LVI SBPO SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL
DE 04 ATÉ 07 NOVEMBRO 2024
FORTALEZA | CEARÁ

Uma Proposta de Adaptação Dinâmica da Iluminação Urbana baseada em IoT e DCOP

Bruno César Nogueira
Instituto de Computação – Universidade Federal Fluminense[1]
Niterói, RJ - Brasil
brunocn@id.uff.br

Flávia Coimbra Delicato[1]
fdelicato@gmail.com

Rebeca Campos Motta[1]
becacmotta@gmail.com

Fábio Protti[1]
fabio@ic.uff.br

RESUMO

Este trabalho apresenta um modelo dinâmico para gestão de iluminação pública utilizando Problemas de Otimização de Restrições Distribuídas (DCOP) no contexto de IoT, visando otimizar o consumo de energia em áreas urbanas. Ao ajustar dinamicamente a intensidade da iluminação com base em variáveis ambientais em tempo real, como tráfego de veículos, presença de pedestres e condições climáticas, o modelo proposto busca aumentar a eficiência energética quando comparado ao modelo tradicional estático ou adaptações baseadas em horários pré-estabelecidos. A utilização do DCOP permite a coordenação eficaz de dispositivos autônomos, proporcionando uma solução ágil e sustentável às necessidades de iluminação urbana, com reduções significativas no consumo de energia em comparação com sistemas estáticos tradicionais.

PALAVRAS CHAVE. Cidades Inteligentes, DCOP, IoT.

Tópicos: SE-CRIS

ABSTRACT

This work presents a dynamic model for public lighting management using Distributed Constraint Optimization Problems (DCOP) in the context of IoT, aiming to optimize energy consumption in urban areas. By dynamically adjusting lighting intensity based on real-time environmental variables, such as vehicle traffic, pedestrian presence and weather conditions, the proposed model seeks to increase energy efficiency when compared to the traditional static model or adaptations based on pre-established schedules. The use of DCOP allows the effective coordination of autonomous devices, providing an agile and sustainable solution to urban lighting needs, with significant reductions in energy consumption compared to traditional static systems.

KEYWORDS. Smart Cities. DCOP. IoT.

Paper topics: SE-CRIS

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

1. Introdução

A modernização dos sistemas de iluminação pública, especialmente a transição de lâmpadas de vapor de sódio ou mercúrio para lâmpadas de diodo emissor de luz (LED), representa um avanço significativo em termos de eficiência energética, longevidade da iluminação e capacidade de controle. Lâmpadas LED não apenas consomem uma fração da energia utilizada por suas contrapartes tradicionais entregando uma melhor qualidade de luz, mas também oferecem uma vida útil mais longa. Enquanto as lâmpadas de vapor metálico podem funcionar de 12 a 24 mil horas, as lâmpadas LED podem ir até 100 mil horas de funcionamento [P. Fragoso et al., 2020].

Tradicionalmente, os sistemas de iluminação pública operam em um esquema estático, onde a automação de acender e apagar as lâmpadas fica a cargo de um componente conhecido como relé fotoelétrico. Este componente monitora a intensidade luminosa de um determinado local, sendo acionado ao captar um nível de luminosidade abaixo ou acima do configurado, liberando ou interrompendo a energia elétrica que vai para a lâmpada. Essa abordagem, embora simples, não aproveita todo o potencial da tecnologia LED, no que diz respeito ao uso conjunto de diversos sensores para fornecer uma iluminação dinâmica, resultando em consumo desnecessário de energia durante períodos de baixa demanda [Souza et al., 2022]. Lâmpadas LED, diferentemente das lâmpadas convencionais, possibilitam o uso adequado da técnica de dimerização [Pasolini et al., 2019], que permite o ajuste da intensidade da luz emitida por uma lâmpada sem causar prejuízo ao tempo de vida útil. Tal capacidade de ajustar a potência da lâmpada conforme as necessidades específicas do ambiente não só contribui para uma maior redução do consumo de energia como também adiciona uma camada de adaptação ao sistema de iluminação pública.

Neste trabalho, propomos um modelo para a dimerização inteligente da iluminação urbana que utiliza a abordagem de Otimização Distribuída de Restrições (DCOP - *Distributed Constraint Optimization Problem*). Este modelo visa adaptar dinamicamente a intensidade da iluminação pública, respondendo em tempo real a eventos variáveis como o fluxo de tráfego de veículos, a presença de pedestres, e as condições meteorológicas, como chuvas. A escolha pelo DCOP fundamenta-se na sua capacidade de coordenar dispositivos autônomos em uma rede complexa, permitindo assim uma gestão mais eficiente e sustentável do consumo de energia. Ao invés de seguir um esquema estático ou adaptações baseadas em horários pré-estabelecidos, nosso modelo foca na reação contextual à dinâmica urbana, esperando-se, como resultado, uma economia de energia devido à otimização da iluminação pública com base nas variáveis do ambiente consideradas.

Este artigo é estruturado da seguinte forma: a seção 2 aborda o conceito de DCOP. Na seção 3, a modelagem DCOP do sistema de iluminação pública auto-adaptativo é detalhada. A seção 4 apresenta o Estudo de Viabilidade, descrevendo o cenário de teste e os resultados obtidos. A seção 5 discute trabalhos relacionados, destacando a aplicabilidade e a flexibilidade do formalismo DCOP. A seção 6 sintetiza os resultados alcançados, destacando a vantagem do modelo.

2. Trabalhos Relacionados

Em [Zhang et al., 2003] foi proposto um sistema de coordenação em redes de sensores sem fio para equilibrar detecção rápida de objetos e conservação de energia. O sistema minimiza a comunicação entre sensores, reduzindo latência e consumo energético. Dois algoritmos distribuídos foram analisados: breakout distribuído (DBA) e busca estocástica distribuída (DSA), sendo o DSA superior em equilibrar detecção de objetos e conservação de energia, sob condições controladas.

Em [Junges, 2007] e [Junges e Bazzan, 2007] comparam os algoritmos DCOP - OptAPO, ADOPT e DPOP - no controle de tráfego semafórico. Os autores avaliam a eficiência dos algoritmos listados e realizam simulações que analisaram o impacto das soluções propostas em variáveis de tráfego, como densidade e velocidade média, visando otimizar o desempenho do tráfego.

Já em [Corrêa, 2015] foi estudado a problemática dos desastres urbanos, enfatizando a necessidade de coordenação entre agentes heterogêneos para tomada de decisões eficientes e rápidas.

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

O DCOP é formulado como um problema em que agentes são responsáveis por tarefas do desastre, com seu domínio composto pelas tarefas percebidas no ambiente. O modelo proposto, FGMD (Formação de Grupos pela Minimização da Distância), busca formar grupos de agentes para minimizar uma métrica de distância sobre as tarefas em seus domínios. Ao formalizar o problema de alocação de tarefas como um DCOP e otimizá-lo com o algoritmo BMS (*Binary Max-Sum*)), promoveu uma coordenação eficaz entre os agentes em situações de desastre urbano.

Em [Rust et al., 2016] é proposto uma modelagem DCOP para coordenar dispositivos em ambientes inteligentes, como casas inteligentes, sem a necessidade de intervenção humana. O modelo proposto permite que os dispositivos cooperem autonomamente para alcançar os objetivos definidos pelo usuário, adaptando-se dinamicamente a mudanças no ambiente. Foram analisados os resultados do uso de dois algoritmos DCOP (DPOP e Max-Sum) utilizados para implementar a coordenação entre os dispositivos.

Em [Ali et al., 2021] é apresentado um sistema de gestão de estacionamento descentralizado. Usando DCOP, o problema é modelado eficientemente para alocar vagas em áreas centrais da cidade. A abordagem descentralizada distribui os cálculos por todos os dispositivos disponíveis, aumentando poder computacional, escalabilidade e adaptabilidade do sistema. O algoritmo Max-Sum foi identificado como o mais adequado devido à sua rápida execução e eficiência na geração de mensagens.

Por meio dos exemplos acima, podemos observar a adaptabilidade do formalismo DCOP em variados domínios, com destaque para sua capacidade de otimizar a coordenação em sistemas multiagentes distribuídos. Assim, nossa proposta alia-se à visão de cidades mais inteligentes e sustentáveis, demonstrando como a otimização distribuída em um sistema orientado a agentes, pode ser utilizada na melhoria da gestão urbana.

3. Problemas de Otimização de Restrições Distribuída (DCOP)

Os problemas de restrições distribuídas visa a resolução de problemas onde a natureza dinâmica e distribuída do problema ou a eficiência proporcionada pela distribuição são fundamentais.

O DCOP consiste na atribuição de uma ou mais variáveis a agentes autônomos que, de forma colaborativa, devem encontrar a melhor solução para o problema por meio das funções de custo. As funções de custo, também chamadas de funções de utilidade, são a soma dos custos individuais de cada atribuição de variável, mais os custos das relações entre as variáveis.

De acordo com [Modi et al., 2003] um problema DCOP pode ser definido formalmente pela tupla (*A, V, D, F,* μ) onde:

- $A = \{a_1, a_2, \ldots, a_n\}$ é um conjunto de n agentes;
- $V = \{x_1, x_2, \ldots, x_n\}$ é o conjunto de n variáveis de forma que cada variável está associada a um agente.
- $D = \{d_1, d_2, \ldots, d_n\}$ é o conjunto de domínios finitos e discretos onde cada variável x_i pode representar valores do domínio *Di*;
- $f_{i,j} : d_i \times d_j \rightarrow \mathbb{N}$ é o conjunto de funções de custo ou utilidade que descrevem as restrições para o par de variáveis x_i, x_j;
- função objetivo $F(\mathrm{O})$, definida como uma agregação sobre o conjunto de restrições. O objetivo, com essa função, é encontrar um conjunto de valores *O** para as variáveis *V*, tal que a função objetivo seja minimizada ou maximizada. A função objetivo *F(O)* é definida como:

$$F(O) = \sum_{x_i, x_j \in V} f_{ij}(d_i, d_j), \text{ onde } x_i \leftarrow d_i, x_j \leftarrow d_j$$

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

- μ: $V \rightarrow$ A é uma função que atribui o controle de cada variável a um agente.

Na figura 1, temos um exemplo ilustrativo de um DCOP representado como um grafo de restrições. Este exemplo inclui um conjunto de agentes $A = a_1, a_2, a_3, a_4$, cada um associado a uma variável do conjunto $V = x_1, x_2, x_3, x_4$, todas com um domínio de valores $D_i = 0, 1$. As relações entre esses agentes são definidas por restrições, representadas pelas arestas do grafo. Portanto, temos quatro funções de custo correspondentes às arestas: $f(x_1, x_2), f(x_1, x_3), f(x_2, x_3), f(x_2, x_4)$. Dois agentes são considerados vizinhos se houver uma restrição diretamente entre eles; por exemplo, x_1 e x_3 são vizinhos, enquanto x_1 e x_4 não, pois não estão diretamente conectados.

Neste DCOP, a função objetivo F é avaliada com base nas atribuições das variáveis. Por exemplo, se todas as variáveis assumirem o valor zero, a função objetivo é

$$F((x_1, 0), (x_2, 0), (x_3, 0), (x_4, 0)) = 4.$$

Em contraste, se todas as variáveis assumirem o valor um, a função objetivo é

$$F((x_1, 1), (x_2, 1), (x_3, 1), (x_4, 1)) = 0.$$

Portanto, a atribuição ótima $O^* = (x_1, 1), (x_2, 1), (x_3, 1), (x_4, 1)$ é aquela que minimiza a função objetivo F, indicando a solução ideal para este DCOP.

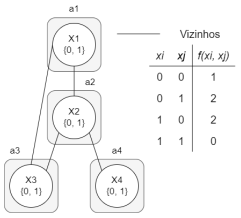


Figura 1: Exemplo de um DCOP

3.1. Algoritmos DCOP

Algoritmos DCOP são especialmente relevantes pelo suporte que oferecem no processo de tomada de decisão entre múltiplos agentes autônomos. Segue um breve resumo do funcionamento de três algoritmos descentralizados e síncronos [Fioretto et al., 2018] usados nesse trabalho.

O DPOP (*Distributed Pseudo-tree Optimization Procedure*) [Petcu e Faltings, 2005] é um algoritmo completo e síncrono que opera através de uma pseudo-árvore DFS (*Depth-First Search*) para otimizar problemas distribuídos. Funciona em três fases principais: organização dos agentes em uma pseudo-árvore, propagação de mensagens UTIL que contêm custos agregados de subproblemas de cada agente, e a propagação de mensagens VALUE, que direcionam a escolha de valores ótimos para as variáveis com base nas mensagens UTIL. Inicialmente, cada agente, começando pelas folhas, calcula e propaga custos para seus pais até a raiz. Após todas as mensagens UTIL serem recebidas pela raiz, inicia-se a fase de propagação de VALUE, onde cada agente seleciona e propaga o valor ótimo para suas variáveis, começando pela raiz até as folhas. Este método assegura a otimização eficiente, embora requeira uma grande quantidade de memória e seja criticado pelo tamanho exponencial das mensagens necessárias.

Os algoritmos de busca local incompletos, como o DSA (*Distributed Stochastic Algorithm*) [Zhang et al., 2005] e o MGM (*Maximum Gain Message*) [Maheswaran et al., 2004] operam trocando informações entre agentes vizinhos e atualizando as atribuições baseadas nas informações

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

recebidas. São projetados para melhorar iterativamente as soluções locais de cada agente e são conhecidos por sua capacidade de continuar melhorando a solução ao longo do tempo, embora não garantam encontrar a solução ótima.

O DSA difere do MGM ao introduzir uma componente estocástica na decisão de atualização dos valores das variáveis. No DSA, cada agente decide, com base em uma probabilidade p definida, se adota o novo valor que maximiza seu ganho local ou se mantém o valor atual, mesmo que outras opções também reduzam o custo, o que ajuda a evitar mínimos locais e promove uma exploração mais ampla do espaço de solução. Por outro lado, no MGM, o agente só atualiza seu valor se o ganho calculado for o maior entre todos os ganhos de seus vizinhos, seguindo uma abordagem mais determinística e competitiva. Esta diferença fundamental reflete uma abordagem mais agressiva no MGM para convergir rapidamente para melhores soluções locais, enquanto o DSA incorpora um elemento de aleatoriedade para potencialmente explorar soluções mais diversificadas, evitando assim ficar preso em soluções sub-ótimas.

4. Descrição da Proposta

Em nosso cenário, a gestão da iluminação pública é concebida como uma rede inteligente e adaptável onde os dispositivos IoT (atuadores e sensores) são fundamentais para a otimização do consumo energético, alinhando-se às necessidades variáveis do ambiente urbano. Os postes de iluminação (atuadores) possuem a capacidade de ajuste de luminosidade via dispositivos de dimerização. Por sua vez, os sensores monitoram aspectos como o volume do tráfego de veículos, a presença de pedestres e as condições climáticas, tais como a chuva, fornecendo dados para o ajuste dinâmico da iluminação dos postes.

Desta forma, quando um sensor detecta tráfego intenso, presença de pedestres ou chuva, a iluminação aumenta, enquanto em períodos de baixo tráfego de veículos sem a detecção de pedestres ou chuva, a luminosidade diminui.

4.1. Otimização da Iluminação Pública como um Problema DCOP

Considere P o conjunto de postes de iluminação, sendo v_i a variável que representa o nível de luminosidade de cada poste $p_i \in P$, onde $v_i \in D_p$. O domínio D_p define os possíveis níveis de luminosidade que cada poste pode assumir. Para cada poste de luz incide um conjunto de restrições associado a cada nível de luminosidade onde o custo total está relacionado à quantidade de conflitos entre as restrições de cada poste, sendo utilizado como parâmetro de comparação entre os algoritmos DCOP.

Considere S o conjunto de sensores (de tráfego, meteorológicos e de presença) disponíveis na infraestrutura de iluminação pública, sendo s_i^k a variável que representa uma informação do ambiente capturada por um dos respectivos sensores k referente a um poste p_i , onde $s_i^k \in D_s$. O domínio D_s engloba informações sobre o volume de tráfego e também indica se houve detecção de pedestres ou chuva próximo de um determinado poste. Os estados dos sensores s_i^k não são controláveis pelo sistema de gestão da iluminação, fornecendo apenas valores de leitura, utilizados para ajustar dinamicamente os níveis de iluminação dos postes.

Considere R como o conjunto de restrições definidas pelo gestor urbano. Cada restrição $r_i \in R$ é uma tupla condição-ação que depende de cada poste p_i e da leitura dos respectivos sensores s_i^k para ser ativada. A parte da condição específica define quando a restrição deve ser ativada (mudança no volume do tráfego, chuva ou presença de pedestres) e é representada por expressões booleanas relacionadas aos estados dos atuadores ou dos sensores, utilizando predicados binários ($>$, $<$, $=$). A parte da ação define o que deve acontecer quando a restrição é ativada. Por exemplo, se o sensor de tráfego de um determinado poste detectar um baixo volume de carros (nível de luminosidade 1) mas o sensor de presença detectar pedestres (nível de luminosidade 2), será atribuído

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

o nível de luminosidade 2 para esse poste, uma vez que a presença de pedestres é prioritária em comparação ao volume de tráfego.

O conjunto de restrições é crucial para que o sistema de gestão da iluminação possa ajustar os níveis de luz de forma dinâmica, assegurando que as metas de iluminação sejam atingidas sob diversas condições impostas pelo ambiente, maximizando o atendimento às restrições e minimizando o consumo de energia.

Assim, podemos formalizar o problema de otimização da iluminação pública como DCOP da seguinte forma:

- $A = \{a_1, a_2, \ldots, a_n\}$ é o conjunto de agentes, onde cada agente a_i está associado a um poste de luz p_i;

- $V = \{v_1, v_2, \ldots, v_n\}$ é o conjunto de variáveis v_i que representam o nível de luminosidade de cada poste $p_i \in P$;

- $S = \{s_1^k, s_2^k, \ldots, s_n^k \mid 1 \leq k \leq 3\}$ é o conjunto de sensores, sendo s_i^k a variável que representa o dado capturado pelo sensor k ($1 \leq k \leq 3$) de cada poste p_i, o qual é dotado de três sensores: tráfego (s_i^1), chuva (s_i^2) e pedestre (s_i^3);

- $D = \{D_1, D_2, \ldots, D_n\} \cup \{Ds_1^k, Ds_2^k, \ldots, Ds_n^k \mid 1 \leq k \leq 3\}$ é o conjunto de domínios de todas as variáveis, onde D_i contém os níveis de luminosidade de cada poste de luz p_i, e Ds_i^k os valores capturados por seus respectivos sensores;

- $C = \{\{c_1^k, c_2^k, \ldots, c_n^k\} \cup \{r_1^k, r_2^k, \ldots, r_n^k\} \mid 1 \leq k \leq 3\}$ é o conjunto de funções de custo (restrições), onde cada $c_i^k : D_i \to \mathbb{R}$ é uma restrição rígida que força a variável de cada sensor a não mudar seu valor durante o processo de otimização. Já cada $r_i^k : R_i \to \mathbb{R}$ é uma regra que atribuiu um valor de luminosidade para cada v_i dependendo da entrada de cada s_i^k. Desta forma, C determina grau de conflito de todos os postes envolvidos no processo de otimização.

  Sabendo que $k = 1$, $k = 2$ e $k = 3$, dizem respeito aos sensores de tráfego, chuva e pedestre, respectivamente, e que r_i^1 pode conter o estado de tráfego baixo ($r_i^{1^B}$), moderado ($r_i^{1^M}$) ou alto ($r_i^{1^A}$), as restrições rígidas que configuram as variáveis de entrada dos sensores são dadas por:

$$c_i^1 = \begin{cases} 0 & \text{se } s_i^1 = valortrafego \\ +\infty & \text{caso contrário} \end{cases}$$

$$c_i^2 = \begin{cases} 0 & \text{se } s_i^2 = valorchuva \\ +\infty & \text{caso contrário} \end{cases}$$

$$c_i^3 = \begin{cases} 0 & \text{se } s_i^3 = valorpedestre \\ +\infty & \text{caso contrário} \end{cases}$$

  onde $valortrafego$, $valorchuva$ e $valorpedestre$ são valores estabelecidos segundo a situação.

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

A função de custo não apenas considera o poste atual, mas também inclui o impacto nos postes adjacentes para as condições de tráfego (moderado e alto), chuva e pedestre, respectivamente. Assim temos:

$$
\begin{aligned}
r_i^{1^B} &= (s_i^1 \leq 500) \cdot |v_i - 1| \\
r_i^{1^M} &= (500 < s_i^1 \leq 1200) \cdot (|v_i - 2| + 10 \cdot |v_{i+1} - 2|) \\
r_i^{1^A} &= (s_i^1 > 1200) \cdot (|v_i - 3| + 10 \cdot |v_{i+1} - 3| + 10 \cdot |v_{i+2} - 2|) \\
r_i^2 &= 10 \cdot (s_i^2) \cdot (|v_i - 2| + 10 \cdot |v_{i+1} - 2|) \\
r_i^3 &= 20 \cdot (s_i^3) \cdot (|v_i - 3| + 10 \cdot |v_{i+1} - 3| + 10 \cdot |v_{i+2} - 2|)
\end{aligned}
$$

onde as expressões relacionais acima ($(s_i^1 \leq 500)$, $(500 < s_i^1 \leq 1200)$ e $(s_i^1 > 1200)$) assumem o valor 1 ou 0 dependendo de sua validade, ou falsidade, respectivamente. Como essas expressões tratam de valores disjuntos de s_i^1, apenas uma delas será ativada em cada instante.

A atribuição dos níveis de luminosidade dos postes para cada volume de tráfego seguiram as normas da ABNT NBR 5101, que trata sobre iluminação pública [Técnicas, 2018]. Já para detecção de pedestres e chuva, foram atribuídos os níveis de luminosidade 2 e 3, respectivamente. Desta forma temos:

$$
v_i = \begin{cases}
1 & \text{se } s_i^{1^B} \leq 500 \text{ (Baixo Tráfego)} \\
2 & \text{se } 500 < s_i^{1^M} \leq 1200 \text{ (Tráfego Moderado)} \\
3 & \text{se } s_i^{1^A} > 1200 \text{ (Alto Tráfego)} \\
2 & \text{se } s_i^2 = 1 \text{ (Detecção de Pedestre)} \\
3 & \text{se } s_i^3 = 1 \text{ (Chuva Detectada)}
\end{cases}
$$

- μ é a função de mapeamento que liga variáveis e restrições aos dispositivos de iluminação (agentes).

A função objetivo do problema DCOP para otimização da iluminação pública é formulada como:

$$
F = \min \left(\sum_{\substack{1 \leq i \leq n \\ 1 \leq k \leq 3}} c_i^k + \sum_{1 \leq i \leq n} (r_i^{1^B} + r_i^{1^M} + r_i^{1^A} + r_i^2 + r_i^3) \right).
$$

Este modelo DCOP busca a interação entre sensores, atuadores e restrições, adaptando a iluminação pública para responder dinamicamente às condições locais do ambiente dentro da infraestrutura de uma cidade inteligente.

5. Estudo de Viabilidade

O estudo de viabilidade foi realizado para avaliar a eficácia de três algoritmos DCOP discutidos na subseção 3.1, aplicados à modelagem proposta para a otimização da iluminação pública, visando principalmente a redução do consumo energético. Utilizou-se a biblioteca pyDCOP[1], uma ferramenta de código aberto ideal para aplicações IoT, que facilita a implementação de agentes distribuídos.

[1] https://pydcop.readthedocs.io/en/latest/

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

O experimento foi dividido em duas fases principais: inicialmente, foi feita uma comparação de desempenho entre os algoritmos DPOP, DSA e MGM, para cada cenário criado, utilizando um mesmo conjunto de dados sintéticos, para todos os sensores, sem variação ao longo do tempo. Na segunda fase, a análise focou nos níveis de luminosidade de cada poste sob condições de tráfego variáveis ao longo do tempo, utilizando dados reais, excluindo-se os sensores de pedestres e chuva para evitar viés na base de dados. Os detalhes técnicos e os resultados obtidos serão explorados nas subseções a seguir.

5.1. Análise Comparativa dos Algoritmos DCOP

Os algoritmos DCOP foram executados em quatro cenários fictícios que crescem de forma linear, com 10, 50, 100 e 500 postes de iluminação. Os critérios de avaliação incluíram a quantidade de vezes que cada algoritmo encontrou a solução ótima e a rapidez na entrega dos resultados. O DPOP, sendo um algoritmo completo, retornou soluções ótimas, com tempos de execução previsíveis em todos os cenários. No entanto, sua aplicação para 500 postes foi inviável devido a limitações de memória ocasionado pelo tamanho da pseudo-árvore gerada.

Para garantir a confiabilidade dos resultados e aferir a estabilidade dos algoritmos em condições variáveis, realizamos 100 iterações de teste para cada cenário de otimização.

Os algoritmos DSA e MGM, ambos incompletos e operando até uma condição de parada pré-definida de 20 ciclos, exibiram comportamentos distintos na frequência com que alcançaram a solução de custo ótimo. O DSA demonstrou uma boa consistência em encontrar a solução ótima em todos os cenários nas 100 iterações executadas, variando apenas a quantidade de vezes que isso ocorre em ciclos específicos, conforme ilustrado na figura 2. Em um mesmo cenário, o ciclo em que a solução ótima começa a ser alcançada pode variar dependendo do valor de p utilizado, exemplificado nas figuras 3 e 4 que ilustram a frequência com que o custo ótimo foi alcançado em cada cenário ao longo de 20 ciclos para diferentes configurações de p.

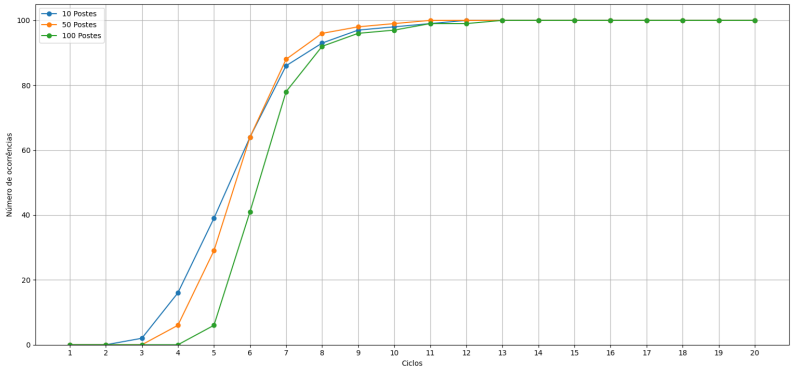


Figura 2: Comparativo entre as áreas de otimização - DSA (p=0.7)

Essa análise detalhada mostra que, em cenários de menor escala, valores mais altos de p resultam em uma convergência mais rápida ao custo ótimo, demonstrando a eficácia do algoritmo em responder a mudanças frequentes. Em contrapartida, nos cenários com maior número de postes, valores mais baixos de p promovem uma progressão mais lenta na obtenção do custo ótimo, sugerindo que uma abordagem mais conservadora pode ser benéfica em aplicações de maior complexidade.

O MGM, por outro lado, exibe um comportamento distinto em comparação ao DSA. Embora o MGM também consiga alcançar a solução de custo ótimo em todos os cenários analisados, ele não o faz consistentemente em todas as 100 iterações, como observado na figura 5. A probabilidade de encontrar a solução ótima tende a diminuir à medida que a complexidade do cenário

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

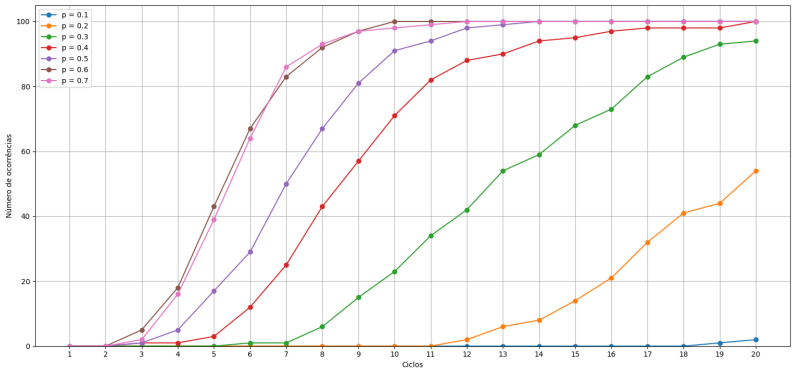


Figura 3: Área de Otimização com 10 Postes

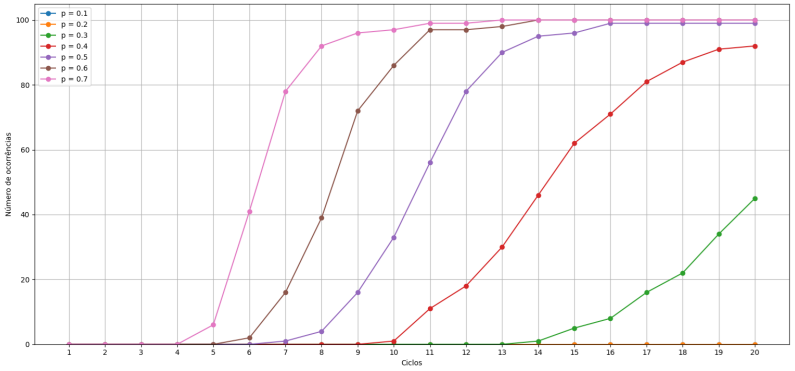


Figura 4: Área de Otimização com 100 Postes

aumenta, uma característica que pode ser atribuída à tendência do MGM de ficar preso em soluções sub-ótimas. Além disso, a solução ótima no MGM é geralmente alcançada em ciclos mais avançados em comparação ao DSA, quando ambos são aplicados aos mesmos cenários, destacando uma diferença significativa no comportamento desses dois algoritmos de busca local.

Por último, foram realizadas análises complementares para os cenários de 10, 50 e 100 postes para examinar as diferenças de desempenho entre os algoritmos DPOP, DSA e MGM em relação ao tempo necessário para alcançar soluções ótimas. Na figura 6 são apresentadas as análises para 50 e 100 postes. Observa-se que os algoritmos de busca local, DSA e MGM, demonstram a capacidade de encontrar soluções ótimas em um tempo geralmente inferior ao do DPOP. O DSA apresenta tempos mais baixos em comparação ao MGM, indicando uma eficiência e consistência superiores na obtenção de soluções ótimas com mínima variação de tempo para um mesmo ciclo para cada cenário. Esta observação sugere que o DSA pode ser particularmente vantajoso para cenários que exigem respostas rápidas e confiáveis.

Considerando os resultados apresentados, podemos concluir que o DSA é o algoritmo mais adequado para o problema proposto. Além de retornar resultados em todas as 100 iterações, como o DPOP, o DSA o faz em menos tempo e demonstra potencial para escalar eficientemente em cenários de maior complexidade, algo que o DPOP não conseguiu para o cenário de 500 postes.

5.2. Análise comparativa dos resultados da otimização

Prosseguindo com a análise dos algoritmos DCOP, esta subseção foca na aplicação prática dos algoritmos DPOP e DSA utilizando uma base de dados real. A escolha desses dois algoritmos

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

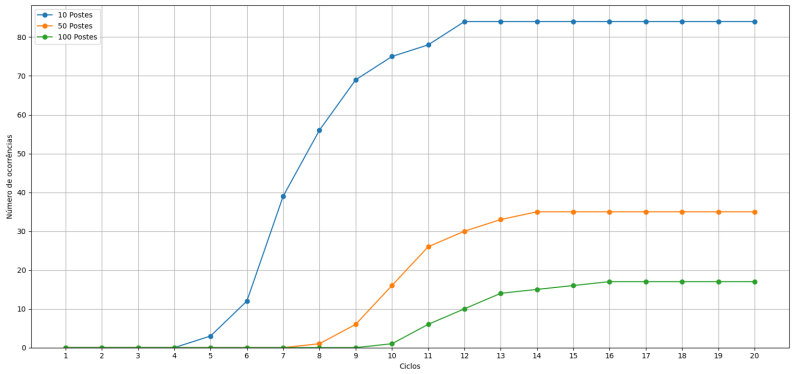


Figura 5: Comparativo entre as áreas de otimização - MGM

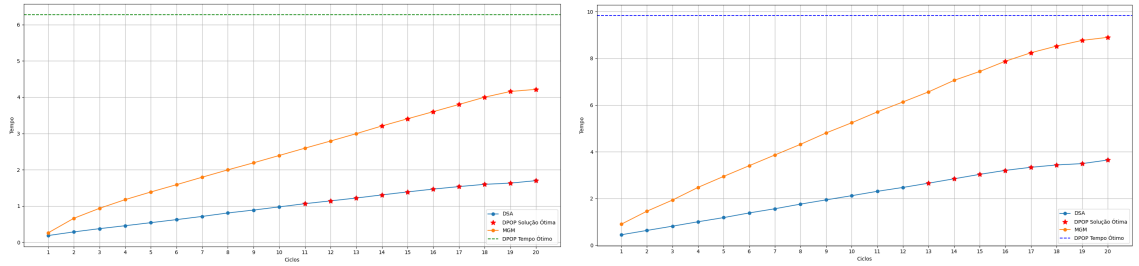


Figura 6: Comparação do Tempo para Soluções Ótimas - 50 e 100 postes

baseia-se em seus desempenhos, conforme discutido anteriormente, onde ambos demonstraram alcançar soluções de custo ótimo de forma consistente, garantido que a saída dos níveis de iluminação estão de acordo com a informação captada pelos sensores, desta forma tornando-os ideais para avaliar a aplicabilidade do modelo DCOP em condições dinâmicas.

Para esse teste, utilizou-se um conjunto de dados da Autarquia de Trânsito e Transporte Urbano do Recife (CTTU)[2], que detalha o fluxo de veículos em cinco ruas durante o mês de janeiro de 2024. Dentro do modelo DCOP, as informações de tráfego de cada rua, durante o período de funcionamento dos postes, são utilizadas para ajustar a iluminação de forma dinâmica.

Em [P. Fragoso et al., 2020], foram realizadas simulações no software Dialux para determinar a potência ideal de diversos modelos de lâmpadas LED. O mapeamento dessas potências foram aplicadas a seguinte dinâmica de fluxo de veículos de acordo a uma faixa horária: 18h-22h (alto fluxo), 22h-00h (fluxo moderado) e 00h-06h (baixo fluxo). Para este estudo, aplicou-se a técnica de dimerização em uma lâmpada de 60W, ajustando a potência para 42W em períodos de fluxo moderado e para 22W em períodos de baixo fluxo, sendo a potência nominal de 60W utilizada nos horários de alto fluxo. Assim, ao mapear o tráfego de veículos para esses valores de potência ajustados, o modelo DCOP, utilizando os algoritmos DPOP e DSA, foi capaz de gerenciar a iluminação pública de forma mais eficiente e adaptativa, contribuindo para reduções significativas no consumo de energia

Essa redução do consumo energético pode ser observado na figura 7 a qual ilustra os resultados do consumo energético para um conjunto de 50 postes de iluminação em três datas específicas ao longo de um mês, comparando o desempenho do modelo DCOP empregando os algoritmos DPOP e DSA com métodos tradicionais de iluminação. O gráfico demonstra que o modelo adap-

[2]http://dados.recife.pe.gov.br/ca/dataset/velocidade-das-vias-quantitativo-por-velocidade-media-2024

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

tativo apresentou uma economia de energia, com custos variando conforme a demanda de tráfego e horário. Em contraste, os métodos estático e de horário pré-definido mostram um consumo energético mais alto e constante, independente da variação de demanda ao longo da noite. Esta análise evidencia o benefício do uso de tecnologias adaptativas em sistemas de iluminação pública, promovendo não apenas maior eficiência energética, mas também adaptabilidade em resposta às condições reais de uso.

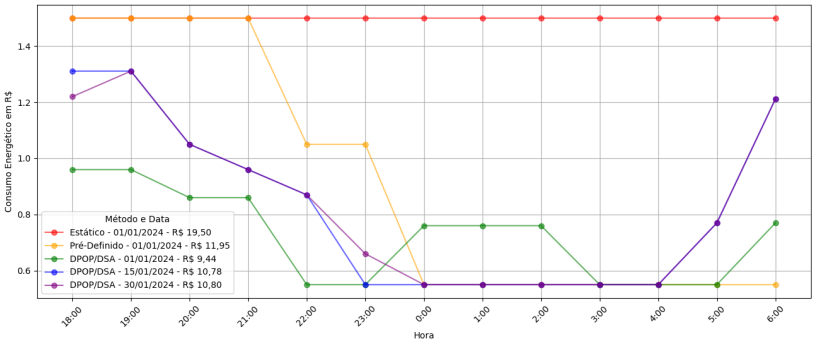


Figura 7: Resposta adaptativa do modelo DCOP

6. Conclusão

Este trabalho propôs uma gestão de iluminação urbana utilizando um modelo DCOP com aplicação em IoT, visando otimizar o uso energético em cenários urbanos dinâmicos. Demonstramos, por meio de um estudo de viabilidade, que a intensidade da iluminação pode ser adaptada em tempo real conforme variáveis ambientais como tráfego de veículos, presença de pedestres e condições climáticas. Os resultados ressaltam a eficácia do modelo proposto em reduzir o consumo de energia quando comparado com sistemas de iluminação tradicionais.

A análise comparativa dos algoritmos DCOP revelou que o DSA, embora incompleto, apresenta desempenho superior em alcançar soluções ótimas em diversos cenários de teste, destacando-se especialmente em condições de maior complexidade e demanda variável. A aplicação prática do modelo confirmou sua relevância e aplicabilidade, mostrando uma gestão de iluminação pública mais eficiente e responsiva

Como trabalhos futuros propomos incluir dados sintéticos de pedestres e chuva na base de dados da CTTU, permitindo uma simulação mais abrangente das variáveis ambientais que influenciam a demanda por iluminação. Além disso, planejamos desenvolver modelos customizáveis baseados em dados de iluminação pública específicos da cidade de Niterói. Com isso, objetivamos criar pequenos cluster distribuídos para o controle adaptativo da iluminação pública de uma determinada região ou bairro, refletindo de maneira mais precisa as condições reais de uso.

Agradecimentos. Este trabalho foi parcialmente financiado pelo CNPq (proc. 405940/2022-0 e 152041/2022-2), CAPES (88887.954253/2024-00) e pela FAPERJ (200.972/2022). Esta pesquisa é parte do INCT de Redes de Comunicação e Internet das Coisas Inteligentes (ICoNIoT). A Professora Flavia Delicato é bolsista de produtividade do CNPq.

Referências

Ali, A., Arib, S., e Aknine, S. (2021). A new parking space allocation system based on a distributed constraint optimization approach. In *Proceedings of the 13th International Conference on Agents and Artificial Intelligence*. SCITEPRESS - Science and Technology Publications. URL `http://dx.doi.org/10.5220/0010249201960204`.

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br

Corrêa, A. (2015). Alocação de tarefas de desastre na plataforma rmasbench: uma abordagem baseada em passagem de mensagens e formação de grupos. Master's thesis, (Mestrado em Computação) - Instituto de Informática - Universidade Federal do Rio Grade do Sul, Porto Alegre, RS.

Fioretto, F., Pontelli, E., e Yeoh, W. (2018). Distributed constraint optimization problems and applications: A survey. *Journal of Artificial Intelligence Research*, 61:623–698. ISSN 1076-9757. URL http://dx.doi.org/10.1613/jair.5565.

Junges, R. (2007). Comparação de algoritmos para otimização de restrições distribuídas em um cenário de controle semafórico. Master's thesis, (Mestrado em Computação) - Instituto de Informática - Universidade Federal do Rio Grade do Sul, Porto Alegre, RS.

Junges, R. e Bazzan, A. L. (2007). Modelling synchronization of traffic lights as a dcop. In *Proceedings of the 5th European Workshop on Multiagent Systems*, p. 564–579.

Maheswaran, R., Pearce, J., e Tambe, M. (2004). Distributed Algorithms for DCOP: A Graphical-Game-Based Approach. In *Distributed Algorithms for DCOP*, p. 432–439.

Modi, P. J., Shen, W.-M., Tambe, M., e Yokoo, M. (2003). An asynchronous complete method for distributed constraint optimization. In *Proceedings of the second international joint conference on Autonomous agents and multiagent systems*, AAMAS03. ACM.

P. Fragoso, A., Zamboti Fortes, M., A.P. Moraes, D., P. Lopes, A., e M. E. Pereira, A. (2020). Análise da economia de energia com dimerização quando da aplicação da tecnologia led na iluminação pública - estudo de caso: Cidade do rio de janeiro. In *Anais do Simpósio Brasileiro de Sistemas Elétricos 2020*, Anais SBSE 2020.

Pasolini, G., Toppan, P., Zabini, F., Castro, C. D., e Andrisano, O. (2019). Design, deployment and evolution of heterogeneous smart public lighting systems. *Applied Sciences*, 9(16):3281. ISSN 2076-3417. URL http://dx.doi.org/10.3390/app9163281.

Petcu, A. e Faltings, B. (2005). A scalable method formultiagent constraint optimization. In *9thInternational Joint Conference on Artificial Intelligence, pages266*, volume 271.

Rust, P., Picard, G., e Ramparany, F. (2016). Using message-passing dcop algorithms to solve energy-efficient smart environment configuration problems. In *IJCAI*, p. 468–474.

Souza, A. d. C. B. P., Fortes, M. Z., Santos, M. T., e Medina, V. P. (2022). Potencial de eficientização dos sistemas de iluminação pública. *REVISTA DE TECNOLOGIA APLICADA*, 10(3):18–23.

Técnicas, A. B. d. N. (2018). *ABNT NBR 5101: iluminação pública: procedimento*. Abnt. ISBN 978-85-07-07743-5.

Zhang, W., Wang, G., Xing, Z., e Wittenburg, L. (2005). Distributed stochastic search and distributed breakout: properties, comparison and applications to constraint optimization problems in sensor networks. *Artificial Intelligence*, 161(1). ISSN 0004-3702. URL https://www.sciencedirect.com/science/article/pii/S0004370204001481.

Zhang, W., Xing, Z., Wang, G., e Wittenburg, L. (2003). An analysis and application of distributed constraint satisfaction and optimization algorithms in sensor networks. In *AAMAS*, volume 3, p. 185–192. Citeseer.

DOI: 10.59254/sbpo-2024-193506
https://proceedings.science/p/193506?lang=pt-br