



ESTUDO PROPOSITIVO SOBRE AVALIAÇÃO DA QUALIDADE EM EDUCAÇÃO UTILIZANDO SEMIÓTICA COMPUTACIONAL E REDES NEURAIS ARTIFICIAIS

Trabalho de Conclusão de Curso

Engenharia de Computação

Sabrina Guimarães Tavares de Andrade Bezerra
Orientador: Prof. Fernando Buarque de Lima Neto, PhD



**UNIVERSIDADE
DE PERNAMBUCO**

**Universidade de Pernambuco
Escola Politécnica de Pernambuco
Graduação em Engenharia de Computação**

**SABRINA GUIMARÃES TAVARES DE
ANDRADE BEZERRA**

**ESTUDO PROPOSITIVO SOBRE
AVALIAÇÃO DA QUALIDADE EM
EDUCAÇÃO UTILIZANDO SEMIÓTICA
COMPUTACIONAL E REDES NEURAIS
ARTIFICIAIS**

Monografia apresentada como requisito parcial para obtenção do diploma de Bacharel em Engenharia de Computação pela Escola Politécnica de Pernambuco – Universidade de Pernambuco.

Recife, junho de 2014.

MONOGRAFIA DE FINAL DE CURSO

Avaliação Final (para o presidente da banca)*

No dia 11 de 7 de 2014, às 11:00 horas, reuniu-se para deliberar a defesa da monografia de conclusão de curso do discente SABRINA GUIMARAES TAVARES DE ANDRADE BEZERRA, orientado pelo professor Fernando Buarque de Lima Neto, sob título ESTUDO PROPOSITIVO SOBRE AVALIAÇÃO DA QUALIDADE EM EDUCAÇÃO UTILIZANDO SEMIÓTICA COMPUTACIONAL E REDES NEURAIAS ARTIFICIAIS, a banca composta pelos professores:

Joabe Bezerra de Jesus Júnior

Fernando Buarque de Lima Neto

Após a apresentação da monografia e discussão entre os membros da Banca, a mesma foi considerada:

Aprovada Aprovada com Restrições* Reprovada

e foi-lhe atribuída nota: 9,5 (nove e meio)

*(Obrigatório o preenchimento do campo abaixo com comentários para o autor)

O discente terá 7 dias para entrega da versão final da monografia a contar da data deste documento.

JOABÉ BEZERRA DE JESUS JÚNIOR

FERNANDO BUARQUE DE LIMA NETO

Agradecimentos

Àqueles que dedicaram seu tempo de forma a ajudar, seja assumindo o papel de orientadores ou apenas de ouvintes, meus sinceros agradecimentos.

*“The question isn’t who is going to let me;
it’s who is going to stop me.”*

- Ayn Rand

Resumo

Uma escola eficaz normalmente é associada ao ensino-aprendizado de habilidades essenciais. Porém, o conceito de qualidade não se limita apenas ao cumprimento do currículo escolar e para que haja educação de qualidade, é necessário estabelecer padrões mínimos a serem atingidos. Avaliar o desempenho do aluno não fornece indicadores reais sobre o nível da educação, se esta avaliação não for acompanhada por análises que ajudem a explicar o resultado, e estes indicadores não podem se basear apenas em médias. Além disso, sendo o aluno a unidade mais relevante do processo educacional, é preciso maior foco nas suas necessidades e dificuldades – é preciso individualizar, ou seja, lidar de forma mais específica com as necessidades, auxiliando no desenvolvimento adequado das suas habilidades. Contudo, a análise de todos esses fatores depende do contexto em que estão inseridos, implicando em um conhecimento prévio que permita a associação de informações. Realizar essas análises nem sempre é uma tarefa fácil, já que, para cada caso, é necessário um processo interpretativo único. Portanto, surge a necessidade de estudos como o aqui apresentado que auxiliem no processo de tomada de decisão em contextos educacionais. Este trabalho tem como objetivo idealizar uma ferramenta que permita a análise destes fatores e indicadores, utilizando conceitos da semiótica de Charles Sanders Peirce e de redes neurais artificiais.

Abstract

An effective school is usually associated with teaching & learning of essential skills. However, the concept of quality is not limited to the fulfillment of the school curriculum and, in order to quality in education, it is necessary to establish minimum standards to be achieved. Evaluate the student's performance does not provide real indicators of the education level if this evaluation is not accompanied by analyses that help to explain the result, and these indicators cannot only be based on averages. Furthermore, since the student is the most relevant unit of the educational process, it is necessary greater focus on their needs and difficulties – individualization is needed. This means dealing with attentively to their needs, aiding in the proper development of their skills. However, the analysis of so many factors depends on the context in which they are inserted, implying a priori knowledge that allows the association of information. Performing these analyses is not always an easy task, since, in each case, an unique interpretative process is needed. Hence, the need for studies to assist in the decision-making process within educational contexts. This work has the main goal of idealizing the premises for the construction of a tool that allows the analysis of the above mentioned factors and indicators, using concepts from Charles Sanders Peirce's semiotics and also from artificial neural networks.

Sumário

| | |
|--|-----------|
| Índice de figuras | ix |
| Índice de tabelas | x |
| Tabela de símbolos e siglas | xi |
| Capítulo 1 Introdução | 1 |
| 1.1 Motivação e caracterização do problema | 1 |
| 1.2 Objetivos | 2 |
| 1.2.1 Objetivo principal | 2 |
| 1.2.2 Objetivos secundários | 2 |
| 1.3 Estrutura do documento | 3 |
| Capítulo 2 Formulação teórica | 4 |
| 2.1 Qualidade em educação | 4 |
| 2.2 Semiótica | 5 |
| 2.2.1 Categorias da consciência | 6 |
| 2.2.2 Signo e as classificações triádicas | 7 |
| 2.2.3 Semiose | 9 |
| 2.2.4 Aplicação computacional | 10 |
| 2.3 Redes neurais artificiais | 11 |
| 2.3.1 Self-Organizing Map | 13 |
| 2.3.2 Medidas de similaridade e dissimilaridade | 16 |
| Capítulo 3 Modelo proposto | 18 |
| 3.1 Modelo proposto | 18 |
| 3.1.1 Análise semiótica | 20 |
| 3.2 Ferramenta: versão preliminar | 22 |
| 3.3 Métricas para análise de confiabilidade | 24 |
| Capítulo 4 Experimentos e resultados | 26 |
| 4.1 Definição de parâmetros | 26 |
| 4.1.1 Definição do número de neurônios | 27 |
| 4.1.2 Definição do intervalo de pesos do usuário | 28 |
| 4.2 Análise de variação do mapa | 29 |

| | |
|---|-----------|
| 4.2.1 <i>User Knowledge Modeling Data Set</i> | 29 |
| 4.2.2 <i>USA Universities Data Set</i> | 34 |
| Capítulo 5 Considerações finais | 39 |
| 5.1 Conclusões | 39 |
| 5.2 Trabalhos futuros | 39 |
| Bibliografia | 41 |
| Apêndice A Diagramas UML | 43 |
| Apêndice B Vizinhanças para o banco <i>User Knowledge Modeling</i> | 45 |
| Apêndice C Vizinhanças para o banco <i>USA Universities</i> | 47 |

Índice de figuras

| | |
|---|----|
| Figura 1. Categorias da consciência como definidas por Peirce | 7 |
| Figura 2. Modelo triádico S-O-I | 8 |
| Figura 3. Espaços de representação definidos por Gudwin para analisar o processo de semiose | 11 |
| Figura 4. Ilustração de um neurônio biológico | 12 |
| Figura 5. Estrutura de um <i>Self-Organizing Map</i> | 14 |
| Figura 6. Redução da vizinhança em um mapa auto-organizável..... | 16 |
| Figura 7. Modelo proposto para avaliar a qualidade na educação..... | 20 |
| Figura 8. Processo de funcionamento da ferramenta proposta | 20 |
| Figura 9. Tripla S-O-I para processamento de um ícone | 21 |
| Figura 10. Tripla S-O-I para o mapa gerado pelo modelo proposto..... | 22 |
| Figura 11. Diagrama UML simplificado da ferramenta preliminar proposta..... | 24 |
| Figura 12. Decaimento do erro de quantização para definição do número de neurônios utilizando o banco de dados <i>User Knowledge Modeling</i> | 27 |
| Figura 13. Decaimento do erro de quantização para definição do número de neurônios utilizando o banco de dados <i>USA Universities</i> | 28 |
| Figura 14. Mapa não ponderado para o banco <i>User Knowledge Modeling</i> , com vizinhança ao redor do aluno 218 | 31 |
| Figura 15. Mapa ponderado com vetor <i>Tests-Only</i> para o banco <i>User Knowledge Modeling</i> , com vizinhança ao redor do aluno 218 | 32 |
| Figura 16. Mapa ponderado com vetor <i>Time-Only</i> para o banco <i>User Knowledge Modeling</i> , com vizinhança ao redor do aluno 218 | 33 |
| Figura 17. Mapa não ponderado para o banco <i>USA Universities</i> , com vizinhança ao redor da <i>Seattle Pacific University</i> (ID 1022)..... | 36 |
| Figura 18. Mapa ponderado pelo vetor de pesos <i>Salary</i> para o banco <i>USA Universities</i> , com vizinhança ao redor da <i>Seattle Pacific University</i> (ID 1022)..... | 37 |
| Figura 19. Mapa ponderado pelo vetor de pesos <i>Professor-Number</i> para o banco <i>USA Universities</i> , com vizinhança ao redor da <i>Seattle Pacific University</i> (ID 1022) | 38 |

Índice de tabelas

| | |
|--|----|
| Tabela 1. Organização das bases de dados utilizadas para treinamento e validação da ferramenta proposta | 26 |
| Tabela 2. Erro médio da rede e custo computacional para definição da quantidade de neurônios..... | 27 |
| Tabela 3. Média de 30 execuções da rede para definição do intervalo de pesos do usuário | 29 |
| Tabela 4. Tabela de vetores de peso do usuário para análise da variação do mapa utilizando o banco de dados <i>User Knowledge Modeling</i> | 31 |
| Tabela 5. Erro médio para o banco de dados <i>User Knowledge Modeling</i> com diferentes ponderações..... | 34 |
| Tabela 6. Tabela de vetores de peso do usuário para análise da variação do mapa utilizando o banco de dados <i>USA Universities</i> | 35 |
| Tabela 7. Erro médio para o banco de dados <i>USA Universities</i> com diferentes ponderações | 38 |

Tabela de símbolos e siglas

BMU – Do inglês, *Best Matching Unit*

IEEE – Do inglês, *Institute of Electrical and Electronics Engineers*

PNE – Plano Nacional de Educação

RNA – Redes neurais artificiais

S-O-I – Signo, objeto, interpretante

SOM – Do inglês, *Self-Organizing Map*

UNICEF – Fundo das Nações Unidas para a Infância

Capítulo 1

Introdução

Neste capítulo estão descritos a motivação para a pesquisa, os objetivos deste trabalho, assim como a descrição da estrutura do documento.

1.1 Motivação e caracterização do problema

O senso comum define escola de qualidade como sendo um ambiente onde alunos aprendem habilidades essenciais como, por exemplo, ler e escrever [1] [2]. Porém, o conceito de qualidade em educação não se limita apenas à perspectiva pedagógica ou ao cumprimento dos componentes curriculares, mas também engloba aspectos sociais, políticos e econômicos [3]; além da relevância, eficácia e efetividade do ensino para a formação de cidadãos cômnicos de suas responsabilidades e direitos.

Para Darling-Hammond e Ascher [4], a validade da educação – relação entre os objetivos e os resultados escolares – não pode ser baseada em médias, onde médias não apresentam os desvios existentes. Avaliar os níveis de desempenho dos alunos não fornece indicadores reais sobre a qualidade da educação, se esta avaliação não for acompanhada de análises que ajudem a explicar os resultados [5] [6]. Sendo o aluno a unidade mais relevante no processo educacional, é preciso um foco maior nas suas necessidades e dificuldades [5], ou seja, há a necessidade de individualizar os resultados nas avaliações de qualidade. A análise dos fatores contribuintes para uma escola de qualidade depende também do contexto em que eles estão inseridos, sendo necessário processos interpretativos únicos para cada caso.

A semiótica [7], definida como a ciência geral dos signos [8], pode ser uma ferramenta interessante para a análise dos processos de ensino e aprendizagem e suas implicações no ambiente escolar. Isso, posto que o binômio ensino e aprendizagem acontece pela troca de signos e pela forma como esses signos são transmitidos e interpretados [9], onde signo é uma representação de algo [8] [10]. Porém, para que haja uma representação no contexto correto, é necessário um

conhecimento prévio que permita a associação entre essas informações [7] [11], ou seja, uma correta interpretação. Neste contexto, redes neurais artificiais [12] são ferramentas que também podem realizar classificações de forma satisfatória [13]. Contudo, seu uso não fica restrito apenas à classificações, sendo utilizadas, por exemplo, para ajudar a organizar materiais educacionais de forma a maximizar o ensino [14].

Assim, é importante definir políticas para avaliação da aprendizagem que sejam orientadas não apenas ao progresso do aluno, mas também ao desenvolvimento do sistema educacional e que sejam coerentes com o conceito de qualidade da educação [2]. A construção de ferramentas que auxiliem no processo de tomada de decisão, e que sejam capazes de lidar automaticamente com a diversidade, é, portanto, uma contribuição bastante plausível, além de muito necessária, para realizar uma análise mais acurada da qualidade da educação.

1.2 Objetivos

1.2.1 Objetivo principal

Este trabalho tem como objetivo principal a concepção de uma ferramenta que auxilie na avaliação da qualidade da educação, utilizando conceitos de semiótica. A ferramenta fornecerá a um educador uma forma de visualizar melhor os fatores que podem contribuir para melhorar os processos educacionais utilizados por ele.

1.2.2 Objetivos secundários

De forma a atingir o objetivo principal deste trabalho, os seguintes objetivos secundários foram estabelecidos:

- desenvolver uma versão preliminar da ferramenta, aplicando conceitos de semiótica computacional ao seu desenvolvimento;
- realizar experimentos com dados abertos relacionados à educação;
- analisar os resultados dos experimentos;
- investigar a possibilidade de combinar *Self-Organizing Map* para análise de dados, visando a obtenção de melhores resultados;

- investigar métricas de similaridade e dissimilaridade em contextos educacionais; e,
- investigar métricas e distâncias semânticas.

1.3 Estrutura do documento

Este documento está dividido em cinco capítulos, cujos respectivos resumos estão apresentados abaixo:

- **Capítulo 1: introdução**

Este capítulo contém os textos introdutórios deste trabalho, sendo eles a motivação e a caracterização do problema, além dos objetivos e metas e a descrição de como o documento está organizado.

- **Capítulo 2: formulação teórica**

Este capítulo fornece os textos necessários para o embasamento teórico do trabalho. Logo, serão descritos conceitos de semiótica, qualidade em educação, redes neurais artificiais e métricas de similaridade e dissimilaridade e de distância semântica.

- **Capítulo 3: ferramenta proposta**

Este capítulo é constituído pela principal contribuição do trabalho: a descrição de uma ferramenta preliminar para auxiliar a análise de indicadores de qualidade em educação, baseada nos conceitos apresentados no capítulo anterior.

- **Capítulo 4: experimentos e resultados**

Este capítulo possui as informações referentes aos testes e resultados obtidos pela ferramenta preliminar desenvolvida: experimentos relacionados à definição de parâmetros, tais como número de neurônios e definição de um intervalo para os valores do usuário; e experimentos relacionados à variação e análise de confiabilidade do mapa, ao variar os pesos informados ao sistema.

- **Capítulo 5: conclusões e trabalhos futuros**

Neste capítulo são apresentadas as conclusões do trabalho, suas contribuições e possíveis trabalhos futuros.

Capítulo 2

Formulação teórica

Este capítulo tem como finalidade fornecer as informações necessárias para o entendimento do documento. A primeira seção define conceitos sobre educação, como qualidade em educação e indicadores utilizados para avaliar esta qualidade. A segunda seção é composta por conceitos filosóficos e definições que embasam a proposta: conceitos sobre a semiótica de Charles Sanders Peirce, com ênfase no signo e possíveis aplicações computacionais [14]. Por fim, a última seção trata sobre redes neurais artificiais (RNA), mais especificamente sobre o *Self-Organizing Map* (SOM) [15], ou rede neural de Kohonen, e as métricas de similaridade e dissimilaridade que podem ser utilizadas na rede.

2.1 Qualidade em educação

Inicialmente é necessário definir o conceito de educação. Educação, para alguns, está restrita aos diferentes níveis de escolarização ao quais fica-se submetido no sistema escolar. Outros entendem como um espaço múltiplo, compreendendo diferentes atores, espaços e processos sistemáticos ou assistemáticos [3]. Assumindo a segunda definição, pode-se entender educação como um dos elementos centrais das relações sociais, contribuindo para que estas sejam remodeladas e mantidas.

Uma escola é considerada como uma escola de qualidade se os alunos aprendem habilidades essenciais, como ler, escrever e realizar operações matemáticas [1] [2]. Entretanto, considerando esta remodelagem das relações sociais, precisa-se compreender que o conceito de qualidade também está sujeito a modificações. Ele está vinculado às demandas e vigências da época atual e não apenas restrito ao ambiente escolar.

Qualidade da educação é um fenômeno complexo que envolve múltiplas dimensões – estas dimensões sendo internas ou externas ao ambiente escolar. Sob esta ótica, deve-se considerar os diferentes atores, os processos de ensino-aprendizagem, os currículos pedagógicos, as expectativas de aprendizagem, bem

como os diferentes fatores que interferem direta ou indiretamente nos resultados educativos [3] [5]. É importante desenvolver uma análise articulada dos diferentes aspectos que interferem no processo de construção de uma escola de qualidade. Isso significa dizer que é fundamental identificar e apontar elementos constituintes comuns de uma escola eficaz, identificando as similaridades a serem consideradas para essa qualificação. Além dos aspectos objetivos, as características da gestão financeira, administrativa e pedagógica, os juízos de valor, as propriedades que explicitam a natureza do trabalho escolar possuem sua importância. Assim como a visão dos agentes escolares e da comunidade sobre o papel e as finalidades da escola [5].

Segundo o Banco Mundial [23], a eficácia das escolas se dá quando os professores conhecem o conteúdo e as metas do currículo. Além da forma como organizam a classe, favorecendo a aprendizagem, e quando avaliam o progresso dos alunos e sua própria eficácia, de modo a ajustar-se continuamente [5]. Entretanto, avaliar um aluno não se resume apenas a uma prova que avalia os objetivos propostos (e.g., avaliar o conhecimento em um dado assunto), trata-se de um processo que deve considerar os aspectos cognitivos, psicomotores e afetivos; além de existir a necessidade de diferentes formas de avaliação [24]. Sendo o aluno a unidade mais relevante no processo educacional, é preciso que o foco seja nas suas necessidades e dificuldades. Apenas avaliar os níveis de desempenho dos alunos não fornece indicadores reais sobre a qualidade da educação, se esta avaliação não for acompanhada de outras análises que ajudem a explicar os resultados [5] e estas análises não podem ser baseadas em médias [4]. As médias escondem informações individuais dos estudantes, portanto não serão válidas quaisquer interpretações sobre o progresso da escola ou do aluno a partir de indicadores baseados em tendências.

Este trabalho tem como intuito fornecer indicadores visuais que representem de forma adequada as relações existentes entre os fatores relevantes para a qualidade, além de fornecer a possibilidade de análises individuais, seja em relação a um aluno ou em relação a uma instituição.

2.2 Semiótica

A semiótica, definida como a ciência do signos [8], teve o início do seu estudo na Grécia antiga, com pensadores como Platão e Aristóteles. Com John Locke em “A

Doutrina dos Signos”, finalmente teve seus postulados mais concretos definidos. Porém, apenas com Charles Sanders Peirce, a semiótica desenvolveu-se profundamente, tornando-se uma ciência e uma filosofia [16].

Lúcia Santaella, pesquisadora brasileira, define a semiótica como sendo a ciência que tem por objeto de estudo todas as linguagens possíveis [10], diferindo-a da linguística, que tem por estudo apenas as linguagens verbais. Em outras palavras, a transmissão de informações é uma transmissão de signos, sendo o signo o elemento mais básico de um processo de comunicação. Onde o signo, de forma resumida, é uma relação entre algo (objeto), de como este algo é representado (*representamen*) e de como ele é interpretado (interpretante) [17]. Então tem-se que a linguagem é uma gama intrincada de formas sociais de comunicação e de significação [10], ou seja, a semiótica estuda os fenômenos de significação [14], sendo fenômeno qualquer coisa que esteja presente à mente [10] [11] (e.g., uma ideia, uma palavra, uma ação, uma sensação).

Os fenômenos de significação ficam localizados na consciência dos seres-atores interpretantes do ambiente, em uma parte de suas mentes que possui diferentes profundidades representativas. São estas profundidades que definem as categorias onde as abstrações e conceitos mais gerais se encontram na mente, de forma a auxiliar na interpretação do mundo empírico [13]. As categorias mais conhecidas são as categorias definidas por Aristóteles. Das suas dez categorias, as mais conhecidas são: 1. itens (objetos); 2. qualidades (propriedades); 3. estados; e 4. relações (espacial, temporal...). Peirce, não satisfeito com estas categorias de fenômenos, dedicou-se à criação de sua própria doutrina de categorias, descritas na próxima seção.

2.2.1 Categorias da consciência

Antes de falar de consciência, é necessário definir a diferença entre consciência e razão: razão é apenas uma parte da consciência, populada pelos pensamentos sob os quais se tem controle; consciência, segundo Peirce, é o lago onde as ideias estão em constante movimento, sendo a razão apenas a camada mais superficial [10]. Neste lago, existem três categorias: Primeiridade (qualidade), Secundidade (relação) e Terceiridade (representação) [7] [10].

Primeiridade é um sentimento imediato, primitivo e simples. É uma consciência imediata acerca de algo, uma forma de existir sem referência a qualquer outra coisa [7] [10], por exemplo, uma qualidade. Mas qualidades são apenas uma parte do fenômeno, existindo apenas quando encarnadas em uma matéria, o que leva à Secundidade.

Secundidade é um primeiro em um segundo. Retomando o exemplo da qualidade, a secundidade seria a qualidade (primeiro) existindo em um fato (segundo): o tom de azul presente no céu [10]. Contudo, o fenômeno não existe de forma completa, faltando-lhe a representação deste azul presente no céu. Para que ela exista, é necessário haver um terceiro termo [11].

Terceiridade é a síntese intelectual entre o primeiro e o segundo. Neste estado da consciência, existe a interpretação e representação do mundo, a conexão entre fatos e qualidades. Com a presença do terceiro termo, é possível devidamente interpretar o vermelho em uma rosa como “a rosa é vermelha” [10].

A Figura 1 ilustra as três categorias da consciência: inicialmente, existe a percepção apenas da cor vermelha; em segunda instância, o vermelho é percebido como existente em uma rosa; e, por fim, forma-se a relação intelectual entre a rosa e a sua cor. A definição destas três categorias é essencial para compreender como acontece o processo de representação de informações, ou seja, como acontece a significação. A próxima seção descreve os conceitos de signo e semiose, também referentes às categorias e ao processo de significação.



Figura 1. Categorias da consciência como definidas por Peirce

2.2.2 Signo e as classificações triádicas

Signo é tudo aquilo que representa algo para alguém [8] [11]. Contudo, esta representação possui apenas algumas características do objeto real que o signo intenta por representar [10] [11]. Por exemplo, uma foto ou uma planta baixa de uma

uma casa não representam o objeto casa em sua totalidade – da mesma forma que a palavra “casa” não o faz –, apenas representam parcialmente, dependendo da natureza do signo utilizado (a natureza de uma foto não é a mesma natureza de uma planta baixa).

Mas nem tudo pode ser considerado como um signo, apenas o que é capaz de dar origem a outros signos pode ser considerado como um. E esta geração de signo, esta leitura de um primeiro signo em outro signo [7], é denominada de interpretante [11], diferente de intérprete. Interpretante é o processo relacional que se origina na mente do intérprete [10] – a representação de um objeto em um signo.

Estes três elementos em conjunto definem o modelo triádico S-O-I (signo, objeto, interpretante) de Peirce, exemplificado pela Figura 2. Ressaltando que Peirce assume como signo, ora o conjunto dos três elementos, ora apenas a representação do objeto em questão.

A linha tracejada indica que não existe uma relação direta entre o *representamen* e o objeto, sendo a sua existência apenas possível se houver um interpretante.

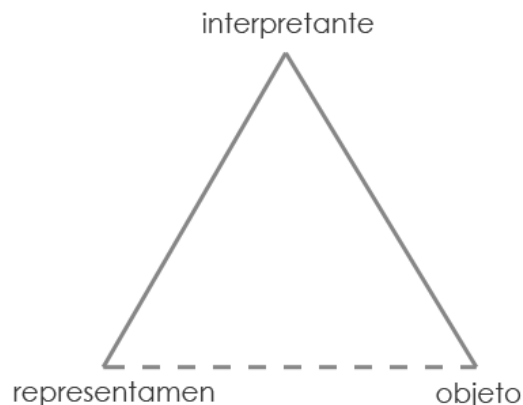


Figura 2. Modelo triádico S-O-I

Fonte: extraído de [8].

O signo não é uma coisa rígida e fixa, e sim um emaranhado de relações possuidoras de sutis diferenciações entre as partes dos objetos (diferentes representações) que mantemos em nossas mentes [10]. Peirce então estabeleceu uma rede de classificações, sempre triádicas, dos tipos possíveis de signo. No total,

existem 10 classificações triádicas (tricotomias) [11], onde três destas tricotomias podem ser consideradas como mais gerais às quais Peirce dedicou atenção minuciosa: relação do signo com ele mesmo (primeira tricotomia); do signo com o *representamen* (segunda tricotomia); e do signo com o interpretante (terceira tricotomia).

Entretanto, Peirce diz que a mais importante divisão dos signos encontra-se na segunda tricotomia, definida por ícones, índices e símbolos [7] [11]. A segunda tricotomia é constituída da relação da representação (*representamen*) com o objeto [7] [10] [11], sendo dividida em:

- Ícone – Um ícone é um signo que se refere ao objeto que denota apenas em virtude das suas próprias características, em termos de sua similaridade com o objeto. Pode representar qualquer coisa, desde que haja semelhança entre o ícone e o que ele intenta representar. Imagens, em geral, são ícones.
- Índice – Um índice se refere ao objeto que denota em virtude de ser afetado por este objeto. Exemplo: onde há fumaça, há fogo. Isto quer dizer que através de um indício (causa) tiramos conclusões. É resultado de uma relação de causalidade.
- Símbolo – Um símbolo se refere ao objeto em virtude de uma associação de ideias, sejam convenções ou leis. Por exemplo, uma aliança é rapidamente associada ao casamento ou a algum tipo de relacionamento.

Pode-se perceber que cada um dos elementos da tricotomia possui relação com uma das três categorias da consciência definidas anteriormente. O ícone representa a primeiridade; o índice a secundidade; e o símbolo a terceiridade. Esta relação existe para cada um dos elementos das dez tricotomias.

Os signos, quando apresentados à mente, geram outros signos, criando um processo infinito de significação, denominado semiose [10].

2.2.3 Semiose

A tripla S-O-I (chamada de semiose) modela o processo cognitivo básico de interpretação [14]. Esse processo ocorre de maneira diferente para cada indivíduo, ou

seja, um mesmo objeto será representado de maneiras distintas por diferentes indivíduos [7]. Sendo possível, também, que o mesmo signo provoque efeitos diferentes para o mesmo intérprete [16].

Analogamente à definição de Peirce, Morris definiu a semiose como o processo em que algo funciona como um signo. A semiose definida por Morris é composta por três elementos, relativos à teoria de Peirce. São eles: o veículo sígnico (*representamen*), o *designatum* (objeto) e o interpretante; o intérprete representa um quarto fator [16] que também pode ser levado em consideração.

Considerando a relação triádica da semiose, pode-se abstrair outras relações, denominadas semântica, pragmática e sintática. Estas, sendo relações diádicas entre os três elementos principais. Semântica é uma relação entre os signos e seus respectivos significados, logo sua principal investigação é a parcela da realidade representada pelo signo. A pragmática estuda o valor de um signo para aqueles que o utilizam, ou seja, a significação social de um signo, que é dependente do contexto e por isso vai além da visão semântica. A sintática estuda a organização de signos simples em signos complexos e suas implicações na semântica e na pragmática [16]. A próxima seção deste documento discorre sobre alguns estudos relacionados à aplicação computacional de conceitos semióticos.

2.2.4 Aplicação computacional

O intuito da semiótica computacional é desenvolver e modelar sistemas baseados em conceitos semióticos, ou seja, desenvolver sistemas autônomos inteligentes, capazes de manifestar comportamentos como percepção e julgamento de valores. Alguns estudos já foram conduzidos nesta área pelo professor Ricardo Gudwin, da UNICAMP, onde um deles foi a proposta de um ambiente computacional básico onde seria possível analisar a semiose [14].

Este ambiente proposto por Gudwin é composto por dois espaços de representação: o espaço interno e o externo, ilustrados pela Figura 3, onde a semiose pode envolver atividades em ambos.

O espaço de representação externo refere-se ao ambiente percebido pelo intérprete, composto por todos os elementos que podem ser sensorialmente percebidos. O espaço de representação interno corresponde a um espaço mental,

onde os signos estão localizados. Este espaço encontra-se dentro do intérprete, o sujeito que se tem a intenção de modelar e onde o processo de semiose ocorrerá.




Figura 3. Espaços de representação definidos por Gudwin para analisar o processo de semiose

Fonte: extraído de [14].

Além dos espaços de representação, outro mecanismo é apresentado: o foco de atenção. O propósito deste mecanismo é permitir ao intérprete assimilar informações, seja internamente ou externamente, selecionando uma determinada área que esteja contida no espaço em questão.

Esta abordagem proposta por Gudwin serve como base para a definição de novos sistemas que utilizem conceitos semióticos. Alguns desses conceitos apresentados por ele serão considerados ao longo deste trabalho.

2.3 Redes neurais artificiais

O que se entende por redes neurais artificiais são modelos computacionais que possuem como metáfora o funcionamento do cérebro humano, adquirindo conhecimento através da experiência [18].

O cérebro humano é um sistema de processamento paralelo que, apesar de ter seus elementos constitutivos, os neurônios, que são individualmente lentos, é capaz de processar trilhões de operações simultaneamente. O neurônio biológico (ilustrado na Figura 4) dispara, ou não, gerando um impulso nervoso dependente do tipo de

estímulo ao qual foi submetido: se o estímulo for maior que o limiar excitatório, ele gera um impulso; caso contrário, não responde ao estímulo (ou seja, não dispara). O impulso de um neurônio se propaga a outros na região sináptica, constituída do axônio de um neurônio e do dendrito do outro [18].

Analogamente, uma rede neural também é constituída de neurônios – unidades de processamento interconectadas – e de sinapses – conexão entre os neurônios [12] [18]. O neurônio artificial funciona de forma semelhante ao neurônio biológico, reagindo de acordo com o resultado gerado por uma função de ativação.

O conhecimento adquirido pela rede é o resultado de computações matemáticas que alteram os pesos das conexões entre os neurônios, onde estes pesos representam o conhecimento da rede. Este aprendizado pode ser realizado de duas formas [12] [18]:

- Aprendizado supervisionado: além das entradas da rede, também é fornecida a saída desejada. A rede será treinada de acordo com essas informações, enquanto os valores das conexões serão modificados de acordo com a diferença entre a saída desejada e a saída obtida.
- Aprendizado não-supervisionado: as saídas desejadas não são fornecidas à rede, que será treinada apenas com os dados de entrada. O resultado será fruto exclusivamente das regras de alocação geradas internamente, baseando-se nas características dos dados de entrada.




Figura 4. Ilustração de um neurônio biológico

Fonte: extraído do site <http://www.sogab.com.br/> [acessado em junho de 2014]

Uma rede neural pode ser utilizada com diferentes propósitos: classificação, agrupamento ou previsão. Incluindo realizar agrupamentos de conceitos simbólicos e classificação de contextos. Dentre os modelos mais conhecidos de redes neurais, duas se destacam em termos de representação interna de conceitos: redes que utilizem o algoritmo *backpropagation* [12] para treinamento e o *Self-Organizing Map* [13] [15].

Para este trabalho, a rede considerada foi o *Self-Organizing Map* (descrita na próxima seção) por ser uma rede de aprendizado não-supervisionado [15], permitindo assim que, considerando regras internas, sejam encontradas automaticamente as melhores associações para registros de entrada. Além de gerar um mapa visual de como os dados foram distribuídos. As próximas seções deste capítulo abordarão conceitos referentes à rede de Kohonen.

2.3.1 Self-Organizing Map

O *Self-Organizing Map*, ou rede de Kohonen, é um tipo de rede neural artificial auto-organizável, baseada no princípio de que as informações, no cérebro, são organizadas de forma espacial [15].

O principal motivo para utilizar uma rede Kohonen é devido a sua capacidade de criar *clusters* (agrupamentos), onde os elementos que pertencem a um mesmo *cluster* possuem similaridades [12] [15]. Além disso, a rede possui a capacidade de reduzir a dimensionalidade dos dados fornecidos. Como saída (*output*), é gerado um mapa unidimensional, bidimensional ou, até mesmo, tridimensional com a representação destes dados, mantendo a relação entre as propriedades relevantes.

A rede Kohonen, como ilustrada pela Figura 5, possui uma camada de entrada (*input layer*), composta por vetores de dados (*data vector*) que estão conectados a todos os neurônios da rede. Estes neurônios formam um mapa (*feature map*), onde cada um deles possui um vetor de pesos (*weights*) de mesmo tamanho do vetor de entrada.

Para definir a quantidade de neurônios do mapa, pode-se utilizar empiricamente a equação (1), onde N é a quantidade de registros utilizados para o treino da rede.

$$S = 5 \sqrt{N} \quad (1)$$




Figura 5. Estrutura de um *Self-Organizing Map*

Fonte: extraído do site <http://tex.stackexchange.com/> [acessado em junho de 2014]

Porém, para que seja gerado este *feature map*, é necessário que haja um processo de aprendizado na rede. Este aprendizado ocorre de forma competitiva, ou seja, cada neurônio compete com o outro de forma a ser o escolhido como *Best Matching Unit* (BMU) para responder aos dados de entrada. O BMU nada mais é do que o neurônio vencedor da disputa, ou seja, o neurônio ativado por aquele dado de entrada. Essa competição entre os neurônios pode acontecer de duas formas: *winner take all* (vencedor leva tudo) ou *winner take quota* (vencedor leva parte) [18].

No caso *winner take all*, uma das formas existentes de cálculo de vizinhança, apenas o neurônio ativado pelo dado de entrada terá seus pesos ajustados segundo a equação (2); no caso *winner take quota*, existe uma vizinhança de ativação ao redor do BMU – para este trabalho, será considerada a vizinhança gaussiana por permitir uma convergência mais estável [19], definida pela equação (4). Os neurônios pertencentes à vizinhança, assim como o neurônio vencedor terão seus pesos alterados, como demonstrado pela equação (3).

$$w_{ij}^v(\text{novo}) = w_{ij}^v(\text{antigo}) + \alpha \cdot (x_j - w_{ij}^v(\text{antigo})) \quad (2)$$

$$w_{ij}^v(\text{novo}) = w_{ij}^v(\text{antigo}) + \alpha \cdot h_j^v \cdot (x_j - w_{ij}^v(\text{antigo})) \quad (3)$$

$$h_i^v(n) = \exp \left[-\frac{d_i^v}{2\sigma^2(n)} \right] \quad (4)$$

Onde: w_{ij}^v são os pesos sinápticos que ligam o exemplo de entrada ao neurônio vencedor; x_j é o exemplo de entrada; α é a taxa de aprendizagem; $h_i^v(n)$ é o valor da vizinhança entre o neurônio vizinho i e o neurônio vencedor v ; e d_i^v é a distância do neurônio vencedor para o neurônio vizinho.

No entanto, para que seja possível ter uma organização no mapa topológico, a vizinhança de ativação (σ), que inicialmente compreende o mapa inteiro, precisa reduzir com o aumento do número de iterações, sendo decaimento exponencial um dos possíveis como definido pela equação (5). Para que haja ajustes mais finos, a taxa de aprendizagem (α) também precisa reduzir ao longo das iterações, segundo a equação de decaimento exponencial (6). A Figura 6 demonstra o decaimento da vizinhança retangular utilizada em um mapa auto-organizável.

$$\sigma(n) = \sigma(0)\exp \left[-\frac{n}{\tau_1} \right] \quad (5)$$

$$\alpha(n) = \alpha(0)\exp \left[-\frac{n}{\tau_2} \right] \quad (6)$$

Onde: $\alpha(0)$ e $\sigma(0)$ são os valores iniciais para a taxa de aprendizagem e para a largura da função de vizinhança, respectivamente; τ_1 e τ_2 são constantes de tempo que diminuem à medida que a quantidade de iterações aumenta.

Para que um neurônio seja ativado, é considerada uma métrica que define a distância do dado de entrada para o neurônio, onde o neurônio que possuir a menor distância para o exemplo, será ativado (será o BMU para aquele dado de entrada). A próxima seção descreve medidas de similaridade e dissimilaridade que podem ser utilizadas em uma rede de Kohonen.




Figura 6. Redução da vizinhança em um mapa auto-organizável

Fonte: extraído do site <http://www.dct.ufms.br/> [acessado em junho de 2014]

2.3.2 Medidas de similaridade e dissimilaridade

Inicialmente, é preciso compreender a diferença entre os termos métrica e medida. O IEEE (*Institute of Electrical and Electronics Engineers*) define métrica como uma medida quantitativa do grau em que um sistema, componente, ou processo possui um dado atributo [20]. Onde entende-se por medida um valor fixo atribuído a um determinado objeto ou evento.

O mapa auto-organizável de Kohonen, como explicado na seção anterior, utiliza medidas de distância entre os vetores para definir qual o BMU para uma determinada entrada. Apesar da medida mais utilizada ser a distância euclidiana [18], outras medidas podem ser consideradas, como: distância euclidiana ponderada, distância *Manhattan* (também chamada de *City Block*) e distância de Mahalanobis [21] [22].

Outra distância que pode ser citada, é a distância de Minkowsky, que se trata de uma generalização da distância euclidiana e Manhattan, como demonstrado pela equação (7). Se o valor de p for igual a 1, temos a distância Manhattan (equação (8)); se $p = 2$, temos a distância euclidiana (equação (9)).

$$M(\bar{x}, \bar{y}) = (\sum_{k=1}^n (x_k - y_k)^p)^{\frac{1}{p}} \quad (7)$$

$$Dm(\bar{x}, \bar{y}) = \sum_{k=1}^n |x_k - y_k| \quad (8)$$

$$De(\bar{x}, \bar{y}) = \sqrt{(\sum_{k=1}^n (x_k - y_k)^2)} \quad (9)$$

Porém, quando alguns atributos podem se mostrar mais relevantes que outros ou é necessário que algum parâmetro receba maior atenção, pode-se utilizar uma variação da distância euclidiana, ponderando-a. A distância euclidiana ponderada está descrita pela equação (10), onde p_k representa o peso atribuído àquele determinado atributo.

$$De(\bar{x}, \bar{y}) = \sqrt{(\sum_{k=1}^n p_k (x_k - y_k)^2)} \quad (10)$$

Para este trabalho a medida utilizada foi a distância euclidiana ponderada. Com a possibilidade de definir pesos para cada parâmetro, é possível inserir subjetividade ao distribuir os elementos no mapa, ou seja, é possível gerar variações no mapa de acordo com a variação desses pesos.

Capítulo 3

Modelo proposto

Este capítulo apresenta a formulação proposta para o modelo, descrevendo a relação entre os conceitos apresentados anteriormente; a descrição da ferramenta preliminar desenvolvida, baseada no modelo; e métricas que podem ser utilizadas para analisar a qualidade dos mapas gerados pela ferramenta.

3.1 Modelo proposto

O processo de gerar indicadores de qualidade, como proposto pela UNICEF (Fundo das Nações Unidas para a Infância) [1], consiste em reuniões realizadas com agentes relacionados à escola (professores, funcionários, pais de alunos...), onde um formulário abrangendo sete dimensões da escola é distribuído. Cada pergunta possui três respostas, sendo sinalizadores nas cores vermelho (não atende), amarelo (atende parcialmente) e verde (atende) em relação aos elementos da escola. Cada agente deve responder ao questionário e, por fim, é contabilizada a quantidade de sinalizadores de cada uma das cores. Este tipo de abordagem se baseia no voto da maioria, eliminando avaliações individuais.

A ferramenta inicialmente idealizada nesta proposta fornece uma forma de analisar melhor o panorama de instituições educacionais, gerando indicadores mais condizentes com a realidade. Como foi dito anteriormente, a análise da eficácia e da efetividade de uma escola não pode ser restrita apenas ao desempenho do aluno. Por exemplo, provas que medem o conhecimento em um dado assunto apenas fornecem este tipo de informação: o quanto um aluno conhece sobre o assunto. Eventualmente, estas notas são utilizadas para gerar médias que representam um indicador de qualidade para a escola. Avaliar devidamente um aluno ou uma escola requer mais que médias. Para gerar estes indicadores individuais, a ferramenta utiliza conceitos de semiótica computacional e uma rede neural artificial (e não apenas médias, sabidamente pouco expressivas para o problema em lide).

O sistema concebido tem dois elementos principais: a interface com o usuário, que fornece uma visualização multiperspectiva para melhor avaliação do mapa gerado pela rede neural, além de estabelecer a comunicação com o usuário para que os dados possam ser fornecidos; e a rede neural de Kohonen, responsável pela geração dos indicadores.

A interface é constituída de três partes: a primeira parte possui a interação com o usuário, por onde ele fornece os dados e outras informações necessárias; a segunda parte é responsável por apresentar o mapa; e a terceira parte é responsável por fornecer uma forma alternativa de visualização dos dados informados. Esta segunda forma de visualização é feita a partir do uso de uma tabela que lista os dados passados como entrada à rede. Este tipo de visualização dos dados auxilia a comparação entre os atributos de cada um dos registros que estejam sob análise.

A escolha de uma rede de Kohonen para ser aplicada ao problema deve-se a duas de suas capacidades, já discutidas anteriormente: a geração de um mapa topológico e sua capacidade de agrupamento (com vistas a agregar coerentemente aspectos simbólicos similares). A representação gráfica dos dados na forma de um mapa é dotada de discursos e sentidos próprios, da mesma forma que textos escritos, onde a informação passada está presa a uma temporalidade em particular [25]. Esta forma de representação é muito mais provável de produzir *insights* a respeito do contexto em que os dados estão inseridos [19], permitindo também que a criação de sentido seja realizada de forma mais rápida. O uso de uma imagem para transmissão de conhecimento adequa-se melhor à necessidade deste problema do que apenas um número, onde esta imagem é capaz de fornecer informações individuais acerca de todos os dados informados, assim como o panorama geral.

A rede de Kohonen utilizada possui como medida de similaridade a distância euclidiana ponderada. Os pesos utilizados nesta distância são informados pelo usuário, onde referem-se às suas preferências: o parâmetro que for assumido como elemento mais significativo receberá um peso maior em relação aos outros atributos. Por exemplo, um professor pode informar dados como frequência, participação e notas de um aluno. Se ele acredita que a frequência e a participação são mais relevantes que as notas, estes dois parâmetros receberão pesos maiores. Essa forma de ponderação possibilita que elementos subjetivos (*i.e.*, preferências do usuário)

sejam adicionados ao sistema. Cada forma de ponderação irá gerar um mapa diferenciado que poderá ser analisado sob diferentes perspectivas pedagógicas, favorecendo a identificação de elementos mais relevantes para melhorar a qualidade da educação. A Figura 7 apresenta o modelo proposto.

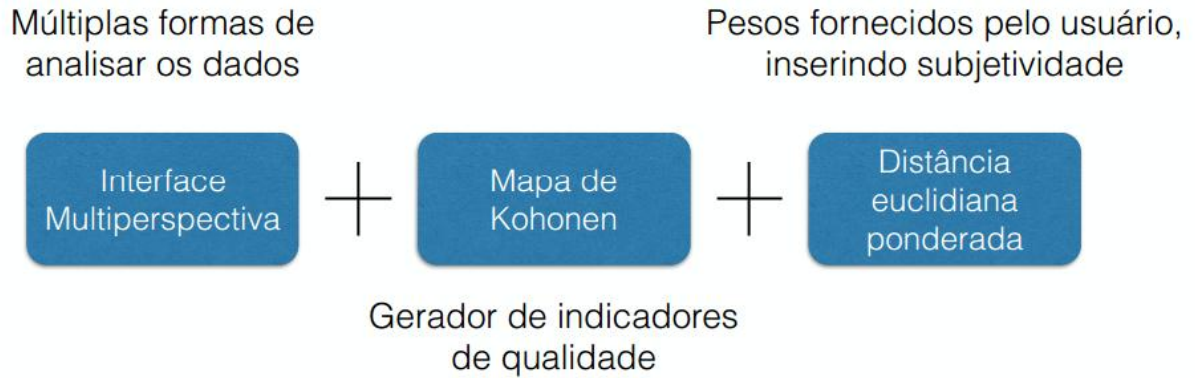


Figura 7. Modelo proposto para avaliar a qualidade na educação

No modelo proposto, o primeiro passo a ser realizado é informar ao sistema o banco de dados que será utilizado para o treinamento na rede, assim como os pesos referentes a cada um dos atributos. A rede de Kohonen é então treinada com estes dados, utilizando os pesos na distância euclidiana ponderada. Por fim, o mapa gerado é apresentado ao usuário juntamente com a lista dos dados de entrada. Posteriormente, é possível ao usuário informar outros *inputs* e verificar qual neurônio foi ativado. A Figura 8 ilustra o processo de funcionamento do sistema concebido.

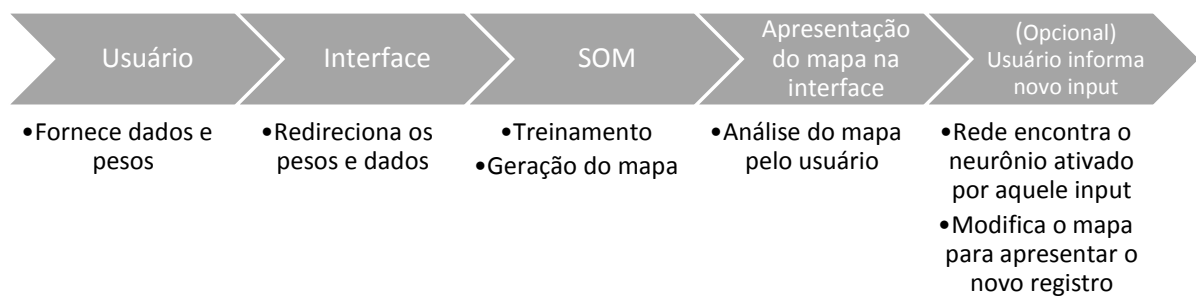


Figura 8. Processo de funcionamento da ferramenta proposta

3.1.1 Análise semiótica

Considerando a segunda tricotomia de Peirce, descrita no segundo capítulo, tem-se dois tipos de signos que, ao entrarem no sistema, são interpretados diretamente: os ícones e os símbolos. No caso de um ícone, o signo interno que for

mais similar ao dado (signo) de entrada é considerado como o interpretante deste signo que entrou no sistema, ou seja, fornece a representação. Esta fase de interpretação icônica sempre é necessária, visto que é a única forma de um signo entrar no sistema [26].

A rede de Kohonen realiza o agrupamento de acordo com a similaridade entre os dados, portanto trata-se de uma rede icônica. A Figura 9 ilustra a tríade S-O-I em relação a um ícone na rede de Kohonen. O neurônio vencedor funciona como um interpretante para o signo (dado de entrada) que está sendo apresentado à rede.

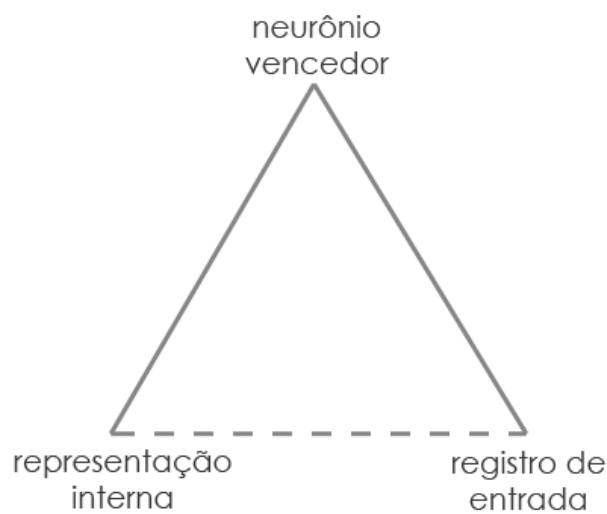


Figura 9. Tripla S-O-I para processamento de um ícone

Na abordagem icônica, os vetores de dados representam (com alguma abstração) o próprio conceito que está sendo passado à rede. Portanto, a distância existente entre os vetores no mapa também representa a distância semântica entre os conceitos [27] [28] [29]. Além disso, a abordagem icônica possibilita melhor visualização das relações entre os dados, considerando a distância entre os pontos [29]. Por exemplo, instituições ou alunos que são apresentados juntos em um mapa possuem características similares, portanto, poderia-se assumir que uma determinada abordagem funcionaria de forma similar quando aplicada aos dois elementos.

A variação da posição de um ícone (conceito) no mapa está, portanto, relacionada à variação das características do vetor Ou seja, à variação dos valores do vetor. Essa variação de posição não precisa ser, necessariamente, provocada pela variação da característica, podendo ser provocada também pela variação da importância atribuída à característica. Sob esta ótica, os pesos informados pelo

usuário são uma forma de reordenar os conceitos no mapa, permitindo análises diferenciadas e produzindo interpretações diferentes.

Apesar de Kohonen ser uma rede icônica, o mapa gerado age como um índice – um indicador de algo. Representações visuais são indicadores de algum tipo de contexto [25]. Elas não são fontes de investigação em si, mas meios para se investigar e interpretar aspectos relevantes em relação ao contexto em que estão inseridas. Permitindo, ainda, que sejam gerados diferentes efeitos para a mesma imagem [25] [30], possibilitando que a cada avaliação do indicador novas relações sejam encontradas entre os dados, onde estas novas avaliações podem significar novas abordagens a serem aplicadas à resolução de um determinado problema. Desta forma, um mapa gerado por um *self-organizing map* mostra-se extremamente útil e relevante para análise ponderada de indicadores, sejam eles educacionais ou não. A Figura 10 apresenta a tripla S-O-I considerando o mapa gerado pelo modelo proposto.

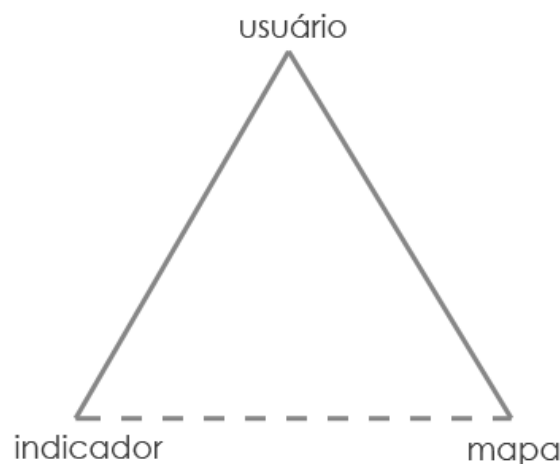


Figura 10. Tripla S-O-I para o mapa gerado pelo modelo proposto

3.2 Ferramenta: versão preliminar

Uma versão preliminar da ferramenta, que utiliza a ideia apresentada para o conceito educacional, foi implementada na plataforma Microsoft .NET 4.5 utilizando a linguagem C#. Esta linguagem foi escolhida devido a maior familiaridade e por possuir bibliotecas que auxiliaram no desenvolvimento, além de ser uma linguagem orientada a objetos. A Figura 11 apresenta o diagrama de classe simplificado da ferramenta, mostrando apenas as relações entre as classes. O diagrama UML com os detalhes

dos atributos e métodos estão apresentados no Apêndice A, assim como um diagrama de sequência do funcionamento do sistema.

A classe central do sistema é Map, onde o mapa de Kohonen está implementado e onde ocorre a maior parte do processo de interpretação dos dados. Alguns detalhes de implementação do mapa foram separados em outras classes para fornecer maior modularidade ao sistema, sendo divididos entre as classes: Neuron (os ícones), composta apenas pelos métodos referentes a cada um dos neurônios, que também utiliza a classe NeighborhoodFunctions onde as funções de vizinhança ficam implementadas; SimilarityDistances, onde estão localizadas as funções de similaridade, permitindo que qualquer alteração na medida de distância seja realizada apenas em uma parte do sistema, sendo estas distâncias as responsáveis por definir o neurônio vencedor e permitir que realmente haja a representação interna daquele dado, ou seja, definirá o interpretante daquele objeto; e AdjacencyMatrix, responsável por fornecer informações de adjacência entre os neurônios.

A classe MainWindow representa a maior parte da interface do sistema, responsável por apresentar as visualizações geradas pela rede e fornecer o menu com opções para que o usuário informe os dados e pesos, ou seja, onde o indicador (mapa) será apresentado. Esta classe é auxiliada pela classe InputWindow, que recebe um novo *input* informado pelo usuário. Os dados informados pelo usuário são passados à classe Map através de um controlador, chamado MainController, evitando uma comunicação direta da interface com o núcleo do sistema.

Antes que o treino da rede possa ser realizado, os dados passam por uma filtragem que desconsidera registros com informações faltantes. A classe Util é responsável por realizar a filtragem e o *parsing* dos dados para uma representação que possa ser utilizada pelo sistema. Uma vez que foram devidamente realizados, o treinamento da rede inicia – começa o processo de gerar um mapa icônico que funcionará, posteriormente, como um indicador. Ao terminar, os erros para análise da qualidade do mapa são computados. Estes erros estão descritos na próxima seção do documento.

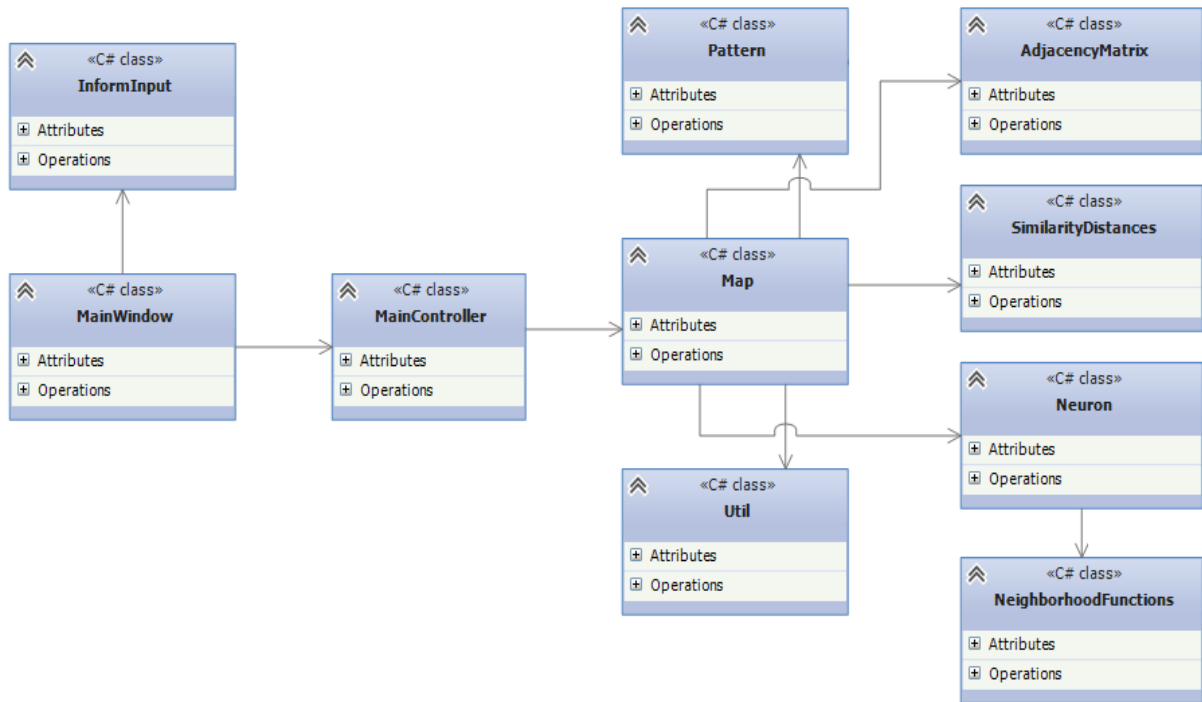


Figura 11. Diagrama UML simplificado da ferramenta preliminar proposta

3.3 Métricas para análise de confiabilidade

De forma a analisar a confiabilidade e a qualidade de um mapa de Kohonen, pode-se utilizar as seguintes medidas: erro de quantização, produto topográfico, erro topográfico, preservação da vizinhança e distorção do mapa auto-organizável [31].

Neste trabalho, apenas o erro de quantização e o erro topográfico foram considerados. O produto topográfico, preservação da vizinhança e o erro topográfico referem-se à preservação da topologia, onde o último, por ser mais simples e mais utilizado, foi escolhido como medida a ser utilizada.

O erro de quantização indica quão bem o mapa é capaz de se ajustar aos dados de entrada [31], onde o menor valor para o erro indica um mapa que se adequa melhor. O erro pode ser calculado através da equação (11), onde N representa a quantidade de registros utilizados para o treino; x_i é o valor do vetor de entrada; e m_c é o centróide do *cluster*. No caso do SOM, o centróide do *cluster* é o neurônio vencedor.

$$E_q = \frac{1}{N} \sum_{i=1}^N \|x_i - m_c\| \tag{11}$$

Para calcular o erro topográfico, para cada registro da tabela de treino encontra-se o primeiro e o segundo BMU. Se eles não forem adjacentes no mapa, é considerado como um erro, como ilustra a equação (12). Ao final, o erro total é normalizado no intervalo entre [0, 1] segundo a equação (13). Caso o erro seja igual a zero, existe uma perfeita preservação da topologia dos dados [31].

$$u(x_i) = \begin{cases} 1, & \text{caso não sejam adjacentes} \\ 0, & \text{caso sejam adjacentes} \end{cases} \quad (12)$$

$$E_t = \frac{1}{N} \sum_{i=1} u(x_i) \quad (13)$$

Uma forma de reduzir o erro de quantização é aumentar o número de neurônios da rede [31]. Por exemplo, um mapa com erro de quantização igual a 0.55 precisa de mais neurônios para que os dados se ajustem de forma adequada. Contudo, aumentar o número de neurônios implica em aumentar o erro topológico, ou seja, modificar a quantidade de neurônios da rede significa modificar algumas propriedades topológicas, além de aumentar o tempo de treinamento. Existe uma relação de dependência entre os dois erros descritos. Um mapa com boa qualidade teria que possuir os dois valores próximos a zero, indicando que os dados se ajustaram de forma adequada e não houve perda na topologia.

Capítulo 4

Experimentos e resultados

Este capítulo descreve os experimentos realizados com o protótipo da ferramenta desenvolvida e os resultados alcançados. Os dois primeiros experimentos descritos são relacionados à definição de parâmetros: definição da quantidade de neurônios da rede, visto que a equação definida anteriormente trata-se de um estudo empírico, não atendendo a todos os casos; e definição do intervalo em que os pesos informados pelo usuário estarão compreendidos. Além dos experimentos referentes à definição de parâmetros, também realizou-se experimentos para analisar se a variação do mapa está de acordo com o esperado (já no domínio de educação) e se, ao variar os pesos, o mapa mantém um índice de qualidade aceitável (pouca distorção em relação aos dados de entrada).

Os dados utilizados passaram por pré-processamento, onde os registros com dados faltantes foram desconsiderados e os valores dos atributos foram normalizados a partir do maior valor, de forma a recaírem sobre o intervalo $[0, 1]$, evitando que valores muito altos influenciassem em demasia os cálculos da rede. A Tabela 1 apresenta dados referentes às bases de dados utilizadas nos experimentos.

Tabela 1. Organização das bases de dados utilizadas para treinamento e validação da ferramenta proposta

| Nome | Atributos | Atributos desconsiderados | Total de registros | Registros desconsiderados |
|--------------------------------|-----------|---------------------------|--------------------|---------------------------|
| <i>User Knowledge Modeling</i> | 5 | - | 403 | - |
| <i>USA Universities</i> | 15 | 1 | 1161 | 115 |

4.1 Definição de parâmetros

Estes experimentos tem como objetivo definir o número de neurônios e o intervalo onde os pesos do usuário estarão compreendidos. Além do erro de quantização e do erro topográfico, o custo computacional também foi levado em consideração para definir quais os melhores valores para os parâmetros.

4.1.1 Definição do número de neurônios

Verificou-se que a quantidade de neurônios (N) definida pela equação (1), apresentada no Capítulo 2, não obteve os melhores resultados considerando bancos de dados com poucos registros, como, por exemplo, o banco *User Knowledge Modeling*, que possuía 403 registros. Então, realizou-se um experimento para definir uma quantidade de neurônios que representasse adequadamente os dados. Um total de 30 execuções foi realizado para as variações: N , $N + 3$, $N + 5$ e $N + 10$. Para cada variação, computou-se os erros descritos anteriormente. A Tabela 2 apresenta os resultados dos testes em relação ao número de neurônios, onde o custo computacional do treinamento está em segundos. A Figura 12 e a Figura 13 ilustram o decaimento do erro de quantização ao longo das iterações. O erro topográfico foi computado após o fim do treinamento.

Tabela 2. Erro médio da rede e custo computacional para definição da quantidade de neurônios

| Banco de dados | Informações | N | N + 3 | N + 5 | N + 10 |
|---|---------------------|-----------|-----------|----------|----------|
| <i>User Knowledge Modeling Data Set</i> | Quantização | 0,256589 | 0,229048 | 0,225494 | 0,200164 |
| | Topográfico | 0,131136 | 0,073643 | 0,073901 | 0,084366 |
| | Custo computacional | 4s | 8s | 11s | 37s |
| <i>USA Universities</i> | Quantização | 0,035417 | 0,034454 | 0,033941 | 0,033083 |
| | Topográfico | 0,0587833 | 0,0624146 | 0,064928 | 0,067194 |
| | Custo computacional | 101s | 152s | 227s | 673s |

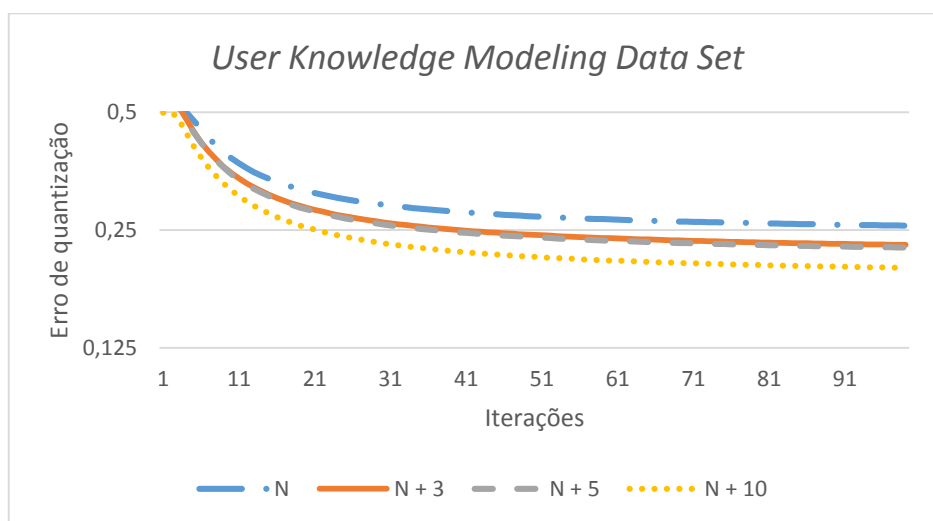


Figura 12. Decaimento do erro de quantização para definição do número de neurônios utilizando o banco de dados *User Knowledge Modeling*

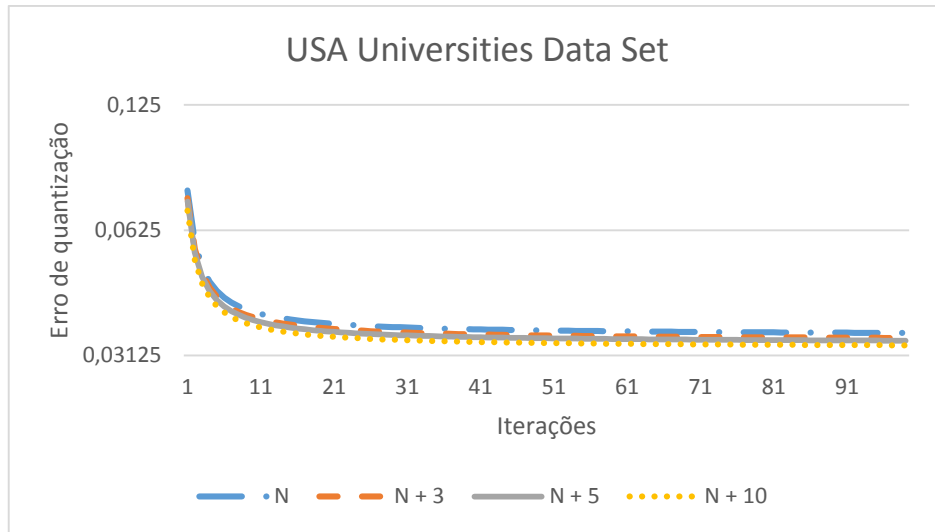


Figura 13. Decaimento do erro de quantização para definição do número de neurônios utilizando o banco de dados *USA Universities*

Como os erros entre a quantidade de neurônios $N + 3$ e $N + 5$ não sofreram tantas variações, e a quantidade $N + 10$ possui um alto custo computacional em relação às outras, optou-se por utilizar a quantidade de neurônios $N + 5$. Esta quantidade de neurônios obteve bons resultados tanto para bancos pequenos, quanto bancos de alta dimensionalidade, além da melhor visualização fornecida pelo mapa com esta configuração, em comparação a $N + 3$.

4.1.2 Definição do intervalo de pesos do usuário

Além do número de neurônios, é necessário analisar o intervalo onde os pesos do usuário estarão compreendidos e sua influência na qualidade do mapa gerado. Um total de três intervalos foi analisado: $[0, 3]$, $[0, 5]$ e $[0, 10]$. Para isso, considerou-se que um atributo, selecionado aleatoriamente, teria peso igual ao valor máximo de cada intervalo e todos os outros com pesos iguais a 1. Esta abordagem foi adotada devido ao fato que os erros aumentam significativamente quando apenas um valor possui peso máximo, ou seja, dentre os testes, esta configuração se mostrou o pior caso. A Tabela 3 apresenta o resultado de 30 execuções para cada um dos intervalos.

Percebe-se que existe uma variação tanto no erro topográfico quanto no erro de quantização ao inserir os pesos. Contudo, as variações são pequenas em relação a um mapa não ponderado com quantidade de neurônios $N + 5$. Para este trabalho, o intervalo aceito como melhor foi o intervalo $[0, 5]$, por não ser tão restrito quanto o

intervalo [0, 3] e não ter aumentado tanto o valor dos erros em relação ao intervalo [0, 10].

Tabela 3. Média de 30 execuções da rede para definição do intervalo de pesos do usuário

| Banco de dados | Erros | Não ponderado | [0, 3] | [0, 5] | [0, 10] |
|---|-------------|---------------|-----------|-----------|----------|
| <i>User Knowledge Modeling Data Set</i> | Quantização | 0,225494 | 0,234152 | 0,25374 | 0,287549 |
| | Topográfico | 0,073901 | 0,095865 | 0,090956 | 0,073385 |
| <i>USA Universities</i> | Quantização | 0,033941 | 0,034746 | 0,035654 | 0,038547 |
| | Topográfico | 0,064928 | 0,0787833 | 0,0724146 | 0,064347 |

4.2 Análise de variação do mapa

O objetivo destes experimentos é analisar a variação do mapa de acordo com variação dos pesos do usuário. Para isto, utilizou-se as duas bases de dados já mencionadas: *User Knowledge Modeling* e *USA Universities*. Para cada banco, criou-se dois vetores de pesos de usuário para analisar as variações, utilizando a forma não ponderada para comparação. Para cada uma das ponderações, espera-se que seja gerado um mapa inteiramente novo. Além da análise de variação dos mapas, é necessário realizar uma análise da distorção, representada pelos valores dos erros de quantização e topográfico. Espera-se que os erros de mapas ponderados mantenham-se próximos aos erros de um mapa não ponderado.

4.2.1 *User Knowledge Modeling Data Set*

Para este cenário, utilizou-se o banco de dados *User Knowledge Modeling Data Set* [32], que encontra-se disponível no repositório *UCI Machine Learning* [33]. O banco de dados é composto por dados de alunos, distribuídos em 5 parâmetros e um *label* com a classificação de conhecimento que ele possui, este podendo variar entre: *very low*, *low*, *middle* e *high*. A escolha deste banco deve-se ao fato de permitir uma análise de alunos e seu desempenho em uma dada disciplina, encaixando-se na proposta deste trabalho.

As características foram geradas a partir da análise de atividades e caminhos de navegação em uma ferramenta de aprendizado *web* proposta pelo autor. Para a classificação final, os dados coletados passam por processos de ajuste de pesos, por

algoritmos de computação evolucionária, por algoritmos de clusterização e, finalmente, por um processo de normalização dos valores entre 0 e 1.

Os cinco parâmetros existentes no banco podem ser divididos em duas partes: três parâmetros em relação ao assunto proposto no momento e dois em relação ao conhecimento necessário para compreensão do assunto (pré-requisitos). Para o assunto proposto, tem-se os seguintes atributos:

- STG – grau de tempo dedicado ao estudo;
- SCG – grau de repetições; e,
- PEG – desempenho nos testes.

Para os pré-requisitos:

- STR – grau de tempo dedicado ao estudo; e,
- LPR – nível de conhecimento para o pré-requisito.

Neste experimento, os dados passados a rede foram ponderados de três formas diferentes e um aluno foi escolhido como objeto de estudo. Para cada ponderação do mapa, a vizinhança ao redor deste aluno foi analisada. Inicialmente, tem-se o mapa sem qualquer ponderação, ou seja, todos os atributos possuem a mesma importância. O mapa sem ponderação é apresentado pela Figura 14, onde a vizinhança do aluno 218 está representada pelo quadrado em vermelho.

Para analisar a variação do mapa em relação a um mapa não ponderado, adotou-se duas variações dos pesos. Uma delas pondera o peso dos testes com relevância máxima (PEG), assim como o conhecimento acerca do pré-requisitos (LPR), e todos os outros parâmetros com valor igual a zero, ou seja, são completamente desconsiderados. Esta variação foi chamada de *Tests-Only*, ilustrada pelo mapa da Figura 15. A segunda variação pondera com peso máximo apenas o parâmetro referente ao tempo de estudo do aluno para o assunto atual (STG), pondera com valor 3 o tempo dedicado ao estudo dos pré-requisitos (STR) e todos os outros parâmetros possuem peso igual a 1. Esta segunda variação foi chamada de *Time-Only*. A Tabela 4 ilustra os dois vetores de peso utilizados. A Figura 16 ilustra o mapa para a ponderação *Time-Only*. As vizinhanças para cada um dos vetores apresentados podem ser encontradas no Apêndice B.

O comportamento esperado para este experimento é que a cada forma de ponderação, tenha-se um mapa de alunos diferente e, conseqüentemente, um indicador diferente que seria baseado nas preferências do usuário.

Tabela 4. Tabela de vetores de peso do usuário para análise da variação do mapa utilizando o banco de dados *User Knowledge Modeling*

| Nomenclatura | STG | SCG | STR | LPR | PEG |
|-------------------|-----|-----|-----|-----|-----|
| Não ponderado | 1 | 1 | 1 | 1 | 1 |
| <i>Time-Only</i> | 5 | 1 | 3 | 1 | 1 |
| <i>Tests-Only</i> | 0 | 0 | 0 | 5 | 5 |



Figura 14. Mapa não ponderado para o banco *User Knowledge Modeling*, com vizinhança ao redor do aluno 218

Percebe-se que o aluno com ID 218, na Figura 14, possui um nível de conhecimento alto (*high*) e está cercado por alunos com conhecimento de cada uma das classes existente no banco, no mapa não ponderado: baixo (*low*), muito baixo (*very low*), alto (*high*) e médio (*middle*).



Figura 15. Mapa ponderado com vetor *Tests-Only* para o banco *User Knowledge Modeling*, com vizinhança ao redor do aluno 218

Na segunda variação (*Tests-Only*), como era esperado, a topologia dos dados mudou completamente ao modificar o valor dos pesos, ponderando a nota dos testes com valor máximo, assim como o conhecimento acerca dos pré-requisitos. A separação entre os alunos ficou muito mais acentuada e houve uma mudança significativa na vizinhança do aluno 218, sendo composta agora exclusivamente por outros alunos com conhecimento alto. O aluno com ID 218 ativou o mesmo neurônio que o aluno com ID 254, sendo um comportamento esperado, visto que os dois

possuem a mesma classificação (*high*) o que indica uma provável semelhança entre os dois registros.



Figura 16. Mapa ponderado com vetor *Time-Only* para o banco *User Knowledge Modeling*, com vizinhança ao redor do aluno 218

Na variação *Time-Only*, novamente a topologia dos dados sofreu modificações, onde a nova distribuição apresenta diferenças em relação às duas variações anteriores. O aluno 218 ativou o mesmo neurônio que o aluno 245, onde esta ativação do mesmo neurônio significa uma grande proximidade conceitual entre os registros que o ativaram.

Nos três mapas, percebe-se também alguns espaços vazios, onde estes espaços vazios representam neurônios não ativados após o treinamento. Em outras palavras, os neurônios não são similares aos padrões de entrada apresentados, portanto não são ativados.

Além de avaliar se existe a variação, também é necessário analisar como as ponderações impactam nos erros do mapa. A Tabela 5 apresenta os erros médios para cada um dos vetores de peso, após 30 execuções.

Tabela 5. Erro médio para o banco de dados *User Knowledge Modeling* com diferentes ponderações

| Forma de ponderação | Erros | Valor |
|---------------------|-------------|-------------|
| Não ponderado | Quantização | 0,227242374 |
| | Topográfico | 0,075271317 |
| <i>Tests-Only</i> | Quantização | 0,221592709 |
| | Topográfico | 0,077519379 |
| <i>Time-Only</i> | Quantização | 0,233877265 |
| | Topográfico | 0,086899224 |

Considerando os diferentes mapas gerados pelos dois vetores de peso, comparando-os com um mapa não ponderado, pode-se afirmar que o experimento atingiu o seu objetivo e com erros com pouca diferença em relação aos de um mapa não ponderado.

4.2.2 USA Universities Data Set

De forma análoga ao experimento anterior, utilizou-se o banco *AAUP Faculty Salary Data* [34] (chamado ao longo deste trabalho de *USA Universities*) que consiste de uma lista de todas as universidades existentes nos Estados Unidos da América no ano de 1995. São 1161 registros com 15 atributos, um *label* (nome da universidade) e um ID federal. Dentre os atributos, dois são não numéricos: o estado ao qual a universidade pertence e o tipo da instituição. O tipo da instituição foi ignorado, assim como o ID federal, enquanto o estado foi convertido em um valor numérico. Dos 1161 registros, 115 possuem dados faltantes e não foram utilizados nos experimentos.

O banco consiste de informações sobre a quantidade de professores adjuntos, assistentes e associados e as respectivas médias de salários e compensações. A escolha deste banco deve-se ao fato de o salário do professor ser considerado como fator relevante para a qualidade da educação, além de ser parte do PNE (Plano

Nacional de Educação) [35], e permite uma análise a nível institucional. As siglas adotadas para os parâmetros são:

- ST – Estado onde a faculdade se encontra;
- ASP – Média de salário de professor adjunto;
- ASA – Média de salário de professor associado;
- AST – Média de salário de professor assistente;
- AAL – Média de salário de todos os cargos de professor;
- ACP – Média de compensação de professor adjunto;
- ACA – Média de compensação de professor associado;
- ACT – Média de compensação de professor assistente;
- ACL – Média de compensação de todos os cargos de professor;
- NP – Número de professores adjuntos;
- NA – Número de professores associados;
- NT – Número de professores assistentes;
- NI – Número de instrutores;
- NF – Total de professores e instrutores.

Novamente, dois vetores de pesos foram gerados para avaliar a variação em relação a um mapa não ponderado. A Tabela 6 ilustra os vetores (*Salary*, que atribui maior peso à média de salários dos professores adjuntos e associados; e *Professor-Number*, que atribui pesos maiores à quantidade de professores) para este banco de dados. Devido à grande quantidade de atributos que permaneceriam com peso igual a 1, a tabela apresenta apenas os atributos que tiveram seus pesos modificados, sendo um total de 4. Todos os outros atributos não apresentados possuem valor igual a 1.

Tabela 6. Tabela de vetores de peso do usuário para análise da variação do mapa utilizando o banco de dados *USA Universities*

| Nomenclatura | ASP | ASA | NP | NA |
|-------------------------|-----|-----|----|----|
| Não ponderado | 1 | 1 | 1 | 1 |
| <i>Salary</i> | 5 | 5 | 1 | 1 |
| <i>Professor-Number</i> | 1 | 1 | 5 | 3 |

A Figura 187 apresenta o mapa não ponderado com vizinhança ao redor da Seattle Pacific University (ID 1022). O vetor *Salary* está ilustrado pela Figura 178, enquanto o mapa para o vetor *Professor-Number* está apresentado na Figura 19. As vizinhanças referentes a estes vetores de peso encontram-se no Apêndice C, onde os atributos apresentados são apenas os que foram ponderados nas duas variações.

Alguns dados não constam nas figuras devido ao tamanho do mapa gerado e o tamanho da janela de apresentação do mapa, na interface do sistema, que não é capaz de apresentar mapas com mais de 17 colunas, sendo necessário o uso do *scroll* para visualização total. Uma vizinhança maior para cada mapa gerado também encontra-se no Apêndice C.




Figura 17. Mapa não ponderado para o banco *USA Universities*, com vizinhança ao redor da *Seattle Pacific University* (ID 1022)

Com o mapa não ponderado, tem-se a configuração inicial para o banco de dados. Inicialmente, a *Seattle Pacific University* (em azul) está rodeada por outras instituições similares, ou seja, instituições com proximidade semântica.




Figura 18. Mapa ponderado pelo vetor de pesos *Salary* para o banco *USA Universities*, com vizinhança ao redor da *Seattle Pacific University* (ID 1022)

Percebe-se, ao utilizar o vetor de pesos *Salary* que houve mudança na vizinhança, onde a *Seattle Pacific University* (em amarelo) agora está rodeada por outras universidades onde os salários dos professores são mais similares aos seus, em relação ao mapa não ponderado. Ou seja, a nova topologia do mapa está de acordo com a ponderação fornecida e de acordo com o esperado.

Ao utilizar o vetor *Professor-Number*, novamente tem-se a mudança na vizinhança da universidade de ID 1022 (em cinza escuro). Além disso, da mesma forma como ocorreu com o banco de dados *User Knowledge Modeling*, alguns neurônios não foram ativados por registros de entrada.

Como esperado, os três mapas gerados possuem configurações diferentes e os erros possuem pouca variação em relação ao mapa não ponderado, como demonstrado pela Tabela 7, portanto, pode-se afirmar que o experimento atingiu seus objetivos. Ressaltando que as ponderações podem ser diferentes e isso pode atender aspectos investigativos diversos do contexto e domínio desejado.




Figura 19. Mapa ponderado pelo vetor de pesos *Professor-Number* para o banco *USA Universities*, com vizinhança ao redor da *Seattle Pacific University* (ID 1022)

Tabela 7. Erro médio para o banco de dados *USA Universities* com diferentes ponderações

| Forma de ponderação | Erros | Valor |
|-------------------------|-------------|----------|
| Não ponderado | Quantização | 0,033941 |
| | Topográfico | 0,064928 |
| <i>Salary</i> | Quantização | 0,034548 |
| | Topográfico | 0,068756 |
| <i>Professor-Number</i> | Quantização | 0,032789 |
| | Topográfico | 0,061248 |

Capítulo 5

Considerações finais

Este capítulo descreve as considerações finais do trabalho, assim como apresenta a lista de trabalhos futuros a serem realizados.

5.1 Conclusões

O objetivo principal deste trabalho foi idealizar uma ferramenta para avaliação da qualidade em educação, baseada em semiótica computacional e redes neurais artificiais, permitindo que uma análise com individualização (ou seja, lidar de forma mais específica com determinados fatores) fosse possível. Em outras palavras, há a possibilidade de lidar com diversidade.

Os resultados preliminares obtidos nos experimentos demonstram que o mapa gerado possui confiabilidade, permitindo que as análises sejam feitas com segurança, visto que a distorção dos dados é muito pequena. Além de fornecer a opção de múltiplas perspectivas de análises, baseadas nos pesos do usuário em questão. É possível gerar, também, indicadores que fornecem uma ampla visão do contexto, não existindo apenas uma única informação generalizada como, por exemplo, a média de alunos de uma turma ou de uma instituição.

Outro fator de relevância observado é a incorporação de processos cognitivos, realizados pelo usuário durante a análise das informações. Esta característica permite que o esforço empregado na busca de informações seja direcionado para a informação específica que o usuário procura, tornando mais simples o processo de aquisição de conhecimento.

5.2 Trabalhos futuros

Com base nos resultados obtidos e no desempenho preliminar da ferramenta, pode-se listar algumas melhorias em alguns trabalhos futuros:

- Combinar o *self-organizing map* com técnicas de inteligência computacional de busca para melhorar o seu desempenho. Por exemplo, o banco de dados tiver uma alta dimensionalidade, o processo de treinamento tem um alto custo computacional, não sendo viável o tempo de espera para geração do indicador.
- Adaptar o sistema para que ele seja capaz de lidar com dados simbólicos, ou seja, dados não-numéricos.
- Aprimorar a identificação dos *clusters* gerados pelo mapa de Kohonen, fornecendo também informações estatísticas em relação a estes agrupamentos.
- Utilizar bases de dados abertas com dados escolares do Brasil e/ou construir uma base de dados especificamente projetada para análises de qualidade.
- Desenvolver um módulo extração de características para integração com a ferramenta proposta. Este módulo permitirá que a avaliação do contexto seja feita pelo próprio sistema, diminuindo a carga cognitiva (processo interpretativo) delegada ao usuário.
- Aplicar exaustivamente o sistema em uma instituição educacional para validação e realização de outros experimentos.

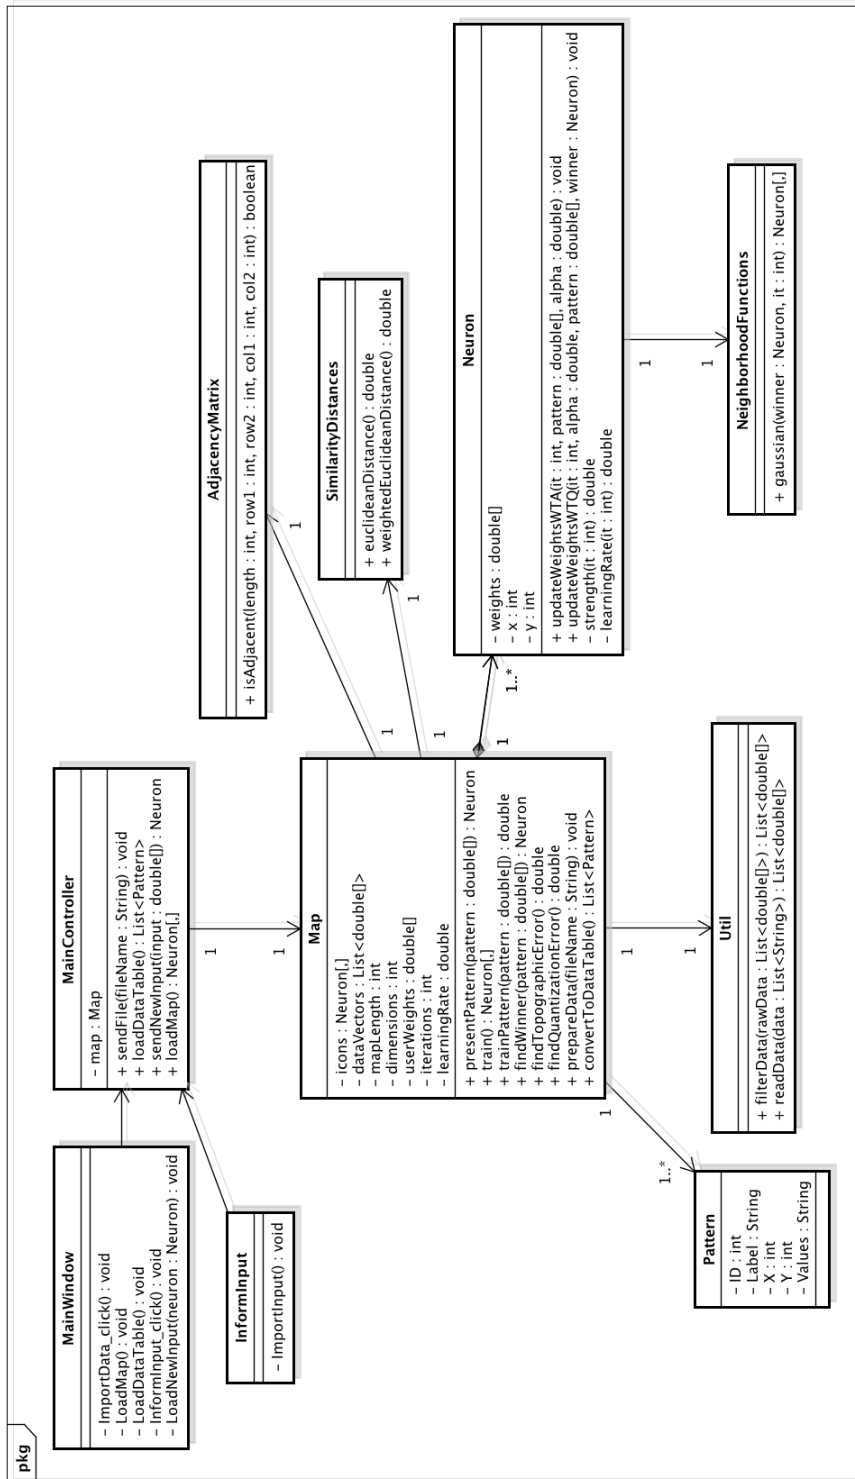
Bibliografia

- [1] UNICEF; PNUD; INEP-MEC. **Indicadores da qualidade na educação**. São Paulo: Ação Educativa, 2004.
- [2] EDUCAÇÃO de qualidade para todos: um assunto de direitos humanos. Brasília: UNESCO, OREALC, 2008.
- [3] DOURADO, L. F.; OLIVEIRA, J. F. A qualidade da educação: perspectivas e desafios. **Caderno Cedec**, V. 29, N.78, Campinas, 2009. 201-215.
- [4] DARLING-HAMMOND, L.; ASCHER, C. Creating accountability in big city school systems. **Urban Diversities Series**, New York, 1991.
- [5] DOURADO, L. F.; OLIVEIRA, J. F.; SANTOS, C. A. **A qualidade da educação: conceitos e definições**. INEP. Brasília. 2007.
- [6] NERI, M. **Equidade e eficiência na educação: motivações e metas**. FGV. Rio de Janeiro. 2007.
- [7] PEIRCE, C. S. **Semiótica**. 2. ed. São Paulo: Perspectiva, v. Coleção Estudos, 2012.
- [8] ECO, U. **Tratado geral de semiótica**. São Paulo: Perspectiva, v. Estudos, 2012.
- [9] SILVA, A. C. T. A perspectiva semiótica da educação. **Teoria E Prática Da Educação**, v. 11, p. 259-267, 2008.
- [10] SANTAELLA, L. **O que é semiótica**. São Paulo: Brasiliense.
- [11] PEIRCE, C. S. **Semiótica e filosofia**. São Paulo: Cultrix.
- [12] HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2a. ed. Porto Alegre: Bookman, 2001.
- [13] RITTER, H.; KOHONEN, T. Self-organizing semantic maps. **Biological Cybernetics**, v.61, 61, 1989. 241-254.
- [14] FERREIRA, F. R.; SILVEIRA, I. F.; MUSTARO, P. N. Uso de Redes de Kohonen na Recuperação Personalizada de Objetos de Aprendizagem: Um Estudo de Caso no Ensino de Ritmos Musicais Brasileiros. **Anais do XXVIII Congresso da SBC**, São Paulo, 2008. 352-361.
- [15] GUDWIN, R. **Semiônica : uma proposta de contribuição à semiótica computacional**. UNICAMP. Campinas. 2002.
- [16] KOHONEN, T. The self-organizing map. **Proceedings of the IEEE**, v. 78, n. 9, p. 1464–1479, Setembro 1990.
- [17] **Banco Mundial**. Disponível em: <<http://www.worldbank.org/pt/country/brazil>>. Acesso em: 09 abr. 2014.
- [18] SOUSA, C. P. **Avaliação do rendimento escolar**. São Paulo: Papirus, 1995.
- [19] MORRIS, C. **Fundamentos da teoria dos signos. Tradução de António Fidalgo**. [S.l.]: [s.n.].


- [20] CHANDLER, D. **Semotics: the basics**. 2nd. ed. [S.l.]: Routledge, 2007.
- [21] VALENÇA, M. S. **Fundamentos das redes neurais: exemplos em Java**. 2a. ed. Olinda: Livro Rápido, 2010.
- [22] LIN, X.; SOERGEL, D.; MARCHIONINI, G. A self-organizing semantic map for information retrieval. **Proceedings of the 14th annual international ACM SIGIR conference on Research and development in information retrieval**, Chicago, 1991. 262-269.
- [23] IEEE. **IEEE Standard Glossary of Software Engineering Terminology**. [S.l.]: [s.n.], 1990.
- [24] DEZA, M. M.; DEZA, E. **Encyclopedia of Distances**. [S.l.]: Springer, 2009.
- [25] PAUL, S.; GUPTA, M. Image segmentation by self organizing map with Mahalanobis distance. **International Journal of Emerging Technology and Advanced Engineering**, v. 3, p. 288-291, 2013.
- [26] KLANOVICZ, J. Fontes abertas: inteligência e o uso de imagens. **Revista Brasileira de Inteligência**, Brasília, v. 2, p. 63-75, 2006.
- [27] GUDWIN, R. R.; GOMIDE, F. A. C. **Sistemas Inteligentes Semióticos segundo a Semiótica Behaviorista de Charles Morris**. DCA/FEE/UNICAMP. Campinas. 1996.
- [28] SOARES, L. S. L. **Métrica para avaliação do valor semântico entre/em sistemas com acoplamento parcial**. Universidade de Pernambuco. Recife. 2013.
- [29] RODDICK, J. F.; HORNSBY, K.; VRIES, D. A unifying semantic distance model for determining the similarity of attribute values. **ACSC '03 Proceedings of the 26th Australasian computer science conference**, Darlinghurst, 2003. 111-118.
- [30] CROUCH, D. B. **The visual display of information in an information retrieval environment**. SIGIR '86. [S.l.]: [s.n.]. 1986. p. 58-67.
- [31] SANTAELLA, L.; NÖTH, W. **Imagem: cognição e semiótica**. São Paulo: Iluminuras, 1999.
- [32] PÖLZLBAUER, G. Survey and comparison of quality measures for self-organizing maps. **Proceedings of the Fifth Workshop on Data Analysis**, Vienna, 2004.
- [33] KAHRAMAN, H. T.; SAGIROGLU, S.; COLAK, I. Developing intuitive knowledge classifier and modeling of users' domain dependent data in web. **Knowledge Based Systems**, v. 37, p. 283-295, 2013.
- [34] **UCI Machine Learning**. Disponível em: <<http://archive.ics.uci.edu/ml/>>. Acesso em: 09 abr. 2014.
- [35] LOCK, R. Dataset: "AAUP Faculty Salary data". Disponível em: <http://www.amstat.org/publications/jse/jse_data_archive.htm>. Acesso em: 21 abr. 2014.
- [36] Plano Nacional da Educação: questões desafiadoras e embates emblemáticos. INEP. Brasília. 2013.

Apêndice A

Diagramas UML



powered by Astah



powered by Atalaia

Apêndice B

Vizinhanças para o banco *User*

Knowledge Modeling

Este apêndice apresenta as vizinhanças para cada um dos mapas gerados nos experimentos com o banco de dados *User Knowledge Modeling Data Set*. Os atributos apresentados são: STG – grau de tempo dedicado ao estudo do assunto em questão; SCG – grau de repetições; PEG – desempenho nos testes no assunto em questão; STR – grau de tempo dedicado ao estudo do pré-requisito; e LPR – nível de conhecimento acerca do pré-requisito.

| Vizinhança não ponderada | | | | | |
|---|-----|------|------|------|------|
| Classificação | ID | STG | SCG | STR | LPR |
| <i>High</i> | 218 | 0.60 | 0.31 | 0.31 | 0.87 |
| <i>Low</i> | 154 | 0.39 | 0.26 | 0.39 | 0.77 |
| <i>Very low</i> | 201 | 0.59 | 0.18 | 0.31 | 0.55 |
| <i>Low</i> | 217 | 0.52 | 0.29 | 0.32 | 0.50 |
| <i>Middle</i> | 222 | 0.77 | 0.26 | 0.59 | 0.78 |
| Vizinhança ponderada pelo vetor <i>Tests-Only</i> | | | | | |
| Classificação | ID | STG | SCG | STR | LPR |
| <i>High</i> | 218 | 0.60 | 0.31 | 0.31 | 0.87 |
| <i>High</i> | 190 | 0.49 | 0.90 | 0.52 | 0.90 |
| <i>High</i> | 226 | 0.77 | 0.29 | 0.74 | 0.82 |
| <i>High</i> | 230 | 0.72 | 0.60 | 0.45 | 0.79 |
| <i>High</i> | 234 | 0.83 | 0.44 | 0.49 | 0.91 |
| <i>High</i> | 254 | 0.61 | 0.78 | 0.69 | 0.92 |

| Vizinhança ponderada pelo vetor <i>Time-Only</i> | | | | | |
|--|-----|------|------|------|------|
| Classificação | ID | STG | SCG | STR | LPR |
| <i>High</i> | 218 | 0.60 | 0.31 | 0.31 | 0.87 |
| <i>High</i> | 182 | 0.45 | 0.65 | 0.19 | 0.99 |
| <i>Low</i> | 186 | 0.49 | 0.64 | 0.34 | 0.78 |
| <i>Middle</i> | 214 | 0.76 | 0.25 | 0.07 | 0.83 |
| <i>Low</i> | 217 | 0.52 | 0.28 | 0.32 | 0.5 |
| <i>Middle</i> | 245 | 0.62 | 0.62 | 0.24 | 0.65 |

Apêndice C

Vizinhanças para o banco *USA*

Universities

Este apêndice apresenta as vizinhanças para cada um dos mapas gerados nos experimentos com o banco *USA Universities* e os mapas. Os atributos apresentados são: ASP – média de salário de professor adjunto, ASA – média de salário de professor associado, NP – número de professores adjuntos e NA – número de professores associados. Os mapas estão apresentados na ordem: não ponderado, *Professor-Number* e *Salary*.

| Vizinhança não ponderada | | | | | |
|---|------|-----|-----|----|----|
| Nome | ID | ASP | ASA | NP | NA |
| <i>Seattle Pacific University</i> | 1022 | 457 | 388 | 50 | 48 |
| <i>Henderson State University</i> | 32 | 447 | 375 | 55 | 42 |
| <i>Biola University</i> | 45 | 455 | 369 | 57 | 31 |
| <i>Oklahoma Baptist University</i> | 745 | 379 | 335 | 22 | 33 |
| <i>Southern Oregon State Coll.</i> | 766 | 460 | 371 | 72 | 49 |
| <i>Lander University</i> | 868 | 453 | 381 | 34 | 31 |
| <i>Lynchburg College</i> | 982 | 465 | 392 | 49 | 36 |
| <i>Mary Washington College</i> | 996 | 475 | 397 | 59 | 43 |
| Vizinhança ponderada pelo vetor <i>Salary</i> | | | | | |
| Nome | ID | ASP | ASA | NP | NA |
| <i>Seattle Pacific University</i> | 1022 | 457 | 388 | 50 | 48 |
| <i>Texas A&M Univ. - Kingsville</i> | 940 | 467 | 393 | 72 | 51 |
| <i>Abilene Christian University</i> | 914 | 424 | 375 | 68 | 42 |

| Vizinhança ponderada pelo vetor <i>Salary</i> | | | | | |
|--|-----------|------------|------------|-----------|-----------|
| Nome | ID | ASP | ASA | NP | NA |
| <i>Francis Marion University</i> | 879 | 476 | 394 | 66 | 37 |
| <i>Belmont University</i> | 889 | 484 | 372 | 42 | 54 |
| <i>Southeastern Okla. St. Univ.</i> | 751 | 464 | 407 | 33 | 17 |
| <i>Columbus College</i> | 160 | 465 | 375 | 75 | 50 |
| <i>Fort Valley State College</i> | 162 | 471 | 382 | 37 | 39 |
| <i>Lewis University</i> | 225 | 467 | 392 | 37 | 20 |
| Vizinhança ponderada pelo vetor <i>Professor-Number</i> | | | | | |
| Nome | ID | ASP | ASA | NP | NA |
| <i>Seattle Pacific University</i> | 1022 | 457 | 388 | 50 | 48 |
| <i>Fort Valley State College</i> | 162 | 471 | 382 | 37 | 39 |
| <i>East Central University</i> | 741 | 453 | 407 | 39 | 31 |
| <i>Francis Marion University</i> | 879 | 476 | 394 | 67 | 37 |
| <i>Belmont University</i> | 889 | 484 | 372 | 42 | 54 |
| <i>Tarleton State University</i> | 938 | 446 | 399 | 42 | 48 |
| <i>Lynchburg College</i> | 982 | 465 | 392 | 49 | 36 |
| <i>Mary Washington College</i> | 996 | 475 | 397 | 59 | 43 |
| <i>Virginia State University</i> | 1002 | 453 | 416 | 55 | 49 |

| | | | | | | | | | | | | | | | | |
|-----------------|------------------|------------------|------------------|-----------------|-----------------|-------------------|-----------------|------------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|-----------------|
| | 269 Indiana | 1043 St. Norl | 903 Rhodes | 911 Univers | 145 Stetson | 1025 Univers | | 853 Provide | 775 Buckne | 850 Clarion | 820 Slippery | 1038 Marquet | 794 Indiana | 368 Northe | 442 Wayne | 909 Univ of |
| 944 Texas V | | 822 Phila Co | | 855 Rhode | 758 Lewis B | 913 Univ. of | 827 St. Jose | 394 Morgar | 86 Univers | 595 Kean C | 593 Montck | 821 West C | | 630 Cornell | 166 Georgia | 1028 Washin |
| 803 Marywc | 1005 Virginia | 994 Sweet E | 397 St.Mary | 1036 Lawren | 709 Willams | | 710 John Co | 838 Univers | 669 SUNY C | 939 Texas C | 84 Univ.of | 973 College | 686 Long Is | 857 Univers | 50 CalSt.Li | 130 Howarc |
| 773 Beaver | 1054 Univ. W | 1033 Beloit C | 959 Texas A | 837 Univ. of | 867 Furman | 301 Washbi | 963 Univ. of | 334 Loyola | 185 Drake L | 783 Duques | 614 Univers | 737 Wright | | 711 Kent St | 719 Ohio Un | 1045 Univ. W |
| 955 Texas A | 1039 Milwau | 780 Del. Val | 978 Hamprd | 944 Pembro | 731 Wittent | 2066 Indiana W | 619 Canisus | 1023 Seattle | 1020 Gonzag | 436 Northe | 725 Univers | | 726 Univers | 761 Oregon | | 1071 West V |
| 847 Alltwm.C | 778 Chatha | 843 Westmi | 988 Randolj | 646 Mercy C | 1015 Saint M | 962 Univ. of | 678 SUNY C | 465 St. Olaf | 466 Univ. W | | 109 Univ. of | 733 Youngs | 1017 Univers | 584 Univers | 767 Univers | 723 Univ. of |
| 925 Our Lac | 704 Mount | 980 Hollins | 1042 Ripon C | 856 Salve R | 964 Univ. of | 1046 Univ. W | 974 Christo | 1051 Univ. W | 677 SUNY C | 958 Univ. of | | 493 Univ.of | 140 Florida | 949 Univ. of | 986 Old Do | 924 Univers |
| 933 St. Edw | 866 Conver | 405 Bedlam | 578 Franklin | 609 Eastern | 805 Messial | 981 Longwv | 923 Midwes | 484 Northw | 673 SUNY C | 854 Rhode | 1057 Univ. W | 764 Portlan | 414 Univ.of | | | 550 Univ. of |
| 984 Mary B. | 709 Hiram C | 684 Wagne | 1072 West V. | 957 Univ. of | 574 Wayne | 961 Texas A | 455 Gustav | 937 Prairie | 389 Frostbu | 468 Winonz | 1053 Univ. W | 1029 Westen | 670 SUNY C | | | 900 Middle |
| 1047 Viterbo | 258 Franklin | 1012 Lyndon | 1034 Carthag | 880 August | 982 Lynchb | | 996 Mary W. | 752 Stwvtrr | 1052 Univ. W | 1048 Univ. W | 553 Westen | 1055 Univ. W | 569 Univ.of | 398 Towsor | 983 James I | 1074 Univers |
| 1010 Green I | 976 Emory | 1011 Johnso | 747 Univ. of | 892 David L | 868 Lander | 1022 Seattle | 766 Southe | 1002 Virginia | | 904 Tennes | 1003 Norfolk | 554 Univ. of | 951 Univ. of | 24 Univers | | 520 Appala |
| 755 Concor | 977 Ferrum | 1031 Whitwv | 865 Columb | 1037 Marian | 742 Langstc | 45 Biola U | 12 Hendoc | 938 Tarleton | | | 266 Indiana | 488 Southe | 740 Univers | | 473 Central | 893 East Te |
| 917 East Te. | 1060 Bluefiel | 902 WVlegar | 1067 Salem | 891 Christia | 707 Univers | 878 Univ. St | 914 Abilene | 988 Glinocf | 293 Empori | 173 West G | 316 Murray | 945 Texas V | 928 Sam Hc | | | |
| 906 Tusculu | 1062 Davis a | 1064 Glenvill | 1073 Wheeli | 1061 Concor | 1068 Shephe | 699 Cedarni | 1014 Norwic | | 876 Winthrt | 731 Nations | 864 College | | | | | 1049 Univ. W |
| 993 Saint Pi | 1027 Walla V | 1024 Saint M | 1004 Virginia | 1069 West Li | 1070 West V. | 513 Eastern | 1063 Fairmor | | 953 West Ti | 979 Hampt | 1018 Central | 935 Stephe | | 1019 Eastern | 559 Univ. of | 969 Weber |

| | | | | | | | | | | | | | | | | |
|-----------------|-----------------|-----------------|------------------|------------------|-----------------|------------------|-----------------|-----------------|-----------------|-------------------|------------------|-----------------|-----------------|-----------------|-------------------|------------------|
| 808 Muhler | 932 Southw | 1030 Whitma | 1000 Virginia | 994 Sweet E | 959 Texas A | 1005 Virginia | 955 Texas A | 780 Del. Val | 957 Univ. of | 1072 West V | 1012 Lyndon | 1035 Concor | 1066 Univers | 1024 Saint M | 1016 Trinity t | 999 Virginia |
| 774 Bryn M. | | | 785 Elizabet | 1036 Lawren | 822 Phila.Co | 1054 Univ. W | 159 Berry C | 989 Randol | 980 Hollins | 866 Conver | 457 Westm | 1047 Viterbo | 865 Columb | 1067 Salem | 1062 Davis a | 1027 Walla V |
| 97 Colorac | 781 Dickins | 980 SUNY C | 855 Rhode | 1043 St. Norl | 962 Univ. of | 467 Univ. M | 806 Moravi | 978 Hampd | 1042 Ripon C | 709 Hiram C | 804 Mercyh | 984 Mary B. | 976 Emory i | 898 Maryvil | 1073 Wheelin | 1064 Glennvil |
| 1013 Middlet | 846 York C | 664 St. Law | 177 Univ. of | | 771 Alleghe | 1015 Saint M | 985 Marym | 991 Roanok | 843 Westm | 562 Chadro | 992 Shenan | 931 St. Edw | 1037 Maran | 977 Ferrum | 537 Johnsor | 1060 Bluefiel |
| 1006 Washin | 681 Union C | 827 St. Jose | 913 Univ. of | 441 Univ.of | 1056 Univ. W | 731 Witten | 617 Alfred I | 1039 Milwau | 947 Univers | 885 South E | 880 August | 1034 Carthaj | 746 Okla. C | 891 Christia | 1061 Concor | 1069 West Li |
| 852 Bryant t | 853 Provide | 1025 Univers | 798 La Salle | 963 Univ. of | 769 Willams | 697 Capital | 586 Plymou | 759 Linfield | 981 Longwv | 964 Univ. of | 609 Eastern | 874 Univ. St | 451 College | 742 Langst | 1068 Shephe | 205 Lewis C |
| 995 Univers | 956 Univ. of | | 838 Univers | 145 Stetson | 758 Lewis B | 867 Furman | 717 Ohio N | 1046 Univ. W | 923 Michwes | 961 Texas A | 162 Fort Va | 982 Lynchb | 889 Belman | 875 Coastal | 699 Cedarvi | 920 Housto |
| 813 East Str | 492 Univ.of | 775 Buckne | 127 Gallaud | 93 Cal.St.U | 440 Univ.of | 1023 Seattle | 678 SUNY C | | 915 Angelo | 455 Gustav | 996 Mary W | 1022 Seattle | 741 East Ce | | 968 Southe | 1070 West V |
| 600 Seton F | 850 Clarion | 552 Wake F | 86 Univers | 716 Oberlin | 674 SUNY C | 23 Univ. Al | 675 SUNY C | 1051 Univ. W | 389 Frostbu | 937 Prairie l | 1002 Virginia | 879 Francis | 938 Tarleton | 760 Westen | 1014 Norwic | 1063 Fairmo |
| 819 Shipper | 883 Defenbbl | 420 Slipps | 4 Univ.Al | 939 Texas C | 783 Duques | 564 Creight | 677 SUNY C | 958 Univ. of | | 1021 Pacific I | 447 Bernidji | | | | 953 West Tr | 342 Xavier t |
| 654 Renssel | 840 Villamon | | 593 Montcl | 372 Univ. of | 490 Saint Lc | 640 Ithaca C | | 1057 Univ. W | 676 SUNY C | 468 Winone | 1052 Univ. W | 173 West G | | 876 Winthrc | 743 Northes | 872 South C |
| 927 Rice Un | | 830 Southe | 1038 Marque | 973 College | | 737 Wright | | | 1055 Univ. W | 459 Moorhe | 1048 Univ. W | 1003 Norfolk | 266 Indiana | | | 979 Hampt |
| 851 Brown I | | 360 Univ. of | 686 Long Is | | | | 733 Youngs | 764 Portlan | 1029 Westen | 905 Tennes | 928 Sam Hc | 554 Univ. of | 945 Texas V | 926 Univ. of | 864 College | 801 Jackaed |
| 912 Vander | 630 Cornell | 998 George | | 423 Central | 954 Baylor I | | 1017 Univers | | 398 Towson | 509 Univers | 951 Univ. of | 35 Univ. A | 740 Univers | | | 887 Univers |
| 1007 Univers | 442 Wayne | | 857 Univers | 719 Ohio U | 711 Kent St | 761 Oregon | | 551 Univ. of | | | 1049 Univ. W | 24 Univers | | | | 886 South E |
| 873 | 573 | 866 | | 1045 | | 767 | 866 | 615 | 510 | | | 893 | | | | 815 |

| | | | | | | | | | | | | | | | | |
|--------------|---------------|---------------|--------------|---------------|--------------|--------------|--------------|--------------|--------------|--------------|---------------|---------------|--------------|--------------|----------------|---------------|
| 932 Southw | | 785 Elizabeth | 688 SUNY C | 839 Ursinus | 374 Stoneh | 806 Moravi | 989 Randolj | 778 Chatha | 836 Univ. of | 866 Conwen | 941 Texas L | 1047 Viterbo | 977 Ferrum | 975 Eastern | 1016 Trinity I | 1027 Walla V |
| 589 Drew U | 808 Muhlen | 824 Robert | | 1043 St. Norl | 1015 Saint M | 829 Susque | 991 Roanok | 1042 Ripon C | 880 Hollins | 925 Our Lat | 970 Westmi | 984 Mary B | 1066 Univer | 930 Wilmin | 1024 Saint M | 1004 Virginia |
| 774 Bryn M | 781 Dickins | 644 Marist I | 855 Rhode | 903 Rhodes | 1036 Lawren | 959 Texas A | 420 Alma C | 978 Hampd | 843 Westmi | 431 Madon | 1034 Cartha | 936 Sul Ros | 1037 Marian | 1067 Salem | 1073 Wheelin | 1064 Glenvill |
| 618 Bard Cc | 846 York Cc | | | 769 Willam | 771 Alleghe | 837 Univ. of | 544 Pembrc | 985 Marym | 856 Salve R | 885 South E | 880 August | 804 Mercurh | 1035 Concor | 891 Christia | 1061 Concor | 1069 West Li |
| 607 Ramap | 1013 Middlel | 1025 Univer | 934 St. Mar | 768 Lewis B | 255 DePauw | 697 Capital | 586 Plymou | 803 Marywc | 844 Wilkes I | 964 Univ. of | 982 Lynchb | 874 Univ. St | 451 College | 540 Merred | 907 Union I | 1068 Shepht |
| 1006 Washin | 946 Trinity I | | 643 Manhat | 963 Univ. of | 619 Canisiu | 1056 Univ. W | 717 Ohio N | 1046 Univ. W | 981 Longwv | 996 Mary W | 162 Fort Va | 889 Belmor | 225 Lewis U | 610 New M | 920 Housto | 1070 West V |
| 852 Bryant I | 956 Univ. of | | 716 Oberfln | 838 Univer | 710 John Cc | 732 Xavier I | 285 Valpara | 532 Fayette | 923 Midwes | 373 Springf | 879 Franca | 1022 Seattl | 751 Southe | 1014 Norwic | 968 Southe | 878 Univ. St |
| | 591 Jersey C | 775 Buckne | 754 Univer | 669 SUNY C | 674 SUNY C | 1023 Seattl | 1020 Gonzag | 1051 Univ. W | 447 Bermidj | 25 Auburn | 940 Texas A | 160 Colum | 914 Abilene | 760 Westen | | 1063 Fairm |
| 819 Shipper | 818 Millersv | 850 Clarion | | 939 Texas C | 783 Duques | 494 Univ. of | 606 Fairleig | 676 SUNY C | 542 North C | 1052 Univ. W | 937 Prairie V | 1002 Virginia | 938 Tarletor | | 558 Minot S | 342 Xavier I |
| | 653 Pace U | 820 Slipper | 593 Montcl | 49 Cal.St.L | 490 Saint Lc | 564 Creight | | 958 Univ. of | 452 Univer | 908 Univ. of | 918 East Te | | 484 Northw | | 876 Winthr | 953 West Tr |
| 927 Rice Ur | 930 Southe | 667 SUNY a | 1038 Marquet | 973 College | 80 Univ. of | 725 Univer | 132 Univ. of | | 1057 Univ. W | 1053 Univ. W | 1048 Univ. W | 1003 Norfolk | 904 Tennes | 12 Jacksor | 292 Pittsbur | 479 Hampsh |
| 851 Brown I | 682 Univer | | 686 Long Is | | | 737 Wright | 733 Youngs | 764 Portlan | 1029 Westen | 1055 Univ. W | 554 Univ. of | 1019 Eastern | 324 Northw | 172 Valdost | 864 College | 503 Jacksor |
| 912 Vander | 998 George | 794 Indiana | | | 954 Baylor I | 1017 Univer | 140 Florida | | 414 Univ. of | 569 Univ. of | | 928 Sam Hc | 488 Southe | 945 Texas V | 483 Northw | 921 Lamar I |
| 1007 Univer | 668 SUNY a | 630 Cornell | 857 Univer | 719 Ohio U | 701 Oregon | | 949 Univ. of | 551 Univ. of | 458 Mankat | 509 Univer | 1049 Univ. W | | 740 Univer | | | 1018 Central |
| 831 Temple | 199 Univer | 948 Univer | 58 San Jos | 443 Westen | | 767 Univer | 986 Old Do | | | 983 James I | 302 Wichita | 24 Univer | | | 987 Radforn | 1065 Marsha |
| 1044 | 999 | 873 | 1071 | 1045 | 943 | 934 | 605 | 615 | 1076 | | | 893 | 969 | | | |