

An Evolutionary Approach for Video Application Energy Consumption Estimation in Mobile Devices

Irander O. de Amorim

Jose F. V. de Melo*

irandironofre5@gmail.com

flavioedez@hotmail.com

Universidade de Pernambuco (UPE)

Garanhuns, Brasil

Andson M. Balieiro

Universidade Federal Rural de

Pernambuco(UFRPE)

Departamento de Computação (DC)

Recife, Brasil

andson.balieiro@ufrpe.br

Bruno B. dos Santos

Universidade de Pernambuco (UPE)

Garanhuns, Brasil

bruno-barboza@outlook.com

ABSTRACT

In the last years, the multimedia traffic has increased significantly and the mobile devices (e.g. smart phones and tablets) have been widely used to consume this content type. Video applications demand high energy consumption of the device because they perform complex operations and deal with a large data amount. Although hardware improvements in the mobile devices have been achieved, the advances in battery technology have not kept the same pace. In this respect, the combination of video applications with the limited battery capacity of the mobile devices has challenged the academia and industry in the development of techniques for energy management and provision of quality of experience (QoE) to the user. Energy consumption estimation models may assist these techniques, as well as, the decision made process when the computational offloading from the mobile device to the cloud is considered. This paper presents an evolutionary approach based on Genetic Algorithms (GAs) and Swarm Particle Optimization (PSO) for energy consumption estimation in mobile devices running video applications. The proposal is directly applicable to different model types (linear and non-linear ones), without the linearization cost, and it is evaluated in terms of mean squared error (MSE), using energy consumption measurement data of videos with different configurations. Results show the superiority of our proposal in comparison to the literature that adopts the Ordinary Least Squares method.

CCS CONCEPTS

• **Computing methodologies** → **Artificial intelligence; Bio-inspired approaches; Genetic algorithms.**

KEYWORDS

Video Application, Energy Consumption Model for Mobile Devices, Genetic Algorithms, Particle Swarm Optimization

ACM Reference Format:

Irander O. de Amorim, Jose F. V. de Melo, Andson M. Balieiro, and Bruno B. dos Santos. 2019. An Evolutionary Approach for Video Application Energy Consumption Estimation in Mobile Devices. In *Brazilian Symposium on Multimedia and the Web (WebMedia '19)*, October 29–November 1, 2019, Rio de Janeiro, Brazil. ACM, New York, NY, USA, 7 pages. <https://doi.org/10.1145/3323503.3349545>

1 INTRODUÇÃO

O montante de conteúdo multimídia transmitido nas redes de comunicação tem crescido nos últimos anos. Medições da Cisco apontam que em 2014 o tráfego de vídeo correspondia a 55% de todo o tráfego global e estimativas indicam que esse valor será de 82% em 2021 [8]. Fatores como a popularização do acesso à banda larga, redução do custo de produção de conteúdo multimídia de alta qualidade e diversidade de plataformas gratuitas de compartilhamento de vídeos como o Youtube, por exemplo, têm impulsionado esse crescimento.

Somado a isso, nota-se que os dispositivos móveis (smartphones e tablets) têm se tornado popular (em 2016 representaram 45% do total de conexões e 81% do tráfego móvel [7]) e sido usados frequentemente para o consumo de conteúdo multimídia (ex. vídeo), que já correspondem a uma porção considerável do uso diário desses dispositivos [6]. Com essa popularização, melhorias de hardware (ex. CPUs mais rápidas, novas interfaces de comunicação sem fio, telas com altas resoluções) tem sido feitas nos dispositivos, que conduzem a um aumento no consumo de energia. Entretanto, as melhorias na tecnologia de bateria não seguiram a mesma velocidade [19].

As aplicações de vídeo demandam alto consumo de energia dos dispositivos, pois realizam operações complexas e manipulam uma grande quantidade de dados [19]. A combinação dessas aplicações com a limitada capacidade de bateria dos smartphones tem motivado pesquisas na análise e técnicas de gerenciamento de energia de tais dispositivos a fim de prolongar a autonomia da bateria e oferecer melhor qualidade de experiência (QoE) ao usuário [15] [19] [6].

Modelos para estimação do consumo de energia podem auxiliar o desenvolvimento de técnicas de adaptação de vídeo considerando o compromisso entre a qualidade do vídeo e o consumo de energia. Além disso, devido a demanda cada vez maior por capacidade de processamento nos dispositivos, que conduz ao aumento do consumo de energia e redução da sua autonomia de bateria, soluções baseadas em computação em nuvem tais como cloudlet [5], computação na borda com múltiplo acesso (MEC)[4] and mobile cloud computing (MCC)[13] têm sido desenvolvidas tanto para redes atuais (ex. rede

Permission to make digital or hard copies of all or part of this work for personal or classroom use is granted without fee provided that copies are not made or distributed for profit or commercial advantage and that copies bear this notice and the full citation on the first page. Copyrights for components of this work owned by others than ACM must be honored. Abstracting with credit is permitted. To copy otherwise, or republish, to post on servers or to redistribute to lists, requires prior specific permission and/or a fee. Request permissions from permissions@acm.org.

WebMedia '19, October 29–November 1, 2019, Rio de Janeiro, Brazil

© 2019 Association for Computing Machinery.

ACM ISBN 978-1-4503-6763-9/19/10...\$15.00

<https://doi.org/10.1145/3323503.3349545>

celular 4G e Wi-Fi) quanto para compor as redes 5G, que são vislumbradas para suportar aplicações como streaming de vídeo em UHD (ultra high definition) e realidade aumentada, por exemplo. Essas soluções realizam o chamado offloading computacional, que transfere do dispositivo móvel para a nuvem o processamento da aplicação, economizando a energia que seria utilizada no processamento local. Entretanto, a transferência dos dados (envio e recepção) para nuvem insere atraso no tempo de resposta da aplicação, que pode impactar na QoE do usuário, e consome energia do dispositivo na transmissão e recepção dos dados. Deste modo, o compromisso entre consumo de energia e o QoE do usuário deve ser considerado na tomada de decisão sobre o offloading computacional, e modelos de estimação do consumo de energia podem subsidiar este processo.

Neste âmbito, dois modelos analíticos (linear e exponencial) para estimar o consumo de energia de dispositivos executando aplicações de vídeo com diferentes configurações (ex. frames por segundo, taxa de bits e resolução) são propostos em [11]. Os autores utilizam medições via software e o método de mínimos quadrados (MMQ) para determinar os coeficientes dos modelos. O presente trabalho se inspira em [11] e propõe modelos de estimação de consumo de energia de dispositivos móveis considerando diferentes configurações de vídeo. Diferente de [11], adotamos Algoritmos Genéticos (AGs) e Otimização por Enxame de Partículas (PSO) para definir os coeficientes dos modelos. Devido a versatilidade, escalabilidade e simplicidade computacional, os AGs e o PSO têm sido amplamente utilizados para resolver problemas de otimização [1] [12] [18].

A nossa abordagem atua diretamente no modelo alvo para encontrar os melhores coeficientes, sem a necessidade (custo) de linearizar os modelos (ex. exponencial e potência), como ocorre em [11] para a aplicação do MMQ. Para mostrar a flexibilidade da nossa abordagem a diferentes modelos, além do linear e exponencial, consideramos também um modelo potência. A avaliação da proposta ocorre em termos de erro quadrático médio (MSE), utilizando dados de medição do consumo de energia do dispositivo móvel executando vídeos com configurações diversas. Resultados obtidos mostram a superioridade da nossa abordagem em relação a que usa MMQ [11].

Este artigo encontra assim organizado. A Seção 2 destaca os trabalhos relacionados. A Seção 3 apresenta a abordagem proposta, descrevendo os parâmetros de vídeos, modelos analíticos adotados e a estrutura do Algoritmo Genético e da Otimização por Enxame de Partículas desenvolvidos. Valores de medição, configurações de vídeo e a análise dos resultados obtidos pelos modelos são apresentados na Seção 4. Considerações finais são delineadas na Seção 5.

2 TRABALHOS RELACIONADOS

O crescimento do tráfego multimídia, que ocasiona maior consumo de energia dos dispositivos móveis, associado ao ritmo mais lento do desenvolvimento da tecnologia de bateria faz com que diferença entre a capacidade de bateria requisitada e a capacidade disponível aumente [9]. Isso tem motivado pesquisas na análise e técnicas de gerenciamento de energia de tais dispositivos a fim de prolongar a autonomia da bateria e oferecer melhor qualidade de experiência (QoE) ao usuário. Como exemplo, em [15], um estudo do impacto das condições da rede de comunicação sem fio (carga da rede e qualidade do enlace) no consumo de energia de dispositivos móveis

executando aplicação de streaming de vídeo é apresentado. Os autores realizam medições do consumo de energia, considerando diferentes configurações de vídeo (ex. codec, taxa de quadros, resolução, taxa de bits) e condições da rede (ex. carga na rede e qualidade do enlace de comunicação). Na mesma linha, [19] analisa o impacto da qualidade de vídeo e do tipo de rede sem fio (WiFi e 3G) no consumo de energia de dispositivos móveis através de medições via software. Já em [6], a análise do consumo de energia se concentra nos diferentes tipos de telas com a tecnologia AMOLED presentes nos dispositivos. Diferente do nosso trabalho, [6][19][15] focam apenas na análise do impacto dos diferentes elementos no consumo de energia e não propõem nenhum modelo para estimar o consumo de energia de dispositivos móveis em aplicações de vídeo.

Para estimar o consumo de energia de aplicações de vídeo em dispositivos móveis, os autores em [11] apresentam dois modelos analíticos (linear e exponencial) e utilizam o método de mínimos quadrados (MMQ) para determinar os coeficientes dos modelos. Diferente de [11], adotamos Algoritmos Genéticos (AGs) e Otimização por Enxame de Partículas (PSO) para definir os coeficientes dos modelos, atuando diretamente no modelo alvo para encontrar os melhores coeficientes, sem o custo de linearizá-los, como ocorre em [11] para a aplicação do MMQ. Além disso, consideramos um modelo potência para mostrar a flexibilidade da nossa proposta.

AGs e PSOs têm sido adotados na resolução de problemas de otimização [1] [12] [18] [9] [16]. Em [9], os autores formulam o problema do consumo de energia de aplicação multimídia em comunicação dispositivo a dispositivo (D2D). Eles consideram características de vídeo, do canal sem fio, largura de banda, restrição de qualidade e técnicas de codificação, e propõem um algoritmo genético adaptativo para solucionar o problema. Já [16] apresenta um método de otimização adaptativo para serviços de vídeo. Ele se baseia na técnica de codificação de vídeo escalável (SVC) e seleciona dinamicamente o número de camadas recebidas durante a reprodução do vídeo, considerando restrições de energia e qualidade. A proposta adota a otimização por enxame de partículas para definir o momento de comutação das camadas.

Embora existam propostas na literatura que focam na análise e/ou gerenciamento do consumo de energia de aplicações de vídeo em dispositivos móveis, a nossa se diferencia, pois adota técnicas evolucionárias para a construção dos modelos de estimação de consumo de energia e é flexível para a aplicação em outros tipos de modelos, sem o custo de linearização.

3 ABORDAGEM PROPOSTA

Esta seção apresenta os parâmetros de vídeos, modelos analíticos e a estrutura do AG e PSO que compõem a abordagem proposta.

3.1 Parâmetros de Vídeo que Influenciam no Consumo de Energia

Existem vários parâmetros de vídeo que influenciam a qualidade e o consumo de energia dos dispositivos. Resolução do vídeo (altura x largura), taxa de quadros (frames por segundo, fps), taxa de bits (Mbps), informação espacial e temporal de cada vídeo e complexidade da cena são alguns destacados em [11]. Em aplicações de streaming de vídeo online, parâmetros relacionados a rede de comunicação (ex. taxa de dados, qualidade do enlace e carga da

rede) também impactam no consumo de energia das aplicações de vídeo. Neste trabalho, a resolução (altura x largura), a taxa de bits (Mbps) e a taxa de frames (fps) são os parâmetros considerados. A taxa de frames é a quantidade de imagem que um objeto audiovisual exibe ou registra por segundo. A medida que a taxa de frames cresce, o consumo de energia aumenta. A resolução de vídeo refere-se ao tamanho do frame em relação a quantidade de pixels. Caso ela aumente, o consumo de energia será maior, visto que a quantidade de pixels total é o produto altura x largura do frame. Já a taxa de bits indica o número de bits que são processados por unidade de tempo. Neste trabalho, consideraram-se três valores diferentes para a resolução e taxa de frames e dois valores para a taxa de bits, conforme ilustrado na Tabela 1. Embora apenas um subconjunto de parâmetros seja adotado, a abordagem proposta é facilmente extensível para englobar outros parâmetros. Para trabalhos futuros, planeja-se considerar parâmetros de vídeo e de rede simultaneamente.

Table 1: Parâmetros de vídeo e valores adotados na abordagem proposta

Parâmetro	Valor
Resolução	320 x 240 / 720x 480 / 1920 x 1080
Taxa de bits	256/512
Taxa de frames	15/30/90

3.2 Modelos Adotados

Para mostrar a flexibilidade da nossa abordagem, três tipos de modelos analíticos para estimar o consumo energia de aplicações de vídeo em dispositivos móveis foram considerados, linear, exponencial e potência. As Eqs. (1), (2) e (3) descrevem os respectivos modelos, onde p_i , a_i e b_i correspondem ao parâmetro de vídeo i e seus respectivos coeficientes (a serem determinados), k é a constante (base) do modelo exponencial (também a ser determinada) e E é o consumo de energia.

$$(a_1p_1 + a_2p_2 + a_3p_3 + \dots + a_np_n) = E \quad (1)$$

$$k^{(a_1p_1 + a_2p_2 + a_3p_3 + \dots + a_np_n)} = E \quad (2)$$

$$(a_1p_1^{b_1} + a_2p_2^{b_2} + a_3p_3^{b_3} + \dots + a_np_n^{b_n}) = E \quad (3)$$

Embora apenas três modelos tenham sido adotados, a abordagem proposta é flexível para adoção de outros tipos de modelos não lineares, bem como modelos heterogêneos, compostos por modelos lineares e não lineares. Isso se torna interessante, pois uma vez que os parâmetros possuem diferentes influências no consumo de energia, a adoção de um modelo heterogêneo, onde cada parâmetro é associado a função que o melhor representa, possibilita estimativas mais próximas do valor real. Diferentemente de [11], que utiliza MMQ e necessita de linearização prévia de modelos não lineares, a nossa abordagem atua diretamente no modelo, sem o custo (complexidade) de linearizá-lo.

3.3 Algoritmos Genéticos

Para definir os coeficientes dos modelos definidos na Seção 3.2, dois esquemas foram propostos, um baseado em Algoritmo Genético e outro em Otimização por Enxame de Partículas. Nesta seção descrevemos o primeiro. A Seção 3.4 apresenta o segundo.

3.3.1 Estrutura do Cromossomo e Função de Fitness. O AG é um método de busca baseado nos princípios de seleção natural e genética das espécies de Darwin [10]. Ele evolui um conjunto de soluções, representadas pelos cromossomos, durante um período chamado de gerações. Através dos operadores genéticos (seleção, cruzamento e mutação), as diferentes soluções são combinadas a fim de que uma boa solução seja encontrada. Os AGs têm sido amplamente empregados com sucesso na resolução de diversos problemas na literatura [1].

O indivíduo (cromossomo) é formado por um vetor de coeficientes, ilustrado na Fig. 1. Cada gene (posição) refere-se a um coeficiente do modelo a ser determinado. Essa estrutura de cromossomo que codifica os coeficientes do modelo permite que a abordagem proposta seja aplicável a qualquer tipo de modelo (linear, não linear ou heterogêneo).




Figure 1: Estrutura do Cromossomo

A função de fitness para avaliar os indivíduos (soluções X 's) do AG é dada na Eq. (4), onde MSE é o erro quadrático médio (ver Eq. (5)) entre o valor do consumo de energia estimado (y_i^*) com o modelo utilizando os coeficientes definidos no indivíduo e o valor real medido (y_i), S é um fator de escala (adotou-se $S = 1000$) e M é o número de estimativas.

$$fitness(X) = \frac{S}{1 + MSE} \quad (4)$$

$$MSE = \frac{\sum_{i=1}^M (y_i - y_i^*)^2}{M} \quad (5)$$

3.3.2 Operadores Genéticos. A seleção por torneio foi adotada para escolher os indivíduos para o processo de cruzamento [7]. Ela apresenta menor pressão seletiva do que a roleta ponderada, portanto mais democrática. Nela, selecionam-se aleatoriamente e com igual probabilidade n indivíduos na população (neste trabalho adotou-se $n = 3$). Destes, o indivíduo com maior aptidão é escolhido para compor a população intermediária. Este processo se repete até que a população intermediária seja preenchida.

Na operação de cruzamento, que seleciona genes dos pais para criação de novos filhos (indivíduos), simulando a mistura de material genético da reprodução natural, adotou-se o operador aritmético. Ele combina linearmente o material genético dos pais para gerar novos filhos F_i s de acordo com a Eq. (6), onde P_i e P_j são os dois

país do cruzamento, onde $i, j = 1, 2, 3, \dots$, com $i \neq j$ e α é um valor aleatório uniformemente distribuído entre 0 e 1.

$$F_i = \alpha P_i + (1 - \alpha) P_j \quad (6)$$

A mutação é uma operação importante para o sucesso do AG. Ela determina a direção de busca e evita convergência prematura a ótimos locais através da inserção de diversidade na população [7]. Ela ocorre após o cruzamento e altera aleatoriamente os novos filhos. Em nossa abordagem, a mutação uniforme foi adotada. Assim, cada gene do indivíduo (X) pode sofrer alteração na sua composição de acordo com a Eq.(7), onde β é um valor uniformemente distribuído no intervalo (I_{min}, I_{max}) e X_{ant} é o valor do gene antes da mutação. Neste trabalho adotou-se $I_{min} = -1$ e $I_{max} = 1$, pois os valores dos genes (parâmetros de vídeo) foram normalizados entre 0 e 1.

$$X = X_{ant} + \beta \quad (7)$$

As probabilidades de crossover (pc) e mutação (pm) são dois parâmetros que têm grande impacto no desempenho do AG. Elas expressam a frequência com que tais operações ocorrem durante o processo evolutivo [1]. Adotar um valor alto para pm pode resultar em perda de boas soluções durante a evolução do AG, devido a maior chance de alterações nas soluções, especialmente se estratégias elitistas não são empregadas. Por outro lado, um baixo valor de pm pode conduzir a pouca diversidade na população e a convergência prematura do AG [1]. Em termos de pc, um valor elevado pode ocasionar na perda de bons blocos (esquemas) dentro de um cromossomo [10]. Ao passo de que uma probabilidade de cruzamento baixa pode originar um número insuficiente de novos filhos, pouca troca de material genético entre os indivíduos.

Para definir os valores de pc e pm adotados em nosso esquema, vários testes foram conduzidos, envolvendo oito valores para a probabilidade de cruzamento, escolhidos dentro do intervalo $[0,1, 0,8]$, e oito valores para a probabilidade de mutação, definidos no intervalo $[0,01, 0,8]$, conforme sumariza a Tabela 2. A combinação de todos estes casos resulta em 64 casos avaliados. Para cada um, 100 instâncias de execução do AG foram realizadas, onde a média do fitness máximo alcançado na última geração do AG foi calculada. As Figs. 2, 3 e 4 apresentam os resultados dos casos de teste para o AG associado a cada modelo (linear, exponencial e potência), onde os casos de testes 45, 8 e 37 foram os que apresentaram melhor desempenho em termos de fitness máximo (média) e, portanto, selecionados para compor a nossa abordagem com o modelo correspondente. Eles possuem as probabilidades de cruzamento e mutação iguais a 0,6 e 0,3 (modelo linear), 0,8 e 0,1 (modelo exponencial) e 0,5 e 0,3 (modelo potência).

Table 2: Valores de Probabilidades de Cruzamento e Mutação dos Casos de Testes

Pc	0,1/0,2/0,3/0,4/0,5/0,6/0,7/0,8
Pm	0,01/0,03/0,05/0,1/0,3/0,5/0,7/0,8

Além dos valores de pc e pm, o tamanho da população (número de indivíduos no AG) e o número de gerações foram configurados como 200 e 300, respectivamente, sendo este último o critério de parada do AG adotado nesta abordagem. A Tabela 2 sumariza os parâmetros do AG.




Figure 2: Resultados dos casos de teste (pc,pm) do AG com o modelo Linear




Figure 3: Resultados dos casos de teste (pc,pm) do AG com o modelo exponencial





Figure 4: Resultados dos casos de teste (pc,pm) do AG com o modelo potência

Table 3: Parâmetros Adotados no AG

Parâmetro	Valor (Linear/Exp/Pot.)
Tamanho da População	200
Número de Gerações	300
Probabilidade de Cruzamento	0,6/ 0,8/ 0,5
Probabilidade de Mutação	0,3/0,1/ 0,3

3.3.3 Fluxo de Execução do AG. O fluxo de execução da nossa abordagem com o AG é ilustrado na Fig. 5. Inicialmente, dado um modelo de estimação do consumo de energia, cujos coeficientes devem ser determinados, a população de soluções candidatas (indivíduos) para o problema é gerada aleatoriamente. Na criação, a quantidades de coeficientes a serem determinados é considerada. Isso torna a abordagem flexível e aplicável a modelos que consideram diferentes números de parâmetros, coeficientes. Em seguida, os indivíduos são avaliados de acordo com a função de fitness (ver (4)), que considera o inverso do erro quadrático médio (MSE) do valor obtido pelo modelo, utilizando os coeficientes determinados pelo indivíduo, com o valor real (medido), conforme indicado na Seção 3.3.1. Após a avaliação, os indivíduos são submetidos aos operadores de seleção, cruzamento e mutação. Adicionalmente, uma estratégia elitista é empregada para garantir que indivíduos com melhores fitness não sejam perdidos durante o processo evolutivo. Finalizadas estas operações, a nova população de soluções candidatas é formada e o critério de parada (determinado pelo número de gerações) é verificado. Caso não tenha sido atingido, o processo se repete desde a avaliação dos indivíduos. Caso contrário, o indivíduo com maior fitness é escolhido como solução para o problema. Ele apresenta os valores dos coeficientes do modelo de entrada.

**Figure 5: Fluxo de Execução do AG**

3.4 Otimização por Enxame de Partículas

Para encontrar os coeficientes dos modelos descritos na Seção 3.2, além do AG, um esquema baseado em otimização por enxame de partículas foi desenvolvido. O PSO é uma técnica de otimização estocástica de funções não lineares, baseada em populações, e inspirada no comportamento social de um bando de aves a procura de um alvo (ex. alimento, local pra pouso e proteção)[2], que realizam esforço conjunto e compartilham informações para alcançá-lo. Nele, o processo de otimização se inicia com a seleção das variáveis (ex. coeficientes dos parâmetros de vídeo) e restrições do problema. Através da busca no espaço de soluções viáveis, verifica-se qual o ponto ótimo da função objetivo. No nosso cenário isso representa qual a combinação de coeficientes que fazem com que o modelo de estimação do consumo de bateria do dispositivo móvel executando aplicações de vídeo tenham menor MSE, comparando os valores de saída do modelo com os reais de medição. As possíveis soluções são chamadas de partículas e se movem no espaço de busca seguindo as partículas ótimas. Assim, através da simulação do espaço bidimensional, um vetor X define a posição da partícula (valores dos coeficientes) e outro (v) estabelece a sua velocidade de deslocamento.

A cada iteração $k + 1$, cada partícula i atualiza a sua velocidade e posição de acordo com as Eqs. (8) e (9), respectivamente, onde $rand_1$ e $rand_2$ são números aleatórios independentes e uniformemente distribuídos no intervalo de 0 a 1; c_1 e c_2 são os fatores cognitivo e social, que controlam o fluxo de informação entre a partícula e seu enxame. Quando $c_2 > c_1$, a partícula tem mais confiança no enxame, ou seja, na melhor posição alcançada pelo enxame no tempo k , denotada como g_{best} . No caso de $c_1 > c_2$, a melhor posição individual da partícula até o tempo k (p_{best_i}) tem maior influência na atualização da sua velocidade; w é chamado de fator de inércia e controla a influência da velocidade anterior na atualização da velocidade da partícula [3]. A Eq. (10) define o valor de w , onde k_{max} é o número máximo de iterações do PSO, W_{max} e W_{min} são os valores máximo e mínimo para w , respectivamente. Na nossa abordagem, w é inicializado com o valor de W_{max} . A Tabela 4 elenca os valores dos parâmetros do PSO.

Pelas Eqs (8) e (9) nota-se que a velocidade, e, consequentemente, a posição de cada partícula é ajustada considerando a informação social compartilhada pelos membros do enxame, onde cada uma muda sua posição para um ponto onde ela e o enxame tenham tido o maior valor da função objetivo em interações anteriores. Para avaliar cada partícula (solução) do PSO a fim de denotar quão boa é a sua posição (valores dos coeficientes do modelo), utilizou-se o erro quadrático médio (MSE), definido na Eq. (5).

$$v_i(k+1) = w(k+1)v_i(k) + c_1rand_1(p_{best_i}(k) - X_i(k)) + c_2rand_2[g_{best}(k) - X_i(k)] \quad (8)$$

$$X_i(k+1) = X_i(k) + v_i(k+1) \quad (9)$$

$$w(k+1) = \frac{(w(k) - k)}{k_{max}}(W_{max} - W_{min}) \quad (10)$$

Table 4: Parâmetros Adotados no PSO

Parâmetro	Valor
Tamanho da População	200
Número de Gerações	300
Parâmetro Cognitivo (c_1)	2
Parâmetro Social (c_2)	2
Fator de Inércia Inicial	0,8
Fator de Inércia Máximo	0,8
Fator de Inércia Mínimo	0,2

4 AVALIAÇÃO E RESULTADOS

Para avaliar a abordagem proposta, dados de medição do consumo de energia de 90 vídeos educacionais foram utilizados. As medições foram conduzidas utilizando o software Trepp Power Profiler [17], com os vídeos sendo exibidos através do software VLC [14] em um smartphone Lenovo K10a40 com sistema operacional Android 6.0. Para a medição, as interfaces de comunicação com as redes Wi-Fi e celular, bem como as aplicações de notificação e sincronização do dispositivo foram desabilitadas. Cada vídeo possuía duração de 2 minutos e foi configurado com três valores diferentes de resolução e taxa de frames e dois valores distintos de taxa de bits, totalizando 18 configurações. Para cada uma, o consumo energia de 5 diferentes vídeos foram medidos. A Tabela 5 apresenta o consumo de energia médio (em mWh) dos vídeos de acordo com as configurações adotadas.

A avaliação da abordagem proposta se deu em termos de erro quadrático médio (MSE) e utilizou aquela baseada no método de mínimos quadrados (MMQ), descrita em [11], para comparação. Os resultados são apresentados em termos de média, com nível de confiança de 90% e foram obtidos realizando 30 execuções da abordagem proposta para cada modelo considerado. Como não houve interseção entre os intervalos de confiança dos modelos que usam a nossa proposta (AG ou PSO) e os que usam MMQ, as barras dos intervalos foram suprimidas dos gráficos.

A Fig. 6 apresenta o MSE obtido pelas diferentes abordagens. Nota-se que os modelos de estimação que adotaram o AG (AG Linear, AG Exp e AG Pot) ou o PSO (PSO Linear, PSO Exp e PSO Pot) para definir os seus coeficientes alcançaram os melhores resultados que aqueles que usaram o MMQ (MMQLinear e MMQExp). Os esquemas PSOExp, AG Exp, PSO Pot e AG Pot mostraram desempenhos similares e foram os que alcançaram melhores resultado de todos os avaliados, reduzindo o MSE em 96% quando comparados ao MMQ Linear e 94% em relação MMQ Exp. O AG Linear e o PSO Linear também obtiveram desempenhos similares entre si e mesmo sendo usando o modelo analítico com estrutura mais simples, proporcionaram uma redução no MSE de 94% e 91%, comparados ao MMQ Linear e MMQ Exp, respectivamente. Comparando as abordagens que adotam modelos analíticos do mesmo tipo, aqueles que adotaram o AG e PSO para configurar seus coeficientes reduziram o MSE em média em 94,56%, mostrando a superioridade da abordagem proposta e que não somente a escolha do modelo é importante, mas também dos seus coeficientes.

Adicionalmente, observa-se na Fig.6 que a utilização do modelo potência associada ao AG e PSO proporcionou melhores resultados

do que quando o modelo linear é adotado, com redução no MSE de aproximadamente 35%, mostrando que ele consegue capturar melhor a influência dos parâmetros de vídeo no consumo de energia do que o modelo linear.

Um aspecto importante na análise das abordagens é o consumo de energia do dispositivo móvel que elas demandam para definir os coeficientes do modelo. Assim como a baseada em MMQ, a nossa abordagem considera que o AG e o PSO não necessitam executar no dispositivo móvel para calcular os coeficientes do modelo. Eles podem executar em dispositivos externos (ex. computador ou na nuvem), onde apenas os modelos analíticos com os coeficientes já definidos (offline) estariam no dispositivo. Isso corresponde a execução de uma soma ponderada de termos, conforme ilustrado nas Eqs. (1) (2) (3), não causando impacto no consumo de energia do dispositivo móvel.

Além disso, abstraímos a frequência com que a estimação do consumo de energia da aplicação de vídeo é realizada, pois esta decisão seria tomada pela estratégia/mecanismo de gerenciamento de energia/adaptação de vídeo, levando em conta fatores como perfil do usuário, intervalo de tempo, estado atual da bateria e QoE desejada, por exemplo, onde a nossa proposta subsidiaria a estratégia/mecanismo com o valor estimado do consumo de energia.

5 CONCLUSÃO

Este trabalho apresentou uma abordagem evolucionária baseada em algoritmos genéticos e otimização por enxame de partículas para o desenvolvimento de modelos de estimação do consumo de energia de dispositivos móveis executando aplicações de vídeo. Os resultados de avaliação mostraram a superioridade da proposta em relação a que utiliza MMQ, disposta na literatura. Ademais, observou-se que tanto o AG quanto o PSO atuam diretamente no modelo alvo para encontrar os melhores coeficientes, sem o custo de linearizá-lo (ex. modelo exponencial e potência), como ocorre em [11].


Além da flexibilidade da nossa proposta, destacou-se que o uso de AG ou PSO não impacta no consumo de energia do dispositivo móvel, dado que eles podem ser executados em dispositivos externos (ex. computador ou nuvem), retornando os coeficientes do modelo alvo. Desse modo, apenas o modelo analítico com os seus coeficientes já definidos estariam no dispositivo, o que corresponde a execução de apenas uma soma ponderada de termos. Como direção futura, o uso parâmetros relacionados tanto ao vídeo quanto a rede é vislumbrado, a adoção de diferentes modelos heterogêneos para compor o modelo de estimação e a utilização deles no suporte a decisão de offload computacional são pontuadas. Além disso, a comparação entre modelos de smartphones distintos (com diferentes capacidades) é vislumbrada.

REFERENCES

- [1] K. L. Dias A. M. Balieiro, M. R. M. Falcão. 2019. An Evolutionary Scheme for Secondary Virtual Networks Mapping onto Cognitive Radio Substrate. *Wireless Communications and Mobile Computing* 2019 (2019).
- [2] D. W. Boeringer and D.H. Werner. 2004. Particle Swarm Optimization Versus Genetic Algorithm for Phased Array Synthesis. *IEEE Transactions on Antennas and Propagation* 52, 3 (2004), 771–779.
- [3] O. J. B. Carrilho. 2007. *Algoritmo Híbrido para Avaliação da integridade estrutural: uma abordagem heurística*. Ph.D. Dissertation. Universidade de São Paulo (USP), São Carlos, Brasil.

Table 5: Consumo de Energia Médio (em mWh) de vídeos com diferentes configurações

Resolução	320 x 240	720 x 480	1920 x 1080
Taxa de frames(fps)	15/30/90	15/30/90	15/30/90
Taxa de bits(Mbps)	256/512	256/512	256/512
Consumo de Energia (mWh)	16,42/17 /17,33 16,85/16,40/15,72	15,55/16,45/16,11 16,45/17,86/15,61	15,45/16,76/14,28 15,85/16,03/16,97

**Figure 6: Resultados do MSE obtidos pelas diferentes abordagens**

- [4] Min Chen and Yixue Harb. 2018. Task Offloading for Mobile Edge Computing in Software Defined Ultra-Dense Network. *IEEE Journal on Selected Areas in Communications* 36, 3 (2018), 587–597.
- [5] Min Chen, Yixue Harb, yong Li, Chi-Feng Lai, and Di Wu. 2015. On the Computation Offloading at ad hoc Cloudlet: Architecture and Services Modes. *IEEE Communications Magazine* 53, 6 (2015), 18–24.
- [6] X. Chen, Y. Chen, Z. Ma, and F.C.A. Fernandes. 2013. How is Energy Consumed in Smartphones Display Applications?. In *Proceedings of the 14th Workshop on Mobile Computing Systems and Applications*. ACM, Gerogia, USA.
- [7] Cisco. 2017. *Cisco Visual Networking Index: Global Mobile Data Traffic Forecast Update 2016–2021*. White Paper. Cisco.
- [8] Cisco. 2017. *CiscoCisco Visual Networking Index: The Zettabyte Era-Trends and Analysis*. White Paper. Cisco.
- [9] T-T. Huynh C.H. Hai D-T. Huynh, M. Chen. 2019. Energy consumption optimization for green Device-to-Device multimedia communications. *Future Generation Computer Systems* 92 (2019), 1131–1141.
- [10] D.E. Goldberg. 1989. *Genetic Algorithms in Search, Optimization and Machine Learning*. Addison Wesley Publishing Co., Inc.
- [11] D. J. S Gouveia and D. Z. Rodrigues. 2018. Otimização do Streaming de Vídeo utilizando a Informação do Consumo de Energia. In *Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos*. SBRC, Campos do Jordão, Brasil.
- [12] B. Han, J. Lianghai, and D. Schotten. 2018. Slice as an evolutionary service: genetic optimization for inter-slice resource management in 5G networks. *IEEE Access* 6 (2018), 33137–33147.
- [13] J.S.Silva, F.A.A. Lins, E.T.G. Sousa, H. B. Summer, and C. M. Fernandes. 2017. Invasive Technique for measuring the energy consumption of mobile devices applications in mobile cloud environments. In *IEEE International Conference on Systems, Man and Cybernetics*. IEEE, Banff, Canada.
- [14] VideoLan Organization. 2019. VLC media player. Retrieved maio, 2019 from <https://www.videolan.org/index.pt-BR.html>
- [15] O. Ormond G-M Mutean R. Testrian, A-N. Moldovan. 2012. Energy Consumption Analysis of Video Streaming to Android Mobile Devices. In *IEEE Network Operations and Management Symposium*. IEEE, Maui, USA.
- [16] M. Ran. S. Zhou and Z. Lu. 2016. Adaptive energy-efficient and QoE-aware optimization method for mobile video services. In *16th International Symposium on Communications and Information Technologies*. Qingdao, China.
- [17] Qualcomm Technologies. 2019. Trepp Power Profiler. Retrieved maio, 2019 from <https://developer.qualcomm.com/software/trepp-power-profiler>
- [18] Y. Zhang, S. Wang, and Ji G. 2015. A comprehensive Survey on Particle Swarm Optimization Algorithm and Its Application. *Mathematical Problems in Engineering* 2015 (2015), 38.
- [19] N. Zsack and C. Wollf. 2014. *Impact of video quality and wireless network interface on power consumption of mobile devices*. <https://arxiv.org/abs/1407.7667>