

Implementação de redes neurais artificiais para estimativa de potência e torque em geradores de indução para sistemas de micro geração distribuída

Wesley Candido da Silva¹

Renato Kazuo Miyamoto²

RESUMO

Em aplicações industriais, os motores de indução são amplamente utilizados por características consolidadas, como robustez e baixo custo de manutenção. Em sistemas de geração distribuída que utilizam geradores de indução, ou seja, motores de indução operando com velocidade superior à síncrona, o comportamento característico do torque eletromagnético deve ser considerado, visando uma maior eficiência do sistema proposto. Assim, a potência fornecida à rede elétrica deve ser inferior à potência do gerador, devido à perdas oriundas do processo de conversão eletromecânica de energia. As redes neurais artificiais são mecanismos autônomos capazes de estimar parâmetros por meio de dados de treinamento, possuindo fácil implementação e baixo custo. Este trabalho aplica uma rede neural artificial do tipo perceptron com entradas atrasadas no tempo (TDNN-Time Delay Neural Network) com o objetivo de estimar o comportamento do torque e da potência em sistemas com geradores de indução. Os dados de entrada da rede são as correntes trifásicas que são tratadas e treinadas a partir de respostas de torque esperadas via simulação. A validação da Rede Perceptron Multicamadas, foi realizada para novos dados coletados sobre um sistema com tensão de alimentação em desequilíbrio de 5% e com a inserção de harmônicas de 2° e 3° ordem, sendo estes, valores jamais treinados na rede. Os resultados foram considerados satisfatórios, com erro de 0,8% em regime permanente, e 2,5% em transitório.

Palavras-chave: Redes Neurais Artificiais, TDNN, Inteligência Artificial, Gerador de Indução.

¹ Especialista, wesley.candido@sistemafiep.org.br

² Mestre, renato.miyamoto@sistemafiep.org.br

IMPLEMENTATION OF ARTIFICIAL NEURAL NETWORKS FOR POWER AND TORQUE ESTIMATION IN INDUCTION GENERATORS FOR DISTRIBUTED MICRO GENERATION SYSTEMS

ABSTRACT

In industrial applications, induction motors are widely used for consolidated characteristics such as robustness and low maintenance cost. In distributed generation systems that use induction generators, ie induction motors operating at higher than synchronous speed, the characteristic behavior of the electromagnetic torque should be considered, aiming at a higher efficiency of the proposed system. Thus, the power supplied to the power grid must be lower than the generator power, due to losses arising from the electromechanical energy conversion process. Artificial neural networks are autonomous mechanisms capable of estimating parameters through training data, having easy implementation and low cost. This work applies a Time Delay Neural Network (TDNN) type perceptron artificial neural network to estimate torque behavior and power in induction generator systems. Grid input data is like three-phase currents that are treated and trained from expected torque responses via simulation. The validation of the Multilayer Perceptron Network was performed for new data collected about a system with 5% unbalanced supply voltage and a damage insertion of 2° and 3°, which are values already trained in the network. The results were considered satisfactory, with an error of 0.8% in the steady state and 2.5% in the transient.

Key words: Artificial Neural Networks, TDNN, Artificial Intelligence, Induction Generator.

1 INTRODUÇÃO

Os motores de indução trifásicos (MIT) são classificados como a principal fonte de conversão de energia elétrica em motriz. Em particular, os motores tipo gaiola de esquilo possuem uma elevada aplicação industrial justificada por sua robustez e baixo custo (Awadallah and Venkatesh, 2015).

No âmbito atual brasileiro, em que muito se fala em eficiência energética, os motores de indução são responsáveis por elevada parcela de consumo de energia. Segundo estudo da (PROCEL, 2009) os MITs são responsáveis por 49% da energia elétrica consumida no país. Uma pesquisa do EPE (Empresa de Pesquisa Energética) relata que em 2014 houve aumento no consumo energético brasileiro em 2,1% (Ong, 1998).

Motivado por esta elevada fatia de demanda energética, uma alternativa no âmbito de micro e mini geração de energia são os geradores de indução (GI). Diversas implementações de geração de energia adotam geradores síncronos por desconhecimento das técnicas necessárias para correto funcionamento do gerador de indução. O motor de indução com rotor gaiola de esquilo pode ser empregado de maneira eficaz e com elevado custo-benefício em pequenas centrais hidrelétricas e sistemas de cogeração para potências de até 30 kVA. Todavia, projetos de até 50 kVA para operação isolada e 100 kVA para interligada, são factíveis.

A máquina de indução opera como motor quando trabalha abaixo da velocidade síncrona e como gerador quando funciona acima da velocidade síncrona. Para correto manuseio e aplicação desse tipo de sistema na rede elétrica, é necessário conhecer o comportamento dos parâmetros de saída, tais como torque eletromagnético e potência gerada.

A proposta abordada é desenvolver um sistema de estimativa da potência e torque concebidos pela implementação de um gerador de indução. Esse sistema é baseado em uma rede neural artificial que analisa dados de entrada de corrente elétrica, e estima a partir desta análise, o conjugado de saída e velocidade. Sabe-se que a potência fornecida é o produto vetorial do torque eletromagnético e velocidade da máquina. O modelo proposto é proficiente podendo ser implementado em hardware por não exigir alto poder de processamento. A implementação e validação será realizado em ambiente computacional Matlab®/Simulink.

2 GERADOR DE INDUÇÃO

A geração assíncrona foi eventualmente empregada desde o início do século XX e seu uso ausentou-se nos anos 60. Na década de 70, com a considerável elevação do preço do petróleo e energia elétrica aliado com o uso racional de fontes alternativas, a utilização destes sistemas voltou a ser bem visto (Awadallah and Venkatesh, 2015).

O MIT atua como motor na zona de operação abaixo da velocidade síncrona e como gerador quando trabalha acima da velocidade síncrona. Apesar do estudo e comprovação de inúmeros métodos para melhora da performance desses sistemas, qualquer motor de indução sob estas condições pode fornecer energia para rede (Ong, 1998).

Quando o MIT opera como gerador seu eixo recebe potência mecânica por meio de uma máquina primária, e tal potência, após subtração das perdas se converte em energia elétrica. As perdas no gerador são divididas em três grupos: as perdas mecânicas, podemos considerar o atrito e ventilação como fatores elementares; as perdas no núcleo causadas por efeito de histerese e corrente de Foucault; e por fim as perdas por efeito Joule que são originadas pela resistência ôhmica do estator e rotor. A Figura 1 ilustra os modos de operação do MIT.

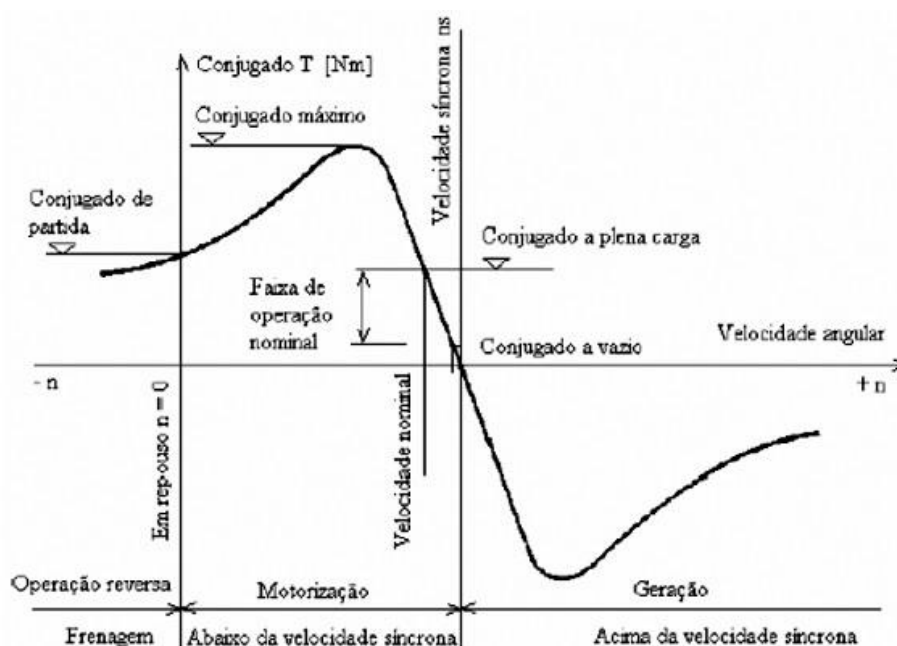


Figura 1: Curva Conjugado x Velocidade do MIT

Uma máquina de indução não é suscetível de entregar a mesma potência ativa no modo gerador para a rede, do mesmo modo que absorveria trabalhando como motor, pois com o aumento das perdas, o MIT trabalha muito próximo da região de saturação.

A potência fornecida pela geração é dada pela equação 1.

$$P = T \cdot \omega \quad (1)$$

Onde T é o torque eletromagnético em $[N.m]$ e ω é a velocidade do rotor em $[rad/s]$.

3 APLICAÇÃO DAS REDE NEURAIIS ARTIFICIAIS

As redes neurais artificiais são um conjunto de ferramentas computacionais inspiradas no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção de conhecimento a partir de informações injetadas na rede. Podem ser definidas como conjunto de unidades de processamento, caracterizadas por neurônios artificiais, estes estão interligados por sinapses artificiais (Da Silva et al., 2010).

Para a estimação da potência fornecida na implementação proposta, foi utilizada uma Rede Perceptron Multicamadas (PMC) com entradas atrasadas no tempo. As redes Perceptron de múltiplas camadas tem sua identificação atribuída pela presença de pelo menos uma camada intermediária de neurônios, localizada entre a camada de entrada e respectiva camada neural de saída, portanto as PMCs possuem no mínimo duas camadas de neurônios distribuídos entre as camadas intermediárias e a camada de saída. Suas aplicações são as mais variadas entre as mais utilizadas estão aproximação universal de funções, previsão de series temporais e reconhecimento de padrões redes (Da Silva et al., 2010).

O algoritmo de treinamento possui dois passos: o primeiro, denominado propagação aplica-se os valores a entrada da RNA e verifica-se a resposta. O valor da camada de saída é comparado com o valor desejado. O segundo passo é feito de maneira inversa, ou seja, da camada de saída para a camada de entrada. O erro produzido na saída da rede é utilizado como parâmetro para ajuste dos pesos e limiares da rede (Goedtel et al., 2006).

O elemento básico de uma RNA é o neurônio artificial também conhecido como elemento de processamento e sua representação está ilustrada na Figura 2.

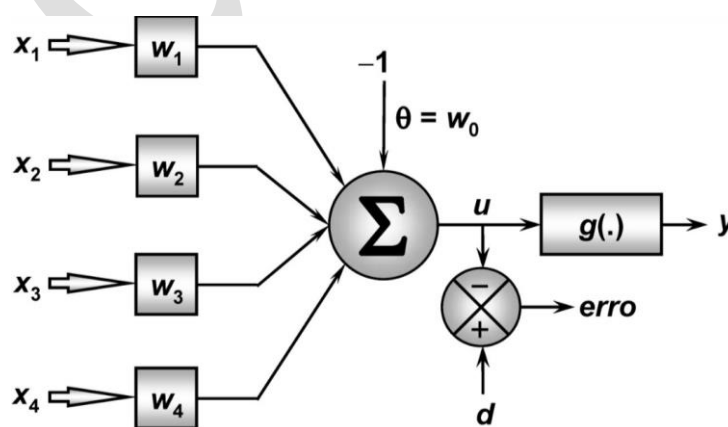


Figura 2: Representação do neurônio artificial.

O equacionamento do neurônio artificial é dado por:

$$v_j(k) = \sum_{i=1}^n X_i \cdot w_i + b \quad (2)$$

Onde:

n é o número de sinais de entrada do neurônio;

X_i é o i -ésimo sinal de entrada do neurônio;

w_i é o peso associado com o i -ésimo sinal de entrada;

b é o limiar de cada neurônio;

$v_j(k)$ é a resposta ponderada do j -ésimo sinal de entrada em relação ao instante k ;

$g(.)$ é a função de ativação do j -ésimo neurônio;

y é o sinal de saída.

Cada neurônio artificial é capaz de computar os sinais de entrada e a respectiva saída. A função de ativação usada para calcular o sinal de saída é tipicamente não-linear. As redes neurais que processam dados analógicos, que estão envolvidas nesta aplicação, têm como função de ativação a tangente hiperbólica pois trabalha com valores de corrente negativa. O processo de ajuste dos pesos da rede w_{jt} associados ao j -ésimo neurônio de saída é feito pelo cálculo do sinal de erro em relação à k -ésima iteração ou ao k -ésimo vetor de entrada. Este sinal de erro é calculado pela seguinte equação:

$$e_{j(k)} = d_{j(k)} - y_{j(k)} \quad (3)$$

Onde $d_{j(k)}$ é a resposta desejada do j -ésimo neurônio de saída. Somando todos os erros quadráticos produzidos pelos neurônios de saída da rede em relação a k -ésima iteração, temos

$$E(k) = 1/2 \sum_{j=1}^p (e_j)^2(k) \quad (4)$$

Onde p é o número de neurônios da saída. Para uma configuração de pesos ótima, $E(k)$ é minimizado pelo ajuste dos pesos sinápticos w_{ji} (Goedtel et al., 2006).

3.1 Rede PMC na Estimativa de Parâmetros

A utilização das redes neurais artificiais em predição de sistemas dinâmicos tem obtido resultados promissores em todas as áreas de atuação. As amostras de corrente são tratadas para que a rede funcione com entradas atrasadas no tempo. A rede PMC com entradas TDNN é uma classe das redes Perceptron empregada para sistemas dinâmicos, cujos comportamentos são variantes no tempo ou dependentes dele. Idealizada por Lang & Hinton em 1988, são definidas na arquitetura *feedforward* de camadas múltiplas, sem qualquer realimentação das saídas dos neurônios com a primeira camada.

A rede utilizada tem entrada estipulada com dez amostras de pico da corrente no domínio da frequência para estimativa do próximo valor de conjugado eletromagnético e velocidade, assim sucessivamente conforme janelamento de atraso temporal.




Figura 3: PMC com 15 neurônios na camada escondida.

Após execução do janelamento das amostras de entrada visando o atraso temporal, usou-se uma rede PMC com treinamento supervisionado conforme Figura. 4.




Figura 4: Implementação PMC.

4 METODOLOGIA

O sistema de geração foi implementado em ambiente computacional Matlab®/Simulink para coleta da amostragem de entrada, e as aquisições são valores eficazes das correntes que foram utilizados para treinamento da rede. Foi utilizado dois motores de indução acoplados ao mesmo eixo ambos com 1CV e baixo momento de inércia. O primeiro motor possui velocidade síncrona de 3600 rpm e o segundo motor com velocidade síncrona de 1800 rpm.

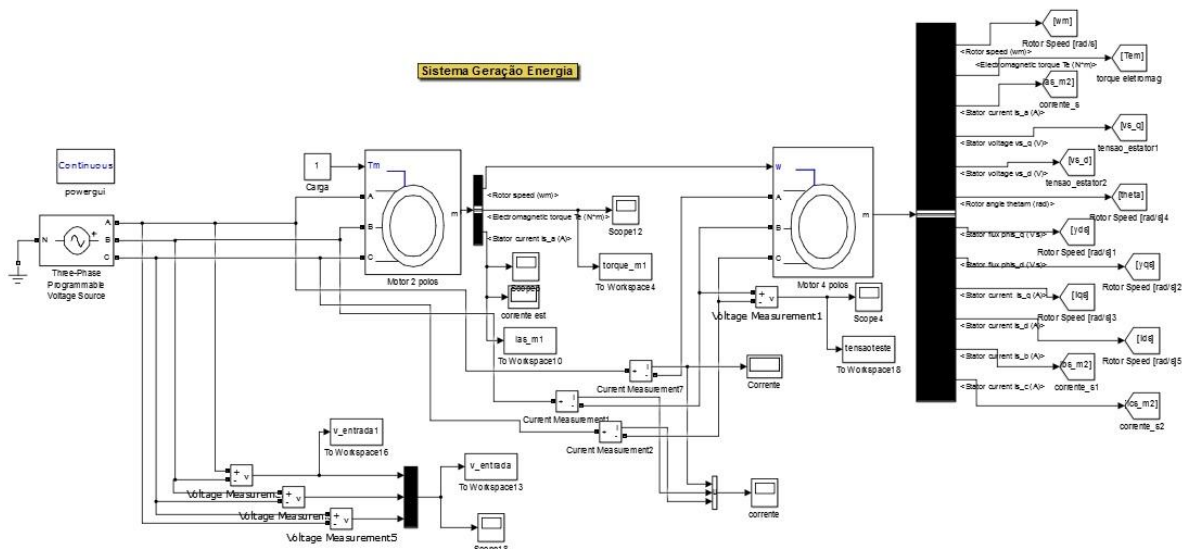


Figura 5: Implementação Sistema Geração.

A Figura 6 apresenta o sistema de geração implementado em ambiente computacional. Os dados coletados foram tratados para inserção na RNA, e o treinamento da rede foi realizado com valores diferentes de camadas e neurônios buscando uma

melhor convergência. A validação da PMC foi realizada para novos dados coletados sobre um sistema com tensão de alimentação em desequilíbrio de 5%.

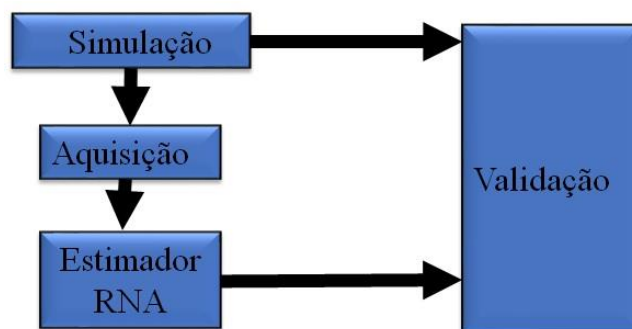


Figura 6: Validação da PMC.

5 RESULTADOS

O treinamento da RNA foi executado após tratamento das amostras de entrada. A rede é constituída por uma camada intermediária com 15 neurônios e o treinamento foi realizado com amostras de tensão trifásica ideal, e com inserção de desequilíbrio de tensão. Para a validação da RNA foi tido como entrada valores de corrente elétrica agora com distorção de 5% na tensão de alimentação. A Figura 7 ilustra as curvas estimadas e simuladas do conjugado eletromagnético.

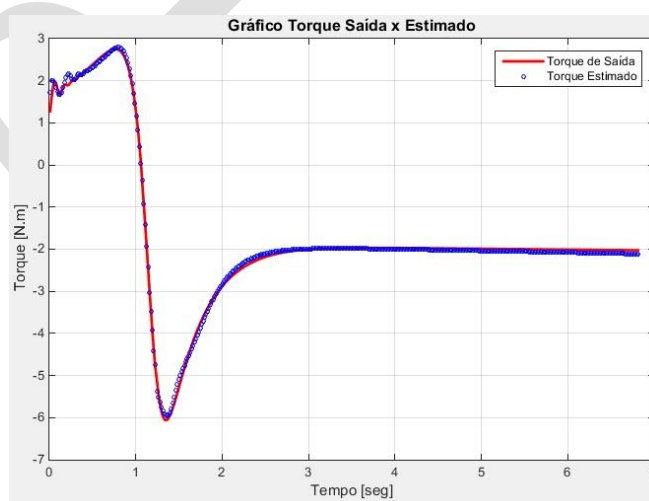


Figura 7: Estimativa do Torque Eletromagnético.

O motor entra no modo de geração rapidamente devido ao baixo momento de inércia considerado para a simulação. Percebe-se a elevada eficiência da rede neural para

estimativa em todos os pontos da curva. A Figura 8 ilustra a estimativa da velocidade de saída.




Figura 8: Estimativa do Torque Eletromagnético.

A rede estima com grande precisão a curva da velocidade de saída com erro máximo de 2 rad/s o que representa 0,8% de erro na estimação. Os pontos de inflexão são os mais difíceis para a estimativa porém os resultados obtidos tornam eficiente a rede treinada. Uma nova estimativa da curva de torque foi realizada com distúrbio em amplitude de tensão e inserção de harmônicas de segunda e terceira ordem na alimentação, a validação foi realizada com dados que nunca foram treinados.

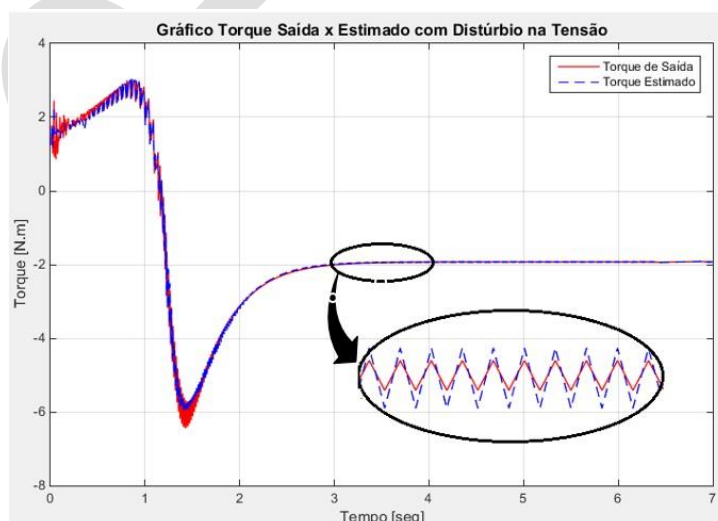


Figura 9: Estimativa do Torque com ripple.

A inserção de harmônicas na alimentação torna o comportamento do torque com elevada oscilação e a RNA mostra-se capaz da estimação deste comportamento. A Figura 10 mostra os erros obtidos na implementação.

Curva	Erro quadrático médio (%)	Variância
Estimação Torque	1,962	0,725
Estimação Velocidade	2,065	0,944
Estimação Torque Ripple	2,530	1,535

Figura 10: Dados da validação.

A Figura 11 ilustra a estimativa da potência de saída resultado da multiplicação de torque e velocidade. A potência no gerador de indução representa uma parcela da potência ativa do sistema, haja vista as perdas por efeito Joule, histerese, corrente de Foucault e perdas no entreferro.




Figura 11: Estimativa do Torque Eletromagnético.

Confirmando o bom desempenho das redes neurais para estimativa de parâmetros percebe-se uma crescente aceitação desta técnica nas mais diversas áreas de aplicação comprovando a versatilidade do método proposto.

6 CONCLUSÃO

A utilização de algoritmos artificiais está tendo grande aceitação em diversas aplicações acadêmicas e industriais por alto poder de precisão, baixo custo de implementação. As redes neurais artificiais são amplamente empregadas no controle e estimação de parâmetros.

Por meio da simulação computacional foi validado uma PMC com estimação de torque, potência e velocidade de um sistema de gerador de indução. O conhecimento e predição do conjugado eletromagnético é essencial para a inserção da máquina na rede, por exemplo, onde é necessário o conhecimento da potência momentânea gerada para obter maior otimização e eficiência energética.

Por fim, percebe-se a aplicabilidade da rede proposta, podendo esta ser configurada para estimativa em qualquer sistema de MITs precisando apenas modificação dos parâmetros de simulação e novo treinamento da rede. O método proposto é eficaz em diversas situações podendo ser facilmente utilizado para técnicas que necessitem da estimação da velocidade, como por exemplo o controle orientado por campo (FOC) para motores de indução que necessite de respostas em baixas velocidades.

REFERÊNCIAS

Awadallah, M. and Venkatesh, B. (2015). Energy storage in flywheels: An overview, *Canadian Journal of Electrical and Computer Engineering* 38(2): 183-193. cited By 0.

Belfedhal, S., Kouadria, S., Berkouk, E. and Meslem, Y. (2013). Flywheel energy storage system with induction machine associated to a variable-speed wind generator. cited By 1.

Da Silva, I., Spatti, D. and Flauzino, R. (2010). *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas - Curso Prático*, ARTLIBER.

Goedel, A., Da Silva, I. and Serni, P. (2006). *A neural approach to estimate the coordination of induction motors* [uma abordagem neural para estimativa de conjugado em motores de indução], *Controle y Automacao* 17(3): 364-380.

Haykin, S. (2009). *Neural Networks and Learning Machines*, number v. 10 in *Neural networks and learning machines*, Prentice Hall.

Ong, C. (1998). *Dynamic Simulation of Electric Machinery: Using MATLAB/SIMULINK*, Prentice Hall PTR.

Schmitt, H., Scalassara, P., Goedel, A. and Endo, W. (2015). Detecting bearing faults in lineconnected induction motors using information theory measures and neural networks, *Journal of Control, Automation and Electrical Systems* 26(5): 535-544.

Xu, K. and Wang, X. (2014). Speed sensorless vector control with wavelet neural network for induction motor drive, *ICIC Express Letters* 8(9): 2431-2436. cited By 2.