

IDENTIFICAÇÃO DE PADRÕES DE OPERAÇÃO EM TURBINAS A GÁS PARA PREDIÇÃO DE FALHAS E SUPORTE À DECISÃO GERENCIAL

Otacilio Jose Pereira (UFBA)

otaciliojpereira@gmail.com

Luciana de Almeida Pacheco (UFBA)

luciana.pacheco@gmail.com

Sergio Torres Sa Barretto (UFBA)

sa.barretto@petrobras.com.br

CRISTIANO HORA DE OLIVEIRA FONTES (UFBA)

cfontes@ufba.br

Carlos Arthur Mattos Teixeira Cavalcante (UFBA)

arthurtc@ufba.br



Este artigo apresenta uma metodologia para a aquisição de conhecimento de uma planta industrial com base em padrões de operação. Mais especificamente, são identificados de forma sistemática padrões de falhas por dispersão de temperatura em uma turbina a gás que representa o principal equipamento da Unidade Termelétrica (UTE) Rômulo Almeida, integrante do parque da Petrobras. A aquisição de conhecimento foi realizada através de técnicas de mineração de dados obtidos a partir de um Sistema de Gerenciamento de Informações de Plantas Industriais, ou Process Information Management System (PIMS), disponível na UTE. Os padrões identificados estão associados à ocorrência de falha logo após a partida da turbina e foram gerados com base em uma análise multivariável que integrou séries temporais referentes a duas variáveis de processo. Os padrões finais obtidos são resultantes da extração de conhecimento do processo a partir de técnicas de agrupamento de séries temporais. A condução do projeto, as práticas exercidas e os resultados obtidos permitem constatar que o bom uso da tecnologia de informação e da engenharia de controle e automação, associadas às boas práticas de gestão e operação das plantas industriais, pode gerar soluções que permitam aos gestores melhorarem seus resultados por exemplo a melhoria da disponibilidade operacional.

Palavras-chaves: Predição de Falhas, Mineração de Dados, Turbinas a Gás

1. Introdução

O conhecimento sobre o comportamento de uma planta industrial é essencial para o gestor em seu papel de planejar, programar e controlar a produção, bem como para o operador em sua função de supervisão e controle dos processos operacionais. A exemplo de empresas de infraestrutura, ligadas ao fornecimento de energia elétrica, a gestão deve potencializar o rendimento da planta, sua lucratividade proveniente da venda de energia e evitar pesadas penalidades contratuais em eventuais ocorrências de cessão do fornecimento (CCEE, 2009). Prover à planta mecanismos de predição de falhas tende a promover maiores rendimentos e uma melhor adequação da operação às potencialidades dos componentes físicos e lógicos do processo.

Um modelo de gestão deve dar suporte às tomadas de decisões. Para isso, é necessário estruturar as medições e informações de forma a permitir a análise e manipulação de cenários operacionais. Estas medições, informações e conhecimentos podem ser obtidos, dentre outras formas, com base na experiência da equipe com a planta ou com base em análises sobre dados históricos do processo. Estas análises históricas são apoiadas por tecnologias de informação e de controle e automação, as quais possibilitam, de forma consistente e ágil, coletar dados dos equipamentos e compor bases de dados com informações e conhecimento. Assim, estes dados viabilizam soluções que permitam aos gestores guiar suas decisões perante diversos tipos de situações, inclusive associadas a eventos de falha.

Este artigo apresenta uma metodologia para a aquisição de conhecimento de uma planta industrial com base em padrões de operação. Mais especificamente, são identificados de forma sistemática padrões de falhas em uma turbina a gás de escala comercial, com capacidade de geração de energia de 27 MW, e que representa o principal equipamento da Unidade Termelétrica (UTE) Rômulo Almeida, integrante do parque da Petrobras. A aquisição de conhecimento foi realizada através de técnicas de mineração de dados obtidos a partir de um Sistema de Gerenciamento de Informações de Plantas Industriais, ou *Process Information Management System* (PIMS), disponível na UTE. Os padrões ou perfis identificados estão associados à ocorrência de falha logo após a partida da turbina e foram gerados com base em uma análise multivariável que integrou séries temporais referentes a duas variáveis de processo. Os padrões finais obtidos são resultantes da extração de conhecimento do processo a partir de técnicas de agrupamento de séries temporais.

A identificação de padrões consiste na primeira etapa de desenvolvimento de um sistema para predição da ocorrência de falhas na turbina. Este sistema inteligente se constituirá em um importante e inovador instrumento de suporte a operadores e gestores, sobretudo em sua função de manter a disponibilidade da geração de energia na UTE estudada.

Na seção 2 é apresentado o sistema em estudo, o cenário de aplicação e aspectos envolvidos. Na seção 3 é apresentada a metodologia e na seção 4 são detalhadas algumas etapas e técnicas voltadas para a identificação dos padrões de operação. Na seção 5 os resultados são apresentados e discutidos.

2. O objeto de estudo e apresentação do problema

Este trabalho tem como objeto de estudo a Unidade Termelétrica Rômulo Almeida (UTE-RA), situada no município de Camaçari (Bahia) e visa identificar padrões de falhas ocasionadas por dispersão de temperatura nas turbinas a gás. A aquisição dos dados foi realizada através de um sistema PIMS conectado à camada de supervisão da Unidade.

A UTE-RA (Figura 1) é uma unidade de cogeração que opera em ciclo combinado. Tem como principal insumo o gás natural e produz vapores de alta e baixa pressão e energia elétrica. A energia elétrica gerada é utilizada para abastecimento do consumo interno de unidades da Petrobras, sendo também exportada para a rede elétrica.



Figura 1 – Visão panorâmica da Unidade Termelétrica Rômulo Almeida (BARRETTO, 2010)

A UTE-RA possui três turbinas a gás (TG), cada uma combinada a um gerador elétrico de 27 MW e a uma caldeira de recuperação (*Heat Recovery Steam Generator – HRSG*). A Unidade dispõe ainda de uma Caldeira Auxiliar (CA) e uma Turbina a Vapor (TV), também acoplada a um gerador de 56 MW, totalizando assim uma capacidade de geração de 137 MW de energia elétrica e de produção de 260,3 t/h de vapor.

2.1. Importância da disponibilidade no fornecimento de energia e vapor

A energia gerada pela UTE é fornecida ao Sistema Interligado Nacional (SIN), no qual o Operador Nacional do Sistema Elétrico (ONS) coordena e controla a operação e transmissão de energia elétrica. Diante de uma demanda futura de energia, o ONS comanda os despachos de geração de energia nas unidades integrantes do SIN. Inicialmente, as unidades geradoras devem declarar a sua capacidade de geração e informar à Câmara Comercializadora de Energia Elétrica (CCEE) o custo operacional em R\$/MW. Em seguida, é realizada uma ordenação de todas as unidades geradoras de energia do território nacional, tendo como critério o custo informado (CCEE, 2009). De posse da demanda futura e das disponibilidades das unidades, o ONS comanda a partida das unidades, que passam a fornecer energia ao SIN. Conforme acordado com o ONS, havendo qualquer ocorrência que impeça o fornecimento de energia por parte da UTE-RA, a Unidade estará sujeita a penalidades significativas, que terão impacto direto no desempenho financeiro da Unidade.

Os vapores de alta e baixa pressão produzidos pela UTE são fornecidos para indústrias do pólo petroquímico de Camaçari. Também neste caso, o fornecimento é regido por regras previstas em contratos. Assim, o não cumprimento de certas cláusulas implicará na aplicação de severas multas contratuais.

Em ambos os casos, observa-se que ter pleno domínio sobre o comportamento da planta é essencial para o gestor. Além da necessidade de conhecer sua capacidade produtiva, é necessário viabilizar alternativas sistemáticas para evitar ou contingenciar a ocorrência de falhas. Dessa forma, espera-se garantir o fornecimento das demandas de energia e vapor previamente estabelecidas, com mínimo risco de interrupção, evitando ou mitigando penalidades e o consequente prejuízo financeiro em razão de indisponibilidades.

Existem também situações de riscos e outras perdas que podem ser melhor gerenciados com o apoio de uma eficiente solução de predição de falhas, a exemplo de danos a equipamentos, o que geraria custos de reposição ou manutenção corretiva e prejuízos pelo tempo parado do equipamento. Além disso, sua operação em condições impróprias poderia constituir em riscos de acidentes com impactos ambientais e humanos.

2.2. Turbinas a Gás e Desarme (“trip”) por Dispersão de Temperatura

No parque produtivo da UTE-RA, o modelo de turbina a gás (TG) instalada é o RB211-G62 DF, do fabricante *Rolls-Royce*. Esta TG é composta pelo gerador de gás modelo RB211 24G DLE DF e pela turbina de potência RT62.

A decisão de escolher a turbina a gás como objeto de estudo foi pautada nos seguintes aspectos: i) a TG é o elemento principal no processo de geração de energia elétrica e é responsável pela maior parte da energia gerada na Unidade (81 MW são gerados pela TG e 56 MW pela TV), ii) uma falha com conseqüente parada da TG possui impacto em todo o processo e continuidade operacional da UTE.

Uma TG, cuja configuração típica é mostrada na Figura 2, é uma turbomáquina que tem como insumos o ar e um combustível. No caso da UTE-RA, o combustível utilizado é o gás natural. A TG produz vapor e energia mecânica e, quando acoplada a um gerador elétrico, possibilita a geração de energia elétrica (SARAVANAMUTTOO, 1996).

Os componentes principais da Turbina a Gás são: compressor, câmara de combustão e expensor. O compressor, localizado à frente da turbina, é responsável pela admissão de ar na TG e compressão. O ar comprimido segue para a câmara de combustão, onde o gás natural se mistura com o comburente, presente na corrente de ar comprimido. Através de uma chama piloto ocorre a combustão, sendo gerados gases de exaustão a altas velocidades e temperaturas que são encaminhadas para o expensor da turbina. O eixo do expensor, por sua vez, é acoplado a um gerador que produz energia elétrica. Quando a Unidade está operando em Ciclo Combinado, os gases de exaustão provenientes da turbina são encaminhados a uma caldeira de recuperação, fechando o ciclo. Quando os gases são liberados para a atmosfera, diz-se que a unidade está operando em Ciclo Aberto.



Figura 2 – Turbina a Gás RB211 24G DLE (Cedido pela *ROLLS-ROYCE*)

O entendimento deste arranjo é propício para identificar algumas variáveis de processo importantes de serem acompanhadas, dentre elas a pressão e a temperatura do ar no compressor, a vazão e a pressão do gás natural, a temperatura dos gases de exaustão e a dispersão de temperatura nos termopares relacionados às câmaras de combustão.

As turbinas podem falhar e parar, tendo-se o desarme do equipamento. Este desarme é denominado de *trip* (SARAVANAMUTTOO 1996). Dentre as causas de ocorrência de falha se destacam a elevada dispersão de temperatura na câmara de combustão, surgência e vibração.

Analisando os relatórios de operação da UTE-RA, referentes a 2009 e 2010, verificou-se que as falhas por dispersão de temperatura foram as mais frequentes nos eventos de *trip*. Em seguida, analisando os eventos de *trip* por dispersão de temperatura dos períodos, verificou-se a possibilidade de implementar ações antecipatórias a partir da definição e acompanhamento de padrões de comportamento dinâmico de algumas variáveis de processo. Assim, optou-se neste trabalho em tomar este tipo de falha como objeto de análise.

As turbinas cujos combustores são classificados como *can type* possuem câmaras de combustão individuais distribuídas radialmente em um anel central, localizado entre o compressor e o expensor (SARAVANAMUTOO 1996). Na Figura 2 esta distribuição radial das câmaras pode ser visualizada na parte posterior da turbina, onde está também um anel de condução do gás natural às câmaras. As TG de modelo RB211 *Rolls-Royce* dispõem de nove combustores. O sistema de controle da RB211 foi projetado para desarmar o equipamento caso a temperatura de operação de alguma das câmaras se distancie em $\pm 150^{\circ}\text{C}$ da média de temperatura de todas as câmaras, de forma a proteger o equipamento de danos por dilatação diferencial. Quando este desarme ocorre, caracteriza-se um *trip* por dispersão de temperatura.

2.3. O sistema de aquisição de dados e a Unidade

Segundo Moraes e Castrucci (2001), a automação em uma planta industrial pode ser representada em cinco níveis (Figura 3).

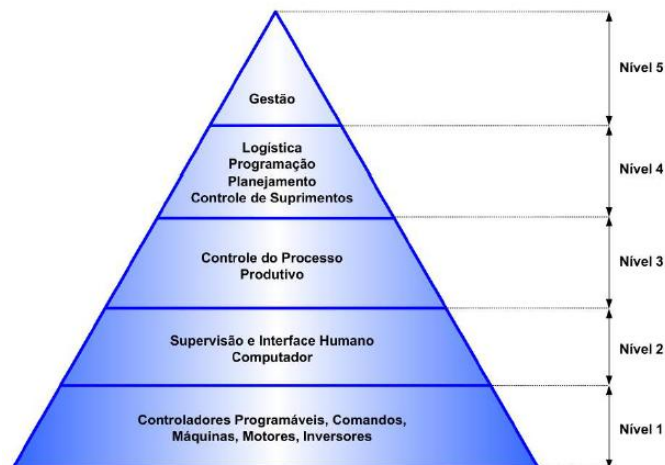


Figura 3 – Pirâmide de Automação (Adaptado de Moraes e Castrucci (2001))

O primeiro nível é a camada de controle, onde estão os instrumentos e equipamentos da planta de processo. No segundo nível estão os softwares de supervisão do processo. No terceiro nível, é feito o gerenciamento do processo produtivo e normalmente é constituído por bancos de dados, a exemplo dos PIMS, com informações obtidas do nível 2. No quarto nível é feita a Programação e o Planejamento da Produção, realizando o gerenciamento e a logística de suprimentos, bem como o projeto de produtos e processos. No quinto nível estão os softwares de apoio decisório, gestão financeira, vendas, pessoal, entre outros. É o nível de gestão da empresa, onde são realizadas as funções de administração corporativa como, por exemplo, o planejamento estratégico, levando em consideração as informações do processo industrial e do mercado.

A fonte de dados para este trabalho é o PIMS, localizado no nível 3, de Controle do Processo Produtivo, da pirâmide (Figura 3). Os PIMS são bancos de dados temporais, ou historiadores de processos, que devido aos seus eficientes algoritmos de exceção e compressão são capazes de armazenar grandes volumes de dados, por períodos na ordem de anos, a um custo

relativamente baixo (SÁ BARRETTO & FERREIRA, 2007; DANG, 2007; BARR, 1994; FRAS & DANG, 2004). Por meio desta tecnologia, foi possível extrair os dados das variáveis armazenadas durante os anos de 2009 e 2010, mais especificamente valores de vazão de gás e temperatura dos gases de exaustão da turbina (com período de amostragem de 1 min) a assim proceder as análises para a identificação dos padrões.

2.4. Predição de Falhas

As plantas industriais têm se tornado cada vez maiores e mais complexas, assim como os perigos e riscos decorrente de falhas, que se tornam cada vez mais críticos para os negócios. Este cenário impulsionou o crescimento da área de diagnóstico de falhas nos últimos anos, sendo encontradas pesquisas em áreas correlatas, como: *Abnormal Event Management* (AEM), *Fault Detection and Diagnosis* (FDD), *Fault Detection and Isolation* (FDI) e *Fault Diagnosis*.

Conforme Korbics (2004), estas áreas também têm crescido por conta dos avanços da tecnologia de informação e das possibilidades de equipar as plantas industriais com medições, controle, monitoramento e supervisão de grande capacidade computacional.

Venkatasubramanian (2003) separa o processo de gerenciar anomalias ou emergências nas seguintes atividades: detectar com antecedência as falhas, diagnosticar as origens e suas causas e tomar decisões e ações de controle e supervisão apropriadas para reposicionar o processo industrial em seu estado operacional normal e seguro. Adicionalmente, apresenta uma classificação das técnicas para construção de sistema de diagnóstico de falhas usando como critério o tipo de conhecimento a priori. Conforme sua classificação, as técnicas podem ser baseadas em modelos ou em dados históricos, e com uma abordagem qualitativa ou quantitativa.

Técnicas baseadas em modelo elaboram o diagnóstico com base no conhecimento de equações físicas sobre as variáveis do sistema. As técnicas baseadas em dados históricos do processo não se restringem ao conhecimento prévio do modelo, mas se baseiam em dados e informações históricas do processo para a criação das soluções. O conhecimento histórico do processo pode ser tratado qualitativamente, por exemplo, para compor sistemas especialistas, ou quantitativamente, para configurar redes neurais e realizar cálculos estatísticos (VENKATASUBRAMANIAN, 2003).

A técnica empregada nesta pesquisa se baseia em dados históricos do processo e apresenta uma abordagem quantitativa, em consequência da qualidade dos dados obtidos de um PIMS conectado à planta de controle e automação analisada.

2.5. Knowledge Discovery in Database (KDD) e Mineração de Dados

A área de KDD é uma área que visa a extrair conhecimento a partir do processamento de um grande volume de dados. A ideia chave é realizar um trabalho de análise que seria impossível ou impraticável por um usuário humano por exemplo. Um processo típico, bem disseminado, dentro da área de KDD realiza, conforme figura 4, as seguintes etapas: seleção de variáveis, pre-processamento, transformação, mineração de dados e interpretação, até a obtenção do conhecimento (FAYYAD, 1996; DE AMO, 2004). Estas etapas nortearam a seqüência de ações e atividades da pesquisa: inicialmente as variáveis a investigar foram selecionadas, sendo realizadas algumas transformações e utilizadas técnicas de mineração, ponto central no processamento.

As principais técnicas de mineração de dados empregadas neste trabalho foram os algoritmos de manipulação de séries temporais, dentre eles o cálculo de similaridade de curvas e a

varredura ou busca linear (*linear scan*), bem como estratégias de agrupamento (*clustering*), realizadas com o emprego do algoritmo Fuzzy C-Means (VLACHOS, 2005 e HOPPNER1999).

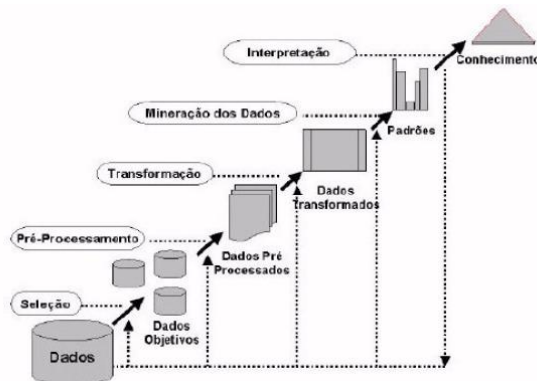


Figura 4 – Processo de KDD (FAYYAD, 1996)

3. Metodologia

A metodologia desenvolvida e aplicada compreendeu três etapas principais: o levantamento e classificação de eventos, seleção do evento a ser analisado e a identificação de padrões de falhas para este evento.

As duas variáveis de processo coletadas foram: a temperatura de exaustão do gás da turbina e a vazão total de gás natural admitido na turbina. A base de dados disponibilizada através do PIMS compreendeu integralmente os anos de 2009 e 2010. Com base neste universo de dados, nas informações obtidas em entrevistas aos especialistas, nos registros de ocorrências operacionais e nas técnicas de mineração analisadas, foram definidos e segregados os eventos que caracterizam os padrões ou estados operacionais de partida da turbina praticados ao longo do período considerado. A Figura 5 ilustra esquematicamente o procedimento desta etapa.

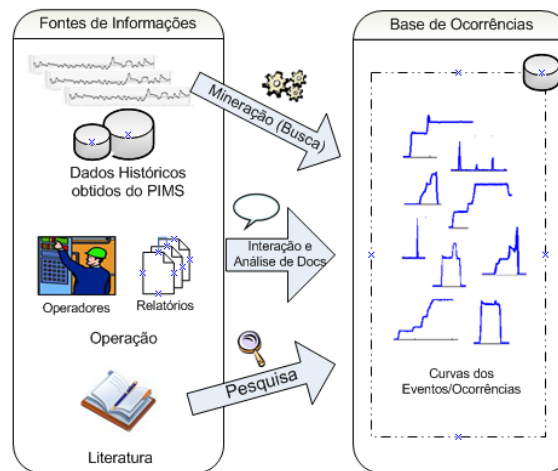


Figura 5 – Etapa de levantamento e definição de eventos

Através da segregação de curvas, foi possível definir alguns tipos de eventos como associados à operação de partida da turbina: partida normal da turbina, partida da turbina com parada posterior, tentativa de partida com parada rápida (2 minutos depois), entre outros. Por sua vez, com o auxílio dos registros de operação, as ocorrências e seus respectivos padrões foram refinados. O evento de partida com parada posterior foi desmembrado em: (i) parada devido a comando normal de operação, (ii) parada devido a desarme (*trip*) por dispersão de

temperatura e (iii) parada devido a desarme por demais motivos. Na segunda etapa, foi considerado apenas o grupo de ocorrências associadas à partida normal e à partida com parada devido a desarme por dispersão de temperatura (partida com falha). Foram utilizadas técnicas de agrupamento de séries temporais que permitiram a obtenção de padrões finais para estes dois casos, conforme ilustrado na Figura 6.

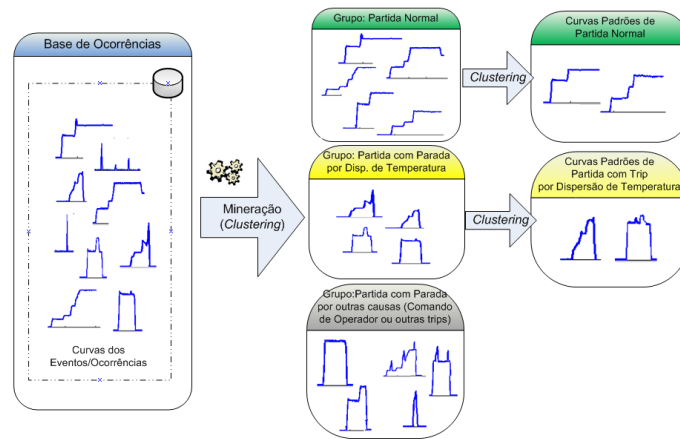


Figura 6 – Segregação das Curvas e Determinação das Curvas Padrões associados à partida da turbina

4. Detalhamento das Técnicas Empregadas

A metodologia desenvolvida apresentou forte ênfase na análise de dados, já que dispunha de uma ampla base de dados históricos integrada à camada de supervisão da UTE-RA. Esta abordagem se mostrou eficaz uma vez que os dados apresentavam uma visão consistente da operação da turbina. Assim, através de um tratamento sistemático, o levantamento de conhecimento foi viabilizado, o que não necessariamente seria possível a partir somente do relato de operadores ou registros operacionais.

Uma primeira funcionalidade necessária foi a caracterização de similaridade entre curvas, que visa quantificar o grau de semelhança entre duas curvas. Os algoritmos comumente empregados para esta finalidade são: distância euclidiana, *Dynamic Time-Warping* (DTW) e *Longest Common Subsequence* (LCSS) (LIAO, 2005 e VLACHOS, 2005). A medida de similaridade por distância euclidiana consiste na soma dos quadrados das diferenças, obtidas em cada instante de tempo. Neste caso, é necessário um pre-processamento das curvas, de modo que elas estejam alinhadas ou deslocadas adequadamente no tempo, evitando assim erros de estimativa de diferença entre elas. A Figura 7 ilustra o procedimento de cálculo da distância euclidiana tomando-se como exemplo duas curvas (*a* e *b*) da temperatura na câmara de exaustão. Para cada instante *i*, é feito o cálculo da distância entre *a*[*i*] e *b*[*i*]. Com a raiz quadrada do somatório destas distâncias, para todos os instantes de tempo do intervalo, tem-se a distância euclidiana entre as curvas. No gráfico 1 da Figura 7, as curvas estão mais próximas, quase se sobrepondo, se refletindo em uma pequena distância euclidiana. Já no gráfico 2 da Figura 7, as curvas diferem bastante entre si, o que refletirá em uma maior distância euclidiana. Por outro lado, verifica-se que este método de cálculo de similaridade é influenciado pela janela de tempo considerada o que implicou na execução de algumas tarefas para corrigir possíveis deslocamentos entre curvas efetivamente similares.

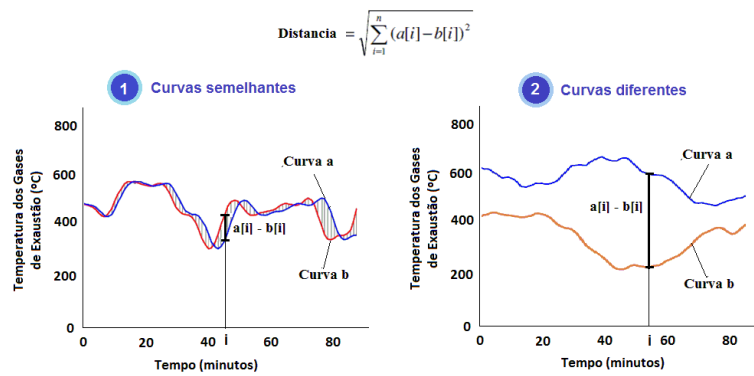


Figura 7 – Medida de similaridade por distância euclidiana (adaptado de VLACHOS, 2005)

Para a captura das ocorrências de um determinado evento, a segunda funcionalidade implementada, adotou-se o algoritmo de varredura linear, do inglês *linear scan* (VLACHOS, 2005). O algoritmo tem como entrada uma amostra de referência, isto é uma curva que no caso da pesquisa representou um evento de partida da turbina, e uma série temporal mais longa, por exemplo os dados da turbina desde 2009. O algoritmo percorre toda a série temporal e para cada instante ele captura uma janela de mesmo tamanho da amostra e calcula a distância entre a janela capturada da série e a amostra de referência. Uma distância pequena entre a janela extraída da série e a amostra de referência indica a ocorrência do evento sendo pesquisado. Ao percorrer toda a série e calcular as distâncias entre as janelas em cada instante e a amostra de referência, o algoritmo ordena e seleciona os pontos com menores distâncias. Esta estratégia, que viabilizou a captura automática de amostras de eventos de partida da turbina diretamente da base de dados PIMS, é ilustrada na Figura 8.

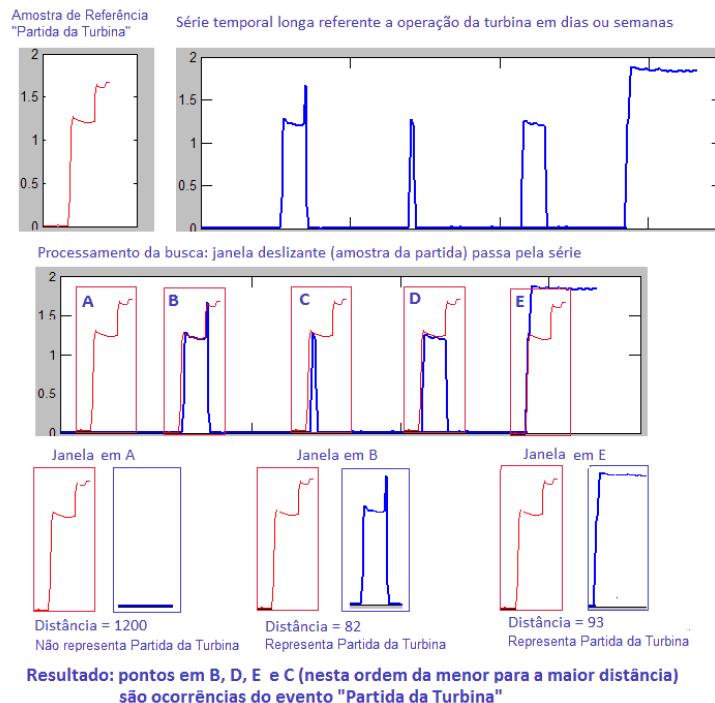


Figura 8 – Procedimento de captura de amostras de eventos operacionais com base nos dados do PIMS

De posse da lista de partidas de turbina desde 2009, obtidas do PIMS, foi realizada a segregação entre as partidas normais, isto é, sem parada, das partidas com parada posterior. Esta segregação foi realizada com base em relatórios de operação.

A etapa final compreendeu a definição de padrões para os dois grupos de interesse: partida normal e partida com parada devido a *trip* por dispersão de temperatura. Nesta etapa foi aplicado um algoritmo de agrupamento (*clustering*) de séries temporais. Este procedimento visa a identificar um ou mais sub-grupos de curvas em cada grupo de interesse. Cada um destes sub-grupos terá, por sua vez, uma curva característica (centro ou protótipo) que representa a identidade daquele sub-grupo (ou *cluster*). Dessa forma, ao final deste procedimento, é possível a tipificação de curvas associadas, respectivamente, às ocorrências de partida normal e de partida com parada devido a *trip* por dispersão de temperatura. O algoritmo de agrupamento usado foi o Fuzzy C-Means, cuja especificação adotada está disponível em Hoppner (1999). O Fuzzy C-Means visa a minimizar uma função de distância entre os protótipos dos clusters e as amostras de curvas. Para tanto, utiliza uma noção de pertinência, baseada em lógica fuzzy, de uma curva em relação aos centros dos *clusters*.

Vale ressaltar que o algoritmo Fuzzy C-Means considerou uma abordagem multivariável. Ou seja, o agrupamento de curvas de temperatura de exaustão do gás da turbina e da vazão de entrada de gás na turbina não foi realizado de forma dissociada, e cada centro de *cluster* obtido (em cada um dos grupos de interesse) deve contemplar ambos os perfis como forma de caracterização completa daquele padrão.

5. Resultados

Entre 2009 e 2010 foram identificados 127 eventos de partida da turbina. A Figura 9 mostra alguns destes eventos ilustrando os perfis simultâneos de vazão de gás e temperatura de exaustão. A primeira curva de vazão de gás representa a amostra de referência de partida tal como descrito na Figura 8. Apenas a curva de vazão de gás foi necessária para determinar os instantes das ocorrências e com esta informação as outras curvas, de temperatura dos gases de exaustão por exemplo, foram capturadas. Destacados com elipses se encontram os pontos que permitiriam identificar semelhanças ao realizar os cálculos de similaridade. No título de cada amostra, são exibidos o número, a data e a hora da ocorrência.

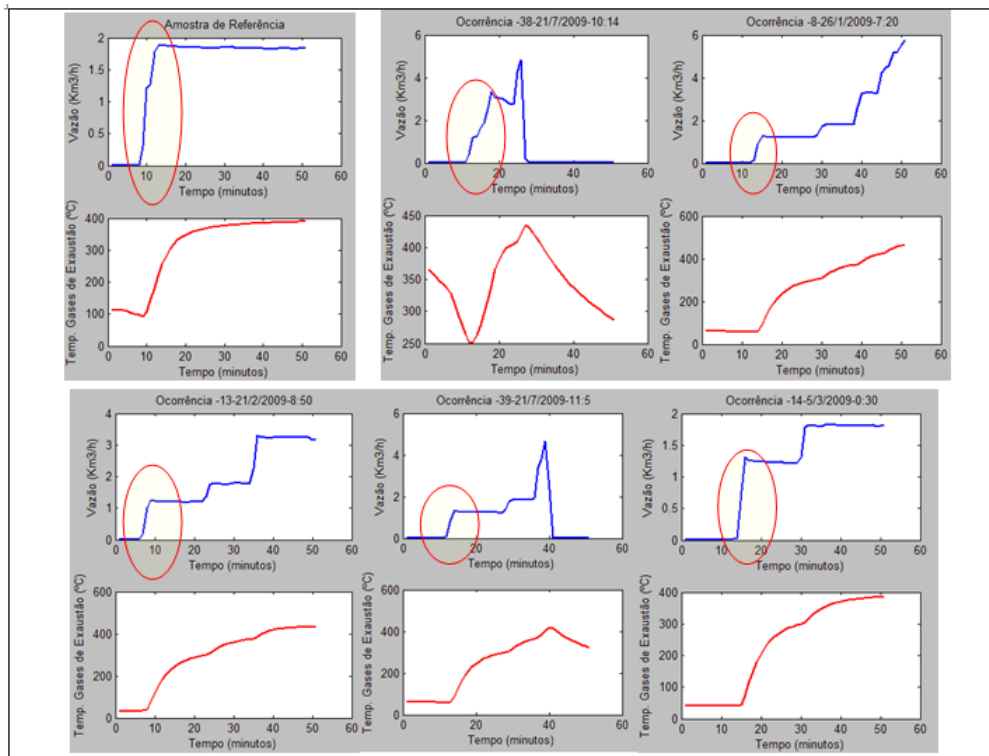


Figura 9 – Amostra de Referência e algumas ocorrências de partidas capturadas pelo método de varredura linear

A segregação das 127 curvas referentes às ocorrências dos eventos de partidas, feita pela análise nos relatórios de operação e confrontada com os resultados do algoritmo de agrupamento (*clustering*), originou alguns grupos de curvas, dentre os quais foram selecionados os de interesse para análise: 69 ocorrências de partida normal e 10 ocorrências de partida com parada posterior devido a *trip* por dispersão de temperatura. Algumas destas amostras estão apresentadas na Figura 10. Na parte superior estão as curvas de partida normal e na parte inferior as curvas da partida com *trip* por dispersão de temperatura.

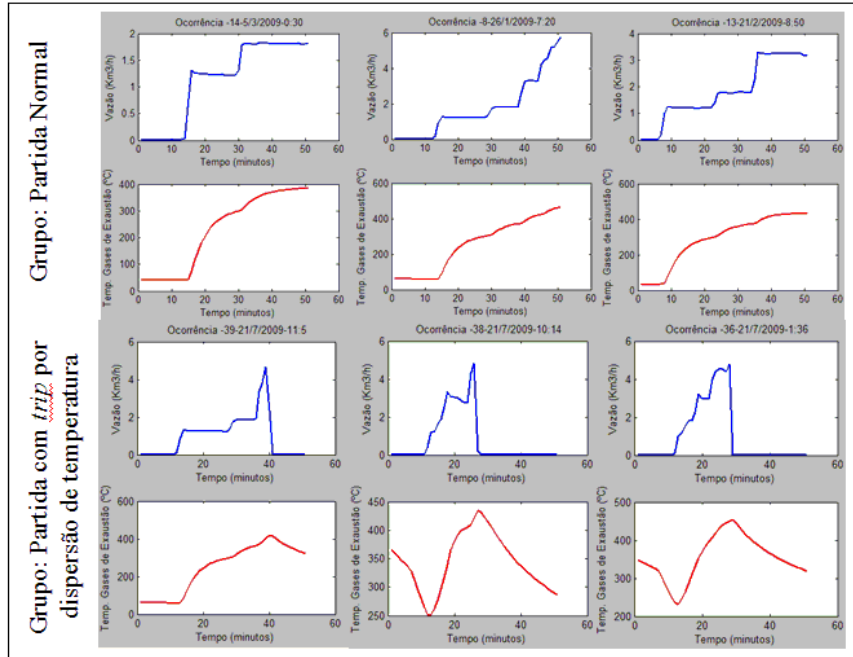


Figura 10 – Segregação das ocorrências em grupos de curvas

Com base nos grupos, novamente o algoritmo de agrupamento (*clustering*), o Fuzzy C-Means, originou as curvas padrões mostradas na Figura 11. Dois grupos (ou dois *clusters*) foram gerados para o caso de partida normal (69 ocorrências) e todas as 10 ocorrências de parada com *trip* por dispersão de temperatura foram agrupadas em um único cluster não se constatando neste caso necessidade de definição de dois ou mais *clusters*. As duas curvas da esquerda são os centros (ou curvas padrão) para partida normal e representam portanto dois perfis típicos que indicam a ocorrência de partida da turbina sem ocorrência de qualquer interrupção posterior. A curva da direita é a curva padrão (centro) de partida com *trip* por dispersão de temperatura. A primeira curva de partida normal representa um padrão de partida com transições mais lentas e graduais. Observa-se que em 50 minutos a vazão de gás atingiu, aproximadamente, 3 Km³/h, o equivalente a uma potência de 4,5 MW. Já a segunda curva de partida normal representa as partidas com transições mais acentuadas. Por exemplo, em 50 minutos a vazão atingiu aproximadamente 8 Km³/h, o que representa 24 MW.

A queda que ocorre na curva da direita não é representativa para caracterizar o padrão de falha, trata-se da turbina parando após o desarme. A parte relevante para a distinção entre uma partida com e sem falha é a parte de subida das curvas. Apesar de se perceber transições mais acentuadas na subida da curva com falha, esta constatação não é suficiente para a concepção e configuração do sistema inteligente. Os padrões de curvas identificados representam fotos resultantes de uma primeira implementação de uma sistemática de tipificação de curvas de vazão de gás e temperatura de exaustão com vistas ao conhecimento de padrões que possam levar ou indicar a ocorrência de parada da TG devido a *trip* por dispersão de temperatura. Estes resultados possuem portanto um potencial direto de utilização como curvas de

referência em sistemas inteligentes que, por sua vez, serão capazes de acompanhar, em tempo real, as duas variáveis analisadas e de forma quantitativa estabelecer dinamicamente a evolução da probabilidade de falha do equipamento ao longo do tempo.




Figura 11 – Curvas padrões de Partida Normal e Partida com *trip* por dispersão de temperatura

6. Considerações

Este trabalho apresentou uma metodologia para a identificação de padrões de operação de turbinas a gás, com objetivo de prover os meios para a implementação de um sistema inteligente para predição de falhas. Esta metodologia é fruto de um projeto de pesquisa que tem como cenário a UTE-RA. A primeira parte do trabalho contemplou a extração automática de todas as ocorrências de partidas da turbina desde 2009. Na segunda parte, os padrões de operação das turbinas durante a partida foram mapeados com ênfase na determinação de *trip* por dispersão de temperatura e de partida normal.

O projeto tem como premissa gerar produtos e resultados que sejam flexíveis e portáteis. Assim, apesar de estar direcionado para tratar especificamente a predição de falhas por dispersão de temperatura em turbinas a gás, tanto a metodologia quanto as ferramentas e técnicas empregadas podem ser adaptadas para tratar problemas de outras naturezas. Outros tipos de falhas podem ser investigados e processados, desde que esteja disponível uma amostra de sua ocorrência e os seus registros nos relatórios de operação.

Além disso, a metodologia pode ser aplicada a outras usinas termelétricas, além da UTE-RA, ou a outros tipos de usinas e equipamentos, desde que disponham de uma boa infraestrutura de coleta e disponibilidade de dados históricos de seus equipamentos. Em uma visão ainda mais ampla, e explorando ainda mais a portabilidade da metodologia, outros tipos de eventos, tais como pontos ótimos de operação (*benchmarks*) também podem ser investigados com as funções implementadas, de maneira que seja possível a compreensão do seu comportamento e a busca da repetibilidade de seus padrões na operação na planta.

Uma relevante característica do cenário de aplicação, no caso a UTE-RA, é a grande disponibilidade de dados históricos da planta industrial, envolvendo medidas de várias grandezas dos diversos componentes de suas turbinas a gás. Esta característica induziu o uso de técnicas de mineração de dados para extrair o conhecimento a respeito do comportamento da turbina a gás, e permitiu conciliar estas informações com os relatórios de operação e gestão da unidade.

Trabalhos análogos, de análise dos dados para identificação do sistema com objetivo de otimizar a operação da planta já foram realizados nesta mesma unidade. Assim, a condução do projeto, as práticas exercidas e os resultados obtidos permitem constatar que o bom uso da tecnologia de informação e da engenharia de controle e automação, associadas às boas práticas de gestão e operação das plantas industriais pode gerar soluções que permitam aos

gestores melhorarem seus resultados, que neste contexto pode ser entendido como a otimização da planta e a melhoria da disponibilidade operacional. Conseqüentemente, obtém-se um aumento da lucratividade e, sobretudo, a redução dos prejuízos decorrentes de paradas e penalidades contratuais.

Referências

- BALASKO, B. ABONYI, J. FEIL, B.** *Fuzzy Clustering and Data Analysis Toolbox*. Department of Process Engineering University of Veszprem, 2002.
- BARR, D. C.** *The Use of a Data Historian to Extend Plant Life*. IEEE Life Management Power Plant, Conference Publication. n. 401, dez. 1994.
- CARVALHO, F. B., TORRES, B. S., FONSECA, M. O., SEIXAS FILHO, C.** *Sistemas PIMS – Conceituação, Usos e Benefícios*. VII Seminário de Automação de Processos da Associação Brasileira de Metalurgia e Materiais – ABM, Santos/SP, Outubro, 2003.
- CCEE, Câmara Comercializadora de Energia Elétrica.** *Determinação de Geração e Consumo*. Brasília, 2009. 37p.
- DANG, T.** *Integration of Power Plant information system with Business information system in the open electricity market: challenges and solutions*. IEEE - 5th International Conference on Industrial Informatics. v. 2, p. 1209-1213. jun. 2007.
- DASH, S. VENKATASUBRAMANIAN, V.** *Challenges in the industrial applications of fault diagnostic systems*. Elsevier Computers and Chemical Engineering, v. 24, p. 785-791, 2000.
- DE AMO, S.** *Técnicas de Mineração de Dados*. XXIV Congresso da Sociedade Brasileira de Computação. Jornada de Atualização em Informática, 31 de Julho a 6 de Agosto 2004, Salvador Brazil.
- FAYYAD, U. M. PIATETSKY, G. SMYTH, P. UTHURUSAMY, R.** *Advances in Knowledge Discovery and Data Mining*. California: American Association for Artificial Intelligence e MIT Press, 1996.
- FRAS, A.; DANG, T.** *Improving industrial application's performances with an Historian*. IEEE - International Conference on Industrial Technology (ICIT). v.2, p.718-721, dez. 2004.
- FLETCHER, P. WALSH, P.P.** *Gas Turbine Performance*. 2.ed. Oxford: Blackwell Science, 2004.
- GIAMPAOLO, Anthony.** *Gas Turbine Handbook, Principles and Practices*. 3.ed.2006. Georgia: The Farmount Press, 2006.
- HOPPNER, F. KLAWONN, R. KRUSE, R. RUNKER, T.** *Fuzzy Cluster Analysis*. Wiley, Chichester, 1999.
- KORBICZ, J.; KOSCIELNY, J. M.; KOWALCZUK, Z.; CHOLEWA, W.** *Fault Diagnosis Models, Artificial Intelligence, Applications*.
- LIAO, T.W.** *Clustering of time series data - a survey*, Science Direct. Pattern Recognition 38 (2005) 1857 – 1874.
- MORAIS, C. C.; CASTRUCCI, P. L.** *Engenharia de Automação Industrial*. 1.ed. Rio de Janeiro: LCT, 2001.
- ROLLS-ROYCE.** *Material de Treinamento do Conjunto RB 211-G62 DF*, 2010.
- SÁ BARRETO, S. T.** *Desenvolvimento de Metodologia para Atualização em Tempo Real de Modelos Matemáticos de Processos Decisórios*. 2009. Dissertação (Mestrado em Mecatrônica) – PPGM, Universidade Federal da Bahia, Salvador.
- SÁ BARRETO; S. T.; FERREIRA, C. V.** *Estrutura Analítica de Projeto (EAP) para projetos infra-estruturais em automação industrial integrada*. In: II Congresso Brasileiro de Gerenciamento de Projetos, Anais do Congresso, Nov. 2007.
- SARAVANAMUTTOO, H. I. H.; ROGERS, G. F. C.; COHEN, H.** *Gas Turbine Theory*. 5.ed. Dorchester: Prentice Hall, 1996.

VENKATASUBRAMANIAN, V. RENGASWAMY, R. YIN, K. KAVURI, S. N. *A review of process fault detection and diagnosis - Part I: Quantitative model-based methods.* Elsevier Computers and Chemical Engineering, v. 27, p. 293-311, 2003.

VENKATASUBRAMANIAN, V.; RENGASWAMY, R.; KAVURI, S. N.; YIN, K. A review of process fault detection and diagnosis - Part III: Process history based methods. Elsevier Computers and Chemical Engineering, v. 27, p. 327-346, 2003.

VLACHOS, M. *A practical Time-Series Tutorial with MATLAB.* European Conference on Machine Learning, 2005.