

Modelo de *Machine Learning* para processamento de *Big Data* em *Fog Computing* aplicada à *Smart Cities*

Matteus Vargas¹, Luiz Fernando Bittencourt¹

¹Instituto de Computação – Universidade Estadual de Campinas (Unicamp)
CEP 13083-852 – Campinas – SP – Brazil

vargas.simao@gmail.com, bit@ic.unicamp.br

Abstract. *The massive spread of IoT devices, wich generate large amounts of data, has created many "smart environments". Although more convenient, Cloud can run into limited power, low bandwidth, or high latency issues. Including distributed learning algorithms in this case acting on devices or on network edge layers such as Fog Computing may be an alternative to address these issues. This concept can be extended to Smart Cities on a larger scale. This paper proposes a distributed learning model implemented in Fog Computing aimed to partition data of a mobile user, process, aggregate and return a response, with lower bandwidth and latency usage.*

Resumo. *A difusão maciça de dispositivos de IoT, geradores de grande quantidade de dados, tem criado muitos "ambientes inteligentes". Apesar de mais conveniente, a Cloud pode esbarrar nas questões de energia limitada, pouca largura de banda ou alta latência. A inclusão de algoritmos de aprendizado distribuído atuando nos dispositivos ou em camadas na borda da rede, como Fog Computing, pode ser uma alternativa para enfrentar essas questões. Esse conceito pode ser estendido para as Smart Cities, em uma escala maior. Este trabalho propõe um modelo de aprendizado distribuído implementado em Fog Computing que visa particionar os dados de um usuário móvel, processar, agregar e devolver uma resposta, com menor uso de largura e banda e menor latência.*

1. Introdução

A difusão de dispositivos de IoT tem criado muitos "ambientes inteligentes"[Vincentelli 2015]. Esses dispositivos são geradores de dados, assim enormes quantidades de dados serão geradas na borda da rede e conhecimento deve ser extraído disso. A *Cloud* pode parecer a solução mais conveniente para a análise em IoT, com alto volume, velocidade e heterogeneidade. Contudo, a transmissão de todos os dados para a *Cloud* esbarra em energia limitada [Valerio et al. 2017], largura de banda ou alta latência [Stolpe 2016].

Os aplicativos com restrição de comunicação requerem algoritmos de análise distribuídos que, em parte, trabalham diretamente nos dispositivos que geram os dados, como sensores e dispositivos incorporados ou encaminhando para camadas anteriores como a própria *Fog Computing*, na borda da rede [Garcia Lopez et al. 2015].

Cenários onde as análises calculadas sobre esses dados podem ser relevantes apenas por um curto período de tempo e em locais específicos, não é preciso grandes movimentações de dados, evitando desperdício de largura de banda. Essa abordagem visa

cenários limitados, mas pode vir a ser estendida para as *Smart Cities* [Valerio et al. 2017]. Este trabalho propõe um modelo para particionamento dos dados em *Smart Cities* com aplicação de aprendizado distribuído focado em usuários móveis.

2. Metodologia

Foi aplicada uma revisão bibliográfica que contempla a delineação do cenário e a problemática. O intuito foi procurar na trabalhos que explorem a aplicação de *Machine Learning* (ML) Distribuído para análise de *Big Data* em Ambientes de *Smart Cities*. Por fim, foram filtrados trabalhos que fossem de 2017 em diante, focado em artigos. A *string* ficou da seguinte forma:

- "smart city"AND "distributed learning"

As bases escolhidas foram a *Scopus*, *IEEE*, *ACM*, *Science Direct* e *Springer*. Foram feitas a checagem de duplicidades e a análise de título e *abstract*, fechando com 21 (vinte e um) artigos. Isso foi o bastante para identificar questões a serem trabalhadas.

3. Proposta

A análise dos artigos trouxeram questões em aberto [Stolpe 2016]. A principal é como manter a eficiência de comunicação, preservando ao mesmo tempo a precisão de seus equivalentes centralizados e consumindo menos largura de banda? Quanta informação deve ser no mínimo comunicada para aprender com êxito com os dados particionados? Como definir "hiper parâmetros" para que não haja conflitos ou repetições de dados?

A proposta aqui é utilizar a camada de *Fog Computing* para realizar o aprendizado distribuído, com mais recursos computacionais (*Cloudlets*), visando escalar para uma *Smart City*, com a premissa de que os dados podem ser quebrados e processados separadamente com ML distribuído na borda da rede [Valerio et al. 2017].

O destaque fica por conta dos usuários móveis. Enquanto eles se movem, as *Cloudlets* ao longo do trajeto capturam partes dos dados, processam, agregam e dão respostas. A princípio, as métricas possíveis de serem avaliadas aqui, do ponto de vista de rede, são o uso da largura de banda e a latência. A busca por métodos de ML Distribuídos mais adequados e a definição se a proposta será implementada ou simulada, bem como as ferramentas necessárias para ambos os casos, são passos futuros.

Referências

- Garcia Lopez, P., Montresor, A., Epema, D., Datta, A., Higashino, T., Iamnitchi, A., Barcellos, M., Felber, P., and Riviere, E. (2015). Edge-centric computing: Vision and challenges. *ACM SIGCOMM Computer Communication Review*, 45(5):37–42.
- Stolpe, M. (2016). The internet of things: Opportunities and challenges for distributed data analysis. *ACM SIGKDD Explorations Newsletter*, 18(1):15–34.
- Valerio, L., Passarella, A., and Conti, M. (2017). A communication efficient distributed learning framework for smart environments. *Pervasive and Mobile Computing*, 41:46–68.
- Vincentelli, A. S. (2015). Let's get physical: Adding physical dimensions to cyber systems. In *2015 IEEE/ACM International Symposium on Low Power Electronics and Design (ISLPED)*, pages 1–2. IEEE.