

Cálculo preditivo de classificação das notas do ENADE utilizando Redes Neurais Artificiais

Predictive calculation of classification of ENADE notes using Artificial Neural Networks

Ricardo Modugno Nunes

Universidade Católica de Petrópolis

ricardomodugno@gmail.com

Giovane Quadrelli

Universidade Católica de Petrópolis

giovane.quadrelli@ucp.br

Tiago Bittencourt Nazaré

Universidade Católica de Petrópolis

tiago_bit@yahoo.com.br

Resumo

Este artigo tem como escopo o desenvolvimento de um modelo classificatório com finalidade preditiva de calcular o Conceito Final do Exame Nacional de Desempenho dos Estudantes (ENADE) por meio de uma Rede Neural Artificial (RNA), que através do seu mecanismo de aprendizado supervisionado forneça com precisão de 99,997% de acerto os Conceitos ENADE para toda e qualquer Instituições de Ensino Superior (IES) que se pretenda avaliar. Desta forma, a situação problema reside nas quantidades de variáveis e considerações necessárias a se fazer quando se deseja calcular o Conceito Final do ENADE. Ancorado em análise quantitativa adotada realizou-se um estudo visando à praticidade destes cálculos, a possibilidade de elaborar simulações e criar cenários relevantes, de forma a fornecer aos gestores e coordenadores das IES – Instituições de Ensino Superior, indicadores que facilitem eliminar falhas preventivamente durante o processo de formação dos alunos. Neste desenvolvimento, foi utilizado a base de dados fornecida pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP) e o software MATLAB versão 2017a (*MathWorks, Inc.*) – *Neural Networks Toolbox*.

Palavras-chave: Classificação ENADE; Instituição de Ensino Superior; Indicadores ENADE; MATLAB; Redes Neurais Artificiais; SINAES.

Abstract

This article aims to develop a classificatory model with a predictive purpose of calculating the Final Concept of the National Examination of Student Performance (ENADE) through an Artificial Neural Network (RNA), which through its supervised learning mechanism provides with 99.997% accuracy of the ENADE Concepts for any and all Institutions of Higher

Education (HEI) that it is intended to evaluate. In this way, the problem situation lies in the quantities of variables and considerations necessary to be done when calculating the ENADE Final Concept. Anchored in the quantitative analysis adopted, a study was carried out aiming at the practicality of these calculations, the possibility of elaborating simulations and creating relevant scenarios, in order to provide the managers and coordinators of HEIs - Institutions of Higher Education, indicators that facilitate eliminating failures during the process of student training. In this development, we used the database provided by the National Institute of Educational Studies and Research Anísio Teixeira (INEP) and the software MATLAB version 2017a (MathWorks, Inc.) - Neural Networks Toolbox.

Keywords: ENADE Classification; Institution of Higher Education; Indicators ENADE; MATLAB; Artificial Neural Networks; SINAES.

1. Introdução

Toda graduação no Brasil atualmente precisa ser avaliada. Conforme Lei nº 10.861, de 14 de abril de 2004, dando criação ao Sistema Nacional de Avaliação da Educação Superior (SINAES) que é formado por três componentes principais: a avaliação das instituições, dos cursos e do desempenho dos estudantes. O SINAES avalia todos os aspectos que giram em torno desses três eixos, principalmente o ensino, a pesquisa, a extensão, a responsabilidade social, o desempenho dos alunos, a gestão da instituição, o corpo docente e as instalações, avaliando desta forma a qualidade de ensino em relação ao sistema de educação brasileiro como um todo. A essas avaliações que ajudam no processo educacional são denominados Indicadores Educacionais.

Os Indicadores Educacionais são medidas construídas a partir dos diferentes dados que são produzidos pelo Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), uma autarquia federal vinculada ao Ministério da Educação (MEC). São úteis, principalmente, para o monitoramento dos sistemas educacionais, considerando o acesso, a permanência e a aprendizagem (INEP, 2010).

Alguns indicadores de avaliação de ensino, tais como Exame Nacional de Desempenho dos Estudantes (ENADE), o Certificação Profissional ANBIMA Série 10 (CPA-10), o Conceito Preliminar de Curso (CPC) são atribuídos à cursos de graduação e tem influenciado o desenvolvimento das Instituições, a escolha de alunos em ingressar ou não em determinados cursos e fundamentalmente a possibilidade de uma instituição oferecer bolsas de estudo para o financiamento do curso pretendido.

Um dos indicadores e instrumentos criados pelo governo, o ENADE tem como objetivo avaliar a qualidade da educação superior no Brasil, utilizando-se de Indicadores instituídos pelo MEC.

O ENADE tem por objetivo avaliar o desempenho dos formandos dos cursos de ensino superior público e privado do país. São avaliações obrigatórias formadas de questões objetivas e subjetivas, onde a periodicidade máxima é trienal para cada área do conhecimento, onde se pode avaliar desta forma o rendimento em relação aos conteúdos programáticos específicos, habilidades e competências adquiridas ao longo de toda a formação.

Segundo o INEP (2010), cursos que receberem conceitos “1” e “2” estarão impossibilitados de abrir novas turmas e podendo até ter que encerrar suas atividades, pois não possuem desempenho suficiente de acordo com as exigências curriculares do INEP. A partir do conceito “3”, os cursos passam a receber incentivos para funcionar de maneira mais adequada, tais como, disponibilidade de bolsas de estudos e financiamentos por programas de crédito estudantil. O conceito máximo, portanto seria o de número “5”.

Outro fator importante é o de que a nota é calculada para cada curso, para cada tipo de Instituição de Ensino Superior (IES), por um município, por uma área de avaliação e, a partir de 2008, passou a considerar em seu processo apenas o desempenho dos alunos concluintes.

As instituições de Ensino Superior buscam identificar quais aspectos e características que possam formar e criar um determinado perfil, que poderia direcionar se um curso teria ou não um bom desempenho em uma futura avaliação do ENADE (Cruz, Nossa, Balassiano, & Teixeira, 2013).

Mediante esta observação, este artigo tem como objetivo identificar se um curso terá um bom desempenho ou não segundo avaliação do ENADE, promovendo provas em caráter simulado e calculando-as antecipadamente com os mesmos critérios utilizados pela Instituição autárquica, identificando desta forma o desempenho de um determinado curso e, por conseguinte seu hipotético Conceito ENADE (CE) de avaliação utilizando cálculo por Redes Neurais Artificiais (RNAs).

Esta RNA criada visa à praticidade de cálculos do Conceito Final ENADE, elaborar simulações e cenários distintos, norteando e direcionando ações de gestores e coordenadores, corrigindo falhas e eliminando lacunas detectadas durante a formação dos alunos, medindo e avaliando previamente o desempenho de alunos em cursos de graduação Universitária por meio dos conceitos obtidos nas provas do ENADE.

Por fim, as análises de parâmetros revelados neste trabalho garantem a possibilidade de elaboração de estratégias e indicadores, revelando as possibilidades de melhorias pontuais ao longo de todo o processo de formação nas IES.

2. Redes Neurais Artificiais

As RNAs são desenvolvidas para modelar relações complexas em várias áreas do conhecimento. Por não ser uma estrutura linear, uma RNA consegue captar as características mais complexas dos dados, o que nem sempre é possível utilizando as técnicas tradicionais de estatística, afirma Braga, Ludemir e Carvalho (2010).

São capazes de resolver uma gama de problemas de grande complexidade. Sendo assim, são modelos extremamente úteis em situações que não se é possíveis definir explicitamente uma lista de regras, ou quando o os banco de dados e as regras de cálculos não possuem um padrão de constância, muito utilizadas, portanto para classificação de padrões e previsões.

São sistemas compostos de unidades de processamento que tem como objetivo, determinar funções matemáticas onde estas unidades podem ser dispostas em uma ou mais camadas. Quando complexas são interligadas por um número maior de conexões, que são associadas a pesos e que após o processamento inicial de aprendizagem, armazenam reiteradamente o conhecimento adquirido pela própria rede.

O funcionamento de RNA é baseado em uma estrutura biológica de grande complexidade, o cérebro humano. Sua grande vantagem em se comparada aos métodos estatísticos conhecidos, é o de otimização, ou seja, não requerer informações detalhadas sobre o processo físico a ser modelado, sendo assim, uma rede neural é capaz de extrair regras básicas a partir de dados reais ou como são denominados Banco de Dados, diferindo da computação programada, onde é necessário um conjunto de regras rígidas pré-fixadas e algoritmos.

Como uma RNA executa seu aprendizado a partir de dados, as escolhas das variáveis de entrada são de suma importância. Embora uma rede neural tenha condições de modelar problemas difíceis e complexos, é preciso que existam dados e observações confiáveis e suficientemente representativas para que o conhecimento possa ser extraído de forma que o aprendizado da RNA aconteça com sucesso e segurança.

Segundo Zanetti, Sousa, Carvalho e Bernardo (2008) as RNAs possuem forma de treinamento com pesos em suas conexões. Aprendem através de exemplos e são distribuídos em camadas interconectadas, passando por um processo de treinamento a partir de casos reais conhecidos, adquirindo a partir daí, a sistemática necessária para executar adequadamente o processo desejado dos dados fornecidos.

Uma fase importante na composição de toda RNA é o treinamento. Seguindo o algoritmo de treinamento escolhido, são ajustados pesos e conexões da rede, onde se utiliza o conjunto de teste que previamente foi extraído do Banco de Dados total, para que se consiga assim determinar o desempenho da RNA. A partir do momento que esses padrões são apresentados para RNA e ela consegue reconhece-los, atinge-se o intento de que as etapas de Treinamento e Teste foram bem sucedidas.

As RNAs possuem basicamente 3 camadas: Camada de Entrada: onde os padrões são apresentados à rede; Camadas Intermediárias ou Ocultas: onde é feita a maior parte do processamento, através das conexões ponderadas; podem ser consideradas como extratoras de características; Camada de Saída: onde o resultado final é concluído e apresentado.

3. Metodologia

O presente artigo é uma análise quantitativa, usando como base de dados os resultados obtidos no ENADE de 2011, 2014.

Segundo Martins e Alonso (2012) a dificuldade de formulação e cálculos precisos do Conceito do ENADE, fazer hipóteses e confirma-las é uma prática árdua e improvável no dia a dia de gestores e coordenadores de cursos de graduação. O método de cálculo do CE por RNAs funciona a partir do problema proposto, proporcionando possibilidade de vários testes e simulações de notas atribuídas aos alunos, sugerindo hipóteses e recalculando sempre que necessário o CE, caracterizado então de forma secundária, por um método também hipotético-dedutivo.

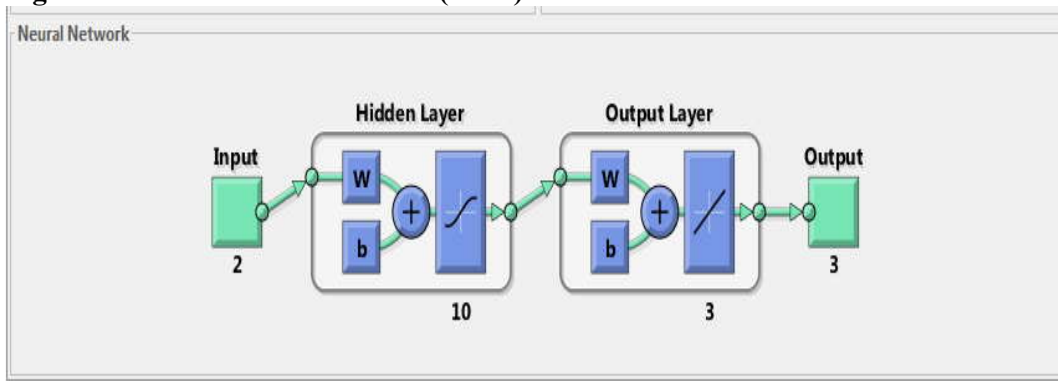
Para os estudos bibliográficos, foram utilizados livros dispostos no acervo da Universidade Católica de Petrópolis e artigos online disponíveis no *Google Acadêmico* e *Scielo*, além da legislação específica no site do INEP. A Base de Dados da Rede Neural Artificial, teve como origem de um download da planilha de resultados no site do ENADE (<http://portal.inep.gov.br/ENADE>) e através do *Microsoft Excel 2010*, filtrou-se dados do curso de Engenharia de Produção utilizando-se assim uma base de dados com 329 registros. A Rede foi criada utilizando-se como entrada duas matrizes numéricas, 10 neurônios no algoritmo Levenberg-Marquardt, com o auxílio da interface gráfica *NNSTART* do software *Matlab 2017a (MathWorks, Inc.)* e um micro *Dell Optiplex 780 core I3 com 4Gby* de memória *RAM*.

As discussões acerca dos resultados das verificações das hipóteses são apresentadas na seção seguinte.

4. Resultados

4.1. Testes de validação

Utilizou-se neste estudo a RNA do tipo “perceptron” de múltiplas camadas multilayerperceptron (MLP), onde se torna a mais indicada para este caso pois o sinal de entrada se propaga para frente, tipo “feedforward”, ou seja, camada por camada sendo em seguida retro propagado para a correção do erro, este procedimento foi repetido durante várias iterações até a finalização do teste de validação. Todos os neurônios presentes na RNA utilizada foram configurados com base no modelo apresentado por Haykin (2001). A Figura 1 demonstra a configuração da Rede Neural Artificial criada.

Figura 1 – Rede Neural Artificial (RNA)

Composta de 2 entradas, 10 neurônios e 3 saídas, onde tais entradas referem-se as notas que os alunos obtiveram na prova de conhecimentos gerais e específicos.

A Rede foi treinada de forma supervisionada com o algoritmo de Levenberg-Marquardt, utilizando-se para aproximação do mínimo da função de erro, o método de Newton Ford (2015). Este algoritmo foi o mais indicado, pois devido à sua superioridade em relação aos outros algoritmos mais utilizados tais como o back-propagation, relatado por Soares e Nadal (2000) que de acordo com os quais, embora o algoritmo de Levenberg-Marquardt demande maior tempo de processamento que o back-propagation, para cada iteração de treinamento a sua rápida convergência diminui sensivelmente não só o número total de iterações necessárias ao treinamento, mas, também, o tempo de processamento conforme Figura 2.

Figura 2 – Treinamento da rede

A captura de tela mostra a interface do software Neural Fitting (nftool) durante o treinamento da rede neural. O título da janela é "Neural Fitting (nftool)".

O painel principal é intitulado "Train Network" e contém o seguinte conteúdo:

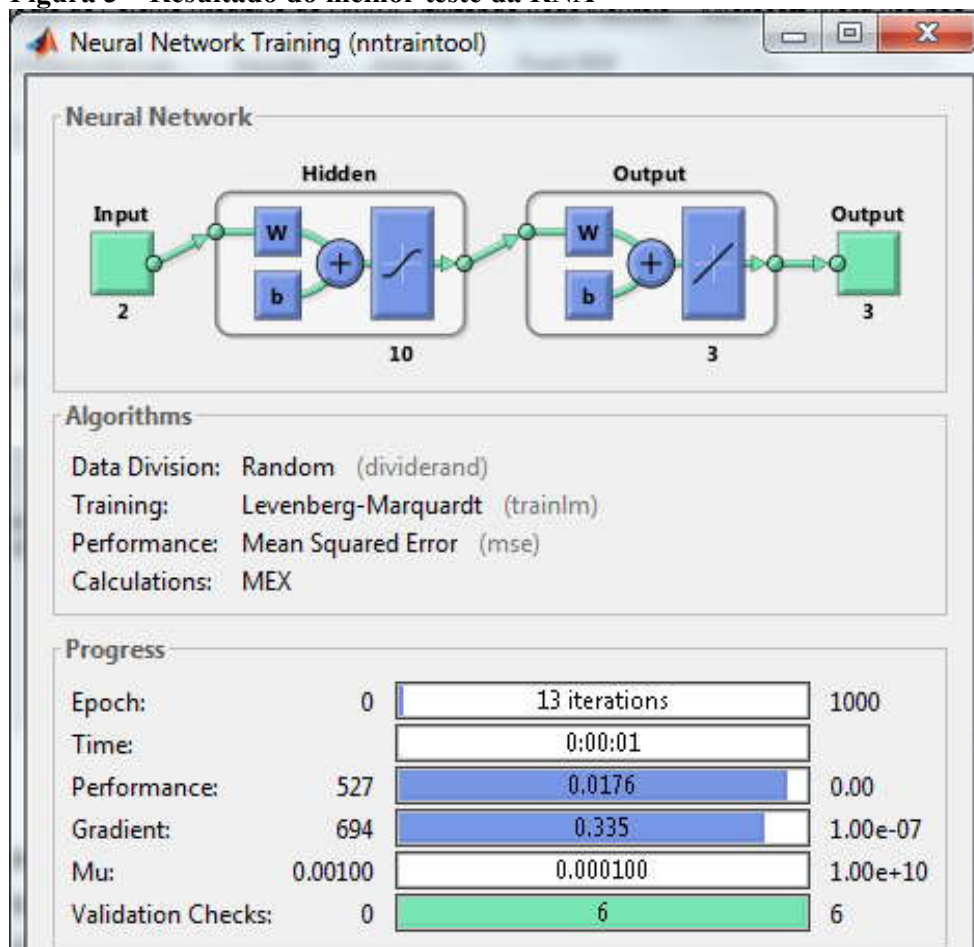
- Train Network:**
 - Choose a training algorithm: Levenberg-Marquardt
 - This algorithm typically requires more memory but less time. Training automatically stops when generalization stops improving, as indicated by an increase in the mean square error of the validation samples.
 - Train using Levenberg-Marquardt. (trainlm)
 - Train
- Results:**

	Samples	MSE	R
Training:	156	-	-
Validation:	33	-	-
Testing:	33	-	-

 - Plot Fit
 - Plot Error Histogram
 - Plot Regression
- Notes:**
 - Training multiple times will generate different results due to different initial conditions and sampling.
 - Mean Squared Error is the average squared difference between outputs and targets. Lower values are better. Zero means no error.
 - Regression R Values measure the correlation between outputs and targets. An R value of 1 means a close relationship, 0 a random relationship.

Para tanto se utilizou como base de dados, o resultado do ENADE de 2014 para a área de Engenharia de Produção (6208), considerando-se como Entrada de Dados às colunas intituladas “Nota Bruta – Formação Geral (FG)” e a “Nota Bruta – Conhecimento Específico (CE)” bem como as correspondentes Saídas de Dados, e foram consideradas Saídas de Dados às colunas de nomenclatura (INEP) “Nota Bruta – Geral”, “Nota Padronizada – Geral” e por fim o “Conceito ENADE (Faixa)” (Fig. 6). Após filtragem dos dados, seleciona-se 156 amostras e 33 registros para Validação e para Teste (Figura 2 – Results), para uma RNA que proporcionasse o melhor desempenho. Foram realizados vários testes, variando-se o número de camadas intermediárias, o número de neurônios e a função de ativação nas camadas. Para cada combinação dessas características a rede foi treinada e testada possibilitando a escolha da melhor RNA conforme Figura 3.

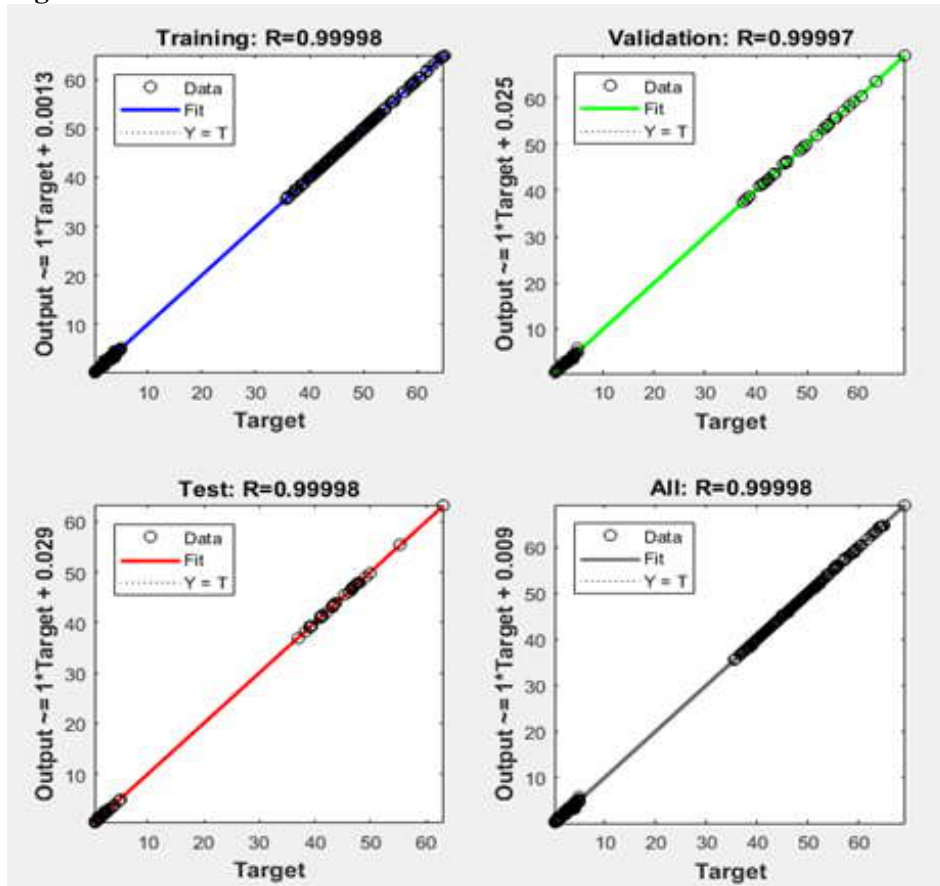
Figura 3 – Resultado do melhor teste da RNA



O melhor desempenho foi obtido utilizando-se 13 interações (épocas) e com tempo de processamento de 1 segundo.

Nos graficos da RNA ilustrados na Figura 4, verifica-se que os parâmetros Training e Validation retornam valor igual a 0,99997 identificando o percentual de 99,997% de assertividade da rede, com um erro de 0.00031 para o treinamento e -3.85. O teste de regressão demonstrou que a RNA aprendeu de forma eficiente como se realizam os complexos cálculos do ENADE.

Figura 4 – Graficos dos resultados da RNA



Esta comparação pode ser observada na seleção de 11 resultados obtidos no cálculo do software (Figura 5), quando comparados com o resultado do exame do ENADE exibidos no Quadro 1.

Figura 5 – Resultados dos cálculos da RNA

Command Window		
ans =		
35.6096	0.1451	1.1169
35.8831	0.1889	1.0118
35.9670	0.2027	1.0148
36.6945	0.3258	0.9382
36.7253	0.3262	0.8804
37.0003	0.3733	0.9173
37.1992	0.4067	0.9193
37.2664	0.4198	0.9194
37.3354	0.4312	0.9222
37.3585	0.4356	0.9219
37.4625	0.4494	0.9306

Os resultados da primeira coluna (Figura 5) correspondem as Nota Bruta-Geral, a segunda as Nota Padronizada-Geral e a terceira ao Conceito ENADE.

Quadro 1 – Seleção de resultados ENADE

			FG- Formação Geral	CE - Conhecimento Específico	Nota Bruta - Geral	Nota Padronizada - Geral	Conceito Enade - Faixa
RJ	244	226	53,2	29,7	35,6	0,136	1,00
MA	18	15	55,0	29,4	35,8	0,179	1,00
GO	48	47	54,5	29,7	35,9	0,195	1,00
SP	37	31	50,5	32,1	36,7	0,324	1,00
MS	63	50	56,0	30,3	36,7	0,325	1,00
MG	57	56	53,4	31,5	37,0	0,376	1,00
AM	40	32	53,0	31,9	37,2	0,411	1,00
AL	70	48	51,1	32,7	37,3	0,418	1,00
SP	17	17	51,1	32,7	37,3	0,429	1,00
SP	26	23	50,7	32,9	37,4	0,433	1,00
SC	30	29	53,9	32,0	37,5	0,453	1,00
RJ	98	74	53,7	32,2	37,6	0,469	1,00
SC	122	90	55,8	31,6	37,6	0,477	1,00

Todas as respostas aos cálculos da Rede Neural foram comparadas um a um aos cálculos fornecidos pelo ENADE (Quadro 1), e todos os resultados tiveram a mesma precisão. O 7º registro (linha) ilustrado no Quadro 1, apresenta nota da Formação Geral (FG) como Entrada1 (53,00) e nota Conhecimento Específico (CE) como Entrada2 (31,9), resultando na Saída1-Nota Bruta (37,2), Saída2-Nota Geral (0,411) e Saída3-Conceito ENADE (1). O sistema gerou como resultado final (Fig. 5) para a Saída1 (37.1992), Saída2 (0.4067) e Saída3 (0,9193). Foram feitos testes em outros cursos (Áreas) e os resultados obtidos foram igualmente satisfatórios, atingindo graus de confiabilidade da ordem de 99,998%.

4.2. Simulações e hipóteses

Após o Teste e Validação da Rede já modelada, executa-se enfim a grande motivação deste artigo, a de se entender como e qual melhor forma de se impactar o Conceito Final do ENADE através das notas de FG e de CE. Simulações e Hipóteses foram atribuídas a essas notas e logo depois de submetidas à RNA modelada, afim de que nos indique quais são os impactos causados no Conceito ENADE.

Foram atribuídos acréscimos nas notas de FG e de CE e de forma que, tal impacto tem o objetivo de aumentar em pelo menos 1 (um) ponto no valor do Conceito ENADE (Faixa), tornando assim, uma real e satisfatória relevância para as IES. Tais simulações foram executadas e calculadas na RNA construída, testada e validada ao que atribuímos nomenclaturas para efeito meramente comparativo:

- Simulação-1: Acréscimo de 10% as Notas da FG (Formação Geral) e em 10% as Notas de CE (Conhecimento Específico);
- Simulação-2: Acréscimo de 20% as Notas da FG (Formação Geral) e em 20% as Notas de CE (Conhecimento Específico);
- Simulação-3: Acréscimo de 10% as Notas da FG (Formação Geral) e em 20% as Notas de CE (Conhecimento Específico);
- Simulação-4: Acréscimo de 20% as Notas da FG (Formação Geral) e em 10% as Notas de CE (Conhecimento Específico);

Considera-se para efeito dos estudos, as 5 (cinco) primeiras notas que tiveram conceito ENADE “1”, as 5 primeiras notas que tiveram conceito ENADE “2” e as 5 primeiras notas que tiveram conceito ENADE “3”, como pode ser verificado nos Quadros 2, 3 e 4

respectivamente. Os conceitos “4” e “5” não foram objetos desta pesquisa nesta etapa de estudo, pois tais conceitos não causariam impacto negativo às Instituições de Ensino.

Quadro 2 – Simulação para conceito ENADE “1”.

CONCEITO ENADE	SIMULAÇÃO-1 SAIDA 10 X 10	SIMULAÇÃO-2 SAIDA 20 X 20	SIMULAÇÃO-3 SAIDA 10 X 20	SIMULAÇÃO-4 SAIDA 20 X 10
1	39.0869 0.7177 1	42.6538 1.3129 2	41.3302 1.0933 2	40.4703 0.9532 1
1	39.4833 0.7842 1	44.8172 1.6853 2	41.7263 1.1585 2	42.7943 1.3565 1
1	40.3544 0.9330 1	45.5447 1.7957 3	42.7727 1.3342 2	43.1206 1.3921 2
1	40.9105 1.0236 2	46.2231 1.9097 3	43.3379 1.4252 2	43.8804 1.5249 2
1	41.3087 1.0895 2	46.6804 1.9855 3	43.7544 1.4935 2	44.3324 1.6023 2

Fazendo uma leitura preliminar nos resultados dos cálculos obtido na RNA nas colunas das Simulações, percebe-se que o acréscimo de 10% nas notas FG e CE (Simulação-1 SAIDA 10x10) em todos os Quadros 1, 2 e 3, são pouco relevantes para as alterações esperadas, ou seja, um acréscimo de pelo menos um ponto no conceito ENADE. Já as hipóteses de acréscimo em 20% atendem perfeitamente como percebido nas colunas (Simulação-2 SAIDA 20x20) na ilustração do Quadro 3.

Quadro 3 – Simulação para conceito ENADE “2”

CONCEITO ENADE	SIMULAÇÃO-1 SAIDA 10 X 10	SIMULAÇÃO-2 SAIDA 20 X 20	SIMULAÇÃO-3 SAIDA 10 X 20	SIMULAÇÃO-4 SAIDA 20 X 10
2	43.6567 1.4772 2	49.2560 2.4095 3	46.2524 1.9095 3	46.6613 1.9845 3
2	44.0976 1.5521 2	49.9321 2.5278 3	46.6682 1.9823 3	47.5558 2.1471 2
2	44.4400 1.6088 2	50.2434 2.5763 3	47.0435 2.0445 3	47.7854 2.1801 3
2	44.3619 1.5971 2	49.8816 2.5133 3	47.1699 2.0613 3	47.0886 2.0520 3
2	44.9523 1.6918 2	50.6757 2.6441 4	47.6485 2.1431 3	47.9468 2.1944 3

Outra análise relevante, é a hipótese de acréscimos diferentes nas notas FG e CE comparativamente verificado nas colunas de Simulação-3 e Simulação-4. Contudo, o estudo demonstra que se torna mais evidente o aumento da nota do Conceito ENADE (Faixa) quando o acréscimo maior de 20% se da na nota de CE, o que ocorre e pode ser verificado na Simulação-3 quando comparada com o acréscimo maior de 20% na nota FG ocorrido na Simulação-4 e demonstrado no Quadro 4.

Quadro 4 – Simulação para conceito ENADE “3”

CONCEITO ENADE	SIMULAÇÃO-1 SAIDA 10 X 10	SIMULAÇÃO-2 SAIDA 20 X 20	SIMULAÇÃO-3 SAIDA 10 X 20	SIMULAÇÃO-4 SAIDA 20 X 10
3	50.7065 2.6488 3	57.1482 3.7148 4	53.7643 3.1566 4	54.0782 3.2159 3
3	50.8332 2.6698 3	57.2366 3.7284 4	53.9620 3.1895 4	54.0953 3.2124 3
3	50.9521 2.6895 3	57.3561 3.7483 4	54.1129 3.2145 4	54.1771 3.2242 3
3	51.2347 2.7366 4	57.8742 3.8365 4	54.2753 3.2413 4	54.6887 3.3206 3
3	51.2107 2.7323 3	57.7019 3.8054 4	54.3608 3.2559 4	54.4832 3.2769 3

5. Conclusão

Amparado pela Lei nº 10.861 em 2004, onde foi estabelecida a criação do SINAES, as instituições de ensino Superior passaram a ser avaliadas, bem como o desempenho de seus estudantes. Um dos indicadores e instrumentos criados pelo governo, foi o ENADE que tem como objetivo a avaliação na qualidade da educação superior no Brasil, utilizando-se de Indicadores instituídos pelo MEC.

Com o intuito de assistir as universidades este artigo objetivou-se a criar uma RNA capaz de receber as notas das provas de conhecimento geral e específico e informar o Conceito Final do ENADE.

A RNA foi criada utilizando o software MATLAB composta de 2 entradas, 10 neurônios e 3 saídas, onde tais entradas referem-se as notas que os alunos obtiveram na prova de conhecimentos gerais e específicos. A Rede foi treinada de forma supervisionada com o algoritmo de Levenberg-Marquardt, utilizado para aproximação do mínimo da função de erro. Utilizou-se como base de dados, o resultado do ENADE de 2014 para a área de Engenharia de Produção (6208), considerando-se como Entrada de Dados a “Nota Bruta – FG”, a “Nota Bruta – CE” e suas correspondentes Saídas de Dados, que foram a “Nota Bruta – Geral”, a “Nota Padronizada – Geral” e o “Conceito ENADE (Faixa)”. Após filtragem e seleção dos dados, foram Validados e Testados, para uma RNA que proporcionasse o melhor desempenho.

Foram realizadas simulações a fim de projetar como se comportaria as instituições com as seguintes mudanças nas notas FG com acréscimo de 10%, e igual acréscimo nas notas de CE; depois numa segunda simulação, o acréscimo de 20% nas notas da FG e iguais 20% nas notas de CE; uma terceira simulação que foi o acréscimo de 10% nas notas da FG, e em 20% nas notas de CE e por fim uma quarta simulação que constou de um acréscimo de 20% nas notas da FG e em 10% nas Notas de CE.

O estudo aponta que se torna evidente o aumento da nota do Conceito ENADE (Faixa) quando o acréscimo maior de 20% se da na nota de CE, quando comparada ao mesmo acréscimo de 20% na nota FG, ou seja, quando se compara a terceira simulação com a quarta.

Isto requer dizer que na prática para que uma IES aumente seu Conceito Final junto ao ENADE serão necessárias medidas que façam com que os alunos acertem pelo menos 10% a mais nas questões que influenciem a nota FG e pelo menos 20% a mais nas questões que tragam igualmente influência à nota CE. Demonstrando assim, que o CE é altamente relevante, principalmente quando se trata da avaliação para a classificação do Conceito ENADE.

Referências

- Braga, A. P., Ludemir, T. B., & Carvalho, A. C. P. L. F. (2010). *Redes neurais artificiais: teoria e aplicações*. Rio de Janeiro: LTC.
- Cruz, A. J., Nossa, V., Balassiano, M., & Teixeira, A. (2013). Desempenho dos alunos no ENADE de 2013: um estudo empírico a partir do conteúdo curricular dos cursos de Ciências Contábeis no Brasil. *Advances in Scientific and Applied Accounting*, 6(2), 178-203.
- Ford, N. (2015). *Expert systems and artificial intelligence: an information manager's guide*. London: Library Association Publishing.
- Haykin, S. (2001). *Redes Neurais: princípios e prática*. Porto Alegre: Bookman.

Instituto Nacional de Pesquisas Educacionais Anísio Teixeira. (2010). *Cálculo do conceito ENADE*. Recuperado em 15 fevereiro, 2017, de http://download.inep.gov.br/educacao_superior/enade/notas_tecnicas/2010/Nota_Tecnica_Conceito_Enade_2010.pdf

Martins, M. R., & Alonso, D. F. (2012, janeiro/julho). ENADE e a gestão de cursos superiores de tecnologia em instituições de educação superior do setor privado: implicações para o currículo. *Revista Eletrônica Pesquiseduca*, 4(7), 184-200.

Soares, A. P.; Nadal, A. C. P. (2000). *Redes Neurais Artificiais: teoria e aplicações*. Rio de Janeiro: LTC.

Zanetti, S. S., Sousa, E. F., Carvalho, D. F., & Bernardo, S. (2008, março/abril). Estimação da evapotranspiração de referência no estado do Rio de Janeiro usando redes neurais artificiais. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 12(2), 174-180. Recuperado em 10 novembro, 2017, de http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1415-43662008000200010&lng=en&nrm=iso