

Gerenciamento Pelo Lado da Demanda Industrial: Uma Abordagem Considerando Previsão de Geração Distribuída

Tarcisio P. Bernabé* Helder R. O. Rocha*
Jussara F. Fardin* Lucas F. S. Azeredo* Ícaro H. Honorato*

* Programa de Pós-Graduação em Engenharia Elétrica,
Universidade Federal do Espírito Santo, Brasil
(e-mail: tarcisioprest@gmail.com, helder.rocha@ufes.br,
jussara.fardin@ufes.br, lucas.azeredo@aluno.ufes.br,
icaro.h.honorato@gmail.com).

Abstract: This paper presents a computational solution to the demand-planning problem with the objective of minimizing the energy cost of a job-shop industrial environment, considering the presence of distributed generation (DG), as well as green and blue time-differentiated prices, applied at Brazilian energy market. The proposed solution consists of a DG forecasting system, that applies extreme learning machine networks, and an optimization system based on a genetic algorithm. Simulations were performed with three different industrial environments in order to validate the proposed model.

Resumo: Este trabalho apresenta uma solução computacional para o problema de planejamento de demanda com objetivo de minimizar o custo com energia elétrica de um ambiente industrial do tipo *job-shop*, considerando a presença de geração distribuída (GD), além de tarifas horossazonais verde e azul, aplicadas no mercado brasileiro de energia. A solução proposta conta com um sistema de previsão de GD, que utiliza redes neurais do tipo ELM - *Extreme Learning Machine*, e um sistema de otimização baseado em algoritmos genéticos. Foram realizadas simulações com três ambientes produtivos diferentes com o objetivo de validar o modelo proposto.

Keywords: Job-shop; demand-side management; distributed generation; genetic algorithm; extreme learning machine;

Palavras-chaves: Job-shop; gerenciamento pelo lado da demanda; geração distribuída; algoritmo genético; máquina de aprendizado extremo.

1. INTRODUÇÃO

Um estudo realizado pela *International Energy Agency* (IEA), em 2019, analisando dados entre 1974 e 2017, constatou que ao longo das últimas décadas, o consumo de energia elétrica ao redor do mundo cresceu a uma taxa histórica de 3.3% ao ano. Em 2017, de toda a energia consumida pelos países da OCDE, cerca de 32% foram destinados ao setor industrial. Nos demais países, esse percentual saltou para quase 50%, segundo a IEA (2019). Contudo, a ampliação da capacidade de geração de energia tornou-se um desafio, tendo em vista limitações físicas, de recursos naturais e financeiros ou, ainda, por questões ambientais. Desta forma, surge a necessidade de desenvolver alternativas que visem minimizar os impactos ambientais e financeiros de novas unidades geradoras e otimizar o uso de energia elétrica, em especial no setor industrial, que é responsável pela maior parcela de consumo de energia.

Dentro desse contexto, o sistema elétrico de potência (SEP) vem sofrendo inúmeras mudanças estruturais, com destaque para a inserção de centros de geração distribuída (GD) próximas aos centros de consumo e o fortalecimento

das redes inteligentes (*smart grids*), que são microrredes (*microgrids*) dotadas de sistemas de comunicação e controle entre seus elementos, possibilitando o uso eficiente e otimizado da energia elétrica (Hadjsaïdb and Sabonna-dièrè, 2013).

Atrelado ao conceito de *smart grids* está o Gerenciamento pelo Lado da Demanda (GLD), que pode ser definido como o planejamento e a implementação de técnicas, que envolvem ações das concessionárias destinadas a influenciar os consumidores de forma a produzir alterações desejadas na curva de carga. Ou seja, são medidas que buscam reduzir os picos de demanda e o consumo total de energia, melhorar a confiabilidade da rede e eficiência energética, gerenciar os gastos com energia, favorecer a geração distribuída, aumentar a utilização e o fator de carga das unidades geradoras, proporcionar o deslocamento de carga quando o sistema estiver operando próximo à capacidade de geração e, até mesmo, evitar a construção de unidades de geração, transmissão ou distribuição, que poderiam ficar subutilizadas (Gellings and Chamberlin, 1993), (Cortez et al., 2016).

Ademais, ciente do aumento da participação das energias renováveis na matriz energética mundial (IEA, 2019), a

aplicação do GLD em microrredes torna-se muito importante para adaptação do consumo aos perfis de geração de fontes renováveis de natureza intermitente e estocástica, através da previsão da capacidade de geração interna e da energia elétrica demandada pelos dispositivos consumidores de energia elétrica, por exemplo. Contudo, trata-se de um problema complexo, que requer a utilização de técnicas de análise de dados e de modelos de previsão (Zortea et al., 2017), (Christo et al., 2016).

Estudos realizados pelo Laboratório de Energias Renováveis dos Estados Unidos (NREL), em uma planta eólica de 1920 MW, localizada no estado do Arizona, mostraram que um aumento de 20% no índice de acerto do sistema de previsão poderia reduzir o custo anual de operação em até 195 milhões de dólares, considerando uma penetração média anual de 24% (Lew et al., 2011). Em outro estudo simulando a operação de uma planta solar com 19.5 GW de potência instalada, equivalente a 18% de penetração média anual, obteve-se uma economia de, aproximadamente, 11 milhões de dólares nos custos de operação com o aumento de 25% no índice de acerto da previsão (Martinez-Anido et al., 2016). Esses resultados mostram o potencial econômico da inserção de algoritmos de previsão em sistemas que dispõem de fontes solar e eólica.

O GLD pode ser aplicado em nível industrial, comercial ou residencial. Contudo, é no setor industrial em que há maior potencial para ganhos e também os maiores desafios devido às suas características. A indústria possui destaque devido à grande quantidade de cargas com possibilidade de controle, um alto consumo de energia, ou seja, envolve um alto valor financeiro e, além disso, a existência de uma infraestrutura de medição avançada, permitindo a redução do investimento inicial e *payback*. Entretanto, os processos tendem a ser muito complexos, integrados e dependentes. Logo, escalonar os processos de modo que a produção seja atendida no tempo desejado, a um baixo custo, obedecendo-se os critérios de precedência e restrições, torna-se um grande desafio (Mohamed and Khan, 2009).

Dessa forma, o presente trabalho apresenta uma solução para minimizar o custo com energia elétrica através da otimização da programação de produção industrial com base em algoritmos genéticos (AG), levando em consideração a previsão de geração interna com uso de ELM - *extreme learning machines*. A solução proposta, considera que a indústria disponha de GD, do tipo solar e eólica, e tarifa horo-sazonal (THS) verde ou azul, de acordo com as diretrizes de tarifação de energia elétrica no Brasil definidas pela Agência Nacional de Energia Elétrica (ANEEL), com base na Resolução Normativa nº414 de 2010.

2. SISTEMA GLD INDUSTRIAL

Uma topologia típica para um sistema GLD industrial é apresentada na Figura 1. O sistema é composto por três grupos. O primeiro é responsável pelo fornecimento de energia à planta que pode ser através de geração interna, compra direta da concessionária ou, até mesmo, por banco de baterias. O segundo é composto por cargas industriais, cada uma com atuadores individuais com intuito de ativar, ou não, um processo em determinado instante. O terceiro, e mais importante, é o centro de gerenciamento e con-

trole, que interliga todo o sistema sendo responsável pela programação dos processos da indústria em questão com intuito de minimizar o custo de energia elétrica, baseado na geração de energia interna, valor da tarifa instantânea e necessidades do processo produtivo (Zortea et al., 2017). Vale ressaltar que no presente trabalho não foi considerado o uso de banco de baterias ou qualquer tipo de armazenamento interno, uma vez que toda a energia excedente gerada é vendida para a concessionária.




Figura 1. GLD industrial: topologia (Zortea et al., 2017).

Dessa forma, considerando-se as premissas previamente apresentadas, o problema GLD industrial pode ser formulado como:

$$\text{Min} \left\{ \sum_{i=1}^M [E_c(i) \times C_c(i) - E_e(i) \times C_v(i)] + CD \right\}, \quad (1)$$

onde:

- $E_c(i)$ indica o montante de energia consumida no período de funcionamento i ;
- $C_c(i)$ é o valor do custo de energia no posto horário i , de acordo com a THS verde ou azul, no horário de ponta ou fora de ponta;
- $E_e(i)$ indica o montante de energia renovável excedente gerada no período de funcionamento i ;
- $C_v(i)$ é o valor de venda de energia excedente para a concessionária no posto horário i ;
- CD indica o custo referente à demanda contratada e ultrapassada;
- M é o número de períodos no qual se divide o funcionamento da *smart grid*.

O montante de energia consumida é o valor líquido de energia elétrica gasta pela indústria após subtração da energia renovável gerada, ou seja:

$$E_c(i) = \sum_{m=1}^{Ma} [X(i, m) \times P_L(m) \times T_t(m) - E_r(i)], \quad (2)$$

onde:

- $X(i, m)$ indica se o m -ésimo equipamento elétrico da *smart grid* está ligado no período de funcionamento i ;
- $P_L(m)$ é a potência nominal do m -ésimo equipamento elétrico da *smart grid*;
- $T_t(m)$ é o tempo de trabalho do m -ésimo equipamento elétrico da *smart grid*;
- $E_r(i)$ indica o montante de energia renovável gerada no período de funcionamento i ;

- M_a é o número de equipamentos da *smart grid*.

Este trabalho aborda a programação da produção em um ambiente produtivo do tipo *job-shop* que representa o ambiente operacional de empresas manufatureiras com as seguintes características: alta variedade de produtos, volume baixo de produção e uma organização dividida em áreas funcionais. Formalmente, o modelo *job-shop* é definido como um conjunto de n tarefas (*jobs*), um conjunto de m máquinas definidas sequencialmente para cada tarefa t . A série de operações deve ser determinada no instante de início da produção da fábrica, cada operação deve ser realizada em uma única máquina por um determinado período de tempo sem interrupção, e cada máquina pode realizar somente uma operação de cada vez (Morales and Ronconi, 2016). Dessa forma, é possível perceber que o sistema abordado possui restrições que devem ser incluídas no algoritmo de otimização. São elas: precedência, simultaneidade e máximo período de operação da indústria.

A restrição de precedência é definida em (3) e estabelece que, para uma determinada tarefa (t), a precedência dos períodos de início das operações nas máquinas correspondentes, ou seja, o período de início da operação ($l + 1$) da tarefa (t) em uma máquina (k) deve ser maior ou igual ao período de início da operação (l) na máquina correspondente a essa operação mais seu tempo de processamento.

$$\sum_{k=1}^{M_a} r(t, l, k) \times \{(s(t, k) + p(t, k))\} \leq \sum_{k=1}^{M_a} r(t, l + 1, k) \times (s(t, k); t = 1, \dots, Ta; l = 1, \dots, M_a - 1, \quad (3)$$

onde:

- $r(t, l, k)$ indica se a operação l da t -ésima tarefa requer a máquina elétrica k ;
- $s(t, k)$ é o período de início de funcionamento da máquina k na t -ésima tarefa;
- $p(t, k)$ é o tempo de processamento da máquina elétrica k na t -ésima tarefa;
- Ta é o número de tarefas.

Outro fator importante está relacionado aos equipamentos ou máquinas elétricas da indústria, os quais não podem estar funcionando simultaneamente em duas operações. Com intuito de simplificar o problema, neste trabalho, é considerada a existência de uma máquina para cada operação, ou seja, para cada operação l existe uma máquina m , simplificando a restrição de simultaneidade.

Por último, a restrição do período de operação da indústria, ou seja, a *smart grid* deve ter um tempo máximo de funcionamento no período. No presente trabalho, este tempo é equivalente ao *makespan*, que é definido como o tempo de execução da *smart grid*, quando todas as operações são alocadas em série. Tal restrição é descrita em (4).

$$\sum_{k=1}^{M_a} r(t, l, k) \times \{(s(t, k) + p(t, k))\} \leq M; t = 1, \dots, Ta. \quad (4)$$

3. SISTEMA DE PREVISÃO DE GERAÇÃO DISTRIBUÍDA

A previsão da capacidade de geração interna de uma *smart grid* dotada de fontes de geração intermitente tem como objetivo maximizar os ganhos obtidos através da GLD. Dessa forma, optou-se pela metodologia utilizada por Rocha et al. (2018), que se enquadra ao problema aqui abordado. O autor utiliza redes neurais do tipo ELM, que possuem alta velocidade de aprendizagem e boa capacidade de generalização, baseando-se na metodologia desenvolvida por Huang et al. (2011), para realizar a previsão da capacidade de geração de energia com 24 horas de antecedência de uma microrrede dotada de fontes renováveis, a partir de informações climáticas.

Inicialmente, Rocha et al. (2018) consideram a existência de um microgerador eólico e outro solar, os quais são modelados matematicamente para obtenção dos dados históricos das potências geradas pela *smart grid*, através de padrões meteorológicos. Estes dados são usados para validação e treinamento do modelo de previsão. Os modelos matemáticos utilizados para modelar os painéis fotovoltaicos e turbina eólica foram extraídos de (Abdelaziz et al., 2015) e (Fiorotti, 2015), respectivamente.

Os dados meteorológicos utilizados foram coletados da estação meteorológica do Campus de São Mateus da Universidade Federal do Espírito Santo (UFES). São 21.648 padrões de entrada (data, hora [UTC], temperatura média [°C], umidade relativa média [%], pressão média [hPa], velocidade do vento [m/s], direção do vento, rajada do vento [m/s] e irradiação [kW/m²]) amostrados de hora em hora, no período de 01/01/2014 a 20/06/2016.

Os valores de potência obtidos pelos modelos matemáticos foram deslocados em 24 horas, formando o padrão completo: dados meteorológicos medidos no dia D na hora k (usados na entrada da rede ELM); potência total estimada no dia $D + 1$ na hora k . Dados inconsistentes e ausente foram descartados e os dados restantes foram normalizados no intervalo entre 0 e 1. Em seguida, as amostras foram separadas em dois conjuntos, são eles: 80% para treino e 20% para teste.

A arquitetura resultante do processo de treinamento foi: rede ELM com 110 neurônios na camada oculta; função de ativação *sigmoide*; matriz de pesos [9x110]; e, com um *bias* associado a cada neurônio. A solução proposta por Rocha et al. (2018) obteve como resultado: raiz do erro quadrático médio (REQM) de 0,0813.

No presente trabalho foram mantidas a mesma abordagem e base de dados utilizadas em (Rocha et al., 2018), porém adaptou-se o modelo em, pelo menos, três fatores. O primeiro diz respeito às *variáveis de entrada*. Através da análise de correlação entre *inputs* e *target*, percebeu-se a incidência de informação redundante e, portanto, desnecessária. Dessa forma, o modelo proposto neste trabalho utiliza como *inputs* apenas as seguintes variáveis: velocidade do vento, irradiação, temperatura ambiente e hora do dia.

A segunda adaptação refere-se ao *horizonte de previsão*. Ao contrário do modelo de Rocha et al. (2018), neste trabalho faz-se necessário um horizonte de previsão variável de

acordo com o *makespan* do processo. Por exemplo, no processo industrial apresentado em (Tonini et al., 2018), o *makespan* é de 33 horas. Logo, para que o GLD contemple todo o período de operação é necessário dispor da previsão de geração interna de pelo menos 33 horas à frente.

Além disso, foi considerado um fator de escala com objetivo de aumentar a potência gerada pela microrrede utilizada em (Rocha et al., 2018), de forma que haja equivalência com a carga instalada nas plantas industriais aqui sugeridas. Basicamente, se a indústria tem uma demanda média em *kW*, faz sentido que seja considerando uma GD de mesma ordem.

Na Tabela 1 são apresentados os resultados obtidos para o modelo proposto neste trabalho considerando três horizontes de previsão diferentes (24, 48 e 72 horas), através das seguintes métricas de avaliação: *REQM*, *EQM* - erro quadrático médio, *EM* - erro absoluto médio e R^2 - coeficiente de determinação. Percebe-se um aumento de, aproximadamente, 12,15% na *REQM*, 26,39% no *EQM* e 11,98% no *EM* e diminuição de 1 p.p, aproximadamente, no R^2 , quando se aumenta o horizonte de previsão de 24 para 72 horas. Esses resultados indicam que, apesar da necessidade de se utilizar um algoritmo de previsão com horizonte variável, é necessário considerar a piora dos resultados quando se estende o horizonte de previsão desejado. Por último, a Figura 2 apresenta uma comparação entre a demanda obtida pelo modelo matemático (*target*) e a prevista pelo modelo ELM, considerando 3 horizontes de previsão diferentes, antes da aplicação do fator de escala proposto anteriormente.

Tabela 1. Resultados obtidos para diferentes horizontes de previsão.

Horizonte	<i>REQM</i>	<i>EQM</i>	<i>EM</i>	R^2
24 horas	0,0849	0,0072	0,0484	0,9392
48 horas	0,0943	0,0089	0,0541	0,9309
72 horas	0,0953	0,0091	0,0542	0,9282




Figura 2. Previsão do dia 25/01/2015 ao dia 27/01/2015.

4. SISTEMA DE OTIMIZAÇÃO

O sistema de otimização proposto neste trabalho aplica a meta-heurística conhecida por AG, proposta por Holland (1975), com intuito de minimizar o custo total gasto com

energia elétrica. Esta meta-heurística baseia-se na teoria da evolução natural desenvolvida por Charles Darwin, ou seja, a partir de uma população inicial busca-se gerar através dos operadores genéticos de seleção, mutação e cruzamento, novos cromossomos com propriedades genéticas superiores às de seus antecedentes.

No caso específico, a população inicial, composta por matrizes soluções, que representam a alocação dos processos ao longo do tempo, foi gerada a partir de uma heurística construtiva obedecendo às restrições previamente apresentadas. Cada matriz solução inicial foi gerada a partir de basicamente dois passos, são eles:

- (1) Selecionar equipamentos sem pré-requisitos para entrar em operação e alocá-los aleatoriamente no intervalo entre $i = 1$ e $i_f = M_i$, em que M_i é o *makespan* dos processos sem pré-requisitos. Dessa forma, esses equipamentos são alocados no início do ciclo de operação da indústria.
- (2) Enquanto houver equipamentos não alocados, selecionar e alocar equipamentos cujos processos pré-requisitos encontram-se já alocados. Similar ao passo anterior, aloca-se equipamento por equipamento de forma aleatória entre $i = i_p$ e $i_f = i_f + t_d$, em que i_p é o instante em que o último processo pré-requisito termina e t_d é a duração do processo que está sendo alocado. Percebe-se que o valor de i_f é incrementado toda vez que um equipamento é alocado, de forma que no final espera-se $i_f = M$.

Na fase de seleção, os cromossomos dos indivíduos tidos como mais aptos são escolhidos para formar a base genética da geração subsequente a deles de acordo com sua função aptidão. Neste caso específico, a função aptidão foi apresentada em (1), ou seja, quanto menor o custo maior será a aptidão. Os cromossomos dos indivíduos, são representados por matrizes soluções, conforme mostra a Figura 3.

	1	2	3	4	5	6	7	8	9	...	M-2	M-1	M
1	1	1	0	0	0	0	0	0	0	...	0	0	0
2	0	1	1	0	0	0	0	0	0	...	0	0	0
3	0	1	0	0	0	0	0	0	0	...	0	0	0
4	0	0	1	0	0	0	0	0	0	...	0	0	0
5	0	0	1	1	1	0	0	0	0	...	0	0	0
...	...	...	...	...	...	...	...	...	...	...	...	...	...
Ma-1	0	0	0	0	0	0	0	0	0	...	0	1	1
Ma	0	0	0	0	0	0	0	0	0	...	1	0	0

Figura 3. Exemplo de cromossomo ou matriz solução.

A dimensão da matriz corresponde ao número máximo de equipamentos e ao *makespan* da indústria em questão. Os elementos da matriz contêm valores binários, assumindo valor "1" quando o equipamento estiver consumindo energia e "0" caso contrário. Por exemplo, o equipamento (linha) 4 encontra-se em funcionamento, somente, no período (coluna) 3.

Em seguida, as soluções selecionadas passam por um processo de cruzamento. O algoritmo define, aleatoriamente, um ou dois pontos de corte entre dois genes adjacentes de cada cromossomo pai selecionado para cruzamento. Em (Flores et al., 2016), é apresentado o processo de cruzamento com apenas um corte. Na Figura 4, é apresentado um exemplo de cruzamento entre dois cromossomos quando tem-se dois pontos de corte. Os cortes dos cromos-

somos pai (à esquerda) são recombinados formando novos cromossomos filho (à direita) de forma que os filhos tenham mais ou menos influência de determinado pai, de acordo com os pontos de corte. Vale ressaltar que os pontos de corte também são definidos aleatoriamente pelo algoritmo buscando diversificar o número de soluções possíveis.




Figura 4. Exemplo de cruzamento entre cromossomos considerando dois pontos de corte.

No processo de mutação, altera-se uma pequena parcela de cromossomos, selecionada de forma aleatória. Na Figura 5 é apresentada a mutação em um equipamento de um determinado cromossomo, em que se desloca os valores para direita ou para a esquerda uma posição, de acordo com uma probabilidade (Flores et al., 2016). No presente trabalho, propõe-se duas mudanças para, mais uma vez, potencializar a diversidade de soluções do AG proposto. Primeiro, permite-se que haja mutação em até todos os equipamentos do cromossomo mutante. Segundo, é possível que haja deslocamento de até 4 posições para direita ou para esquerda. Contudo, o número de posições deslocadas é inversamente proporcional a sua probabilidade de ocorrência.




Figura 5. Exemplo de mutação em um cromossomo (Flores et al., 2016).

Por último, os indivíduos antigos e novos são reordenados de acordo com sua aptidão. Os indivíduos com maior aptidão são mantidos e o restante é descartado, de forma que o número de indivíduos da população se mantém constante. Indivíduos que não respeitam as restrições descritas anteriormente são penalizados com uma baixa aptidão, suficiente para excluí-los da próxima geração do AG. O processo se repete até que o algoritmo atinja o número máximo de gerações, determinado antes da execução do sistema.

5. RESULTADOS

Os resultados obtidos baseiam-se na análise de 3 indústrias com *makespan*, número de equipamentos e, portanto, potência, diferentes para cada uma delas. Sugeriu-se 2 topologias, além da apresentada em (Tonini et al., 2018) porém, com uma redução nas potências dos equipamentos

para a ordem de kW, visando valores mais factíveis. Também foram consideradas as THS verde e azul. Por último, comparou-se os resultados obtidos de cada indústria com os custos das indústrias respectivas operando em série sem considerar a previsão de energia gerada pela GD.

Na Tabela 2, é possível encontrar as características gerais das topologias industriais utilizadas neste trabalho, em que C_{max} é a carga total instalada na indústria em questão. Além disso, vale ressaltar que o horário inicial para início das atividades das indústrias foi de 7 horas da manhã.

Tabela 2. Características gerais das indústrias propostas.

Indústria	M (horas)	M_a	C_{max} (MW)
1	16	10	0,750
2	33	20	1,310
3	48	30	2,175

A estrutura tarifária para THS verde e azul baseiam-se em valores atuais praticados pelas concessionárias no mercado de energia brasileiro e são apresentados nas Tabelas 3 e 4. Para a THS verde a demanda contratada considerada foi de 150 kW e para a THS azul de 50 kW e 150 kW nos horários de ponta e fora ponta, respectivamente. Em relação à venda de energia excedente, foi considerada uma tarifa de 50% do valor da tarifa de consumo, de acordo com o posto horário no instante da venda. Os parâmetros utilizados no AG são apresentados na Tabela 5.

Tabela 3. Estrutura THS verde.

Tipo	Posto Horário	Valor
Demanda	-	17,50 (R\$/kW)
Demanda ult.	-	35,00 (R\$/kW)
Consumo	Ponta	1,35315 (R\$/kWh)
Consumo	Fora ponta	0,39486 (R\$/kWh)

Tabela 4. Estrutura THS azul.

Tipo	Posto Horário	Valor
Demanda	Ponta	32,45 (R\$/kW)
Demanda	Fora ponta	17,50 (R\$/kW)
Demanda ult.	Ponta	64,90 (R\$/kW)
Demanda ult.	Fora de ponta	35,00 (R\$/kW)
Consumo	Ponta	0,56592 (R\$/kWh)
Consumo	Fora ponta	0,39486 (R\$/kWh)

Tabela 5. Parâmetros de simulação do AG.

Parâmetro	Valor
Tamanho da população	1.000
Inicialização da população	Heurística
Número de gerações	100
Método de Seleção	Roleta
Taxa de cruzamento	0,80
Método de cruzamento	1 ou 2 pontos
Taxa de mutação da população	0,02
Taxa de processos mutantes	0,10
Penalidade	1×10^{10}
Elitismo	Sim

Os resultados apresentados nas Tabelas 6 e 7, referem-se ao consumo mensal (30 dias) da indústria considerando um mesmo padrão de consumo e geração do período de operação simulado. Por exemplo, tendo-se o dia 04 de abril de 2016 como alvo para otimização, e sabendo-se que a indústria 1 necessita de menos de um dia para realizar um ciclo completo de produção, o custo mensal refere-se

à execução de 30 ciclos completos considerando a mesma ordem de operação e geração encontrada pelo algoritmo de otimização para a data em questão. Essa generalização foi necessária pois o custo referente à parcela de demanda é calculado pela concessionária mensalmente, enquanto o sistema proposto otimiza o gasto de energia em um período referente ao *makespan* da indústria. No caso das indústrias 2 e 3 são considerados 15 ciclos completos de produção, considerando sempre o mesmo horário de início de operação, ou seja, se a indústria termina o processo às 10 horas da noite, espera-se até 7 horas da manhã do dia seguinte para iniciar um novo ciclo de produção.

Tabela 6. Resultados para THS verde.

Sequencial				
M_a	Cons. (R\$)	Dem. (R\$)	Dem.Ult (R\$)	Total (R\$)
10	7.824,00	2.625,00	0,00	10.449,00
20	9.980,40	2.625,00	1.925,00	14.530,40
30	18.521,85	2.625,00	1.750,00	22.896,85

Otimizado				
M_a	Cons. (R\$)	Dem. (R\$)	Dem.Ult (R\$)	Total (R\$)
10	6.599,70	2.625,00	0,00	9.224,70
20	8.162,25	2.625,00	74,86	10.862,11
30	15.255,75	2.625,00	670,03	18.550,78

Tabela 7. Resultados para THS azul.

Sequencial				
M_a	Cons. (R\$)	Dem. (R\$)	Dem.Ult (R\$)	Total (R\$)
10	7.524,60	4.247,50	1.491,44	13.263,54
20	9.007,80	4.247,50	1.925,00	15.180,30
30	17.646,15	4.247,50	9.731,44	31.625,09

Otimizado				
M_a	Cons. (R\$)	Dem. (R\$)	Dem.Ult (R\$)	Total (R\$)
10	7.340,10	4.247,50	249,86	11.837,46
20	8.459,55	4.247,50	0,00	12.707,05
30	16.908,75	4.247,50	670,03	21.826,28

6. CONCLUSÕES

Neste trabalho foi apresentada uma solução para otimizar a programação de produção de uma indústria do tipo *job-shop* minimizando o custo com energia elétrica. Para tanto, sugeriu-se o emprego da meta-heurística AG, THS, além de considerar a previsão de GD, através do uso de ELM. Os resultados obtidos mostram que a metodologia proposta reduziu o custo de produção com energia elétrica em até 25% para THS verde e 31% para THS azul, aproximadamente, quando se compara o resultado obtido pelo sistema proposto, com o seu equivalente operando em série. Apesar das restrições presentes no sistema GLD Industrial, a metodologia desenvolvida realocou de forma satisfatória os processos em horários cuja energia é mais barata ou que haja maior volume de geração interna, além de diminuir a ocorrência de ultrapassagens. Por último, sugere-se para trabalhos futuros o desenvolvimento de uma metodologia de otimização multiobjetivo, abrangendo-se a variável tempo de produção e a análise da inclusão de um banco de baterias no sistema.

REFERÊNCIAS

Abdelaziz, A., Hegazy, Y., El-Khattam, W., and Othman, M. (2015). Optimal allocation of stochastically depen-

dent renewable energy based distributed generators in unbalanced distribution networks. *Electric Power Systems Research*, 119, 34–44.

Christo, T.M., Bernabe, T.P., Fardin, J.F., and Simonetti, D.S.L. (2016). Wavelets e redes neurais aplicadas à previsão de recurso eólico. In *2016 Congresso Brasileiro de Automática (CBA)*, 2443–2448.

Cortez, V.H.N., Araujo, D.R.R.P., and Araujo, L.R. (2016). Gerenciamento pelo lado da demanda utilizando algoritmos genéticos em sistemas industriais. In *2016 Congresso Brasileiro de Automática (CBA)*, 2443–2448.

Fiorotti, R. (2015). *Metodologia para determinar a potência firme das unidades de geração distribuída e sua aplicação no processo de previsão de demanda das redes de distribuição de energia elétrica*. Dissertação de Mestrado, Universidade Federal do Espírito Santo.

Flores, J.T., Celeste, W.C., Coura, D.J.C., das Dores Risino, S., Rocha, H.R.O., and Moraes, R.E.N. (2016). Demand planning in smart homes. *IEEE Latin America Transactions*, 14(7), 3247–3255.

Gellings, C. and Chamberlin, J. (1993). *Demand-Side Management: Concepts and Methods*. Pennwell Pub.

Hadjsaïdb, N. and Sabonnadière, J.C. (2013). *Smart Grids*. John Wiley & Sons.

Holland, J.H. (1975). Adaptation in natural and artificial systems. *The University of Michigan Press, Ann Arbor, MI*. Reprinted and published in 1992 by MIT Press, Cambridge, MA.

Huang, G.B., Zhou, H., Ding, X., and Zhang, R. (2011). Extreme learning machine for regression and multiclass classification. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 42(2), 513–529.

IEA (2019). Electricity information 2019: Overview.

Lew, D., Milligan, M., Jordan, G., and Piwko, R. (2011). Value of wind power forecasting. Technical report, National Renewable Energy Lab.(NREL), Golden, CO (United States).

Martinez-Anido, C.B., Botor, B., Florita, A.R., Draxl, C., Lu, S., Hamann, H.F., and Hodge, B.M. (2016). The value of day-ahead solar power forecasting improvement. *Solar Energy*, 129, 192–203.

Mohamed, A. and Khan, M.T. (2009). A review of electrical energy management techniques: supply and consumer side (industries). *Journal of Energy in Southern Africa*, 20(3), 14–21.

Morales, S.G. and Ronconi, D.P. (2016). Formulações matemáticas e estratégias de resolução para o problema job shop clássico. *Production*, 26(3), 614–625.

Rocha, H.R.O., Silvestre, L.J., Celeste, W.C., Coura, D.J.C., and Junior, L.O.R. (2018). Forecast of distributed electrical generation system capacity based on seasonal micro generators using elm and pso. *IEEE Latin America Transactions*, 16(4), 1136–1141.

Tonini, M.S.P., Rocha, H.R.O., L. J. Silvestre, W.C.C., Coura, D.J.C., and Fiorotti, R. (2018). Industrial demand management considering distributed generation and differentiated rates in time. In *2018 Simposio Brasileiro de Sistemas Eletricos (SBSE)*, 1–6. IEEE.

Zortea, A.L., Fardin, J.F., Rocha, H.R.O., and Fiorotti, R. (2017). Gerenciamento pelo lado da demanda aplicado a sistemas industriais: metodologias e desafios. In *2017 Simposio Brasileiro de Pesquisa Operacional (SBPO)*, 1–9.