

深層学習を用いたD2Dキャッシュ制御方式

Device to Device Caching Method using Deep Learning

常清 瞳与¹ 上山 憲昭²

Makoto Tsunekiyo Noriaki Kamiyama

福岡大学大学院 工学研究科 電子情報工学専攻¹

Graduate School of Engineering, Fukuoka University

立命館大学 情報理工学部²

College of Information Science and Engineering, Ritsumeikan University

1.はじめに

移動端末で動画を視聴する形態が一般化したこと、セルラネットワーク(CN: cellular network)のバックホールのトラヒック負荷の急激な増大が懸念されている。バックホールの負荷を低減するため、基地局に設けられたキャッシュから動画コンテンツを配信するモバイルエッジコンピューティングが注目されているが、さらに負荷を軽減する方式として、移動端末(MT: mobile terminal)でコンテンツをキャッシュしてD2D(device-to-device)通信で配信することが有効である。しかしMTのキャッシュ容量は有限であるためMTの移動経路上で高い需要が見込めるコンテンツを優先的にキャッシュすることが有効である。そこで本研究では、[1]で提案されている深層学習を用いてコンテンツの需要を推定することをD2Dキャッシュ配信に応用し、深層学習のアルゴリズムの一つである長短期記憶(LSTM: long short-term memory)ニューラルネットワークを用いて、移動経路上の他のMTが要求する可能性の高いコンテンツを推測し、MTにキャッシュするコンテンツを選択する方式を提案する。そして著名映画10タイトルに関するキーワード検索回数の時系列データを用いて、学習用・テスト用の時系列データを作成し、提案方式の需要推定部分の有効性を確認する。様々な場所、様々なコンテンツに対し個別に学習モデルを構築することは困難なことから、ある場所・あるコンテンツに対して作成した学習モデルを汎用的に様々な場所・コンテンツに適用できることが望ましい。そこで異なる地点の実際の映画の検索回数の時系列データに対しLSTMを適用し、ある地点のデータを用いて構築した学習モデルの汎用性を確認する。

2.LSTMを用いた動画コンテンツの需要量推定

時間に固定長のTime Slot(TS)に分割した後、地域の最小エリア(町、市、区などの単位となる地域を表し、以下、DMA(Designated Market Area)と呼ぶ)の各TSにおいて発生した各コンテンツの視聴回数の時系列データから、各DMAの各コンテンツの要求数の時系列データセットを作成する。そしてLSTMを用いて作成した時系列データセットを対象に学習を行い、各都市 c のTS t におけるコンテンツ m の要求発生数 $\hat{x}_{c,m}(t)$ を予測する。

3.評価条件

本稿では、著名な10個の映画のタイトルをキーワードとした検索回数の時系列データを、各映画の視聴回数の時系列データの代わりに用いる。Google Trendsの提供するAPIを用いて、アメリカのカリフォルニア州(CA: California)とニューヨーク州(NY: new york)のDMA(市町区)それぞれある1箇所における著名映画10タイトルに関するキーワード検索回数を取得した。尚、調査期間を公開日から100日間とし、さらに各日の8分毎の検索回数を全てのデータの最大値を100とし、それ以外は最大値に対する比率を設定するように正規化した正規化検索回数を使用した。また、TS一つを8分とし、入力データ x は連続する x タイムスロットの正規化検索回数、出力データ y を $x+1$ 番目のタイムスロットの正規化検索回数とする。今回は $x=5$ として、各州、DMA、映画タイトルに対し、時系列データセット (x, y) を作成する。尚、入力と出力のTSが次のデータでは一つずつシフトするように作成する。学習に使用するデータを各映画タイトルの公開日から99日間とし、残りのおよそ1日分を評価データとなるようにデータセットを分割した。

データセットを学習する際のLSTMのハイパーパラメタを隠れ層の数を15、バッチサイズを55、エポックタイムを100、活性化関数をlinear関数、損失関数を平均二乗誤差、最適化アルゴリズムをRMSpropに各々設定して学習を行った。また、本研究では予測モデルの評価を測る指標として次式で与えられる平均絶対誤差(MAE: mean absolute error)を採用した。MAEは各TSにおける実測値 y_i と予測値 \hat{y}_i^p の差の絶対値の総和で

構成され、0に近いほど高精度な予測ができていることを表す。

$$MAE(y_i, \hat{y}_i^p) = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i^p| \quad (1)$$

4.性能評価

作成した時系列データセットに対してLSTMを適用し、測定された予測値と実測値の比較により提案方式の需要推定部分の有効性を評価する。また、学習モデルの汎用性をCAおよびNYの学習データで構築した学習モデルに対して、CAおよびNYの両方で作成したテストデータを与えた時のMAEを各々比較することで評価する。

図1はNYにおけるAladdinで作成したデータセットに対してLSTMを適用した時の各TSでの予測値と実測値をプロットしたグラフである。グラフの縦軸は正規化検索回数、横軸は時間を表している。各TSの予測値と実測値の誤差に着目すると、最大2.5回程度の誤差が散見されるものの、測定期間全体で見るとおおよその人気傾向は掴めていることから、提案方式の需要推定部分の有効性が確認できる。

図2はCAおよびNYの各映画のテストデータを与えた時のMAEを算出し、1つの学習モデルに対して与えるテストデータを10タイトル分変化させた時のMAEの平均値を示す。グラフの縦軸は10個のテストデータにおける平均MAE、横軸は学習で使用した映画タイトルを表している。図2上部の緑線と赤線はそれぞれCAで作成したテストデータに対して適用する学習モデルをNYとCAのデータで構築したものと変化させた場合のMAEの平均値の推移であり、どのタイトルに関しても誤差は最大0.05以下に抑えられている。図2下部の青線と橙線はNYのテストデータに対して同様の操作を行った場合のグラフであり、先程と同様にどのタイトルに関しても誤差は最大0.05以下に抑えられていることが分かる。以上のことから、異なる地点および映画タイトルにおけるテストデータと学習モデルの依存関係は低く、CAあるいはNYの映画タイトルの近い将来の需要推定にNYあるいはCAのどちらの学習モデルでも適用可能と言える。したがって、学習モデルの汎用性を示している。




図1: LSTMによる予測値と実測値の比較(Aladdin(NY))



図2: 学習モデルの汎用性

謝辞本研究成果は、KDDI財団研究助成寄付金190051の助成を受けたものである。ここに記して謝意を表す。

参考文献

- [1] Arvind Narayanan, Saurabh Verma, Eman Ramadan, Pariya Babaie, and Zhi-Li Zhang, Making Content Caching Policies ‘Smart’ using the DeepCache Framework, Volume 48 Issue 5, October 2018.