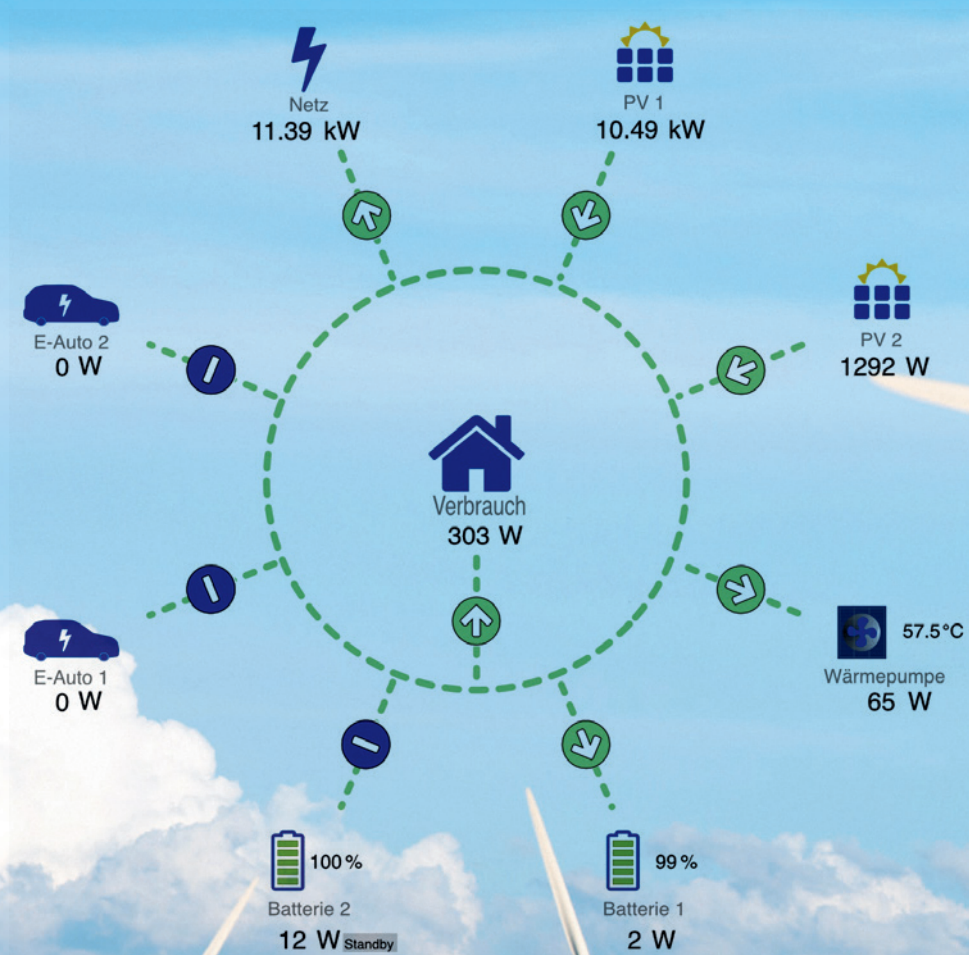


COMPETENCE CENTER HIGH PERFORMANCE COMPUTING





INNOVATION, DISRUPTION UND GANZHEITLICHES DENKEN IN DER WELT DES VERTEILTEN RECHNENS

Die Abteilung hat mit BeeGFS, Pre-Stack PRO, dem Global Address Space Programmiermodell (GPI) sowie dem Big Data Framework GPI-Space innovative, weltweit anerkannte Technologien zur Lösung von Large-Data-Problemen entwickelt. In den vergangenen Jahren haben wir diese Technologiebasis sehr erfolgreich mit Deep-Learning-Methoden kombiniert und internationale Sichtbarkeit gewonnen. Im Kern geht es dabei immer um die skalierbare automatische Parallelisierung von Big-Data-Problemen. Dahinter steht das Konzept des »Memory Driven Computing«, welches Skalierbarkeit und Performance zusammenbringt.

Wir engagieren uns in der EU-geförderten HPC-Forschung mit dem Ziel, europäische Technologien zu stärken und die Marktfähigkeit europäischer HPC-Softwareprodukte zu verbessern. Darüber hinaus ist es unser Anliegen, in Co-Design-Projekten die Mikroelektronikentwicklung und die Anwendungsentwicklung zusammenzubringen. Wir sehen in der anwendungsspezifischen Entwicklung von Compute Hardware einen Weg, Europas Position auf dem stark wachsenden HPC-/Big-Data-Markt zu verbessern.

Das Energiesystem der Zukunft wird aus Millionen von verteilten IoT-Rechnern bestehen. Diese optimieren den Eigenverbrauch von PV-Strom, regeln den Aufbau von Community Grids, steuern große und kleine Stromspeichersysteme und koordinieren den Energiefluss in unseren Energienetzen. In unseren Projekten entwickeln wir Technologien und Lösungen, um diese verteilte Rechnerwelt zu beherrschen. Dabei gilt unser Engagement intelligenten Lösungen, die die Energiewende voranbringen.

Kontakt

franz-josef.pfreundt@itwm.fraunhofer.de


www.itwm.fraunhofer.de/hpc



SCHWERPUNKTE

- Green by IT
 - BeeGFS – Parallel Cluster File System
 - Visualisierung
 - Seismische Datenverarbeitung
 - Datenanalyse und Maschinelles Lernen
 - Skalierbare parallele Programmierung
-





GASPILS UND DAS GPI-2 ECOSYSTEM: GPI-2 SKALIERBARKEIT UND PERFORMANZ LEICHTGEMACHT

1 *GaspILS liefert Skalierbarkeit für FEM- und CFD-Simulationen*

2 *Performance Plot: Skalierbarkeitsvorteile von GaspILS im Vergleich zu PetSC. Jacobi vorkonditioniertes Richardson-Verfahren; 3D-Poisson-Gleichung (2te Ordnung FD-Diskretisierung), kubisches Gitter (359³)*

Verteilte Systeme wie Hochleistungsrechner brauchen hoch effiziente skalierbare Applikationen, um eine gute Performanz zu erzielen. Skalierbarkeit ist hierbei ein Maß für die parallele Effizienz einer Implementierung und sagt letztendlich etwas darüber aus, ob man die zur Verfügung gestellten Ressourcen – wie zum Beispiel CPUs – effizient ausnutzt. Für die Implementierung dieser Applikationen eignet sich das im CC HPC entwickelte parallele Programmiermodell GPI-2 hervorragend.

Um die damit einhergehenden Vorteile direkt und ohne großen Aufwand für eine Vielzahl an Applikationen nutzbar zu machen, wurde GaspILS entwickelt, eine Bibliothek für skalierbare iterative lineare Löser. GaspILS kann von einer Vielzahl an neuen oder bereits existierenden Simulationsprogrammen, die letztendlich ein lineares Gleichungssystem lösen, direkt genutzt werden.


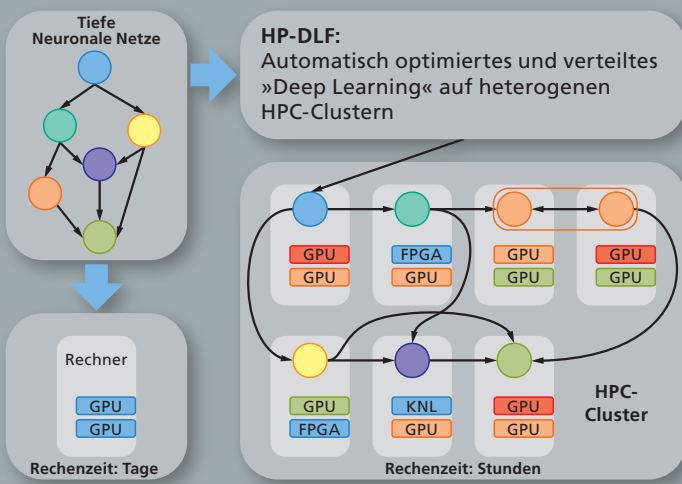
HySCALA sondiert neue Anwendungsfelder und Märkte für GaspILS

GaspILS hat sich bereits in mehreren Industrieprojekten bewährt. Seine weitere Vermarktung wird gegenwärtig im Zuge des EU-Projektes HySCALA (Hybrid SCALable sparse matrix Linear Algebra for industrial applications) gefördert. Ziel hierbei ist es, verschiedene potenzielle neue Marktsegmente und Anwendungsfelder für GaspILS zu analysieren und die spezifischen Anforderungen an eine kompetitive lineare Löserbibliothek zu identifizieren. Gesucht werden vor allem generische, aber dennoch effiziente Vorkonditionierer, die es erlauben, die Anzahl der benötigten Iterationen bis zur Konvergenz des iterativen Verfahrens zu reduzieren und damit die Gesamtlaufzeit für die Lösung zu minimieren. Momentan steht die skalierbare Implementierung solcher effizienten Vorkonditionierer, die auf eine breite Klasse an Problemen angewandt werden können, im Fokus.

Gaspicxx für mehr Produktivität

Innerhalb von GaspILS wurde die Implementierung für die explizite Verwaltung von Kommunikations-Ressourcen für den GPI-2-Datenaustausch abstrahiert und mit Gaspicxx auch für andere Anwendungen zur Verfügung gestellt. Gaspicxx definiert eine einfach zu nutzende C++-Schnittstelle. Die Verwaltung von GPI-2-Kommunikations-Ressourcen wird hierbei ohne Einschränkung der zugrundeliegenden Leistungsfähigkeit komplett von Gaspicxx übernommen. Die Anwendung muss sich nicht mehr darum kümmern. Damit fällt ein Großteil der normalerweise notwendigen Implementierungsarbeiten bei der Entwicklung von GPI-2-Applikationen weg. Die Entwicklung von GPI-2-Applikationen und das Ausnutzen der damit einhergehenden Vorteile – wie die gute Skalierbarkeit – war noch nie so einfach.





HPC FÜR MASCHINELLES LERNEN: HIGH PERFORMANCE DEEP LEARNING FRAMEWORK

Künstliche neuronale Netze haben sich in den vergangenen Jahren in vielen Bereichen des maschinellen Lernens durchgesetzt. So bilden sie beispielsweise auf dem Gebiet der Computervision, der Sprach- und Texterkennung als auch der maschinellen Übersetzung den Stand der Technik. Grund für ihren Erfolg ist u.a. ihre Fähigkeit, hochgradig komplexe Zusammenhänge zwischen rohen Eingabedaten und den klassifizierenden Ausgabedaten (den Labels) herstellen zu können.

Dafür benötigen sie häufig mehrere Millionen freie Parameter, die während des Trainings des Netzes verändert, d. h. gelernt werden. Die große Anzahl dieser sogenannten Gewichte führt allerdings dazu, dass das Training eines einzelnen neuronalen Netzes häufig mehrere Tage oder sogar Wochen dauern kann. Deshalb ist es wünschenswert, diese Algorithmen durch den Einsatz von Supercomputern stark skalierbar zu machen. Dies würde im Idealfall bedeuten, dass eine Verdopplung der Anzahl parallel geschalteter Computer zu einer Halbierung der Laufzeit des Algorithmus führen würde.

Kleine neuronale Netze oder wenige Dateien?

Ein weiteres Problem, auf das man mit neuronalen Netzen trifft, ist ihr großer Bedarf an Hauptspeicher. Das hat zur Folge, dass man auf einem einzelnen Rechner nur relativ kleine neuronale Netze trainieren kann, oder sich bei der Menge der zum Lernen verwendeten Daten beschränken muss. Weder das eine noch das andere ist erstrebenswert, weil die Kapazität, d.h. die Lernfähigkeit des Netzes, reduziert wird. Vielmehr ist es wünschenswert, mit der doppelten Anzahl an Rechnern auch Netze von doppelter Größe trainieren zu können. Dies bezeichnet man im Parallelen Rechnen als schwache Skalierbarkeit.

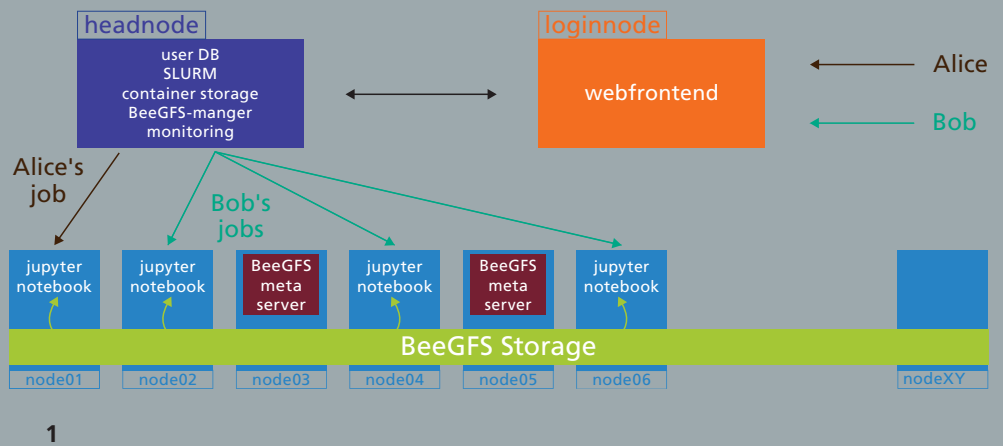
Hohe Skalierbarkeit mit GPI-Space

Sowohl schwache als auch starke Skalierbarkeit beim Training von neuronalen Netzen zu ermöglichen, ist Gegenstand des BMBF-Projekts »High Performance Deep Learning Framework« (HP-DLF). Wir sind dabei vor allem daran interessiert, neuronale Netze beliebiger Größe konstruieren zu können und einen einfachen Zugang zu existierenden und zukünftigen Hochleistungsrechnersystemen zu ermöglichen. Dabei wird von dem Benutzer keinerlei Kenntnis über Paralleles Rechnen vorausgesetzt. Dies realisieren wir mit unserem hauseigenen Laufzeitsystem GPI-Space. Dieses ermöglicht es, Algorithmen automatisch und dynamisch zu parallelisieren, wenn sie in Form eines speziellen Graphen, einem sogenannten Petri-Netz, dargestellt werden.

1 HPC ermöglicht Deep Learning ohne Speicher-grenzen.

2 Große Datenmengen spielen beim Autonomen Fahren eine besondere Rolle.





HPC FÜR MASCHINELLES LERNEN: CARMÉ

1 Vereinfachte Darstellung der wichtigsten Systemkomponenten und deren Verbindung untereinander

Maschinelles Lernen bildet einen immer größeren Schwerpunkt sowohl im wissenschaftlichen als auch im industriellen Bereich. Im Zuge dessen wird in neue, vor allem GPU-basierte Hardware investiert. Dabei reicht die Spanne von einfachen Desktoprechnern bis hin zu High Performance Computing Clustern. Rechencluster können dann dazu genutzt werden, noch größere Datenmengen in der Datenanalyse (DA) und hochkomplexe Systeme – bis hin zum menschlichen Gehirn – im Maschinellen Lernen (ML) zu simulieren und zu verarbeiten.

Maschinelles Lernen auf HPC-Clustern kann eine Herausforderung sein. Dabei stellt die reine Beschaffung der einzelnen Hardware-Komponenten noch die kleinste Herausforderung dar. Denn die größten Fragen ergeben sich im Anschluss:

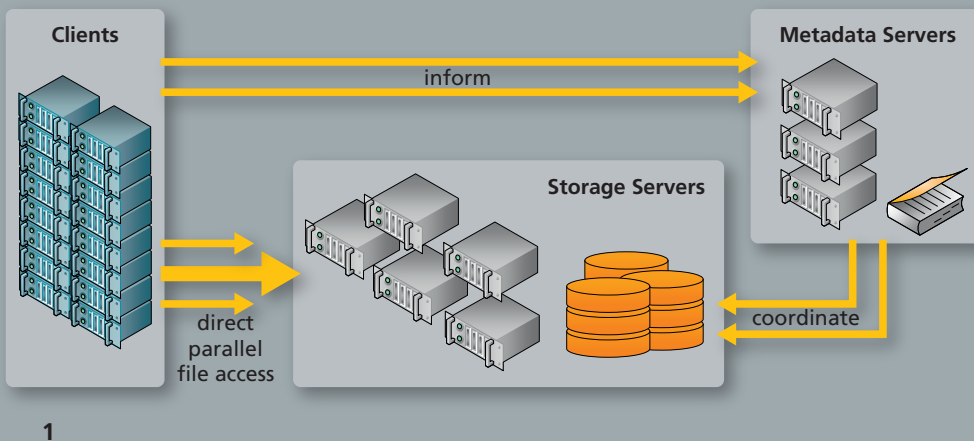
- Wie verwaltet man die vorhandenen Ressourcen?
- Wie kann man Anwendungen auf mehrere GPUs skalieren?
- Wie löst man die Herausforderung, Daten zu speichern und kontinuierlich in Anwendungen zu laden?
- Wie bringt man Nutzer dazu, die Hardware effektiv zu nutzen?

An dieser Stelle setzen wir mit unserem Open-Source Software-Stack Carmé an. Die Grundidee ist dabei, die Welt des Maschinellen Lernens und der Datenanalyse mit der Welt von HPC-Systemen zu kombinieren. Dazu nutzen wir auf der einen Seite etablierte ML- und DA-Werkzeuge und HPC-Backends. Im Detail verwenden wir dafür verschiedene HPC- und ML-Technologien. Einige dieser Technologien wurden in unserer Abteilung entwickelt, wie zum Beispiel das hochverfügbare und verteilte Dateisystem BeeGFS für eine schnelle Anbindung der Daten.

Carmé verbindet die Welt des Maschinellen Lernens und die von HPC-Clustern. ML ist ein stetig und schnell wachsender Bereich. Diese Agilität stellt Rechenzentren vor die Herausforderung, sehr unterschiedliche Anwendungen für einzelne Nutzer bereitzustellen. Somit reicht es nicht nur aus, für die Anwender eine Benutzeroberfläche zu haben, sondern man muss eine reibungslose Integration dieser Oberfläche in vorhandene und entstehende Cluster garantieren. Um Cluster für ML- und DA- Nutzer attraktiv zu machen, muss auf den Clustern eine intuitive Softwareumgebung bereitgestellt werden. Bei der Entwicklung von ML-Anwendungen ist eine interaktive Handhabung des Clusters entscheidend. Damit haben Nutzer die Chance, auf einem komplexen HPC-Cluster die Tools zu verwenden, die sie kennen, was ihnen den Umstieg und die Nutzung eines Clusters vereinfacht.



www.open-carme.org



BEEGFS – DAS DATEISYSTEM FÜR BIG DATA UND KI

Der Erfolg aktueller KI-Technologien wie neuronaler Netze basiert auf der gestiegenen Rechenleistung heutiger Prozessoren – meist GPUs – aber vor allem auf der Verfügbarkeit sehr großer Datenmengen. Neue medizinische Geräte, autonome Fahrzeuge und Genomanalysen liefern immer größere und feiner aufgelöste Daten in schneller Folge und damit die Basis für zukünftige KI-Lösungen. Das von uns entwickelte und von ThinkparQ vermarktete parallele Dateisystem BeeGFS hilft dabei, mit einer sehr flexibel einsetzbaren Software-Lösung der Datenmengen Herr zu werden.

1 BeeGFS-Architektur

BeeGFS ist ein paralleles Dateisystem, bei dem sowohl die Speicherkapazität als auch die Schreib- und Lesegeschwindigkeit mit der Anzahl der angeschlossenen Storage-Einheiten linear anwächst. Es ist eine reine Software-Lösung, die flexibel sowohl auf existierender Hardware als auch auf den neuesten superschnellen Flash-Speichersystemen installiert werden kann. Neben der sehr guten Skalierbarkeit des Systems legt unser Entwicklerteam großen Wert auf eine unkomplizierte Handhabung und ein hohes Maß an Flexibilität bei den potentiellen Einsatzszenarien.


Zwischenspeicherung entfällt

Beim Training tiefer neuronaler Netze (Deep Learning) müssen darüber hinaus die vorhandenen Daten mehrfach sehr schnell den Compute-Einheiten zur Verfügung gestellt werden. Dafür sind die meisten externen Speichersysteme kaum geeignet und die Daten werden direkt in den Computerservern auf schnellen lokalen Systemen (NVMe) zwischengespeichert. Da deren Kapazitäten recht klein sind, ergibt sich hier auch die Notwendigkeit, die Daten parallel auf mehrere Einheiten zu verteilen. Das BeeGFS-Softwaresystem ist speziell für hohe Geschwindigkeitsanforderungen auch bei sehr vielen Dateien optimiert und kann hier seine Stärken ausspielen. So kann BeeGFS direkt auf den Computerservern installiert werden und skaliert bis zu hohen I/O-Geschwindigkeiten von 1 TByte/sec und mehr. Dies hat auch japanische KI-Forscher überzeugt: BeeGFS wird jetzt auf den beiden großen japanischen KI-Systemen TSUBAME 3,0 (HPE) und AI Bridging Cloud Infrastructure (ABCI, Fujitsu) erfolgreich eingesetzt.

Open-Source-Lizenz


Die Software wird unter einer Open-Source-Lizenz vertrieben; die Quelldateien können auch von der BeeGFS Website bezogen werden. Unser Spin-off ThinkparQ bietet weltweit kommerziellen Support für BeeGFS an und steuert die weitere Entwicklung aus Kundensicht. Das gemeinsame Entwicklerteam bringt sein umfangreiches Wissen auch in mehrere EU-Projekte ein, in denen es um die Nutzung von BeeGFS auf zukünftigen Exascale-Rechnersystemen geht.





1

1 Ausschnitt aus dem aus seismischen Daten errechnetem Untergrundabbild; Farbspots zeigen Orte hoher Wahrscheinlichkeit für das Vorliegen von Felsbrocken an.



2

2 Illuminationsdarstellung eines Untergrundbereiches, für den ein Felsbrocken identifiziert wurde; das Fadenkreuz liegt im Symmetriezentrum des identifizierten Musters und zeigt die laterale Position des Felsbrockens in 73 m Tiefe an.

BOULDER-DETECTION MIT MACHINE LEARNING

Die Pfeiler der Windräder von Offshore-Windparks müssen tief in den Schichten unterhalb des Meeresbodens verankert werden. Große Gesteinsbrocken stellen dabei Hindernisse dar, die man vorab erkennen muss, um die exakte Positionierung der Windräder zu planen. Die seismischen Datensätze, die zur allgemeinen Standsicherheitsbestimmung gemessen werden, reichen hier nicht aus. Mit neuen Machine Learning-Methoden können wir Muster im Untergrund schneller detektieren und klassifizieren.

Bisherige Auswerteverfahren der seismischen Datensätze enthüllen zwar die Gesteinsschichtungen des Untergrundes, weisen allerdings einen zu geringen Frequenzgehalt auf, um Felsen im Bereich von 1 m Durchmesser als reflektierende Objekte erkennen zu können. Deshalb müssen die Amplitudenschwachen Diffraktionsantworten ausgewertet werden.


Mustererkennung in Untergrundabbildungen

In einem vom Bundesministerium für Wirtschaft und Energie geförderten Projekt haben wir mit Kollegen vom Fraunhofer-Institut für Windenergiesysteme IWES einen Prozess entwickelt, der diese Diffraktionen in ein typisches Muster in seismischen Untergrundabbildungen überführt. Die Aufgabe, diese Muster oder Diffraktionsobjekte zu erkennen, ist vergleichbar mit der Zuweisung von Pixeln in Photographien zu Objektklassen, wie sie mithilfe tiefer neuronaler Netze möglich ist.

Unser Anwendungsfall beinhaltet ein wesentlich höher-dimensionales Problem, da bereits bei 2D-Untergrundabbildungen zwei weitere Dimensionen hinzukommen: die Beleuchtungsrichtung und die Abhängigkeit vom für die Bilderstellung verwendeten Geschwindigkeitsmodell. Des Weiteren ist der Erduntergrund nicht der direkten Anschauung zugänglich, sodass die Netzwerke anhand realistisch verfremdeter synthetischer Daten trainiert werden müssen.

Anwendernutzen: Reduzierte Datenmenge

Die Anwendungsergebnisse zeigen, dass das Transfer-Learning von synthetischen zu realen Daten gelingt und dass unsere aus einer Vielzahl von Convolutions-Schichten bestehenden Netzwerke die notwendige Komplexität aufweisen, um auch in verrauschten Untergrundabbildungen Wahrscheinlichkeiten für das Vorhandensein von Störobjekten mit einer räumlichen Auflösung von 1 m zu errechnen. Der Nutzen für den Anwender ergibt sich damit aus der erheblichen Reduktion der Menge an Daten aus dem gesamten hoch-dimensionalen Datensatz, die er selbst interpretieren muss.



1



2

CHARGE BIG – ENTWICKLUNG EINER NEUARTIGEN LADEINFRASTRUKTUR FÜR ELEKTRO-FAHRZEUGE

Im Projekt chargeBIG entwickeln wir gemeinsam mit der MAHLE-Gruppe und der eliso GmbH eine neuartige Ladeinfrastruktur für Elektrofahrzeuge. Sie ist kosteneffizient, hochskalierbar und gleichzeitig netzdienlich. Ziel ist es, Parkhäuser möglichst kostengünstig im großen Stil zu elektrifizieren, also alle Parkplätze eines Parkhauses mit einer Lademöglichkeit auszustatten.

Mit konventioneller Technik ist dies sehr teuer und Betreiber von Parkhäusern entscheiden sich gegen die vollständige Elektrifizierung. Stattdessen weisen sie einige Parkplätze mit nur dort installierten Ladesäulen für Elektroautos aus; meist mit dem Nachteil, dass bereits geladene Fahrzeuge die Ladestation versperren.

Ladeinfrastruktur für alle Parkplätze

Hier setzt das chargeBIG-Konzept an: Statt teure Komponenten an wenigen Parkplätzen zu installieren, werden die notwendigen technischen Komponenten an einer zentralen Stelle zusammengefasst und am jeweiligen Parkplatz nur eine Säule mit Ladekabel aufgebaut. Die an jedem Parkplatz notwendigen Komponenten sind auf ein Minimum reduziert. Die Zentralisierung bietet sowohl bei den Herstellungs- als auch bei den laufenden Wartungskosten erhebliche Vorteile, wodurch möglichst alle Parkplätze günstig elektrifiziert werden.

Parkhaus dient als Reallabor


Auf Basis dieses Konzepts entwickelte MAHLE gemeinsam mit dem ITWM bereits einen chargeBIG-Prototypen mit 18 Ladepunkten. Dieser dient als Blaupause für einen Demonstrator mit 108 Ladepunkten, welcher in einem MAHLE-Parkhaus in Stuttgart aufgebaut wird. Das Parkhaus ist gleichzeitig ein Reallabor zur Erprobung des netzdienlichen Betriebs. Neben der Ladeinfrastruktur werden daher auch ein Batteriespeichersystem, eine DC-DC-Schnellladestation (d.h. das Laden eines E-Fahrzeugs mit Gleichspannung direkt aus einer stationären Batterie) und eine Fotovoltaikanlage installiert.

Das in der Green by IT-Gruppe entwickelte Energiemanagementsystem Amperix optimiert den Einsatz der Komponenten, mit Blick auf die Steigerung der lokalen Eigenversorgung, der Absenkung von Spitzenlasten (Peak-Shaving) und der Nutzung flexibler Strompreise. Das Projekt chargeBIG wird gefördert durch das »Sofortprogramm Saubere Luft« des Bundesministeriums für Wirtschaft und Energie. In der wissenschaftlichen Begleitforschung durch das ITWM wird außerdem der Beitrag des Projekts zur NOX-Emissionsminderung in der Stadt Stuttgart analysiert und bewertet.

1 Rendering der chargeBIG-Ladeinfrastruktur; die Ladesäulen sind mit der chargeBIG-Zentrale verbunden.

2 Links: Ladesäule mit Ladestecker, rechts: Prototyp der chargeBIG-Zentrale für 18 Ladepunkte





NEWS AUS DER ABTEILUNG

EPEEC: EUROPEAN JOINT EFFORT TOWARDS A HIGHLY PRODUCTIVE PROGRAMMING ENVIRONMENT



Das Ziel des im Oktober gestarteten Projektes ist die Entwicklung einer parallelen Programmierumgebung für heterogene Supercomputer. Wir erweitern unser verteiltes Programmiermodell GPI, um Maschinelles Lernen besser zu unterstützen, indem wir anwendungsspezifische Datenkompressionsalgorithmen bereitstellen und die Anforderung an die Konsistenz lockern. Heutige Programme beruhen auf einer konsistenten Sicht globaler Eigenschaften, was eine Synchronisation zwischen verteilten Rechenknoten voraussetzt und einen limitierenden Faktor für die Skalierbarkeit darstellt. GPI dagegen ermöglicht EPEEC die Herausforderungen zum Erreichen von Exascale zu bewältigen.

AUTARKE ENERGIEVERSORGUNG DANK AMPERIX®



Im Microgrid Schoonschip, einer Wassersiedlung nördlich von Amsterdam, bilden 30 Häuser eine Energieeinheit, die ihren Strom mittels Solarenergie weitgehend selbst erzeugt und die Energie mit Wärmepumpen und Batterien auch selbst speichert. Die Häuser sind untereinander vernetzt, verfügen aber auch über einen Anschluss an das kommunale Stromnetz. Koordiniert wird die Stromversorgung von unserem Energiemanagementsystem Amperix®. Neben der Steuerung der Stromspeicher implementieren wir hier auch eine Sektorenkopplung.

AUTOMATISIERTE DATENANALYSE MITTELS MASCHINELLEN LERNENS: DEEP TOPOLOGY LEARNING (DETOL)

Deep-Learning-Verfahren sind in vielen Bereichen etabliert, bedürfen aber eines intensiven Trainings. Die dafür eingesetzten künstlichen neuronalen Netze benötigen große Datenmengen sowie enorme Rechenleistung. Ziel des seit Juni laufendes Projektes DeToL ist es, den Entwurfsprozess für Deep-Learning-Lösungen durch automatische, datengetriebene Entwurfsalgorithmen entscheidend zu beschleunigen und zu vereinfachen.

Wir bauen das HPC-Framework, realisieren die Parallelisierung der benötigten Algorithmik und stellen es anschließend zum Testen der Methodik zur Verfügung. Dabei greifen wir u. a. auf unsere Erfahrungen aus dem BMBF-Projekt HP-DLF zurück, in dem wir ein skalierbares Deep Learning Framework für HPC-Systeme entwickeln. (s. Seite 91)



Von vorne, links nach rechts: Sabine Müller, Kalun Ho, Dr. Somnath Madzumdar, Dr. Rui Machado, Dr. Alexandra Carpen-Amarie, Avraam Chatzimichailidis, Dr. Abel Amirbekyan, Dr. Dimitar Stoyanov, Peter Michael Habelitz, Dr. Tiberiu Rotaru, Valentin Tschannen, Dr. Matthias Balzer, Sebastian Schumb, Kai Krüger, Frauke Santacruz, Dr. Norman Ettrich, Matthias Klein, Javad Fadaieghotbi, Bernd Lörwald, Dominik Loroeh, Mikita Vedzeneyeu, Dr. Valeria Bartsch, Dr. Franz-Josef Pfreundt, Dr. Mirko Rahn, Delger Lhamsuren, Dr. Alexander Janot, Bernd Lietzow, Dr. Martin Kühn, Ricard Durall Lopez, Raju Ram, Lukas Ristau, Dr. Peter Labus, Christian Mohrbacher, Matthias Deller, Dr. Dirk Merten, Dr. Dominik Straßel, Julius Roob, Dr. Roman Iakymchuk, Dr. Alexander Klauer, Philipp Reusch, Dr. Janis Keuper, Patrick Reh