Departamento de Engenharia Química

DESENVOLVIMENTO DE UM *SOFT SENSOR* PARA INFERÊNCIA DE ÍNDICE DE FLUIDEZ EM POLIPROPILENO DE UMA PLANTA INDUSTRIAL UTILIZANDO *NEURO-FUZZY*

Alunos: Ariani Rodrigues Chaves da Silva (unieariasilva@fei.edu.br)
Beatriz Alexandre Pacheco (uniebpacheco@fei.edu.br)
Caroline Dutra Silva Santos (uniecarolinesantos@fei.edu.br)
Hyoram Leonardo Sartori Assunção (uniehassuncao@fei.edu.br)
Katia dos Santos Araujo (uniekaraujo@fei.edu.br)
Orientador: Dr. Ivan Carlos Franco (icfranco@fei.edu.br)

Introdução

Com a ascensão da indústria 4.0, a busca por métodos mais automatizados e proativos de controle das variáveis de processos, tem se tornado cada vez mais ativa.

Entretanto nem todas as variáveis podem ser medidas com sensores simples, tendo como exemplo, as propriedades mecânicas e reológicas de polímeros, tradicionalmente medidas em laboratório após a produção.

Buscando antecipar essas análises, existe a possibilidade de criação de modelos que inferem o possível valor dessas propriedades, através de inteligência artificial, utilizando variáveis de fácil medição como vazão e temperatura, permitindo alterações nas condições do processo antes que produtos fora de especificação sejam produzidos, sendo o índice de fluidez de polipropileno o foco desse projeto.

Objetivo

Criar um modelo, utilizando inteligência artificial, pela técnica de *neuro-fuzzy*, que consiga predizer os valores de índice de fluidez dos *pellets* recém extrudados, utilizando dados do processo de extrusão, a fim de implantar um *soft sensor* em plantas de polipropileno.

Metodologia

Para elaboração de uma modelagem empírica temos que inicialmente definir as variáveis que afetam a propriedade de interesse ou que tenham uma relação proporcional a variável de saída. Para o IF levantamos 40 variáveis do processo de extrusão, entre elas temos leituras de pressão, torque, vazão de aditivos e peróxido e temperaturas.

Para melhor precisão na aquisição dos dados foi realizada a retroação do tempo entre a coleta da amostra e a saída dos *pellets* da extrusão. Os dados em seguida foram normalizados no intervalo entre 0 e 1 para evitar priorização de variáveis com escala de grandeza mais expressivas. Com isso conseguimos uma base normalizada e averiguada contendo mais de 1700 linha referentes à produção do ano de 2019 na planta PP4 da Braskem SA.

Entretanto um modelo de 40 variáveis seria muito complexo e dificilmente viável, necessitando a filtragem das variáveis pelas que tivessem maior afinidade entre si e maiores impactos no modelo. Para realizar essa checagem foi utilizado o coeficiente de correlação de Pearson, onde as correlações acima de 0,7 em módulo foram consideradas fortes. Abaixo se encontram as 12 variáveis escolhidas pelo modelo pelo maior número de correlações, descritas na tabela, ou por sua relevância na influencia ao índice de fluidez.

Variáveis de entrada para a rede Neuro-Fuzzy					
Carga da Extrusora	Torque do Motor Principal	Pressão Antes da Throttle Valve	Pressão Depois da Throttle Valve	Pressão Antes das Telas	Pressão Depois das Telas
0	6	9	9	6	4
Vazão de Peróxido	Temperatura do Barril 3	Temperatura do Barril 4	Temperatura do Barril 5	Temperatura do Barril 6	Temperatura do Fundido
0	4	5	5	8	8

Com as variáveis definidas pode-se criar os modelos de inferência utilizando a ferramenta *Toolbox Neuro-fuzzy Designer* do *software MATLAB®*, onde a base inicial foi dividida entre dados de treinamento, teste e simulação e foi utilizada a técnica de *subcluscering* para obtenção das regras *fuzzy* que ditaram as características das funções de pertinência e o polinômio que dita a saída do *soft sensor*, caraterístico do modelo Takagi-Sugeno. Alterando os valores dos parâmetros de *subcluscering* objetivou-se a obtenção de modelos com um pequeno número de MF's (*Membership Functions*), consequente com menor esforço computacional, porém ainda com poucos residuais.

Resultados

Para as análises, foram obtidos cerca de 50 modelos distintos, para então encontrarmos três que se destacaram através da sua relação entre assertividade e esforços computacionais. Os modelos foram chamados de ANFIS01, ANFIS02 e ANFIS03, os quais possuem 4, 6 e 10 funções de pertinência (MFs), respectivamente. Essas funções de pertinência calculam o impacto de cada entrada de acordo com o cenário, e assim atribui um peso no polinômio do modelo, sendo quanto maior o número dessas funções, maior será o esforço computacional do modelo.

Dentre os testes realizados para a base de 2019, encontramos valores de VAF (predição offline) e CV (validação cruzada) que indicam que o ANFIS01 seria o melhor por ter um menor esforço computacional e seus critérios de desempenho indicarem bons resultados.

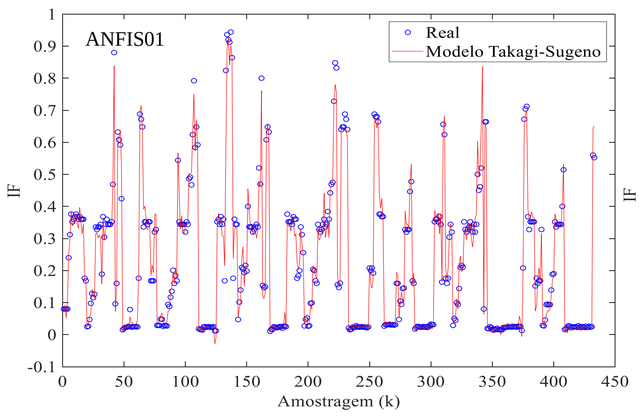

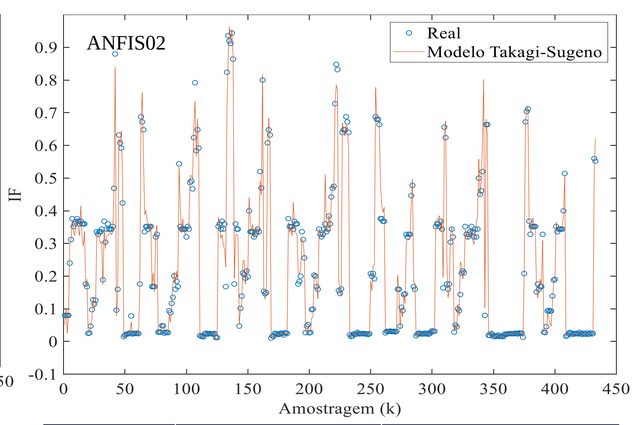

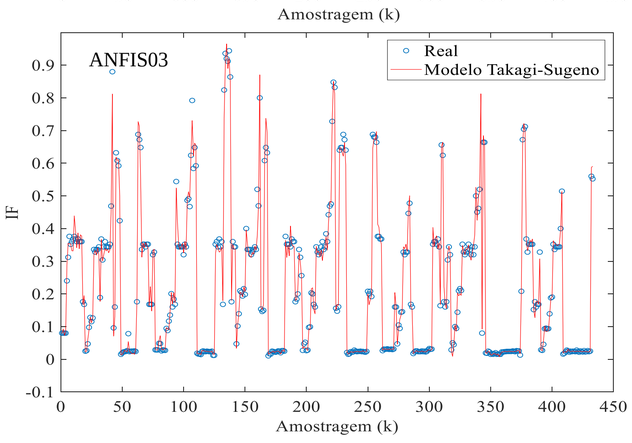

Modelo	Predição off-line (VAF)	Validação cruzada (CV)
ANFIS01	98,26%	0,983
ANFIS02	98,62%	0,986
ANFIS03	99,10%	0,991

Porém buscando reafirmar os resultados iniciais, foram realizados novos testes com uma base atual, do ano de 2020, que através dos critérios de desempenho mostrou que o modelo encontrado anteriormente não seria o indicado por ter seu valor de VAF menor que 80%, mostrando que o modelo mais eficaz seria o ANFIS02, por ter valores de VAF e CV bons em relação aos outros e quantidade de MF's aceitável.

Modelo	Predição off-line (VAF)	Validação Cruzada (CV)
ANFIS01	78,396%	0,783
ANFIS02	83,901%	0,837
ANFIS03	82,938%	0,828

Conclusão

A limpeza dos dados, organização e o uso do Coeficiente de Pearson foram essenciais para a escolha das variáveis e estas foram o suficiente para obter modelos que representassem de forma satisfatória o processo. Fazendo uma análise com dados atuais, foi constatado que o modelo ANFIS02, apesar de possuir seis MF's, representou melhor o processo, portanto foi o modelo escolhido para compor o *soft sensor*.

Os modelo ANFIS02 está sendo aprimorado para que ocorra sua implantação na planta PP4 da Braskem, possibilitando sua abrangência para demais plantas de PP e PE, junto com o trabalho da engenharia de automação os modelos serão utilizados para consulta dos operadores, que poderão realizar pequenas alterações no processo para evitar a produção de produto fora de especificação e em um futuro não tão distante reduzir o numero de amostragens intermediárias.