

GRUPO DE ESTUDO DE OPERAÇÃO DE SISTEMAS ELÉTRICOS - GOP

OTIMIZAÇÃO DA PREVISÃO DE DEMANDA E REQUISITO DE RESERVA: UM NOVO MODELO DE APRENDIZADO DE MÁQUINAS DIRIGIDO PELA APLICAÇÃO

JOAQUIM MASSET LACOMBE DIAS GARCIA (1,2); ALEXANDRE STREET DE AGUIAR (2);
TITO HOMEM DE MELLO (3); FRANCISCO MUÑOZ (4)

PSR SOLUCOES E CONSULTORIA EM ENERGIA LTDA. (1);
PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO (2);
UNIVERSIDADE ADOLFO IBAÑEZ, CHILE (3); GENERADORAS DE CHILE (4)

RESUMO

Os processos de previsão e a tomada de decisão são geralmente modelados em duas etapas sequenciais sem feedback, uma abordagem em malha aberta. Operadores utilizam previsões de carga líquida e requisitos de reserva para programar a operação do sistema e acomodar desvios em tempo real. Não obstante, na prática, operadores cada vez mais utilizam previsões enviesadas de forma ad hoc para se protegerem de custos assimétricos nos erros de previsão. Assim, apresentamos uma nova metodologia de previsão dirigida pela aplicação, em malha fechada, que reconhece o processo decisório da operação e seus custos. O melhor modelo de previsão é, portanto, encontrado de forma co-otimizada com a operação através de um problema de otimização de dois níveis. Experimentos em sistemas de grande porte mostram desempenho consistentemente melhor do que a abordagem padrão em malha aberta.

PALAVRAS-CHAVE

Aprendizado de Máquina Dirigido; Previsão; Planejamento de Reservas; Otimização; Previsão e Otimização Conjunta

1.0 INTRODUÇÃO

A abordagem mais comum para tomar decisões sob incerteza envolve três passos. Na primeira etapa, desenvolve-se uma previsão para todas as incertezas que afetam o problema final de tomada de decisão com base em todas as informações disponíveis. Na segunda etapa, uma ação ou decisão ótima é escolhida a partir da previsão anteriormente realizada. Finalmente, na terceira etapa, implementa-se ações corretivas após a realização de incertezas. Este procedimento de três etapas constitui um processo de previsão de decisão em malha aberta no qual os resultados das decisões não retroalimentam as novas previsões.

No setor elétrico, é comum que os operadores de sistemas usem uma abordagem de decisão de previsão de malha aberta. Primeiro, as cargas são previstas com base em técnicas estatísticas tradicionais (VAN DER MEER, 2018), como mínimos quadrados (MQ), e os requisitos de reserva são definidos por regras simples, baseadas em quantis, valores extremos e desvios padrão de erros de previsão de acordo com padrões de confiabilidade especificados (ELA, 2011), ver também a pesquisa bibliográfica em (DIAS GARCIA, 2021). Em seguida, toma-se a decisão de alocar recursos de geração e agendamento de reservas (CHEN, 2013, DE VOS, 2019). Em tempo real, as reservas são implantadas para garantir que a energia seja suprida em cada barra, compensando os erros de previsão.

Do ponto de vista acadêmico, foi demonstrado que a programação estocástica produz resultados melhores do que métodos determinísticos. Isso ocorre, em geral, porque a primeira leva em consideração as distribuições de probabilidade e as assimetrias de custos nas consequências de cada cenário. Como resultado, modelos estocásticos proporcionam melhores resultados em termos de custo, confiabilidade e eficiência de mercado em comparação com abordagens determinísticas (WANG, 2014). No entanto, como descrito em (ZHENG, 2014), existem pelo menos três principais barreiras para a ampla aceitação dos métodos estocásticos em modelos de *unit commitment* (UC): i) modelagem de incerteza, ii) desempenho computacional e iii) desenho de mercado. O desempenho computacional limita o tamanho de amostras em técnicas de otimização baseadas em amostragem (Aproximação por Média Amostral, AMA). Uma consequência dessa questão é que as soluções AMA tornam-se dependentes de amostras (PAPAVASILIOU, 2013), comprometendo assim a transparência do mercado e impedindo a aceitação das partes interessadas (WANG, 2015). O menos estudado dos três tópicos é o desenho de mercado. Portanto, a maioria dos operadores no mundo todo ainda depende de modelos determinísticos para o despacho econômico ou UC com previsões exógenas para cargas e requisitos de reserva (CHEN, 2013, PJM 2018). Para o leitor interessado,

sugerimos a leitura de um recente artigo sobre o assunto na *newsletter* da *Stochastic Programming Society* (STREET, 2021). Nesse contexto, onde o mercado exige interpretabilidade e reprodutibilidade por parte dos modelos do operador, estes passaram a experimentar e desenvolver regras que incorporassem o conhecimento das consequências das previsões dentro do contexto da operação para produzir previsões viáveis de serem implementadas (seguras) e aceitas pelos agentes (KAZEMPOUR, 2018; WANG, 2015; CHEN, 2013; PJM 2018). Dentro deste contexto, uma alternativa para melhorar o desempenho dos modelos determinísticos das ferramentas de despacho é co-otimizar a previsão da demanda e dos requisitos de reserva com o objetivo de minimizar os custos totais de despacho de energia e reserva.

Há evidências empíricas de que os operadores de sistemas dependem de ações ad hoc — e não apenas de reservas — para lidar com a incerteza nas operações. De acordo com o Relatório Anual de Questões de Mercado e Desempenho do ISO da Califórnia (CAISO, 2020) — a seguir, apresentamos a tradução livre realizada pelos autores — “... os operadores tomam regularmente ações significativas **fora do mercado** para lidar com a incerteza da carga líquida sobre um horizonte de tempo de algumas horas (por exemplo, 2 ou 3 horas). Essas ações incluem introdução de viés artificial de alta na previsão de carga de uma hora e de 15 minutos a frente, despachos excepcionais e aumento antecipado da geração de unidades adicionais a gás antes do horário de pico da noite.” Além disso, os requisitos de reserva são, na prática, empiricamente definidos de acordo com outras regras off-line ad hoc com base na análise off-line (ELA, 2011, PJM 2018). No Brasil, este tema foi discutido sob o nome de *previsão heurística* em fóruns do setor, porém, os autores não encontraram documentação formal sobre o tema. Não obstante, esses procedimentos ad hoc carecem de formalismo técnico e transparência para minimizar os custos operacionais e de confiabilidade. Consequentemente, essa desafiadora aplicação do mundo real requer mais pesquisas observando a questão prática que precisa ser abordada para melhorar o estado da arte atual das práticas da indústria.

Durante anos, a tomada de decisão e a previsão têm sido tratadas como dois processos completamente independentes (BERTSIMAS, 2019). Muitas comunidades, como a Estatística e Pesquisa Operacional, estudaram esses problemas e desenvolveram múltiplas ferramentas combinando probabilidade e otimização. A comunidade de Aprendizado de Máquina (AM), que combina muitas ideias de otimização e probabilidade, também vem enfrentando tais tarefas e propôs métodos para tratá-las em conjunto (BENGIO, 1997). Os métodos clássicos de previsão não levam em conta a aplicação subjacente da previsão. Consequentemente, hipóteses como a simetria de erro de predição em pelo MQ podem não ser as mais adequadas para problemas com desfechos assimétricos. Ao reconhecer a assimetria em problemas particulares, os pesquisadores têm tentado capturá-la empiricamente; no entanto, tal abordagem não leva a aplicação em conta diretamente. Alguns métodos existentes capturam assimetria, como a Regressão Quantílica (RQ) (ROCKAFELLAR, 2008).

Nesse contexto, dois possíveis caminhos de pesquisa são abertos para alcançar melhores resultados: i) foco na melhoria do modelo de tomada de decisão operativa (método prescritivo), que pressupõe que possamos alterá-lo para considerar o impacto das incorporadas (BERTSIMAS, 2019); ou ii) um foco na melhoria do modelo de previsão (método preditivo), que pressupõe que não podemos alterar os modelos de decisão (em nossa aplicação, definido pelos modelos de despacho econômico dos operadores), mas podemos alterar os modelos de previsão para incorporar o custo da aplicação (BENGIO, 1997; ELMACHTOUB, 2021). Neste trabalho, focamos na segunda abordagem.

1.1 Objetivo e Contribuição

O objetivo deste artigo é apresentar uma nova estrutura de aprendizagem dirigida pela aplicação em malha fechada para melhorar o modelo de previsão de demanda e requisito de reservas do operador. Nessa metodologia, as estruturas de minimização de custos *ex-ante* (planejamento) e *ex-post* (implementação) do processo decisório do operador são consideradas na estimação do modelo de previsão a fim de ajustar o custo do erro de previsão de acordo com a sua consequência operativa. Portanto, substituímos o objetivo tradicional de minimização de erros quadráticos por uma estrutura de minimização de custos operativos. Para isso, propomos uma nova estrutura de aprendizagem baseada em um modelo de otimização binível.

O primeiro nível do nosso problema binível busca os parâmetros de um modelo de previsão que tenha o melhor desempenho em termos do objetivo final da aplicação, ou seja, custo de alocação de reservas (*ex-ante*) mais custo de operação em tempo real (*ex-post*). Assim, o problema de primeiro nível contém a especificação do modelo preditivo (seleção de parâmetros) e a métrica de avaliação de custos com base no funcionamento real do sistema para muitas observações. É relevante mencionar que o modelo é flexível para considerar qualquer restrição de exigência de reserva impostas por regras regulatórias e normas de confiabilidade (THE EUROPEAN COMMISSION, 2017, ELA 2011). No segundo nível, o processo de despacho de energia e reserva *ex-ante* do operador do sistema é otimizado com base em 1) a previsão de demanda condicional, e 2) os requisitos de reserva sistêmicos, ambos definidos no primeiro nível para cada ponto dos dados considerados no conjunto de treinamento. Assim, em nosso modelo binível, temos múltiplos problemas paralelos de nível inferior, cada um deles representando o processo determinístico de despacho de duas etapas realizado pelo operador do sistema para cada ponto do conjunto de dados de treinamento. Nesse contexto, o segundo nível garante a retroalimentação da informação caracterizando decisões conjuntas de agendamento de alocações de energia e reservas sem informação perfeita.

Em teoria, pode-se usar técnicas tradicionais de otimização binível para buscar soluções globais, contudo vamos focar na abordagem escalável adequada para métodos de decomposição e computação paralela proposta em (DIAS GARCIA, 2021). Comparamos nossa metodologia com a tradicional previsão sequencial de MQ e a subsequente otimização de energia e reserva. Aplicamos a metodologia proposta a vários estudos de caso, incluindo, um sistema ilustrativo e sistemas de grande porte com até 6.000 barras. Os resultados mostram que a abordagem proposta produz consistentemente melhor desempenho em testes fora da amostra do que o benchmark onde as previsões e decisões são realizadas sequencialmente. Para sistemas todos os sistemas analisados, o método apresenta desempenho de alta qualidade em comparação com a referência.

2.0 O MÉTODO DE APRENDIZADO DIRIGIDO PELA APLICAÇÃO

O método de aprendizado dirigido pela aplicação originalmente proposto em (DIAS GARCIA, 2021) será brevemente discutido aqui por completude. A primeira componente fundamental é uma base de dados históricos $\{y_t, x_t\}_{t \in \{1 \dots T\}}$, na qual y_t são observações da variável a ser prevista, demanda, e x_t são variáveis explicativas que podem incluir *lags* (observações passadas) da variável y_t . O método em si é descrito pelo seguinte modelo de otimização binível:

$$\theta = \underset{\theta, \hat{y}_t, z_t^*}{\operatorname{argmin}} \frac{1}{T} \sum_t G_a(z_t^*, y_t) \quad (1)$$

$$\text{s. a. } \hat{y}_t = \Psi(\theta, x_t) \quad \forall t \in \{1, \dots, T\} \quad (2)$$

$$z_t^* \in \underset{z}{\operatorname{argmin}} G_p(z, \hat{y}_t) \quad \forall t \in \{1, \dots, T\} \quad (3)$$

Neste problema de otimização (1)-(3), $\Psi(\theta, x_t)$ representa um modelo de previsão que depende tanto do vetor de parâmetros, θ , quanto do vetor de dados explicativos x_t . O vetor \hat{y}_t é a previsão gerada para amostra t (compreendendo previsões de demanda e requisitos de reserva). Para toda amostra t , a previsão \hat{y}_t é usada como dado de entrada em um problema de planejamento que minimiza a função de custo $G_p(z, \hat{y}_t)$ e retorna uma decisão ótima z_t^* . Em seguida, o planejamento ótimo, z_t^* , é avaliado no nível de cima contra a realização real, y_t , para cada t . A avaliação é feita com a função de custo, $G_a(z_t^*, y_t)$. Assim, o conhecimento sobre a aplicação é incorporado no processo de estimativa tanto na política de planejamento *ex-ante* quanto na avaliação custo final *ex-post*. Vale notar que a formulação proposta pode ser interpretada como uma otimização sobre θ em um *backtest*, no qual para um determinado θ , a avaliação da performance da previsão é completamente determinada por $G_a(z_t^*(\hat{y}_t), y_t)$. Em outras palavras, o nível de cima identifica os parâmetros com o melhor desempenho de *backtest*.

Esse método deve ser contrastado com o método tradicional de malha aberta, no qual o operador treina um modelo de previsão paramétrico, com parâmetros θ e função de perda $\ell(\cdot; \cdot)$ que mede a distância entre uma previsão $\hat{y}_t(\theta, x_t)$ e a realização y_t . Ou seja, resolve-se o problema: $\min_{\theta} T^{-1} \sum_t \ell(\hat{y}_t(\theta, x_t), y_t)$, que no caso dos mínimos quadrados é: $\theta^{MQ} \in \underset{\theta}{\operatorname{argmin}} T^{-1} \sum_t (\hat{y}_t(\theta, x_t) - y_t)^2$. Em seguida, obtém-se a previsão $\hat{y}_t^{MQ}(\theta^{MQ}, x_t)$ que é usada para obter o planejamento ótimo $z_t^*(\hat{y}_t^{MQ}) \in \underset{z}{\operatorname{argmin}} G_p(z, \hat{y}_t^{MQ})$ que consiste em uma programação de despacho e alocação de reservas em geradores. Finalmente, o verdadeiro y_t é observado e o sistema se adapta em tempo real despachando as reservas alocadas previamente, resultando em um custo $G_a(z_t^*(\hat{y}_t^{MQ}), y_t)$.

3.0 CO-OTIMIZAÇÃO DE PREVISÃO DE DEMANDA E REQUISITOS DE RESERVA VIA APRENDIZADO DIRIGIDO PELA APLICAÇÃO

O objetivo desse modelo é obter as melhores previsões de demanda, \widehat{D}_t , e os melhores requisitos de reserva de subida e descida, \widehat{R}_t^{up} e \widehat{R}_t^{dn} , que conjuntamente minimizam o custo final da aplicação em questão: o despacho e re-despacho de um sistema elétrico. Note que podemos pensar as cargas como uma carga líquida geral que corresponde à carga menos a geração não despachada (por exemplo, geração eólica, solar e pequenas usinas). As entradas do problema são: vetores de dados históricos de demanda nodal, nesse caso as variáveis explicativas serão os próprios *lags* passados de demanda, D_{t-1}, \dots, D_{t-k} , contudo o método também comporta outras explicativas como variáveis climáticas, variáveis indicadoras de calendário, sazonalidades e quaisquer outras explicativas que poderiam ser usadas em regressões lineares; dados da unidade geradoras como capacidade, G , custo ou oferta de preço, c , máxima potência alocável em reservas de subida e descida, $\bar{r}_t^{(up)}, \bar{r}_t^{(dn)}$, preços das reservas, p^{up}, p^{dn} ; custos sistêmicos de corte de carga, δ_t^{LS} , e vertimento de energia, δ_t^{SP} ; capacidade das linhas de transmissão e matriz de sensibilidade de barra, B , que descreve a topologia da rede e a segunda lei de Kirchhoff, descrevendo uma aproximação AC do fluxo de potência ótimo. Como a realidade operativa mostra que o modelo usado no planejamento do sistema, G_p , pode diferir da realidade física do redespacho, G_a , o método permite ainda que os dados físicos sejam diferentes.

Como notação, vamos representar as grandezas descritas no problema do planejamento com um chapéu, por exemplo, \widehat{g}_t , de modo que G é a geração máxima durante a operação real e \widehat{G} é a geração máxima na fase de planejamento. Para manter uma notação matricial compacta as dados definidos anteriormente são vetoriais. Completando a definição do sistema elétrico, temos M , a matriz de incidência com barras nas linhas e geradores nas colunas que vale um quando o gerador está naquela barra e zero caso contrário, e N , a outra matriz de incidência,

na qual suas linhas representam zonas de reservas e suas colunas os geradores. Assim, caso uma entrada dessa matriz tenha o valor um, significa que o gerador associado à coluna dessa entrada se encontra na zona correspondente à linha da entrada. Escrevemos o problema completo como o seguinte modelo binível:

$$\min_{\theta_D, \theta_{R^{up}}, \theta_{R^{dn}}, \frac{1}{T} \sum_t [c^\top g_t + p^{up\top} \hat{r}_t^{(up)*} + p^{dn\top} \hat{r}_t^{(dn)*} + \lambda^{LS} \delta_t^{LS} + \lambda^{SP} \delta_t^{SP}]}$$
 (4)

$$\widehat{D}_t, \widehat{R}_t^{up}, \widehat{R}_t^{dn}, g_t, \delta_t^{LS}, \delta_t^{SP}, g_t^*, r_t^{(up)*}, r_t^{(dn)*}$$

s. a. $\forall t \in \{1, \dots, T\}$:

$$\widehat{D}_t = \Psi_D(\theta_D, x_t) = \theta_D^0 + \theta_D^1 D_{t-1}$$
 (5)

$$\widehat{R}_t^{up} = \Psi_{R^{up}}(\theta_{R^{up}}, x_t) = \theta_{R^{up}}^0$$
 (6)

$$\widehat{R}_t^{dn} = \Psi_{R^{dn}}(\theta_{R^{dn}}, x_t) = \theta_{R^{dn}}^0$$
 (7)

$$e^\top (M g_t - \delta_t^{SP}) = e^\top (D_t - \delta_t^{LS})$$
 (8)

$$-F \leq B(M g_t + \delta_t^{LS} - D_t - \delta_t^{SP}) \leq F$$
 (9)

$$g_t^* - r_t^{(dn)*} \leq g_t \leq g_t^* + r_t^{(up)*}$$
 (10)

$$\delta_t^{LS}, \delta_t^{SP}, \widehat{R}_t^{up}, \widehat{R}_t^{dn}, g_t \geq 0$$
 (11)

$$(g_t^*, r_t^{(up)*}, r_t^{(dn)*}) \in \underset{\widehat{g}_t, \widehat{\delta}_t^{LS}, \widehat{\delta}_t^{SP}, \widehat{r}_t^{(up)*}, \widehat{r}_t^{(dn)*}}{\operatorname{argmin}} [\widehat{c}^\top \widehat{g}_t + \widehat{p}^{up\top} \widehat{r}_t^{(up)*} + \widehat{p}^{dn\top} \widehat{r}_t^{(dn)*} + \widehat{\lambda}^{LS} \widehat{\delta}_t^{LS} + \widehat{\lambda}^{SP} \widehat{\delta}_t^{SP}]$$
 (12)

s. a.

$$e^\top (M \widehat{g}_t - \widehat{\delta}_t^{SP}) = e^\top (\widehat{D}_t - \widehat{\delta}_t^{LS})$$
 (13)

$$\widehat{F} \leq \widehat{B} (M \widehat{g}_t + \widehat{\delta}_t^{LS} - \widehat{D}_t - \widehat{\delta}_t^{SP}) \leq \widehat{F}$$
 (14)

$$N \widehat{r}_t^{(up)*} = \widehat{R}_t^{up}$$
 (15)

$$N \widehat{r}_t^{(dn)*} = \widehat{R}_t^{dn}$$
 (16)

$$\widehat{g}_t + \widehat{r}_t^{(up)*} \leq \widehat{G}$$
 (17)

$$\widehat{g}_t - \widehat{r}_t^{(dn)*} \geq 0$$
 (18)

$$\widehat{r}_t^{(up)*} \leq \widehat{r}_t^{(up)}$$
 (19)

$$\widehat{r}_t^{(dn)*} \leq \widehat{r}_t^{(dn)}$$
 (20)

$$\widehat{g}_t, \widehat{r}_t^{(up)*}, \widehat{r}_t^{(dn)*}, \widehat{\delta}_t^{SP}, \widehat{\delta}_t^{LS} \geq 0$$
 (21)

Neste modelo, (4)-(11) representam o problema do primeiro nível, onde os custos da operação final e estimação de parâmetros são calculados (detalhando o modelo (1)-(2)). Já as expressões (12)-(21) representam em detalhes o segundo nível, que modela o processo de planejamento da operação *ex ante*. Mais especificamente, os modelos de previsão que queremos otimizar parâmetros (2) são detalhados em (5)-(7), que separam explicitamente a previsão de demanda, \widehat{D}_t , e requisitos de reserva de subida e descida, \widehat{R}_t^{up} e \widehat{R}_t^{dn} , um passo à frente. Cada uma dessas previsões depende das explicativas, x_t , lags de demanda, e dos parâmetros que não dependem de t e estamos otimizando $\theta_D, \theta_{R^{up}}, \theta_{R^{dn}}$. Por simplicidade e propósitos didáticos, consideraremos aqui que a previsão de demanda é um modelo autorregressivo de ordem 1, AR(1), enquanto as previsões de reserva são do tipo AR(0). A função objetivo (4) e as restrições (8)-(11) equivalem a (1) no modelo geral. Elas são responsáveis por detalhar o custo real de operação do sistema, métrica que vai dirigir o aprendizado dos parâmetros $\theta_D, \theta_{R^{up}}, \theta_{R^{dn}}$ no lugar de uma métrica tradicional como MQ. Para alcançar esse objetivo precisamos incluir no modelo o problema de redespacho que minimiza o custo da geração final, g_t , e somar os custos das reservas alocadas, $\widehat{r}_t^{(up)*}$ e $\widehat{r}_t^{(dn)*}$, e os custos de eventuais déficits, δ_t^{LS} , e vertimento de geração, δ_t^{SP} . Tal problema deve respeitar restrições de balanço de energia (8), que indica que a soma da geração deve ser igual a demanda; de fluxo de potência, (9), que garante que o fluxo dos circuitos está dentro do limite; de despacho agendado, (10), que obriga a geração final a ficar entre os limites de reserva alocados a cada um dos geradores durante o problema de planejamento (12)-(21); a restrição (11) apenas garante a positividade das variáveis em questão.

O modelo de planejamento, (12)-(21), tem como objetivo principal otimizar o despacho e a alocação de reservas de cada uma das usinas, $\widehat{g}_t, \widehat{r}_t^{(up)*}, \widehat{r}_t^{(dn)*}$, cuja solução ótima, $g_t^*, r_t^{(up)*}, r_t^{(dn)*}$, é usada no modelo de avaliação de custos (redespacho) na restrição (10). Para atingir esse objetivo, o modelo minimiza, na equação (12), o custo de despacho, \widehat{g}_t , e de alocação de reservas, $\widehat{r}_t^{(up)*}, \widehat{r}_t^{(dn)*}$, e os custos de corte de carga e vertimento preventivos, $\widehat{\delta}_t^{LS}, \widehat{\delta}_t^{SP}$. A etapa de planejamento também segue regras análogas àquelas do modelo de avaliação (redespacho): (13) e (14) representam balanço de energia de limites dos fluxos nos circuitos análogos àqueles representados em (8) e (9) – note que no planejamento a demanda é uma previsão que vem do nível de cima –; (15) e (16) representam a alocação de reserva por gerado em cada zona, de modo que a soma de reservas alocadas em cada gerador de determinada área seja igual ao valor determinado pelo modelo do nível de cima $\widehat{R}_t^{up}, \widehat{R}_t^{dn}$; (17) e (18) representam a limitação física

do ponto de despacho e reservas alocadas a gerador; (19) e (20) restringem a reserva que pode ser alocada em cada unidade; e (21) garante a positividade das variáveis em questão.

Este modelo é útil porque as previsões de carga e o par quantidade e localização dos requisitos de reserva são definidos da melhor maneira possível para fins da aplicação. Ou seja, buscam o modelo que maximiza o desempenho operativo. Enquanto o nível inferior, (12)-(21), considera o custo da programação *ex-ante* e alocação de reserva compatível com o nível de informação do operador do sistema (melhor cronograma dado a previsão condicional para o período t), o nível superior seleciona os parâmetros do modelo de previsão visando minimizar o custo médio de funcionamento calculado *ex-post* para um grande conjunto de dados. Nesse sentido, dependendo dos detalhes da rede considerados na parte de avaliação do modelo, este também pode auxiliar na mitigação de problemas de não entregabilidade das reservas associadas a níveis *ad hoc* utilizados em práticas da indústria.

4.0 ESTUDOS DE CASO

4.1 Comportamento Assintótico e Estimativa com Viés Ótimo

Neste estudo veremos a convergência assintótica dos parâmetros estimados e mostramos empiricamente, através de análise fora da amostra, que o uso do modelo de malha fechada é estritamente melhor do que o de malha aberta, desde que tenhamos um tamanho razoável de conjunto de dados na etapa de treinamento. Usaremos o seguinte nomenclatura e código de cores para se referir aos diferentes modelos: MQ-Ex (vermelho): Modelo de referência que representa a abordagem clássica de malha aberta. Ele usa MQ para estimar a demanda e um requisito de reserva exógeno. MQ-Opt (azul): Modelo parcialmente otimizado, MQ são usados para estimar a demanda e apenas os requisitos de reservas são otimizados. Opt-Ex (amarelo): Modelo parcialmente otimizado, onde a demanda é otimizada, enquanto as reservas são definidas de modo exógeno. Este terceiro modelo não é particularmente significativo na prática, mostramos principalmente por completude. Opt-Opt (verde): Este é o modelo totalmente otimizado, onde tanto a previsão de demanda quanto os requisitos de reserva são otimizados.

Para fins didáticos, em todos os casos testados nesta seção, foram definidos requisitos de reserva de subida e descida de ± 1.96 desvios-padrão, respectivamente, dos resíduos estimados da previsão de demanda via MQ. Outra regra exógena *ad hoc* poderia ser usada (ELA 2011). Comparamos e analisamos empiricamente a convergência dos quatro modelos de previsão de demanda e reserva mencionados acima em um sistema teste com uma barra e 3 geradores. Variamos o tamanho do conjunto de dados usado no processo de estimativa de 50 a 1000 observações. Para cada tamanho de conjunto de dados, realizamos 100 estimativas de parâmetros, com diferentes conjuntos de dados gerados a partir do mesmo processo, para estudar a convergência. As estimativas dos modelos MQ-Opt, Opt-Ex e Opt-Opt utilizam o algoritmo escalável sequencial, que dado uma solução para os parâmetros dos modelos, calcula em paralelo o resultado dos modelos do segundo nível. Para mais detalhes, sugerimos a leitura do artigo (DIAS GARCIA, 2021). Para avaliar o desempenho fora da amostra de cada uma das 100 estimativas para cada tamanho de conjunto de dados, calculamos a função objetiva, $G_a(1)$, para um único conjunto de dados fixos com 10000 novas observações (geradas com o mesmo processo estocástico subjacente, mas diferente de todos os outros dados utilizados nos processos de estimativa). Nos gráficos a seguir, as linhas representam valores médios entre os 100 custos estimados com os dados amostrais ou fora da amostra, e as áreas sombreadas representam os quantis de 10% e 90%.

As figuras 1(a) e 1(b) retratam os custos médios de operação fora da amostra como função do tamanho da amostra usada para estimar parâmetros. Assim, eles medem o quão bem os modelos generalizam aos dados que nunca viu antes. Podemos ver que os modelos permitem que mais parâmetros sejam otimizados com desempenho muito melhor do que modelos com modelos de previsão com mais parâmetros definidos externamente. Assim, vemos que a estrutura de aprendizagem orientada a aplicações funciona com sucesso em dados fora da amostra quando estimados com conjuntos de dados maiores que 150. No entanto, notamos que essas melhorias requerem mais dados do que os modelos exógenos clássicos, como mostrado na Figura 1(b). Entre 50 e 120 pontos, o modelo com maior flexibilidade de otimização, Opt-Opt, exibe uma variação de custo mais significativa. Isso se deve à otimização excessiva em um pequeno conjunto de dados que levou a *overfit* e baixa capacidade de generalização.

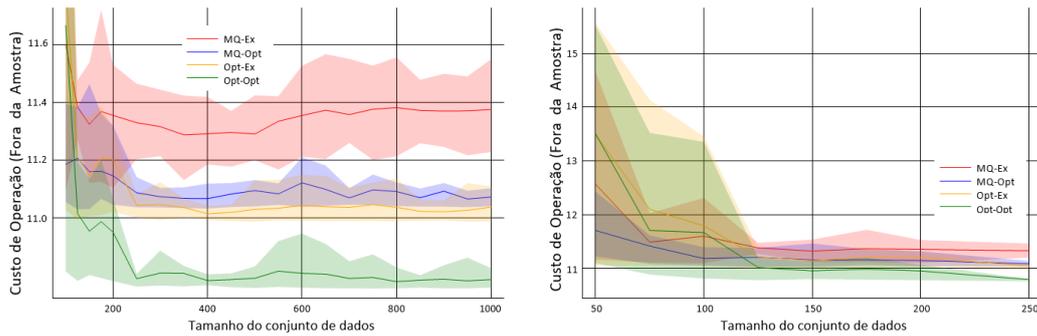
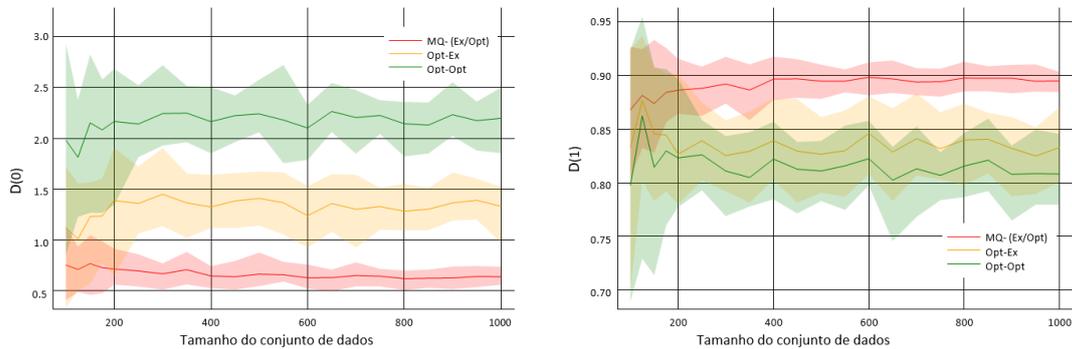


Figura 1. Convergência do custo operativo (a) de 200 a 1000 amostras, (b) de 50 a 250 amostras no dataset.

A Figura 2 mostra como os parâmetros estimados se comportam como funções do tamanho do conjunto de dados de estimativa. Podemos ver que os parâmetros do modelo de carga estão de fato convergindo para valores de longo



prazo. Também é claro ver o viés nesses parâmetros. O termo constante é aumentou enquanto o coeficiente autorregressivo é ligeiramente reduzido. Em última análise, isso leva a um valor de previsão maior, que pode ser interpretado como o ajuste de risco da aplicação devido aos custos de penalização assimétricos (o corte de carga é muito mais caro que o custo de vertimento). O modelo Opt-Opt faz o melhor possível para equilibrar esses custos, priorizando assim o corte de carga aumentando a previsão de carga. O modelo de reservas fixas (Opt-Ex) é menos tendencioso porque as reservas fixas restringem o quanto o modelo de carga pode viés devido ao risco de não ter reserva suficiente para atender a realizações de menor demanda. Observe que o vermelho (MQ-Ex) está em cima do roxo (MQ-Opt) já que ambos usam as mesmas estimativas de MQ para demanda, que exhibe a menor variância. Figura 2. (a) convergência do coeficiente constante, θ_D^0 . (b) convergência do coeficiente linear, θ_D^1 .

Para destacar o viés na previsão de carga apresentamos, na Figura 3 (a), um histograma de desvios: erro := realização – previsão. Valores negativos significam que o valor da previsão estava acima do realizado. A estimativa de MQ leva a um estimador sem viés, visto no histograma vermelho centrado em zero. Por outro lado, a previsão do modelo totalmente endógeno é claramente tendenciosa, pois prevê valores mais elevados do que os realizados. Este fato é corroborado pelas funções cumulativas de distribuição exibidas na Figura 3 (b).

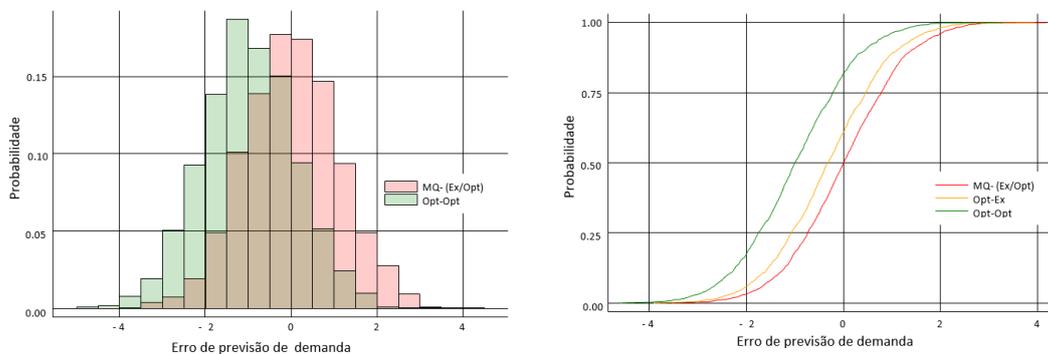


Figura 3. (a) Histograma do erro de previsão. (b) distribuição acumulada do erro de previsão.

4.2 Escalabilidade do Método Proposto

Criamos instâncias com o número de barras variando de 1200 a 6000. Essas instâncias foram criadas conectando várias cópias do caso IEEE 300 barras (BABAEINEJADSAROOKOLAE, 2019). A otimização foi realizada em um Intel Xeon E5-2680 com 12 processadores a 2,50GHz, 128Gb de RAM. Geramos um único conjunto de dados de treinamento com 1.000 observações para cada instância e otimizamos cada problema considerando limites de tempo de quatro e doze horas. Em seguida, avaliamos as soluções obtidas com cada método e prazo computacional com um conjunto de dados comum de 10000 observações fora da amostra.

Os resultados, em termos de custo de Teste e Treino, são retratados na Tabela 1. É evidente que os métodos propostos (MQ-Opt e Opt-Opt) superaram consistentemente a referência (MQ-Ex), apesar de atingirem o limite de tempo para treinamento. O regime de co-otimização (Opt-Opt) foi novamente melhor do que os outros dois métodos (MQ-Ex e MQ-Opt) tanto na avaliação dentro quanto fora da amostra. Além disso, o método teve um bom desempenho, generalizando para o teste fora da amostra o que aprendeu no treino. Para os sistemas maiores, vemos melhorias relativas menores nas funções de custo. Isso se deve (i) ao aumento da dimensão dos programas lineares resolvidos em cada iteração, e (ii) ao número de parâmetros, que aumenta com o tamanho do sistema. Razões (i) e (ii) implicam que, para uma dada configuração computacional, menos iterações são executadas na fase de treinamento, possivelmente produzindo soluções sub-ótimas. Assim, é concebível que resultados muito melhores possam ser obtidos com mais tempo (ou capacidade de processamento), pois as rodadas de 12 horas levam a melhorias que são mais de três vezes as obtidas com corridas de 4 horas. Embora estivéssemos limitados a 12 núcleos, poderíamos usar um núcleo (ou mais) por observação no conjunto de dados de treinamento, levando a acelerações maciças (mais de 1000 núcleos poderiam ser usados em paralelo). Vale ressaltar que, em todos os casos, a estimativa de MQ encontrou coeficientes muito próximos aos verdadeiros. Este fato, juntamente com os ganhos mostrados nas Tabelas 1 e 2 para muitos casos de diferentes tamanhos, indicam que o viés de previsão introduzido por nossa metodologia é consistente na melhora da operação dos sistemas estudados. Notavelmente, os ganhos relevantes foram fundar mesmo em Casos de muito em grande escala poder Sistemas. Para o caso de 3600 barras, a simulação levou a um ganho de 12% para o limite de 12 horas. Portanto, os resultados fornecem forte evidência de que o método é capaz de produzir ganhos significativos na prática.

Barras	Horas	Teste					Treino				
		Opt-Opt		MQ-Opt		MQ-Ex	Opt-Opt		MQ-Opt		MQ-Ex
	(h)	(\$)	(%)	(\$)	(%)	(\$)	(\$)	(%)	(\$)	(%)	(\$)
1200	4	35261	26.38	40103	6.27	47899	34985	26.87	39994	16.41	47843
1200	12	35158	26.60	38843	14.89	47899	34842	27.17	38787	18.93	47843
2400	4	81018	20.23	94675	6.78	101561	78686	19.57	91278	6.70	97832
2400	12	80330	20.91	93739	7.70	101561	77969	20.30	90413	7.58	97832
3600	4	149141	3.51	153484	0.70	154558	147110	3.50	151404	0.68	152439
3600	12	136479	11.70	150303	2.75	154558	134664	11.66	148332	2.69	152439
4800	4	206358	1.22	208300	0.29	208910	209816	1.28	211927	0.29	212546
4800	12	197707	5.36	206539	1.14	208910	201294	5.29	210197	1.11	212546
6000	4	260427	0.96	262493	0.18	262963	262049	0.99	264198	0.18	264668
6000	12	255384	2.88	261500	0.56	262963	257062	2.87	263118	0.59	264668

Tabela 1. Resultados para sistemas de grande escala. MQ-Ex é a referência, só os custos em \$ são mostrados. Para Opt-Opt e MQ-Opt mostramos custos em \$ e melhoria em relação ao MQ-Ex em %.

5.0 CONCLUSÃO

Apresentamos uma estrutura de aprendizado dirigida pela aplicação para estimar conjuntamente os parâmetros de um modelo de previsão de carga e requisito de reserva. Matematicamente formulamos um problema binível que é resolvido como algoritmo iterativo apresentado em (DIAS GARCIA, 2021). O método proposto contrasta com o procedimento sequencial clássico (malha aberta) onde os modelos de previsão são baseados em mínimos quadrados e utilizados no processo de tomada de decisão. O método proposto encontra suporte nas práticas atuais do setor, onde procedimentos ad hoc são implementados adicionando um viés na previsão da carga reduzir empiricamente riscos. A aplicação do nosso modelo fornece não apenas uma compreensão teoricamente fundamentada de tais procedimentos, mas também uma ferramenta computacional flexível para testar práticas atuais e determinar conjuntamente o viés ideal e os requisitos de reserva.

A experiência numérica reportada permite destacar os seguintes principais resultados empíricos: 1) Existe um viés ideal na previsão de carga maximizando o desempenho de um sistema ou operador de mercado no longo prazo.

Além disso, o viés ideal na previsão de carga não está desconectado dos requisitos de reserva. 2) Nosso modelo pode definir de forma endógena o requisito de reserva ideal em toda a rede definindo reservas zonais. 3) Mostramos, em sistemas realistas, de até 6000 barras, que ambos os modelos (otimizando apenas reservas e otimizando a previsão de carga e reservas) foram capazes de melhorar significativamente o custo de operação, mesmo com recursos computacionais limitados. 4) Mostramos que o método de solução pode fornecer soluções de alta qualidade em tempo computacional razoável.

6.0 BIBLIOGRAFIA

VAN DER MEER, Dennis W.; WIDÉN, Joakim; MUNKHAMMAR, Joakim. Review on probabilistic forecasting of photovoltaic power production and electricity consumption. **Renewable and Sustainable Energy Reviews**, v. 81, p. 1484-1512, 2018.

ELA, Erik; MILLIGAN, Michael; KIRBY, Brendan. **Operating reserves and variable generation**. National Renewable Energy Lab.(NREL), Golden, CO (United States), 2011.

DIAS GARCIA, Joaquim Dias et al. Application-Driven Learning via Joint Prediction and Optimization of Demand and Reserves Requirement. **arXiv preprint arXiv:2102.13273**, 2021.

CHEN, Yonghong; GRIBIK, Paul; GARDNER, Joe. Incorporating post zonal reserve deployment transmission constraints into energy and ancillary service co-optimization. **IEEE Transactions on Power Systems**, v.29, 2013.

DE VOS, Kristof et al. Dynamic dimensioning approach for operating reserves: Proof of concept in Belgium. **Energy policy**, v. 124, p. 272-285, 2019.

WANG, Beibei; HOBBS, Benjamin F. A flexible ramping product: Can it help real-time dispatch markets approach the stochastic dispatch ideal?. **Electric Power Systems Research**, v. 109, p. 128-140, 2014.

ZHENG, Qipeng P.; WANG, Jianhui; LIU, Andrew L. Stochastic optimization for unit commitment—A review. **IEEE Transactions on Power Systems**, v. 30, n. 4, p. 1913-1924, 2014.

PAPAVASILIOU, Anthony; OREN, Shmuel S. Multiarea stochastic unit commitment for high wind penetration in a transmission constrained network. **Operations research**, v. 61, n. 3, p. 578-592, 2013.

WANG, Beibei; HOBBS, Benjamin F. Real-time markets for flexiramp: A stochastic unit commitment-based analysis. **IEEE Transactions on Power Systems**, v. 31, n. 2, p. 846-860, 2015.

PJM. 2018. Energy and Ancillary Services Market Operations. PJM Manual 11: (97):200 - <https://pjm.com/-/media/documents/manuals/archive/m11/m11v97-energy-and-ancillary-services-market-operations-07-26-2018.ashx>

STREET, Alexandre, VALLADÃO, David. Real-World Impact of Stochastic Programming: The Electricity Sector Case. *Stochastic Programming Society Newsletter*, v. 2, n. 1, p. 14-17, May 2021.

KAZEMPOUR, Jalal; PINSON, Pierre; HOBBS, Benjamin. A stochastic market design with revenue adequacy and cost recovery by scenario: Benefits and costs. **IEEE Transactions on Power Systems**, v. 33, n. 4, 2018.

CAISO. Annual Report on Market Issues and Performance. Department of Market Monitoring, California Independent System Operator. 2020. <http://www.caiso.com/Documents/2019AnnualReportonMarketIssuesandPerformance.pdf>.

BERTSIMAS, Dimitris; KALLUS, Nathan. From predictive to prescriptive analytics. **Management Science**, v. 66, n. 3, p. 1025-1044, 2020.

BENGIO, Yoshua. Using a financial training criterion rather than a prediction criterion. **International Journal of Neural Systems**, v. 8, n. 04, p. 433-443, 1997.

ROCKAFELLAR, R. Tyrrell; URYASEV, Stan; ZABARANKIN, Michael. Risk tuning with generalized linear regression. **Mathematics of Operations Research**, v. 33, n. 3, p. 712-729, 2008.

ELMACHTOUB, Adam N.; GRIGAS, Paul. Smart “predict, then optimize”. **Management Science**, 2021.

THE EUROPEAN COMMISSION. Commission regulation 2017/1485, establishing a guideline on electricity transmission system operation. <https://eur-lex.europa.eu/legal-content/EN/TXT/HTML/?uri=CELEX:32017R1485>

BABAEINEJADSAROOKOLAEI, Sogol et al. The power grid library for benchmarking ac optimal power flow algorithms. **arXiv preprint arXiv:1908.02788**, 2019.

DADOS BIOGRÁFICOS

(1) JOAQUIM DIAS GARCIA



Joaquim Dias Garcia ingressou na PSR em 2015. Ele divide seu tempo entre: pesquisa e desenvolvimento de metodologias avançadas em otimização estocástica, modelos de equilíbrio / binível e técnicas de reinforcement learning para aplicações de grande porte em mercados de energia; desenvolvimento de novos sistemas computacionais; e contribuições para o ecossistema JuMP na linguagem Julia. Ele tem graduação em engenharia elétrica e em matemática pela PUC-Rio, Brasil. Também cursou um ano na UC Santa Barbara, onde trabalhou com sistemas dinâmicos e controle. Atualmente, está terminando a tese de doutorado em engenharia elétrica com ênfase em pesquisa operacional, também na PUC-Rio.

(2) ALEXANDRE STREET DE AGUIAR

Alexandre Street é professor associado do Departamento de Engenharia Elétrica da PUC-Rio onde leciona Economia da Energia e Otimização. É fundador do Laboratory of Applied Mathematical Programming and Statistics (LAMPS PUC-Rio), onde lidera diversos projetos de P&D. Alexandre Street é senior member da IEEE PES e pesquisador 1 CNPq. É Editor Associado da IEEE Transactions on Power Systems, principal revista científica internacional da área de energia elétrica. Já publicou mais de 40 artigos em revistas científicas internacionais (atraindo mais de 1000 citações) e orientou mais de 30 alunos de pós-graduação em nível de mestrado, doutorado e pós-doutorado.

(3) TITO HOMEM-DE-MELLO

Tito Homem-de-Mello é Professor Titular da Escola de Negócios da Universidade Adolfo Ibañez (Chile) desde 2011. Antes de ingressar na UAI, trabalhou como professor na Northwestern University, University of Illinois-Chicago e Ohio State University, todas nos EUA. O Prof. Homem-de-Mello conduz pesquisas sobre questões relacionadas à tomada de decisões sob incerteza, com aplicações especialmente em energia e recursos naturais. Tem mais de 40 publicações científicas em revistas internacionais e participou como investigador principal em vários projetos de pesquisa no Chile, EUA e Brasil. Atualmente é Diretor do projeto "Operations Research In Energy & Climate Change" no Chile.

(4) FRANCISCO MUÑOZ

Diretor de Pesquisa da Generadoras de Chile. Economista e engenheiro com formação em economia de energia, organização industrial, pesquisa operacional e engenharia mecânica. Ampla experiência em economia de energia, desenho de mercado, regulamentação de serviços públicos, planejamento de transmissão, análise de decisão, antitruste, litígio e estratégia de negócios. Consultor de agências governamentais, organizações internacionais e empresas privadas nos Estados Unidos, América Latina e Europa. Diretor de vários projetos de pesquisa e consultoria. Fellow da Fulbright.