

【社内事例】 NVMe™/NVMe-oF™による機械学習、ディープラーニング処理の効果について

背景

フラッシュメモリは、SLC->MLC->TLC->QLCと高密度化することでメモリセル毎の記憶容量が大きくなりました。さらに、メモリの多層化技術によって大幅に集積度が高まり、大容量化が進んでいます。いっぽう、大容量化の一途を辿るフラッシュメモリの信頼性を維持、向上させるには様々な技術の蓄積が必要になっています。例えば、ECC(Error Correcting Code)はフラッシュメモリにおけるデータの信頼性を維持するために重要な技術のひとつです。ECCはメモリ動作中に起こり得る様々なエラーを訂正し回復させるため、エラーの発生を意識させません。

キオクシアは、既存のECC技術に加え、進化した信頼性アルゴリズムを併用することで、より信頼性の高いECCアルゴリズムを開発しています。キオクシアでは、さらにノンリニア(非線形)型のニューラルネットワークモデルに基づいてより精度の高い信頼性アルゴリズムを開発し、当社メモリ使用時の性能や信頼性を更に高次元なものへ引き上げようとしています。

現状の問題点と解決の方向性

ニューラルネット型の信頼性アルゴリズムを開発し最適化するには、できるだけ多くのデータ(メモリ使用の実績パターン)と、データを解析しフェーズごとに異なるアルゴリズムをデータベースに蓄積することが必要です。キオクシアの信頼性アルゴリズム開発チームは、データの解析とアルゴリズムの最適化に必要なデータベースを作成するインフラストラクチャとして、一般的なx86系CPUサーバとNAS型のファイルサーバを1Gbイーサネットのネットワークで構築しました。解析作業のためにはネットワーク越しにジョブを投入してきたのです。

ところが、このインフラストラクチャでは、データの転送時間がボトルネックになり、解析精度を向上するのに長い時間がかかります。また、1種類のデータを多く解析してもアルゴリズムの精度を向上させるのは難しいため、1パスごとのデータを大容量にしたうえで連続的に解析することが必要でした。従来の手法では大量のデータを使っても、アルゴリズムの精度の向上には限界があったのです。

調査の結果、近年発展著しいDeep Learning(深層学習)をGPUを使って展開することでx86ベースのCPUによるサーバに対してトレーニングの速度を上げることができるとわかりました。Deep Learningでは、学習に用いるデータが増えるにしたがって、精度が著しく改善されます。学習データの収集のため、並列で80-100種類ものデータを解析するプロセスが実行され、同数のデータベースを生成しますが、結果として全体で数百万通りのパラメータサンプルを蓄積するデータベースの大きさは、1TBもの大きさになります。

また、Deep Learningでは、学習に用いるデータベース全体を繰り返しアクセスします。Deep Learningトレーニングによる精度の高いアルゴリズムを生成するには、演算性能が高いGPUをいかに効率的に運用できるか — 連続的にGPUへデータを供給できるか — が重要です。

キオクシアの信頼性アルゴリズム開発チームはまず、NVMe™ SSDを高速ブロックストレージとしてGPUサーバに直接接続し、これを解決しようとしていました。しかし、NVMe™ SSDの単体容量は限られており、それを超える容量のデータでトレーニングをするには、GPUによる処理を中断して、SSD容量にあわせて解析データを分ける必要がありました。また、NASからGPUサーバへデータを転送したり、データベースを格納するためにネットワークの転送速度がボトルネックになっていました。このため、高価なGPUを四六時中稼働させることが難しく、アルゴリズムの最適化にかかる時間を大幅に短縮するまでには至っていませんでした。

NVMe™ SSDとKumoScale™による解決策

キオクシアの信頼性アルゴリズム開発チームでは、高速なブロックストレージと共有ファイルシステムを同時に運用できることを重要な要件として掲げ、これらを解決するストレージ技術としてNVMe™による高速性を挙げました。また、DAS型接続ストレージに比べストレージをGPUに対して柔軟かつ効率的にアロケートできるNVMe-oF™や、複数GPUからデータに同時アクセスできるように共有ファイルシステムを運用することも検討していました。

ブロックストレージに関する要件

- SSD同等の速度で大容量データをトレーニング用アプリケーションに読み込めること
- データセットの大きさに応じて必要な仮想ブロックストレージを柔軟に割り当てられること
- プリ/ポストの分析処理に使用できること

共有ファイルシステムに関する要件

- トレーニング処理に必要な高速パフォーマンス
- すべてのGPUサーバからアクセスできる共有ファイルシステム
- データを複製することなくDeep Learning処理を複数のGPUサーバで分散して行えること
- 解析前後の処理にも利用できること

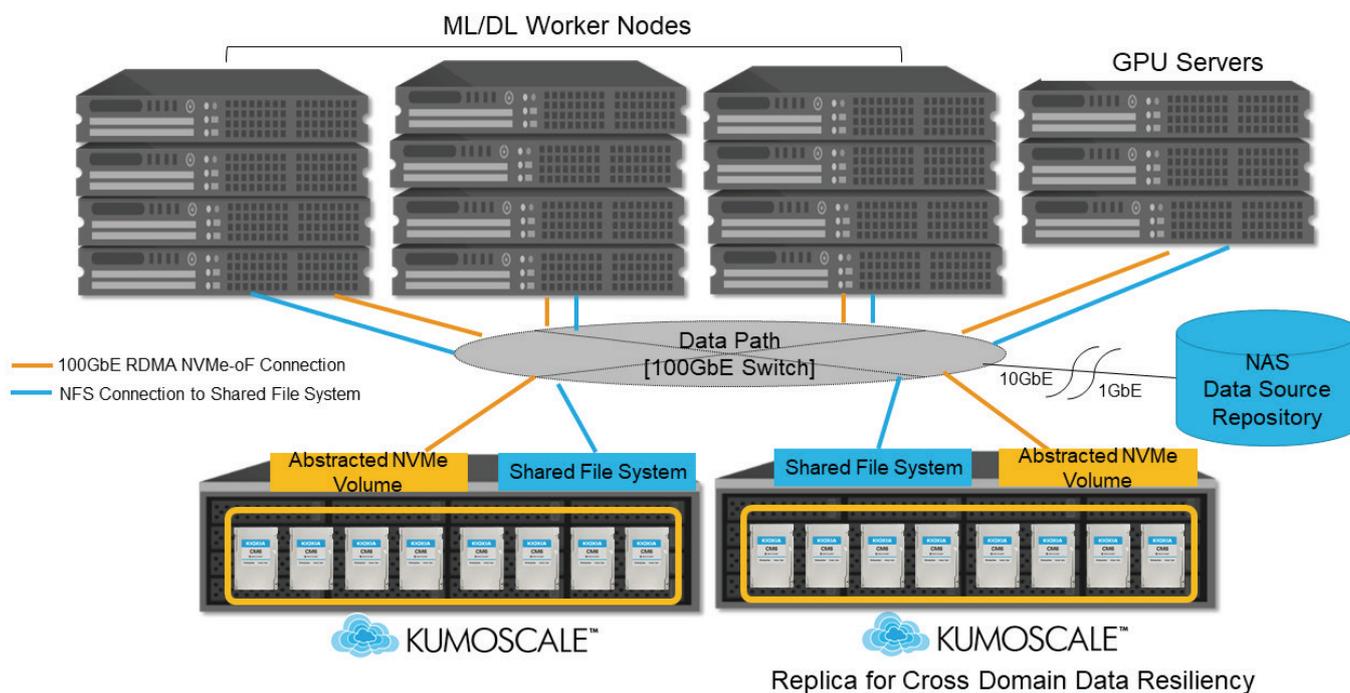
さらに、NVMe-oF™によるネットワーク接続の高速化にも注目し、イーサネットを用いた100Gbイーサネットのネットワークと高速なネットワーク転送プロトコルを採用することも要件に挙げました。

主要なコンポーネント・技術

- Deep Learning用GPUサーバ（100Gbデュアルポートイーサネット、RoCEv2ネットワークプロトコル）
- ネットワークスイッチ（データパス100GB/s冗長構成、コントロールパス1GB/s）
- NVMe-oF™ストレージシステム
 - KumoScale™ストレージノード
 - » NVMe-oF™接続（100GB/sデュアルポートイーサネット、RoCEv2ネットワークプロトコル）
 - » バーチャルブロックストレージ
 - » Cross Domain Data Resiliency（データプロテクション）2レプリカ
 - » 共有ファイルシステム（NFS – GlusterFS）

キオクシアNVMe™ SSD 3.2TB（Total of 150TB）

システム構成図



導入効果と今後の展望

キオクシアのNAND信頼性開発チームによると、DAS接続型のNVMe™ SSDおよびNASを使用していた従来型システムに比べ、トレーニング処理に使用するデータをGPUシステムに投入する時間が大幅に軽減されたとのこと。さらに、学習させるデータベース作成まで含めると、約1週間を要していたこれまでのサイクルが、今回のKumoScale™ストレージシステム導入によりほぼ1日で完了するようになったとのこと。

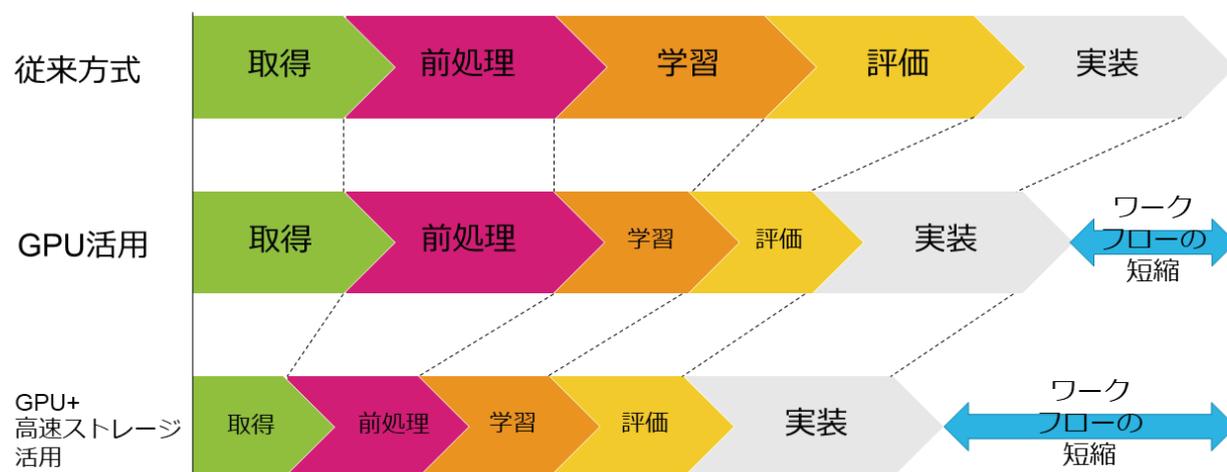
また、複数のGPUを使用したトレーニング処理は、KumoScale™ストレージシステム上に共有ファイルシステムを構築することでデータの複製を行うことなく実施できており、当初の目標通り効率よく行えています。

一方、解析するデータセットが増加しており、四半期平均で約15TBのストレージ容量の増強が必要になっていることも判明しました。解析するデータセットの大きさに応じ、KumoScale™ストレージシステムから、ワーカーノードに切り出す仮想ブロックストレージや共有ファイルシステムの容量変更をより頻繁に行う必要もあります。

解析したデータやトレーニングデータはNASにアーカイブしていますが、新しいNANDデバイスの開発に応じてこれらのアーカイブデータを機動的に利用することも今後の課題です。キオクシアのNAND信頼性開発チームとKumoScale™ソフトウェアの開発チームが協力しこれらの課題に取り組んでいます。

高速ストレージの活用で期待される効果: ワークフロー処理時間の比較

- GPUおよび高速ストレージを活用することで、機械学習ワークフローの広い範囲での改善が可能となる。



*NVMeおよびNVMe-oFは、NVM Express, Inc. の米国またはその他の国における登録商標または商標です。

*その他記載されている社名・商品名・サービス名などは、それぞれ各社が商標として使用している場合があります。