Einsatz von Funktechnologien passt zur Sicherheitsanforderung



**We build AI-based systems.
Tamed for your business.
Wild enough for a revolution.**



www.tamed.ai | ole.meyer@tamed.ai