

# Usando Inteligência Computacional para Problemas em Telecomunicações

Carmelo J. A. Bastos-Filho, *Senior Member, IEEE*, Danilo R. B. Araújo, *Member, IEEE*, and Joaquim F. Martins-Filho, *Senior Member, IEEE*

**Resumo**—O mundo está passando por uma transformação digital em que pessoas, coisas e processos exigem cada vez mais conectividade. Neste cenário, os problemas relacionados a projeto, implantação e operação de redes de telecomunicações estão ficando cada vez mais complexos e ferramentas mais sofisticadas vêm sendo requeridas para a resolução de problemas. Neste contexto, soluções baseadas em Inteligência Computacional surgem como possíveis soluções para problemas de alta complexidade em telecomunicações, desde redes de acesso a redes de transporte. Este artigo apresenta alguns tipos de técnicas baseadas em inteligência computacional e exemplifica problemas em sistemas de telecomunicações que podem ser resolvidos com estas técnicas.

**Index Terms**—Telecomunicações; redes de telecomunicações; Inteligência Computacional; Inteligência Artificial.

## I. TELECOMUNICAÇÕES E INTELIGÊNCIA COMPUTACIONAL

**D**EPOIS de três revoluções industriais, o planeta está passando por seu quarto grande processo de transformação, a transformação digital [1]. Existe uma demanda cada vez maior por informação e, ao mesmo tempo, a quantidade de dados disponíveis vem crescendo exponencialmente nos últimos anos. Por um lado, os dispositivos que podem gerar informação em tempo real, como smartphones, câmeras e dispositivos sensores, foram barateados e popularizados. Por outro lado, também aumentou a disponibilidade para o armazenamento de dados em grandes centros de dados (Datacenters) [2]. Este tipo de situação gera uma demanda por conectividade entre pessoas e dispositivos, e destas pessoas e dispositivos com os datacenters. Estas demandas diferentes geram a necessidade por redes de diferentes tipos e granularidades, implicando em um aumento sem precedentes na complexidade dos sistemas e redes de comunicações. Com o aumento de complexidade, surgem vários problemas relacionados a projeto, implantação e operação de redes de telecomunicações. Estes problemas podem ser de tal natureza que muitas vezes as técnicas heurísticas utilizadas tradicionalmente não conseguem resolver. Exemplos disto são problemas de tomada de decisão adaptativa para operação, otimização de projetos de implantação de redes, projetos de expansão de redes, modelos para representação de conhecimento para modelagem em plano de controle,

entre outros. Neste contexto, surge a possibilidade de utilizar Inteligência computacional para resolver estes problemas. Inteligência computacional pode ser entendida como uma área de conhecimento que estuda sistemas e algoritmos que operam em cenários com imprecisão e estocasticidade. Sistemas inteligentes apresentam tipicamente duas características fundamentais, guardam memória de processos anteriores e são capazes de se adaptar de acordo com o indicativo de sucesso ou com base na estrutura das informações apresentadas. Existe uma certa confusão no entendimento do que vem a ser inteligência computacional e inteligência artificial. Muitas vezes técnicas, ou conjuntos de técnicas bem difundidas, como as técnicas de Deep Learning [3] são apresentadas como técnicas de inteligência artificial. Entretanto, inteligência computacional e inteligência artificial têm formalmente conceitos diferentes. Enquanto o termo inteligência artificial é geralmente utilizado para descrever sistemas que tentam imitar o comportamento de sistemas complexos (usando uma abordagem top-down), o termo inteligência computacional é geralmente utilizado para descrever sistemas que são compostos por agentes reativos simples que interagem gerando a emergência de um comportamento que pode ser usado para resolver problemas complexos. Inteligência computacional também tem sido mencionada com outros termos, como Computação Cognitiva, termo cunhado pela IBM [4]. As principais áreas de Inteligência Computacional são as Redes neurais artificiais; Computação Evolucionária e Inteligência de Enxames; e Lógica nebulosa. As redes neurais artificiais são inspiradas no comportamento de neurônios e apresentam várias arquiteturas, que podem ser usadas para diversas finalidades [5]. O estudo e concepção de algoritmos de Computação Evolucionária e Inteligência de Enxames foram baseados na teoria da evolução de Darwin e no comportamento coletivo de enxames, respectivamente, e são utilizados principalmente para processos de otimização e busca [6]. Lógica nebulosa, que também é conhecida como lógica Fuzzy, é uma forma diferente de representar informação a partir do conceito de grau de pertinência e representações semânticas de informação [7]. Este artigo tem como objetivo apresentar algumas das técnicas de inteligência computacional usando como referencial o tipo de problema atacado, e exemplos de como estas técnicas podem ser usadas para resolver problemas em telecomunicações. O restante deste artigo está estruturado da seguinte forma: na Seção 2 são apresentados tipos de problemas clássicos e exemplos de técnicas de inteligência computacional que podem ser usadas para resolver estes problemas; na Seção 3 são apresentados exemplos de soluções para problemas em telecomunicações

Carmelo J. A. Bastos-Filho é professor da Universidade de Pernambuco, e-mail: carmelofilho@upe.br.

Danilo R. B. Araújo é professor da Universidade Federal Rural de Pernambuco.

Joaquim F. Martins-Filho é professor da Universidade Federal de Pernambuco.

usando Inteligência Computacional; e na Seção 4 é apresentada uma discussão de possíveis oportunidades de aplicação.

#### *A. Tipos de problemas e possíveis técnicas para solução destes problemas usando Inteligência Computacional*

A classificação de problemas encontrados em telecomunicações e em outros domínios do conhecimento geralmente é baseada em um modelo de caixa preta (black box). Um dos problemas possíveis é o de classificação ou regressão. Tipicamente um problema de classificação se caracteriza por definir em que classe uma determinada situação (conjunto de entradas) está enquadrada. Para um determinado problema, pode-se ter duas ou mais classes e é comum aparecerem situações em que se é difícil estabelecer de forma simples a relação das variáveis de entrada com as diversas classes. Inclusive, é comum que o grau de pertencimento a uma classe apresente relações não-lineares com as variáveis e entre as variáveis. A definição do modelo também pode ser colocado como um processo de regressão, cujo objetivo é definir matematicamente o modelo. Por outro lado, em um problema de otimização típico, o modelo é conhecido, bem como um conjunto de saídas desejadas e a tarefa é encontrar as entradas que produzem as saídas desejadas. Um exemplo teórico típico de otimização é o problema do caixeiro viajante, em que deseja-se definir o itinerário em um grafo de forma a minimizar a distância com a restrição de inclusão necessária de todas as cidades. Embora pareça ser um problema abstrato, ele pode ser instanciado em diversos cenários práticos, e o roteamento em redes de telecomunicações é um exemplo prático de especialização deste problema. Já em um problema de clusterização, o objetivo é agrupar dados em subgrupos de acordo com similaridades encontradas dentro da base de dados. De forma geral, este tipo de atividade é executada de forma não-supervisionada. Esta seção tem como objetivo apresentar exemplos de técnicas de inteligência computacional para classificação, regressão, otimização e clusterização.

1) *Técnicas para classificação/regressão*: Problemas que podem ser enquadrados como problemas de classificação ou de regressão são muito comuns em sistemas ou redes de telecomunicações. Com isso, foram propostas diversas técnicas que se propõem a fazer isto. Um exemplo clássico são as redes neurais artificiais (RNA), que foram propostas no meio do século XX, mas somente a partir da década de 1980 começaram a ser amplamente empregadas em problemas de diversas áreas do conhecimento. O tipo mais conhecido de RNA é o perceptron de múltiplas camadas (MLP, Multi Layer Perceptron). O MLP é composto de elementos fundamentais chamados de neurônios artificiais, que por sua vez são elementos que somam entradas ponderadas por pesos, e o somatório é submetido a uma função de ativação não linear para geração de um valor de saída do neurônio. As funções de ativação mais conhecidas são sigmóide logística, tangente hiperbólica e RELU [8]. Os neurônios artificiais são dispostos em paralelo em três tipos de camadas (entrada, escondida e de saída). Os elementos que ligam as camadas são chamados de sinapses, que têm pesos associados. O processo de aprendizado está

diretamente relacionado com a definição destes pesos, que de certa forma estabelece as relações não lineares entre as saídas e entradas. Existem diversos algoritmos para realizar este processo de treinamento dos pesos, entre eles o backpropagation, Levenberg Marquardt e SGD [9]. É importante frisar que em todos os casos existe um processo de representação de conhecimento nos pesos das sinapses. As RNAs vêm sendo largamente utilizadas em problemas de classificação, regressão ou previsão desde a década de 1980. Entretanto, na maioria absoluta das aplicações até poucos anos atrás, as aplicações necessitavam que as entradas apresentadas fossem características explícitas do processo, que por sua vez representam conhecimento prévio do sistema em questão. Um exemplo disso seria a classificação de uma imagem baseada em características processadas da imagem para que a RNA tome a decisão. Este processo exige uma etapa anterior para determinação destas características e, quando muitas, características estão disponíveis, também é necessária uma etapa de definição de quais características são relevantes. Este processo tipicamente é dependente do problema e exige conhecimento prévio do engenheiro de sistemas que está projetando a solução. Há pouco mais de uma década, foi viabilizada a utilização de arquiteturas que tem mais de uma camada escondida. Estas redes ficaram famosas como as redes de aprendizado profundo, Deep Learning [3]. Também foi mostrado que as camadas de rede podem utilizar os famosos neurônios artificiais, mas podem usar outros elementos, como matrizes de convolução ou filtros de redução de dimensionalidade (max pooling), dando origem às Redes neurais convolucionais (ConvNets) [10]. Esta é uma área em plena discussão e muitas arquiteturas vêm sendo exploradas como YOLO, SSD, SPNN, entre outras. Todavia, o aspecto mais importante destas redes é que elas são mais adequadas para serem aplicadas em problemas em que os dados de entrada são crus, ou seja, as entradas da rede não são necessariamente um conjunto de características, e sim os sinais em si, como séries temporais, imagens, espectrogramas de sinais, entre outros. Outro tipo de técnica que ficou muito conhecida e é amplamente utilizada é a máquina de vetor suporte (SVM, Support Vector Machine). As SVM basicamente utilizam um conceito fundamental parecido com as RNA tradicionais, que é de criar uma representação que separa classes que pertencem ao problema, mas neste caso a forma de separação é diferente. As SVMs definem hiperplanos que separam com margem máxima os protótipos que definem as classes, ou seja, são definidas superfícies que separam as classes utilizando as matrizes invertidas de Mel-Penrose [11]. As SVMs tem apresentando bom desempenho em diversos tipos de problemas, mas tipicamente apresentam um custo computacional alto e são dependentes dos protótipos utilizados para definição dos hiperplanos.

#### *B. Técnicas para otimização*

Existem diversos tipos de problema de otimização e basicamente o objetivo é determinar os valores para um conjunto de variáveis de entrada que maximizam ou minimizam os valores de uma ou mais funções de aptidão. Esta função de aptidão basicamente estabelece uma relação biunívoca entre

as variáveis de entrada e um objetivo de otimização, que pode ser de projeto ou operação. Os processos de otimização podem ser classificados em diversas dimensões, de variáveis contínuas ou discretas, combinatorial ou de identificação de regiões promissoras no espaço de decisão, estática ou dinâmica, mono-objetivo ou multi-objetivos, entre outros. Um problema frequente em projeto de redes é a otimização em alta dimensionalidade. Neste tipo de problema, existe um elevado número de variáveis de entrada, como por exemplo centenas de variáveis. As técnicas tradicionais tipicamente não são capazes de apresentar soluções ótimas para este tipo de problema. Neste contexto, surgem como opção as meta-heurísticas, que são métodos geralmente baseados em populações de agentes reativos simples, que interagem entre si de forma iterativa para buscar soluções nestes vastos espaços de decisão. Não existe a garantia de que as soluções para estes problemas são ótimas, até pela própria estocasticidade das abordagens. Entretanto, busca-se prover no final do processo, soluções que sejam satisfatórias, definidas neste caso como soluções que atendam requisitos de projeto ou operação. Para problemas em alta dimensionalidade, surgem como possibilidades as técnicas de computação evolucionária e inteligência de enxames. Existem problemas em que o projetista do sistema pode ter interesse em otimizar mais de um objetivo ao mesmo tempo, como por exemplo maximizar desempenho e minimizar custo de implantação de uma rede. Se estes objetivos forem conflitantes e não se sabe exatamente a relação de ponderação dos objetivos, é necessário utilizar algoritmos que sejam capazes de avaliar e comparar as soluções de uma forma mais adequada. Uma das formas é a utilização do critério de dominância, em que as soluções são comparadas em seus diversos objetivos. Uma solução domina outra se for melhor em pelo menos um dos objetivos e não for pior nos outros objetivos. Geralmente usa-se este tipo de abordagem para avaliar as soluções obtidas por agentes reativos simples, e as melhores soluções (não dominadas) são guardadas em um arquivo externo ou utiliza-se elitismo para manter o conhecimento das melhores soluções no processo iterativo. Existem exemplos destes algoritmos em computação evolucionária e inteligência de enxames. Entre os de computação evolucionária podem ser citados o NSGA-II [12], SPEA2 [13] e MOEA/D [14]. Entre os algoritmos oriundos da área de inteligência de enxames podem ser citados o SMPPO [15], MOPSO-CDR [16] e MOABC [17]. Em alguns outros problemas de engenharia, o número de objetivos conflitantes pode ser maior e técnicas baseadas exclusivamente no conceito de dominância podem não apresentar capacidade de discriminação das soluções de forma a garantir a convergência. Este tipo de problema é conhecido como otimização com muitos objetivos. Tipicamente estes problemas são de difícil solução e são necessárias técnicas complementares para visualização das soluções obtidas. Exemplo de algoritmos para este cenário baseados em computação evolucionária e inteligência de enxames são o NSGA-III [18] e o MaOPSO [19], respectivamente.

### C. Técnicas para clusterização

O objetivo em um problema de clusterização é agrupar dados em subgrupos de acordo com similaridades encontradas

dentro da base de dados analisada. De forma geral, este tipo de atividade é executada de forma não-supervisionada. Um dos algoritmos de clusterização mais tradicionais e utilizado é o K-Means, por ser eficiente e simples. Todavia, o K-means apresenta problemas de convergência para ótimos locais e dependência com o processo de otimização quando aplicados em bases de dados maiores e com entrelaçamento de dados [20]. Uma alternativa é o algoritmo Fuzzy C-Means, que faz uso da lógica de agrupamento fuzzy, isto é, o conceito de que determinada amostra pode não pertencer a somente um grupo (como no K-Means), mas sim a diversos grupos, cada qual com seu grau de pertinência [21]. Os algoritmos clássicos tipicamente utilizam processos iterativos para determinar os centróides dos clusters que definem os grupos no espaço de decisão. Estes algoritmos clássicos, como K-means e Fuzzy C-means, são de fácil compreensão, mas podem não funcionar quando o número de dimensões envolvidas no processo de clusterização é muito alta. Uma alternativa é a utilização de técnicas de clusterização utilizando inteligência de enxames. Como exemplo, podem ser citadas duas variantes do algoritmo PSO: PSO para clusterização, e uma abordagem híbrida combinando PSO. A otimização de enxame de partículas para agrupamento (PSOC) é uma adaptação do PSO para resolver problemas de agrupamento [22] [23]. O método funciona considerando a abordagem parcial, com o uso de centróides e os centróides são definidos utilizando o PSO diretamente. Neste caso, a função de aptidão pode ser o índice silhueta ou outra medida que maximize a distância entre os centróides e minimize a distância dos membros do cluster e seu centróide. Por outro lado, como o algoritmo K-means é certamente o método mais conhecido e amplamente utilizado para resolver tarefas de clustering, a hibridização do K-means com o PSO é, de fato, bastante simples e existem duas possibilidades. No primeiro, o K-means é executado até sua convergência. Então, a solução é assumida como uma das partículas no enxame PSO. As outras partículas são geradas aleatoriamente, e o algoritmo PSO atualiza a velocidade e posição até que o critério de parada seja satisfeito. Essa abordagem é chamada algoritmo PSOKM [24]. A segunda proposta executa o processo inverso: o PSOC é executado até um determinado número de iterações e a melhor solução encontrada é assumida como os centróides iniciais dos K-means. Então, o K-means é executado para refinar a solução obtida pelo PSOC, gerando o algoritmo KMPSOC [25].

## II. EXEMPLOS DE SOLUÇÕES EM TELECOMUNICAÇÕES USANDO INTELIGÊNCIA COMPUTACIONAL

### A. Exemplos de aplicação para classificação/regressão

Alguns estudos já demonstraram que é possível aplicar técnicas de aprendizagem de máquinas para diminuir o custo computacional de ferramentas para análise de enlaces ópticos. Jargon et. al [26] desenvolveram um modelo de rede neural artificial (RNA) para identificar separadamente três penalidades da camada física (OSNR, dispersão cromática e PMD). Neste trabalho a RNA foi treinada a partir de parâmetros de diagramas de olho. Shen et. al [27] desenvolveram um modelo de RNA semelhante, mas treinado a partir de histogramas de

amostragem assíncrona (Asynchronous Amplitude Histograms - AAHs). Embora o uso de modelos substitutos para predição de desempenho de enlaces ópticos seja um avanço e uma alternativa viável aos simuladores de enlaces, o uso dessa mesma abordagem para avaliação do desempenho global de uma rede é ainda mais desafiante. Em [28], os autores propõem uma metodologia para obter um modelo substituto para avaliação da probabilidade de bloqueio de redes ópticas. No artigo é proposta a seleção de características essenciais para um preditor baseada em análise de componentes principais. O modelo substituto proposto usa redes perceptron multicamadas (MLP), treinadas pelo método backpropagation. A abordagem proposta em [28] oferece um speedup de até 7500 vezes com erros na ordem de  $10^{-4}$ . A Fig. 1 apresenta estimativas obtidas para a rede NSFNET usando uma MLP em comparação com as obtidas por um simulador de redes (SIMTON). A MLP deste exemplo foi modelada com 7 parâmetros na camada de entrada, a saber: número de comprimentos de onda disponíveis, fator de isolamento das portas dos ROADMs, comprimento médios dos caminhos (em km), coeficiente de agrupamento da topologia física, concentração de rotas, densidade de enlaces, entropia da TDF dos autovalores do laplaciano da rede. Com base em inspeção visual da figura, é possível perceber que os erros de estimativas são baixos. Por outro lado, o simulador de redes exige um tempo de processamento de 3950 ms até 7533 ms, enquanto a MLP exige apenas 1 ms.

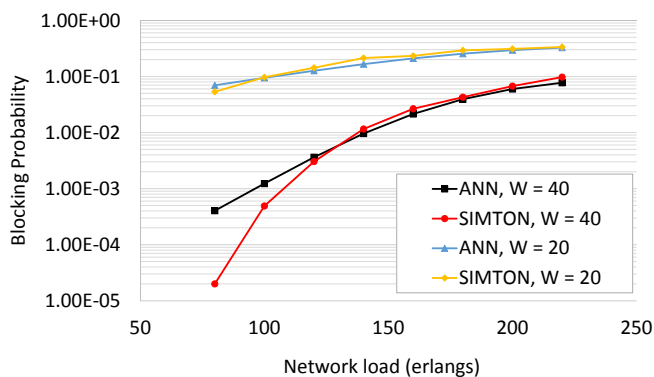


Figura 1: Probabilidade de bloqueio vs. carga da rede para um simulador de redes e para uma MLP, treinada com dados da rede óptica [3].

Em [29], os autores utilizaram redes neurais para regressão de dados das máscaras de amplificadores ópticos. Com o novo meta-modelo obtido é possível oferecer uma caracterização contínua da curva ganho e figura de ruído com erros de estimativa abaixo de 0,1 dB. A Fig. 2a é um exemplo de curva de ganho gerada pela rede perceptron multicamadas, variando a potência de entrada e de saída com resolução de 0,1 dB. A Fig. 2b é um exemplo de curva de figura de ruído gerada pela rede perceptron multicamadas, variando a potência de entrada e de saída com resolução de 0,1 dB.

### B. Exemplos de aplicação para otimização

Algoritmos de otimização multiobjetivos foram usados no passado para o projeto de topologias de rede em geral, e

em especial para o projeto de redes ópticas [30, 31, 32]. Contudo, abordagens multi-objetivas que consideram redes sujeitas a tráfego dinâmico são ainda mais desafiantes, pois as simulações que oferecem o desempenho de redes com tráfego dinâmico geralmente são baseadas no método de Monte Carlo. Por exemplo, a proposta de Chaves et. al [30] exige diversos dias para otimizar uma rede óptica de 14 nós que usa a probabilidade de bloqueio como um dos objetivos conflitantes. Nesta linha, novos estudos foram desenvolvidos para combinar o conceito de modelos substitutos, mencionados na Seção 3.1, com o processo de otimização de redes. Em [33] é proposta uma abordagem evolucionária para otimização multiobjetiva que considera um modelo substituto para avaliação do desempenho da rede. De acordo com este estudo, o uso de Inteligência Computacional permitiu alcançar projetos de redes de qualidade superior exigindo apenas 12% do tempo requerido pelas abordagens anteriores. A Fig. 3 apresenta uma curva de probabilidade de bloqueio vs. custo da rede para a abordagem proposta (quadrados vermelhos) em comparação com uma abordagem tradicional (losango azul) e para as melhores soluções “possíveis” (triângulos verdes). Com base na inspeção visual da Fig. 3 é possível perceber que a abordagem proposta consegue obter projetos de rede mais próximos dos melhores compromissos possíveis, ou seja, com baixo custo e baixa probabilidade de bloqueio.

### C. Exemplos de aplicação para clusterização

Algoritmos de clusterização também foram usados com sucesso no passado para tratar problemas envolvendo redes de telecomunicações. Younis, Krunch e Ramasubramanian [34], apresentam diferentes abordagens de clustering que foram propostas para redes de sensores sem fio (Wireless Sensor Networks - WSNs). O trabalho descreve os benefícios no uso desta técnica, inclusive em função da longevidade das baterias dos sensores. Maheswari, Meenalochani e Sudha [35] realizam uma série de testes com cluster em WSNs alterando o posicionamento tanto da base de observação quanto dos nós. Os resultados do trabalho apontam que para o consumo total da rede ser mínimo, o sensor cabeça de cluster deve estar no centróide do cluster. Nascimento et al [36] propuseram uma nova abordagem para o planejamento de redes ópticas que considera a definição da posição dos nós terminais como uma variável de decisão do problema. Para resolver o problema, algoritmos de clustering foram empregados para determinação da posição dos nós terminais, de forma a corresponder ao centróide dos clusters. Além disso, o processo de otimização permite uma busca local na posição inicialmente definida pelo algoritmo de clustering. Os resultados deste trabalho demonstram que a tarefa de pré-processamento baseada em clustering é promissora para o processo de melhoria da qualidade das soluções e aceleração do processo de convergência do planejamento. O estudo aplicou o conceito de clustering em conjunto com otimização evolucionária com busca local para fornecer projetos de redes ópticas que pudessem cobrir todos os 185 municípios do estado de Pernambuco. A Fig. 4 ilustra o resultado fornecido por um algoritmo de clustering para dividir o estado de Pernambuco quando 4 agrupamentos são solicitados.

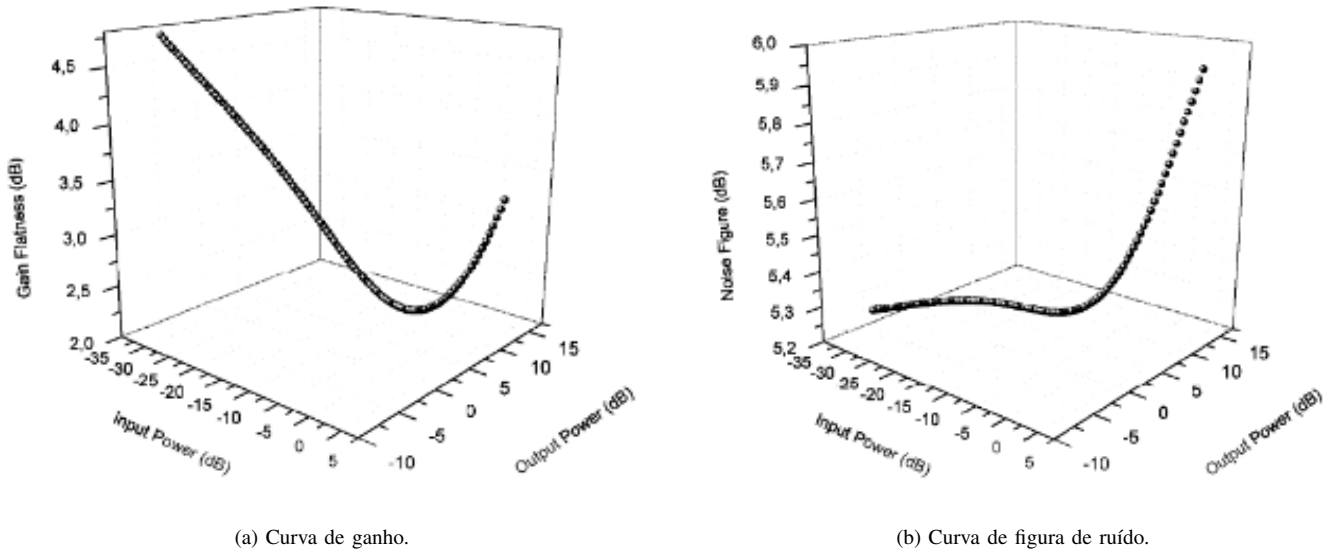


Figura 2: Ganho e figura de ruído x potência de entrada x potência de saída. Curvas geradas por uma rede perceptron multicamadas no estudo [29].

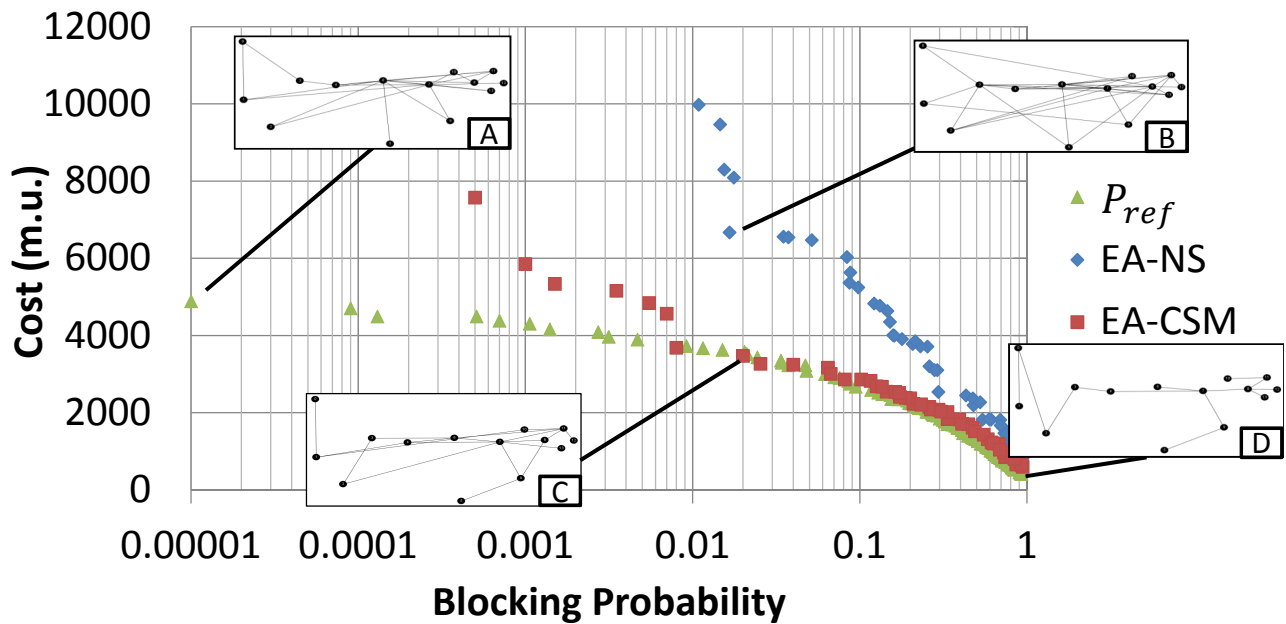


Figura 3: Frente de pareto de referência e duas curvas obtidas em [33] após 15 minutos usando um algoritmo evolucionário com modelo substituto e uma abordagem clássica.

Para obter projetos mais realistas em [36], o estudo considerou a divisão do estado em 18 seções (com 18 nós terminais) para planejamento do backbone estadual. A Fig. 5 apresenta a evolução do indicador hipervolume para a abordagem proposta e para uma abordagem clássica no decorrer das iterações do algoritmo de otimização. Neste estudo, o indicador hipervolume mede se as soluções fornecidas são bons compromissos em termos de custo, probabilidade de bloqueio, gasto energético e robustez. É possível perceber que a abordagem proposta é promissora desde as primeiras execuções do algoritmo e se mantém no decorrer do processo de otimização.

### III. CONCLUSÕES

Este artigo propõe apresentar de forma breve alguns dos tipos comuns de problemas e técnicas que são abordados na área de inteligência computacional. São apresentados em seguida algumas possíveis técnicas que envolvem redes neurais artificiais, computação evolucionária, inteligência de enxames e lógica nebulosa. Na sequência, são apresentados exemplos para ilustrar a aplicação destas técnicas em problemas reais de telecomunicações. Este artigo não se propôs a fazer um mapeamento sistemático ou revisão bibliográfica, mas sim servir de inspiração para que pesquisadores da área





Figura 4: Ilustração do processo de clusterização aplicado em [36] para auxiliar no projeto de uma rede óptica para o estado de Pernambuco. No exemplo são requeridos 4 agrupamentos.




Figura 5: Média do indicador hipervolume para a abordagem proposta em [36] e uma abordagem clássica.

de telecomunicações possam perceber as potencialidades de aplicação destas técnicas em problemas complexos em que as técnicas tradicionalmente utilizadas não conseguem retornar bons resultados. Fica evidente a aderência das técnicas. Entretanto, como foi colocado na Seção 2, muitas técnicas novas e mais sofisticadas vêm sendo desenvolvidas e pouco aplicadas nos problemas de telecomunicações, como por exemplo as técnicas de Deep Learning. Os autores deste artigo também colocam como oportunidades de pesquisa a modelagem de problemas mais complexos, que envolvam a resolução de problemas de natureza diferente de forma simultânea. Um exemplo disso é a otimização em conjunto com técnicas de clusterização para projeto de redes eficientes.

#### ACKNOWLEDGMENT

Os autores agradecem o apoio da CAPES, FACEPE, CNPq, UPE, UFRPE e UFPE.

#### REFERÊNCIAS

- [1] SCHWAB, K., A Quarta Revolução Industrial, Edipr, 1a. Edição, ISBN: 978-8572839785, 2016.
- [2] SHUJA, Junaid et al. Survey of techniques and architectures for designing energy-efficient data centers. *IEEE Systems Journal*, v. 10, n. 2, p. 507-519, 2016.
- [3] GOODFELLOW, Ian et al. *Deep learning*. Cambridge: MIT press, 2016.
- [4] HIGH, Rob. *The era of cognitive systems: An inside look at IBM Watson and how it works*. IBM Corporation, Redbooks, 2012.
- [5] DEGROFF, Dolores; NEELAKANTA, Perambur S. *Neural network modeling: Statistical mechanics and cybernetic perspectives*. CRC Press, 2018.
- [6] ZHANG, Gexiang; PÉREZ-JIMÉNEZ, Mario J.; GHEORGHE, Marian. *Fundamentals of Evolutionary Computation*. In: *Real-life Applications with Membrane Computing*. Springer, Cham, 2017. p. 11-32.

- [7] DE SILVA, Clarence W. *Intelligent control: fuzzy logic applications*. CRC press, 2018.
- [8] LI, Y.; YUAN, Y., Convergence analysis of two-layer neural networks with relu activation. In: *Advances in Neural Information Processing Systems*. 2017. p. 597-607.
- [9] SZE, V. et al. Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, v. 105, n. 12, p. 2295-2329, 2017.
- [10] KETKAR, N. *Convolutional neural networks*. In: *Deep Learning with Python*. Apress, Berkeley, CA, 2017. p. 63-78.
- [11] WANG, L. (Ed.). *Support vector machines: theory and applications*. Springer Science e Business Media, 2005.
- [12] DEB, K. et al. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE transactions on evolutionary computation*, v. 6, n. 2, p. 182-197, 2002.
- [13] ZITZLER, Eckart; LAUMANNNS, Marco; THIELE, Lothar. SPEA2: Improving the strength Pareto evolutionary algorithm. *TIK-report*, v. 103, 2001.
- [14] ZHANG, Qingfu; LI, Hui. MOEA/D: A multiobjective evolutionary algorithm based on decomposition. *IEEE Transactions on evolutionary computation*, v. 11, n. 6, p. 712-731, 2007.
- [15] NEBRO, Antonio J. et al. Smpso: A new pso-based metaheuristic for multi-objective optimization. In: *Computational intelligence in multi-criteria decision-making, 2009. mcdm'09. ieeesymposium on. IEEE*, 2009. p. 66-73.
- [16] SANTANA, Robson A.; PONTES, Murilo Rebelo; BASTOS-FILHO, Carmelo JA. A multiple objective particle swarm optimization approach using crowding distance and roulette wheel. In: *Intelligent Systems Design and Applications, 2009. ISDA'09. Ninth International Conference on. IEEE*, 2009. p. 237-242.
- [17] AKBARI, Reza et al. A multi-objective artificial bee colony algorithm. *Swarm and Evolutionary Computation*, v. 2, p. 39-52, 2012.
- [18] YUAN, Yuan; XU, Hua; WANG, Bo. An improved NSGA-III procedure for evolutionary many-objective optimization. In: *Proceedings of the 2014 Annual Conference on Genetic and Evolutionary Computation. ACM*, 2014. p. 661-668.
- [19] FIGUEIREDO, Elliackin MN; LUDERMIR, Teresa Bernarda; BASTOS-FILHO, Carmelo JA. Many objective particle swarm optimization. *Information Sciences*, v. 374, p. 115-134, 2016.
- [20] MTAZ, K., DURAISWAMYK.: "A Novel Density based improved k-means Clustering Algorithm - Dbkmeans", *International Journal on Computer Science and Engineering*, Vol. 2, n.2, p. 213-218, 2010.
- [21] Ghosh, S., Dubey, S. K.: "Comparative Analysis of K-Means and Fuzzy C-Means Algorithms", *International Journal of Advanced Computer Science and Applications*, Vol. 4, n.4, p. 35-39, 2013.
- [22] D. Van der Merwe and A. Engelbrecht, "Data clustering using particle swarm optimization," in *Proceedings of IEEE Congress on Evolutionary Computation*, 2003, pp. 215-220.
- [23] C.-Y. Chen and F. Ye, "Particle swarm optimization algorithm and its application to clustering analysis," in *Proceedings of IEEE International Conference on Networking, Sensing and Control*, 2004, pp. 789-794.
- [24] H. Khoshdel and B. Saman, "A new hybrid learning-based algorithm for data clustering," in *The 16th CSI International Symposium on Artificial Intelligence and Signal Processing (AISP 2012)*, May 2012, pp. 095-100.
- [25] A. J. M. Rani and L. Parthiban, "Improved particle swarm optimization and k-means clustering algorithm for news article," 2013.
- [26] JARGON, J.; WU, X.; WILLNER, A. Optical performance monitoring using artificial neural networks trained with eye-diagram parameters. *IEEE Photonics Technology Letters*, v. 21, n. 1, p. 54-56, 2009.
- [27] SHEN, T.; MENG, K.; LAU, A. P. T.; DONG, Z.-Y. Optical performance monitoring using artificial neural network trained with asynchronous amplitude histograms. *IEEE Photonics Technology Letters*, v. 22, n. 22, p. 1665-1667, 2010.
- [28] ARAUJO, D. R. B.; BASTOS-FILHO, C. J. A. ; MARTINS-FILHO, J. F. . Methodology to Obtain a Fast and Accurate Estimator for Blocking Probability of Optical Networks. *Journal of Optical Communications and Networking (Print)*, v. 7, p. 380-391, 2015.
- [29] BASTOS-FILHO, CARMELO J. A. ; BARBOZA, E. A. ; MARTINS-FILHO, JOAQUIM F. ; MOURA, U. C. ; OLIVEIRA, J. R. F. . Mapping EDFA Noise Figure and Gain Flatness Over the Power Mask Using Neural Networks. *Journal of Microwaves, Optoelectronics and Electromagnetic Applications*, v. 12, p. 15-26, 2013.
- [30] D. A. R. Chaves, C. J. A. Bastos-Filho, J. F. Martins-Filho, Multiobjective physical topology design of all-optical networks considering qos and capex, *Optical Fiber Communication (OFC), 2010 Conference on (OFC/NFOEC) (2010)* 1-3.

- [31] D. R. B. Araujo, C. J. A. Bastos-Filho, E. A. Barboza, D. A. R. Chaves, J. F. Martins-Filho, An efficient multi-objective evolutionary optimizer to design all-optical networks considering physical impairments and capex, in: Intelligent Systems Design and Applications (ISDA), 2011 11th International Conference on, 2011, pp. 76-81. doi:10.1109/ISDA.2011.6121634.
- [32] C. J. Bastos-Filho, D. R. Araújo, E. A. Barboza, D. A. Chaves, J. F. Martins-Filho, Design of transparent optical networks considering physical impairments, capex and energy consumption, in: Transparent Optical Networks (ICTON), 2011 13th International Conference on, IEEE, 2011, pp. 1-4.
- [33] ARAUJO, D. R. B.; BASTOS-FILHO, C. J. A. ; MARTINS-FILHO, J. F. . An evolutionary approach with surrogate models and network science concepts to design optical networks. Engineering Applications of Artificial Intelligence, v. 43, p. 67-80, 2015.
- [34] YOUNIS, O.; KRUNZ, M.; RAMASUBRAMANIAN, S. Node clustering in wireless sensor networks: recent developments and deployment challenges. IEEE Network, v. 20, n. 3, p. 20 – 25, 2006.
- [35] MAHESWARI, D. U.; MEENALOCHANI, M.; SUDHA, S. Influence of the cluster head position on the lifetime of wireless sensor network A case study. In: 2016 2ND INTERNATIONAL CONFERENCE ON NEXT GENERATION COMPUTING TECHNOLOGIES (NGCT) IS - SN - VO - VL -, 2016. [S.l.], 2016. p. 378 – 381.
- [36] NASCIMENTO, J. C. ; ARAÚJO, D. R. B. ; BASTOS-FILHO, C. J. A. ; MARTINS-FILHO, J. F. . Manyobjective Optimization to Design Physical Topology of Optical Networks with Undefined Node Locations. In: IEEE Congress on Evolutionary Computation (IEEE CEC), 2018, Rio de Janeiro. Proceeding of the 2018 IEEE Congress on Evolutionary Computation, 2018. v. 1. p. 1-7.