



Grupo de Estudo de Geração Eólica, Solar e Armazenamento-GES

Estratégias de O&M utilizadas na gestão de desempenho dos parques eólicos, em Tempo Real, Pós Operação e Engenharia de Manutenção no curto e médio prazo, mostrando os resultados obtidos com a utilização de BigData, Business Intelligence e Machine Learning (ML)

**FLÁVIO MARTINS RIBEIRO(1); MARCUS ANTONIUS QUEIROZ DA CUNHA(1);
CPFL(1);**

RESUMO

No setor de energias renováveis, mais precisamente na geração de energia eólica, ferramentas computacionais aliadas a estratégias de O&M tem sido cada vez mais foco de estudos e investimentos. Esse informe apresenta algumas ferramentas computacionais e estratégias de O&M utilizadas na gestão de desempenho de parques eólicos, em Tempo Real, Pós Operação e Engenharia de Manutenção no curto e médio prazo, mostrando os resultados obtidos com a utilização de Big Data, Business Intelligence (BI) e Machine Learning (ML).

PALAVRAS-CHAVE

Business Intelligence, Aprendizagem de máquina, Machine Learning, Geração eólica

1.0 - INTRODUÇÃO

O Aerogerador é composto por um conjunto de vários componentes que possibilitam a conversão da energia cinética do vento em energia elétrica de maneira controlada, confiável e eficiente. Os aerogeradores podem ser divididos em sistemas mecânicos, elétricos e de controle. Os componentes mecânicos incluem torre, nacelle, pás, cubo, gearbox (caixa de engrenagens), sistema de pitch, sistema de yaw, sensores de velocidade do vento, drive train e freios mecânicos. Os componentes elétricos incluem o gerador elétrico, o conversor eletrônico de potência (quando existente) junto com filtros harmônicos do lado do gerador e da rede, transformador de força e rede trifásica ou ponto de entrega. Os componentes relacionados ao controle dos sistemas de conversão de energia mecânica e elétrica. As partes mais visíveis nas grandes turbinas eólicas são a torre, a nacelle e as pás do rotor, e os demais componentes estão alojados dentro da turbina eólica.

Assim, para monitoramento do funcionamento dos aerogeradores de grande porte, os diversos sistemas podem ser capazes de disponibilizar informações como alarmes de funcionamento dos sistemas, estados e demais pontos digitais dos aerogeradores, além de variáveis analógicas, como potência ativa, potência reativa, correntes elétricas, tensões, frequência elétrica, velocidade do vento, direção do vento, densidade do ar, temperatura ambiente, velocidade do rotor, velocidade do gerador, ângulos do pitch, posição angular da nacelle, posição angular da nacelle em relação ao vento, temperatura dos rolamentos do Gearbox, temperatura do óleo da Gearbox, temperatura dos rolamentos do gerador, temperatura dos enrolamentos do gerador, temperatura da Nacelle, temperatura de painéis, vibração da torre, vibração do Drive train, além de muitos outros, dependendo do fabricante e topologia do aerogerador.

Aerogeradores de grande porte (>1MW) podem ser de 4 tipos diferentes. Os três tipos mais utilizados comercialmente são apresentados na Figura 1.




FIGURA 1 – Topologias de conexão de aerogeradores (YARAMASU, 2015)

Cada fabricante de aerogeradores comerciais de grande porte disponibiliza seus dados em plataformas variadas de dados e em banco de dados próprios e com configurações determinadas pelo próprio fabricante. Assim, realizar trabalhos de criação de banco de dados únicos com informações padronizadas se torna uma tarefa difícil utilizando essas plataformas.

O objeto de estudo utilizado no desenvolvimento das estratégias tratadas nesse informe técnico são 645 aerogeradores diferentes das três topologias mais utilizadas comercialmente e de 6 fabricantes diferentes, conforme Tabela 1,

Tabela 1 – Topologias e nº de aerogeradores por fabricante

Fabricante	Topologia	Nº de AEGs da frota
1	Tipo 2 e Tipo 3	182
2	Tipo 3	147
3	Tipo 3	133
4	Tipo 4	34
5	Tipo 4	109
6	Tipo 3	120

2.0 - DESENVOLVIMENTO DE ESTRATÉGIAS

Devido a diversidade de topologias e fabricantes, o primeiro passo foi desenvolver um Sistema Supervisório (SCADA) único que consolidasse a aquisição de todos os pontos digitais e analógicos dos 645 aerogeradores e diversos pontos do BoP elétrico, se tornando o maior sistema de automação do Brasil em número de pontos supervisionados (~700mil pontos). Esse sistema faz a aquisição em fração de segundos das grandezas dos WTGs e possuem regras de análise de desempenho. O objetivo aqui é não “deixar para amanhã” ajustes de parâmetros e manutenções que podem ser realizadas imediatamente para se obter a maior eficiência na geração de energia.

2.1 ANÁLISE EM TEMPO REAL

Para atingir metas arrojadas de perda por indisponibilidade e perda por ineficiência, o Centro de Operação tem em tempo real visualização do número de aerogeradores, por usina, que estão disponíveis, disponíveis não gerando, indisponíveis e sem comunicação. Além disso, um gráfico de rosca auxilia no entendimento da perda de potência por indisponibilidade ou por eficiência. Uma tela apresentando diversas informações (em tempo real) de todos os conjuntos/complexos eólicos objeto do estudo encontra-se na Figura 2.



FIGURA 2 – Tela de visão geral das usinas eólicas

Na tela apresentada na Figura 2 é possível visualizar gráfico de barras, apresentando número de aerogeradores comunicando (ou não), disponíveis (ou não) e disponíveis gerando (ou não). Além de ser possível visualizar gráficos de rosca para cada conjunto/complexo eólico. Esse gráfico de rosca é dividido em 4 setores: Potência ativa geral, Potência ativa média perdida por indisponibilidade, Potência ativa média perdida por ineficiência e a diferença entre a potência nominal e a soma das três outras, conforme Figura 3.

10 a 13 de novembro de 2019
Belo Horizonte - MG



FIGURA 3 – Legenda de cores do gráfico de rosca de cada usina

A partir das informações apresentados nos gráficos, o operador do Centro de Operação de tempo real consegue ter uma primeira visualização de indisponibilidades e ineficiências, podendo investigar as principais perdas por parques e por aerogeradores, tendo a possibilidade de tratar grandes indisponibilidades e grandes ineficiências ainda em tempo real. Além disso, um alarme é acionado para cada aerogerador que apresenta baixa eficiência, conforme Figura 4.

Data e hora	Área	Estado	Descrição
24/04/2019 10:30:00,997	EDIM.DIM-004		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-003		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-005		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-007		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-008		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-009		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,997	EDOM.DOM-012		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-002		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-006		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-011		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-012		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-013		Potência ativa perdida por ineficiência
24/04/2019 10:30:00,091	EBEN.BEN-014		Potência ativa perdida por ineficiência
24/04/2019 10:20:00,676	EBEN.BEN-008		Potência ativa perdida por ineficiência
24/04/2019 10:10:00,430	EDOM.DOM-006		Potência ativa perdida por ineficiência

FIGURA 4 – Tela com alarmes detalhamento de um aerogerador dentro do SCADA unificado

A partir dos indicativos visuais e alarmes, o operador de tempo real, consegue acessar dados de cada aerogerador, através de uma tela de detalhamento criada dentro do sistema de supervisão, e realizar análise aprofundada da perda visualizada, dependendo do grau de prioridade que tenha essa perda.



FIGURA 5 – Tela de detalhamento de um aerogerador dentro do SCADA unificado

Devido ao grau de ocupação dos operadores de centro de operação nas atividades de tempo real (supervisão e operação dos ativos), pequenas perdas visualizadas graficamente são desprezadas em uma análise de tempo real, sendo investigados em outro momento, através de análises de curto e médio prazo.

2.2 ANÁLISE DE CURTO E MÉDIO PRAZO

Todos os pontos aquisitados pelo supervisório são historiados com estratégias de armazenamento em Big Data, melhorando a capacidade de armazenamento e desempenho de consultas. Através desses dados análises de desempenho com o uso de ferramentas de BI são realizadas pela área de Pós Operação imediatamente no dia seguinte, assim como semanalmente, apresentado em reunião de Análise de Performance (curto prazo). As análises primárias baseiam-se em gráficos de desempenho amplamente conhecidos, como a curva de potência e a curva de potência x velocidade do gerador. Com a consolidação das análises, uma lista de ações específicas para cada área da empresa é desenvolvida e amplamente discutida em reuniões dedicadas. Além disso, indicadores como perdas por eficiência e perdas por indisponibilidade são calculados e permitem acompanhar a evolução das ações que são tomadas para maximizar o desempenho. Como alguns parâmetros de desempenho apenas podem ser observados com maior profundidade de dados na área de Engenharia de Manutenção ocorrem análises mensais, trimestrais e semestrais (médio prazo).

2.2.1. Análise de Curto Prazo

Análises de curto prazo envolve ver pequenas e médias ineficiências que não puderam ser observadas na rápida análise de tempo real, além de poderem ser observadas ineficiências que não foram vistas pelo tempo real por conta de contingências sistêmicas.

Para desenvolvimento das análises de curto prazo foram desenvolvidos dashboards específicos em com curvas, gráficos e tabelas que permitam a análise rápida e precisa. Na Figura 6 é possível analisar as seguintes curvas e informações aquisitadas pelo supervisório e armazenadas com estratégias de BigData:

- a. Gráfico Cascata: contém acompanhamento (com período a escolha) dos indicadores de Geração Realizada e Orçada, perdas ou ganhos energéticos, mostrando graficamente a diferença da geração realizada pela esperada. As variações energéticas acompanhadas são o recurso, condições externas, indisponibilidade, eficiência, perdas na rede de média e de baixa tensão.
- b. Curva de potência x velocidade de vento
- c. Curva de potência x velocidade de gerador
- d. Curva da Posição angular Nacelle x direção do vento:
- e. Curva da Potência ativa x potência reativa
- f. Curva da diferença entre ângulos de blades (pás)



FIGURA 6 – Primeira tela do dashboard para análise de curto prazo

Também há a possibilidade de análises de curvas temporais, conforme Figura 7, onde é apresentado a segunda tela do dashboard, contendo:

- Posição da nacelle e direção do vento.
- Diferença entre os ângulos das blades.
- Razão da posição da nacelle pela direção do vento da torre anemométrica
- Diferença entre direção do vento da Nacelle e da torre anemométrica



FIGURA 7 – Segunda tela do dashboard para análise de curto prazo

Outras variáveis também são estudadas, mas com menor frequência e de forma pontual, como: Análise de Função de Transferência da Nacelle (NTF) e análise dos Ângulos das Pás e a Velocidade do Vento.

2.2.1..Análise de Médio Prazo

As ações listadas durante processo de análise de curto prazo fornecem subsídios e foco nas análises de médio prazo, além de auxiliar na escolha da melhor ferramenta para estudo dos casos. Ferramentas de análise em médio prazo baseiam-se na utilização das informações geradas durante o processo, inclusive envolvendo dados de manutenções (passado, presente, futuro) planejadas e não-planejadas e resultados de performance de cada WTGs, porém com uma série de estudos não comumente realizados.

Alguns desses gráficos envolvem curvas de temperatura correlacionando-os com alarmes e paradas programadas e não programadas, possibilitando que a equipe de engenharia realize uma análise baseada na condição da máquina antes e depois dessa manutenção. Na Figura 8 são apresentados alguns dos diversos dashboards, desenvolvidos em linguagem R, para análise de temperaturas da caixa de engrenagens de um aerogerador Tipo 2 da frota estudada. Além da visualização gráfica de alguns envelopes de temperaturas do Gearbox por potência gerada, também são apresentados alarmes, sendo possível escolher o parque, aerogerador e semana (representação por cores) da análise a ser realizada.

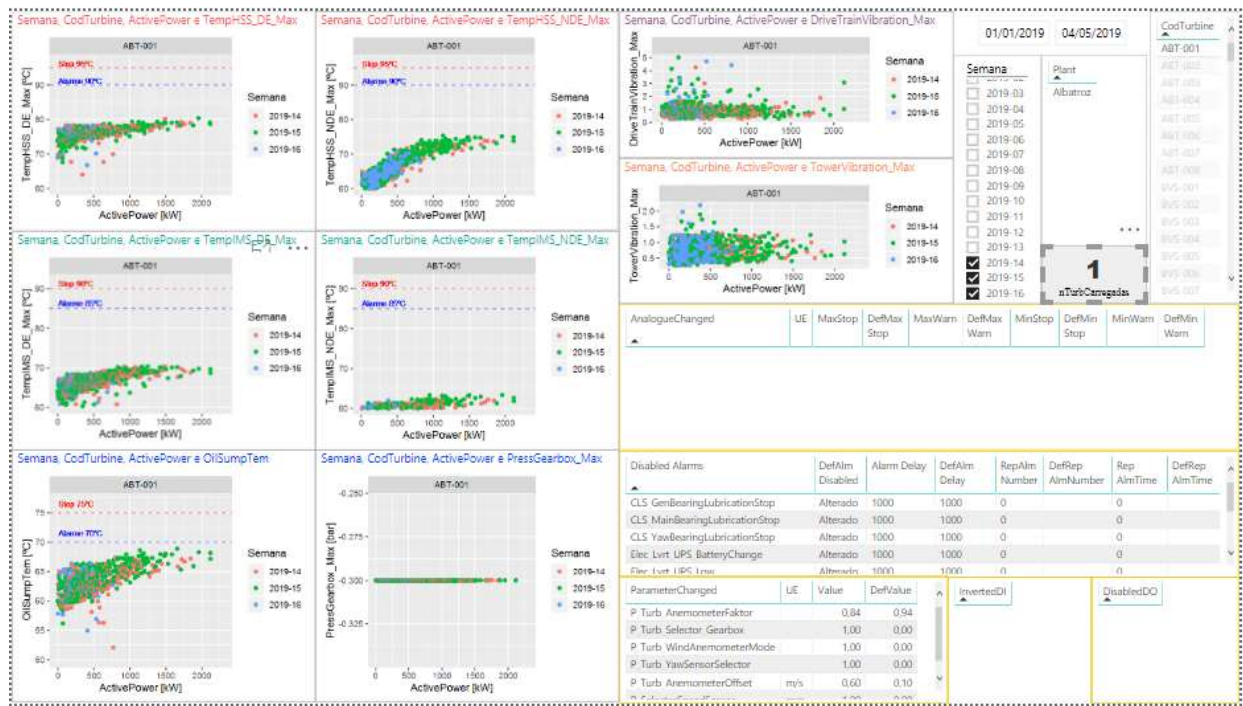


FIGURA 8 – Tela do dashboard para análise de médio prazo

Na Figura 9 são apresentados outros dashboards para análise de temperaturas do gerador também de um aerogerador Tipo 2 da frota estudada. Além da visualização gráfica de alguns envelopes de temperaturas do Gerador por potência gerada, também são apresentados alarmes, sendo possível escolher o parque, aerogerador e semana (representação por cores) da análise a ser realizada.

10 a 13 de novembro de 2019
Belo Horizonte - MG

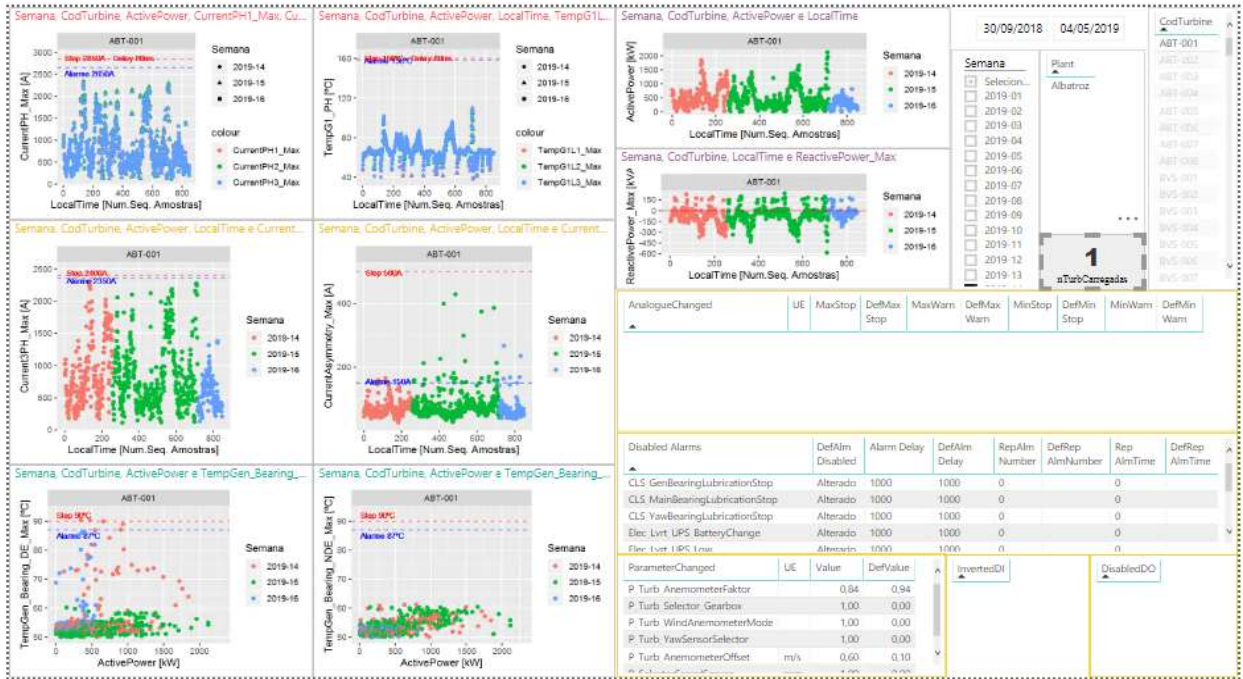


FIGURA 9 – Tela do dashboard para análise de médio prazo

Também para análise de médio prazo, foram desenvolvidos, em um projeto de P&D, algoritmos de aprendizagem de máquina que definiram um modelo de comportamento padrão dos envelopes de temperatura dos grandes componentes dos aerogeradores, com foco principal em gearbox, gerador e rolamentos. Dessa forma, sendo possível aliar as informações do Dashboard desenvolvido e o conhecimento do comportamento padrão dos envelopes de temperatura. Nas Figuras 10 e 11 são apresentadas, respectivamente, as curvas de comportamento padrão do óleo da caixa de engrenagens e do eixo intermediário do Gearbox.

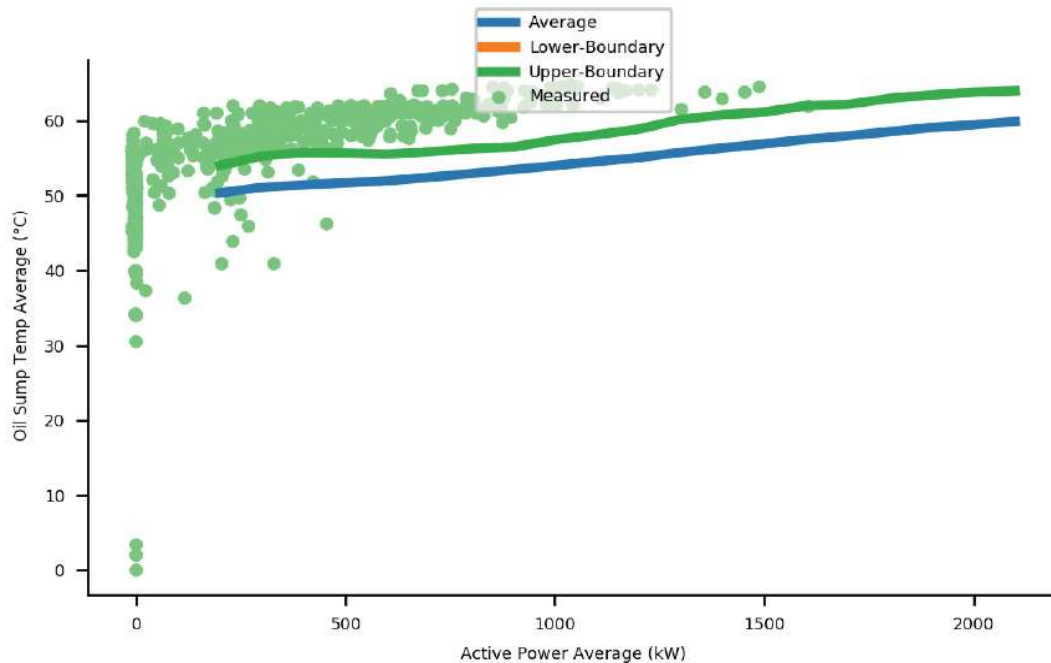


FIGURA 10 – Tela do sistema de predição do comportamento padrão de temperatura dos componentes

Com os modelos de comportamento padrão desenvolvido para cada aerogerador ou grupo de aerogeradores, um outro passo é o desenvolvimento de modelo temporal afim de prever a data de ocorrência da próxima falha, antecipando a aquisição de grandes componentes e realizando as atividades nos períodos de menores perdas.




FIGURA 11 – Tela do sistema de predição do comportamento padrão de temperatura dos componentes

2.3 Trabalhos Futuros ou em desenvolvimento

Visando aperfeiçoar a gestão de desempenho dos WTGs, algoritmos de ML estão em consolidação através de projeto de P&D. Estudos preliminares já identificaram assinaturas padrões de grandezas de grandes componentes, assim como identificação de desvios nessas assinaturas e indicação de predições de falhas. O projeto consiste em estudos de modos de falhas (FMEA) para identificação dos parâmetros de dados "mais fortes", contidas no Big Data, para entrada no bloco de ML para com maior agilidade se chegar nas melhores saídas de predição. Além disso estudos de Setores de Desligamento; Histerese Direcional e acionamentos de yaw; Tempo de Desligamento de partida e conexão à rede; Velocidade de cutin e cutout; Histerese do processo de cutout (Re cutin) e Análise do funcionamento das estratégias de controle do fabricante (LVRT, FRT, ALC, etc), fazem parte deste projeto.

3.0 - CONCLUSÃO

Com as estratégias utilizadas até o momento, e com o desenvolvimento de novas ferramentas, diversas falhas em aerogeradores (sistemas de pitch, yaw, anemômetros, gerador, gearbox, etc.) puderam (e poderão) ser identificadas e corrigidas em seu estágio inicial. Limitações causadas por falhas no controlador do parque e por limitações de temperatura dos componentes dos aerogeradores foram rapidamente identificadas e sanadas. Em alguns casos, dados de temperatura dos componentes de aerogeradores, mesmo com baixa taxa de amostragem, auxiliaram no direcionamento das equipes de manutenção, mostrando que o desenvolvimento de ferramentas computacionais, aliados a dados com a adequada amostragem, trouxeram e trarão cada vez mais benefícios à gestão de usinas eólicas de médio e grande porte.

4.0 - REFERÊNCIAS BIBLIOGRÁFICAS

(1) YARAMASU, V., WU, B., SEN, P. C., KOURO, S., NARIMANI, M.; High-Power Wind Energy Conversion Systems: State-of-art and Emerging Technologies. Proceedings of the IEEE, v.103, nº5, Maio 2015.

5.0 - DADOS BIOGRÁFICOS



Flávio Martins Ribeiro: Formado em Engenharia Elétrica pela Universidade de Uberaba, MBA em Gestão Empresarial pela FGV, dentre outras especializações na área Elétrica, com destaque para Qualidade de Energia pela Universidade de Uberlândia. 20 anos de experiência no setor elétrico, com atuação no Grupo Energisa (na área de distribuição e Geração), Grupo Eletrobras (na área de distribuição e transmissão), Starkraft (na área de Geração) e Atualmente como Superintendente de O&M na CPFL Energias Renováveis.



Marcus Antonius Queiroz da Cunha: Formado em Engenharia Elétrica pela Universidade Federal do Ceará e Telemática pelo Instituto Federal de Ciência, Educação e Tecnologia do Ceará, MBA em Projeto, Controle e Execução em Engenharia Elétrica pelo IPOG e atualmente Mestrando em Energias Renováveis



XXV SNTPEE
SEMINÁRIO NACIONAL DE PRODUÇÃO E
TRANSMISSÃO DE ENERGIA ELÉTRICA

4683
GES/03

10 a 13 de novembro de 2019
Belo Horizonte - MG

Pelo Instituto Federal de Ciência, Educação e Tecnologia do Ceará na área de inteligência computacional para a geração eólica. Atuação profissional como engenheiro de operações no Centro de controle do Sistema na Companhia Energética do Ceará, coordenador de operações da CPFL Renováveis e atualmente atuando na CPFL Renováveis como especialista em análise de performance de aerogeradores.