

**UNIVERSIDADE FEDERAL DOS VALES JEQUITINHONHA E MUCURI
SISTEMAS DE INFORMAÇÃO**

DIEGO GUILHERME RIBEIRO ALMEIDA

**ALGORITMO PARA DETECÇÃO AUTOMÁTICA DE ESTILOS DE
APRENDIZAGEM**

Diamantina, MG

2016

DIEGO GUILHERME RIBEIRO ALMEIDA

**ALGORITMO PARA DETECÇÃO AUTOMÁTICA DE ESTILOS DE
APRENDIZAGEM**

Monografia apresentada ao curso de Sistemas de Informação da Universidade Federal dos Vales Jequitinhonha e Mucuri – UFVJM, como pré-requisito para obtenção do grau de (bacharel ou licenciatura), sob orientação da Professora Doutora Luciana Assis.

Diamantina, MG

2016

DIEGO GUILHERME RIBEIRO ALMEIDA

**ALGORITMO PARA DETECÇÃO AUTOMÁTICA DE ESTILOS DE
APRENDIZAGEM**

Monografia apresentada ao curso de Sistemas de Informação da Universidade Federal dos Vales Jequitinhonha e Mucuri – UFVJM, com pré-requisito para obtenção do grau de bacharel.

COMISSÃO EXAMINADORA

Prof^a Dr. Luciana Pereira de Assis

Prof. Dr. Alessandro Vivas Andrade

Prof. Luiz Filipe Carreiro Salazar

Aprovado em: ___/___/___

À minha avó, Dona Diva (*in memoriam*).

AGRADECIMENTOS

Primeiramente a Deus, já que vir para Diamantina, foram graças a uma sucessão de acontecimentos que alguns chamam de coincidência, mas eu prefiro acreditar que foi Deus.

À minha família, pois sem o sacrifício e apoio de todos isso não teria acontecido, em especial a minha mãe, Rose, meu pai, Wander e meus irmãos, Matheus e Manu que me ajudaram nessa caminhada.

Aos meus amigos da Igreja Batista Central que me suportaram e aguentaram durante todos esses anos.

Aos Brothers da Farrapos que ajudaram nas risadas e nos momentos difíceis.

Ao Colégio Diamantinense, que me acolheu nos últimos anos e trouxeram experiências que eu levarei pra vida inteira.

Aos professores da UFVJM, que alguns eu guardarei um espaço muito especial nas memórias desses anos, em especial a professora orientadora desse projeto, Luciana, que se dispôs mesmo em seu tempo livre pra me aturar e ajudar.

E por último, mas não menos importante, aos amigos mais chegados que irmãos que me ajudaram nessa caminhada: João Victor, Alvaro (Kalango), Thais (binaga), Camila (Morena), Marcos (Molejo), Junior (Animal), Diego (Tião), Amanda, Bethania, Renato (Véi), Ricardo (Elsa) e Camila (Camiloviska).

Valeu Galera!

“O mundo não é um grande arco íris; é um lugar sujo, é um lugar cruel, que não quer saber o quanto você é durão. Vai botar você de joelhos e você vai ficar de joelhos para sempre se você deixar. Você, eu, ninguém vai bater tão duro como a vida, mas não se trata de bater duro. Se trata de quanto você aguenta apanhar e seguir em frente, o quanto você é capaz de aguentar e continuar tentando. É assim que se consegue vencer.”

Rocky Balboa

RESUMO

Um Ambiente Virtual de Aprendizagem é composto por vários tipos de modelos, como o Modelo Pedagógico que contém dois módulos, Estratégia de Ensino e Conteúdo. O Modelo Especialista trabalha com Hipermedia Adaptativa, Apresentação Adaptativa e Suporte de Navegação Adaptativa. O Modelo de Interface é a forma como o Aluno irá interagir com o sistema como um todo. Já o Modelo do Aluno, trata de conhecimento prévio e Estilos de aprendizagem que é onde esse trabalho irá aprofundar.

Os estilos de aprendizagem referem-se a de que forma o aluno tem mais facilidade em aprender e processar informação, podendo variar de um a vários modos diferentes. Cada pessoa possui uma Combinação de Estilos de Aprendizagem que melhor representa o conjunto de áreas onde ela tem mais chances de aprender algo.

A proposta desse trabalho foi uma nova forma de selecionar Combinação de Estilos de Aprendizagem. No algoritmo proposto a seleção de Combinação de Estilos de Aprendizagem é dada pelo histórico das notas obtidas pelos alunos e armazenadas no módulo do estudante. Os resultados obtidos foram comparados com métodos da literatura. Além disso, comparou-se com método de seleção sequencial e aleatório para averiguar a efetividade dos métodos. Os resultados obtidos foram satisfatórios.

ABSTRACT

A Virtual Learning Environment is composed of various types of models, such as the Educational Model that contains two modules, teaching and Content Strategy. The Model Specialist works with Adaptive Hypermedia, adaptive presentation and adaptive navigation support. The interface model is how the student will interact with the system as a whole. But the model student, comes to Prior Knowledge and Learning Styles which is where this work will deepen.

Learning styles refer to so that students can more easily learn and process information, ranging from one to several different modes. Each person has a Learning Styles combination that best represents the number of areas where it is more likely to learn something.

The purpose of this work was a new way to select Learning Styles Combination. In the proposed algorithm the selection of Learning Styles combination is given by the history of the marks obtained by students and stored in the student module. Using literature methods and without the use of sequential or random selection. The results obtained were compared to literature methods. Furthermore, if compared with sequential and random selection method to determine the effectiveness of the methods. The results were satisfactory.

LISTA DE ILUSTRAÇÕES

FIGURA 01 – Arquitetura Clássica de um STI	19
FIGURA 02 – Esquema do Modelo de Estilos de Aprendizagem de Kolb.....	26
FIGURA 03 – Sistema de Tutoria Inteligente Adaptativa.....	30
FIGURA 04 – Atualização do ME durante o processo de Aprendizagem.....	38

LISTA DE TABELAS

TABELA 01 – Dimensões do aprendizado e estilos de ensino	28
TABELA 02 – Relação de experimentos e CEAs com intensidade que os representam.....	52
TABELA 03 – Comparação dos resultados obtidos nos Experimentos referentes ao número de iterações.....	54
TABELA 04 – Relação de médias perdidas, abaixo de 60 pontos, ao final da execução do algoritmo	56
TABELA 05 – Médias de notas com Desvio Padrão	59

LISTA DE ALGORITMOS

ALGORITMO 3.1 – Q-Learning aplicado à modelagem automática e dinâmica de EA.....	40
ALGORITMO 3.2 – Q-Learning	42
ALGORITMO 4.1 – Algoritmo Almeida.....	48

LISTA DE GRÁFICOS

GRÁFICO 1 – Número de passos realizados pela abordagem para a Aprendizagem do aluno por experimento.....	55
GRÁFICO 2 – Relação de Notas Perdidas	57
GRÁFICO 3 – Média de notas.....	59

LISTA DE ABREVIATURAS E SIGLAS

A	Ativo
AR	Aprendizado por Reforço
CA	Conceituação Abstrata
CAI	Instrução Assistida por Computador
CEA	Combinação dos Estilos de Aprendizagem
CPT	Tabelas de Probabilidades condicionais
DAEA	Detecção Automática dos Estilos de Aprendizagem
DAG	Grafo Dirigido sem Ciclos
EA	Estilos de Aprendizagem
EA	Experimentação Ativa
EAD	Educação a Distância
EC	Experiência Concreta
FSLSM	Modelo de Felder e Silverman
G	Global
I	Intuitivo
IA	Inteligência Artificial
ICAI	Instruções Assistidas por Computador Inteligente
IDE	Plataforma de Desenvolvimento
MCOE	Multi-Agent Co-Operative Environment
ME	Modelo do Estudante
OR	Observação Reflexiva
R	Reflexivo
S	Sequencial
SAVER	Software de Assistencia Virtual para Educacion Remota
Seq	Sequencial
STI	Sistemas Tutores Inteligentes
Ve	Verbal
Vi	Visual

SUMÁRIO

CAPÍTULO 1 INTRODUÇÃO	14
1.1 EDUCAÇÃO A DISTÂNCIA E TUTORES INTELIGENTES	14
1.2 OBJETIVOS GERAIS.....	16
1.3 OBJETIVOS ESPECIFICOS	16
CAPÍTULO 2 REFERENCIAL TEÓRICO	17
2.1 SISTEMAS TUTORES INTELIGENTES (STI)	17
2.1.1 ARQUITETURA DOS STI's.....	19
2.1.2 EXEMPLOS DE SISTEMAS TUTORES INTELIGENTES.....	20
2.1.2.1 MULTI-AGENT CO-OPERATIVE ENVIRONMENT (MCOE).....	20
2.1.2.2 DÓRIS.....	21
2.2 ESTILOS DE APRENDIZAGEM.....	23
2.2.1 MODELO DE KOLB	24
2.2.2 MODELO DE FELDER-SILVERMAN.....	27
2.3 DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZAGEM	30
2.3.1 MODELO DO ESTUDANTE.....	31
2.3.2 FORMAS DE DETECTAÇÃO AUTOMÁTICA DOS ESTILOS DE APRENDIZAGEM.....	31
2.3.2.1 PROCESSOS ESTOCÁSTICO E CADEIAS DE MARKOV.....	32
2.3.2.2 REDES BAYESIANAS	33
2.3.2.3 APRENDIZAGEM POR REFORÇO.....	34
CAPÍTULO 3 SISTEMA DE DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZADO	36
3.1 ABORDAGEM PROPOSTA POR DORÇA (2012)	36
3.1 Q-LEARNING	40
3.2 APRENDIZADO POR REFORÇO.....	42

3.3 CADEIA DE MARKOV	44
CAPÍTULO 4 METODOLOGIA	46
4.1 FERRAMENTAS	46
4.1.1 LINGUAGEM DE PROGRAMAÇÃO JAVA	46
4.1.2 ECLIPSE IDE	47
4.2 SELEÇÃO DE CEA POR MEIO DE CLASSIFICAÇÃO DAS NOTAS	47
CAPÍTULO 5 RESULTADOS COMPUTACIONAIS	50
5.1 MÉTODOS DE EXPERIMENTAÇÃO	50
5.2 TESTE	52
5.3 ANÁLISE DE RESULTADOS	59
CAPÍTULO 6 CONCLUSÃO	61
REFERENCIAS BIBLIOGRÁFICAS:	63

CAPÍTULO 1

INTRODUÇÃO

Como introdução do trabalho serão apresentados os conceitos básicos de WEB 2.0, tutores inteligentes e Estilos de Aprendizagem. Na WEB 2.0 serão citados algumas aplicações da ferramenta e a sua influência nos sistemas de Tutores Inteligentes, além de um exemplo que serviu como base para Felder e Silverman desenvolverem seu modelo de dezesseis Combinações de Estilos de Aprendizagem (CEA).

1.1 EDUCAÇÃO A DISTÂNCIA E TUTORES INTELIGENTES

Antes utilizada apenas como uma espécie de “estepe” de ensino, a educação a distância servia para suprir as necessidades que a educação presencial não atingia ou falhava em cumprir. A visão de educação a distância (EaD) era uma visão preconceituosa e distorcida em termos de aprendizagem já que esse modelo era visto como uma subdivisão do ensino e portanto sua formação não possuía as mesmas credenciais (AZEVEDO, 2003).

No Brasil, há um trabalho de EaD muito bem desenvolvido ao longo dos anos como apresentado por (PRETI, 1996). Mesmo com resultados quantitativos a principio positivos, há uma série de problemas relacionados a EaD, como a transição de governos e abandono de alguns programas, desatualização dos materiais didáticos, falta de um acompanhamento mais atencioso aos alunos, falta de um sistema avaliativo eficiente e à não consideração das diferenças regionais, já que a implementação da EaD geralmente são impostas de cima pra baixo em termos de hierarquia educacional;

Para tal, este “novo educador” deverá conhecer as características, necessidades e demandas do alunado, formar-se nas técnicas específicas do modelo a distância, desenvolver atitudes orientadoras e de respeito à personalidade dos estudantes e dar-se conta de que sua função é formar alunos adultos para uma realidade cultural e técnica em constante transformação. E isso só será possível se toda a equipe envolvida no

processo de EAD reconhecer suas limitações, estiver aberta ao diálogo e disposta a construir caminhos, reconhecendo falhas e desvios. O trabalho cooperativo, portanto, será a base da construção deste novo educador e da consolidação dos trabalhos e experiências em EAD (PRETI, 1996).

Segundo (JUNIOR; COUTINHO, 2008), graças a uma variada gama de ambientes virtuais de ensino e aprendizagem com características que diferem em quantidade e tipos de recursos e funcionalidades. Com a tecnologia avançando, estes ambientes virtuais tornam-se cada vez mais ricos e funcionais.

Neder (2000) discute a tutoria como uma orientação acadêmica e ressalta que durante o processo de acompanhamento o tutor precisa estimular e motivar o aluno, além de contribuir para o desenvolvimento da capacidade de organização das atividades acadêmicas e de autoaprendizagem.

Assim, é importante mencionar o surgimento do Sistema Tutor Inteligente (STI's), como um software que dá suporte às atividades de aprendizagem ou ainda programas com propósitos educacionais e que utilizam técnicas de Inteligência Artificial. De uma geral, os STI's se caracterizam por representar separadamente a matéria que se leciona e as formas para ensiná-la. Como possui o objetivo de ser transmitir o ensino de forma personalizada, o aluno é caracterizado como um modelo. Uma característica necessária a esses sistemas, é a necessidade da interface de comunicação ser um módulo bem planejado, de fácil utilização, que favoreça o processo de comunicação tutor-aluno (JUAN et al., 2003).

Os ambientes de Educação à Distância (EAD) oferecem aos alunos um papel ativo na sua própria educação ao fazer o processo de aprendizagem livre de restrições de espaço tempo. Em vez de apenas assistir às aulas, os alunos podem construir ativamente seu próprio conhecimento, desfrutar de uma autonomia considerável e optar por trabalhar de forma colaborativa. A evolução da EAD tem proporcionado uma gradativa substituição dos materiais impressos, distribuídos por correios, aulas exibidas em canais de TV e materiais de áudio e vídeo disponibilizado por *sites* desenvolvidos para a Internet com esse fim (SILVA; DORÇA, 2014).

Um exemplo de modelagem que apresentou resultados satisfatórios foi uma pesquisa na área de ensino de engenharia, Felder e Silverman elaboraram uma proposta para modelagem das características dos Estilos de Aprendizagem (EA) de estudantes por meio de quatro dimensões, com duas possíveis preferências em cada uma. Ainda neste mesmo trabalho foi dito que a aprendizagem se torna mais fácil para

o aluno se as estratégias pedagógicas estiverem segundo os EA do estudante, e confirmam que usar material e atividades instrucionais que vão de acordo com a EA torna o processo de aprendizagem mais efetivo, além de melhorar consideravelmente a performance do aluno (FELDER; SILVERMAN, 1988).

Como mencionado por (PINTO, 2013), na aprendizagem autónoma pode correr-se o risco de os resultados dos alunos não serem os melhores, já que o aluno, é deixado um pouco sozinho, e caso não tenha um apoio, não há garantias de que seu ensino será de qualidade. Uma forma de amenizar esse impacto e facilitar o aprendizado do aluno é conseguindo definir qual o seu melhor tipo de CEA, que irá melhorar sua capacidade de absorção de conteúdo.

A proposta desse trabalho é desenvolver um método que dado um ambiente simulado de um aluno, retorne através das melhores notas de Combinação de Estilos de Aprendizagem (CEA) qual é o melhor EA que se adequa a esse aluno. Para isso foi desenvolvido um algoritmo novo, chamado *Seleção de CEA por meio de classificação das notas*, que será tratado na seção 4.2 do Capítulo 4.

1.2 OBJETIVOS GERAIS

- Propor um algoritmo para detecção de estilo de aprendizagem baseado na nota do aluno para fazer a seleção da melhor Combinação de Estilos de Aprendizagem.

1.3 OBJETIVOS ESPECIFICOS

- Estudar sistema proposto por (Dorça, 2012) que simula um Sistema Tutores Inteligente para detecção automática de estilo de aprendizagem;
- Modificar o sistema com novos algoritmos para seleção de combinação de estilos de aprendizagem que conduz a forma como um conteúdo será apresentado ao aluno;
- Avaliar os resultados obtidos com resultados da literatura.
- Implementação dos algoritmos de seleção sequencial e aleatória de Combinação de Estilos de Aprendizagem para efeitos de comparação com o algoritmo proposto.

CAPÍTULO 2

REFERENCIAL TEÓRICO

Este capítulo apresenta quais foram as referências que serviram de base para a proposta apresentada nesse trabalho. Começando pelo Sistemas Tutores Inteligentes (STI) desde o seu histórico, apresentação, o que são, arquitetura e alguns exemplos já implementados.

Passando por Estilos de Aprendizagem (EA) de alguns dos seus teóricos e a apresentação de dois modelos, o de Kolb e o que foi utilizado nesse trabalho, o modelo de Felder-Silverman. Próximo aos EA, está a Detecção automática dos mesmos, e suas características principais do Modelo de Estudante e de tipos diferentes de se detectar a aprendizagem de forma automatizada.

2.1 SISTEMAS TUTORES INTELIGENTES (STI)

Os Sistemas de Instrução Assistida por Computador (CAI) foram o passo inicial na história dos STI. Na década de 50, apareceram os primeiros sistemas de ensino assistidos por computador, chamados **programas lineares**. Esses programas caracterizavam-se por mostrar o conhecimento de forma linear, isto é, nenhum fator podia mudar a ordem de ensino estabelecida na sua criação pelo próprio programador. No desenvolvimento de uma sessão de ensino, não se levava em consideração, para nenhum fim, o erro do aluno. Acreditava-se que quando uma operação era seguida por um estímulo de reforço, a força da ação era aumentada. Nesta abordagem, os CAI, apenas apresentavam o conteúdo, não motivando o aprendizado evolutivo do aluno, ele apenas seguia uma sequência finita e pré-determinada de ações sem estimular seu raciocínio (JUAN et al., 2003).

Os sucessores dos programas lineares no campo do ensino assistido por computador, foram os programas ramificados ou “programação ramificada” ou ainda programação em árvore que era mais adequada por ter feedback, sendo adaptada ao ensino para dar as respostas aos alunos. Estes tinham um número fixo de temas,

semelhantes aos programas lineares, mas diferenciavam-se pela capacidade de atuar segundo a resposta do aluno (JUAN et al., 2003).

Ao final dos anos 60 e princípio dos anos 70, surgiram os sistemas adaptativos. Esses sistemas foram associados a uma nova filosofia educacional que defende que os alunos aprendem melhor enfrentando-se a problemas de dificuldade adequada, do que atendendo a explicações sistemáticas, isto é, adaptar o ensino às suas necessidades. Os sistemas gerativos são capazes de gerar um problema de acordo com o nível de conhecimento do aluno, construir sua solução e diagnosticar a resposta do aluno. Em geral, a solução para um problema concreto não é única, no entanto, os sistemas gerativos criam só uma solução que era a base de seu diagnóstico (KAELBLING; LITTMAN; MOORE, 1996).

Apesar destes sistemas terem evoluído em termos de recursos gráficos, os sistemas CAI ainda possuem a mesma síntese preestabelecida pelo professor e não adaptável a cada tipo de aluno que o estiver utilizando. Nenhum destes sistemas tem conhecimento, como o ser humano, do domínio que eles estão ensinando, nenhum pode responder questões sérias dos alunos como, o “porque” e o “como” as tarefas são realizadas (KAELBLING; LITTMAN; MOORE, 1996).

Os Sistemas Tutores Inteligentes (STI), nascem como iniciativa no intento de tratar as falhas dos sistemas gerativos e podem ser vistos como CAI inteligente dos anos 80. Esta iniciativa foi beneficiada pelo trabalho dos pesquisadores de Inteligência Artificial (IA) que tinham uma permanente preocupação com o problema da melhor forma de como representar conhecimento dentro de um sistema inteligente. Nos anos 2000, começaram a surgir pesquisas na área de IA através da criação dos ICAI (Instruções Assistidas por Computador Inteligentes). Os ICAI apresentam uma estrutura diferenciada para trabalhar com domínios educacionais, visto que utilizam técnicas de IA e Psicologia Cognitiva para guiar o processo de ensino-aprendizagem (JUAN et al., 2003).

2.1.1 ARQUITETURA DOS STI's

O principal objetivo dos Sistemas Tutores Inteligentes é proporcionar um ensino adaptado a cada aluno, tentando se aproximar ao comportamento de um professor na sala de aula. Estes sistemas se baseiam em uma arquitetura composta basicamente por quatro componentes. A arquitetura básica tradicional (Figura 1), tem quatro componentes:

1. Modelo do aluno: neste módulo estão armazenadas/modeladas as características individuais do aluno.
2. Modelo do tutor: possui o conhecimento sobre as estratégias e táticas para selecioná-las em função das características do aluno (representadas no Modelo do aluno).
3. Modelo do Domínio: detêm o conhecimento sobre a matéria no formato de regras de produção, estereótipos, etc.
4. Modelo da Interface: intermedia a interação entre o tutor e o aluno.

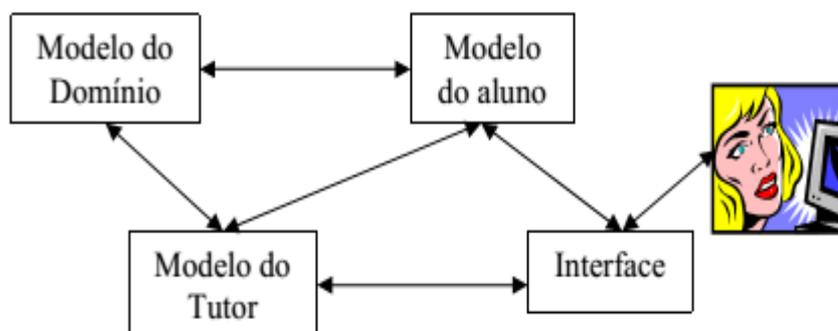


Figura 1: Arquitetura clássica de um STI.

Esta arquitetura é denominada clássica e também conhecida como função tripartida ou arquitetura tradicional de STI. O termo tripartido se refere às funções associadas aos modelos do tutor, do aluno e do domínio. Esta proposta trouxe grandes avanços à modelagem de ambientes educacionais, pois separou o domínio da sua forma de utilização. Permitindo assim, que estratégias de ensino fossem

associadas em função das informações oriundas da modelagem do aluno (JUAN et al., 2003).

Este trabalho irá atuar na área do Modelo do Estudante, buscando encontrar qual é a melhor forma de aprendizado do aluno através das notas referente ao conjunto de CEA's do mesmo.

2.1.2 EXEMPLOS DE SISTEMAS TUTORES INTELIGENTES

Nessa seção serão dados exemplos de Sistemas Tutores Inteligentes, que foram implementados, não foram citados, mas fica o exemplo do MathTutor, um sistema desenvolvido pela Universidade Federal de Santa Catarina (FRIGO; POZZEBON; BITTENCOURT, 2004) e o Tutor Espertinho (KONZEN; FROZZA, 1999) da Universidade de Santa Cruz do Sul. Além desses dois, serão apresentados o Multi-Agent Co-Operative Environment (MCOE) e o Dóris, simplesmente por apresentarem mais base teórica para ser explanado aqui.

2.1.2.1 MULTI-AGENT CO-OPERATIVE ENVIRONMENT (MCOE)

Os Sistemas Tutores Inteligentes (STI), onde cada aluno recebe auxílio personalizado conforme suas necessidades específicas, fica limitado pela falta de teorias mais computadorizadas por parte dos pesquisadores das áreas de Psicologia e Educação. O Multi-Agent Co-Operative Environment foi um modelo abordado de forma construtivista onde o tutor acompanharia as ações do aluno de forma gradativa, interferindo durante todo processo de aprendizado (GIRAFFA; VICCARI, 1999).

De acordo com Goulart e Giraffa, o MCOE apresenta algumas características descritas assim:

O MCOE é composto por três agentes (um tutor e dois agentes), possuidores de um mesmo objetivo, porém conhecimentos diferenciados. No sistema MCOE existem três agentes (tutor e dois estudantes), que têm o mesmo objetivo e conhecimentos

diferenciados. O tutor possui mais conhecimento do que os alunos e estes possuem conhecimentos diferenciados entre si. Os estudantes trabalham juntos e podem trocar mensagens entre si. O tutor monitora as ações dos alunos e se comporta de forma diferenciada com cada um deles, dependendo das ações individuais dos estudantes (GOULART; GIRAFFA, 2001, pg. 266).

As ações do tutor estão associadas a três estratégias, sendo elas:

- Guia: O tutor sugere de forma mais direta o que o aluno deve fazer e sugere ações específicas.
- Reativa: O tutor se comporta em função dos pontos críticos (problemas) que vão surgindo.
- Assistente: O tutor se comporta como um parceiro que sugere ações de forma menos invasiva e procura reforçar o aluno a descobrir caminhos e refletir sobre o que está acontecendo no sistema.

Como há um tempo determinado para as ações ocorrerem, isso altera o comportamento do tutor, visto que, à medida que o tempo passa, mais ele irá intervir no processo e guiar as ações do aluno. Da mesma maneira ele acabará interagindo cada vez mais com o aluno, visto que o ambiente, emoções e estado mental vão se alterando e ocasionando situações que alteram o método desse tutor auxiliá-lo.

2.1.2.2 DÓRIS

O sistema Dóris visa acompanhar a interação do aluno com o sistema, extrair informações para modelagem do perfil do aluno utilizado na personalização do ambiente para auxiliar e orientar o aluno durante a construção de seu aprendizado

Segundo (SANTOS et al., 2001) os agentes que atuam nas atividades educacionais são conhecidos agentes pedagógicos e buscam a troca de informação com o aluno para melhor entender e modelar o agente. Os agentes pedagógicos são uma forma de auxiliar os STIs, já que estes se preocupam com o ambiente ideal de aprendizado, o agente visa melhorar o ambiente de forma a colaborar com o aluno através da

identificação das suas melhores percepções e aptidões na forma de trabalhar (SANTOS et al., 2001).

O objetivo central dos agentes pedagógicos é contribuir para uma aprendizagem efetiva do aluno, gerando um ganho de qualidade para o ambiente onde estão inseridos. As características, os comportamentos e a arquitetura do Agente Pedagógico DÓRIS, que tem como principais funções:

- Extrair características de aprendizado do aluno e disponibilizar ao sistema estas informações, necessárias para uma posterior modelagem do perfil do aluno;
- Guiar e monitorar o aluno durante sua interação com o ambiente de ensino-aprendizagem, auxiliando-o em caso de dúvidas e motivando-o a aprender.

O agente pedagógico foi construído para atuar em um STI com domínio genérico. Desta forma, o agente não possui conhecimento específico sobre o domínio que será abordado.

O agente DÓRIS (SANTOS et al., 2001) apresenta as seguintes características, advindas dos agentes inteligentes:

- *Percepção do ambiente em que está inserido*: o agente extrai as informações do ambiente de aprendizado do aluno, as quais serão utilizadas na personalização deste ambiente;
- *Autonomia*: o agente age sem a interferência humana, sendo invocado automaticamente no momento em que o aluno iniciar a interação com o sistema;
- *Capacidade de agir no ambiente*: o agente monitora e acompanha o aluno no seu processo de aprendizagem. Isto gera ações como: mudança de atitudes do agente e estabelecimento de interação entre agente e aluno;
- *Capacidade social*: o agente interage com o aluno, a fim de realizar sua tarefa de acompanhamento e monitoração;
- *Possui adaptabilidade*: o agente adapta-se às modificações no ambiente, impostas pela aplicação de estratégias de ensino diversificadas;
- *Pode ter mobilidade*: o agente é levado para a máquina do aluno no momento em que este fizer *download* do módulo da aula correspondente, retornando ao servidor central em uma oportunidade pré-definida;

- *Possui conhecimento*: o agente mantém uma base de conhecimento interna, onde são armazenadas as informações extraídas da interação do aluno com o ambiente;
- *Representação através de personagens*.

2.2 ESTILOS DE APRENDIZAGEM

KALATZIS (2008) afirma que cada pessoa tem formas diferentes de aprendizado, ou seja, de aprender e guardar informações. Seja por fatores hereditários, experiências ou exigências do ambiente em que a pessoa vive, isso influenciará na forma como ela aprimora suas habilidades. Neste trabalho o autor cita também os onze modelos de estilos de aprendizagem propostos por DeBello (1990), expondo suas definições, explicações, perspectivas histórica, influência sobre outros modelos, relação com questões educacionais entre outras características.

Dando destaque para três modelos e suas definições:

- Ronald Schmeck: O nível de processamento, capacidade de compreensão por parte do aluno sobre determinado conhecimento, segue do mais raso e recursivo ao mais elabora e profundo. Já que segundo ele, estilos de aprendizagem são produtos da organização de um conjunto de tarefas de processamento da informação.
- Antony F. Gregorc: Consiste em um conjunto de comportamentos observáveis diferentes que fornecem indicativos de como a mente das pessoa entende o que lhe é ensinado e como ela se relaciona com o mundo. A ideia é que as pessoas aprendem em combinações de dualidades, por exemplo: concreto-sequencial, abstrato-aleatório.
- Bernice McCarthy: Todos aprendem continuamente variando entre o abstrato e o concreto, ou seja, as pessoas percebem e sentem, experimentam e agem.

Segundo FELDER e SILVERMAN (1988), as formas de estilos de aprendizagem referem-se em como o indivíduo tem mais facilidade em saber e processar informação. A definição de aprendizagem apresentada em (FELDER; SILVERMAN, 1988) funciona como um processos de duas etapas, recepção e processamento da informação. Na recepção o que é captado pelos sentidos, ou informação externa, e a informação interna, que surge por meio de reflexão ou

introspecção, ficam disponíveis para o indivíduo que vai escolher o que vai ser ou não processado. A segunda etapa, o processamento, já trabalha com a memorização ou raciocínio indutivo ou dedutivo, reflexão ou ação, introspecção ou interação com outros indivíduos. Dessa forma, o resultado desse processamento é que o conhecimento proposto a ser aprendido é feito de uma forma, de outra ou não é aprendido.

(ENTWISTLE, 2001) aborda não somente a forma como o indivíduo processa a informação, mas como ele sente e age nas situações de aprendizagem. (KEEFE, 1987) vai definir estilos de aprendizagem como sendo comportamentos psicológicos, afetivos e cognitivos que podem servir como indicadores relativamente controlados de como os alunos percebem, integram e respondem ao ambiente. (DUNN, 1990) já diz que é uma forma com a qual cada aluno começa a se concentrar, processar e armazenar uma informação recente e difícil.

(KURI; NÉLSON, 2006) vão citar dois modelos de Estilos de Aprendizagem, sendo um de (KOLB, 1984) e outro de (FELDER; SILVERMAN, 1988), para dar uma visão mais geral ambos serão explicados nesse trabalho, porém como é visto em (ALMEIDA, 2010), (MIRANDA, 2005), (PRETO, 2000), (KURI; NÉLSON, 2006) além de outros materiais encontrados na literatura, o modelo amplamente utilizado é o proposto por (FELDER; SILVERMAN, 1988).

2.2.1 MODELO DE KOLB

David Kolb desenvolveu um Modelo de Aprendizagem, denominado vivencial por dar prioridade à experimentação. O principal ponto do modelo é sua montagem que é através de um *ciclo de aprendizagem*, ou seja, como o aluno, a partir das suas experiências gera conceitos que irão contribuir para aumentar sua eficiência no aprendizado. Esse processo pode ser definido como um ciclo de quatro estágios ou fases: Experiência Concreta (EC), que leva a Observação Reflexiva (OR), logo em seguida, a Conceituação Abstrata (CA) e, por fim a Experimentação Ativa (EA), que leva a novas experiências, resultando assim num novo ciclo.

(KURI; NÉLSON, 2006) descrevem as diferentes fases do Modelo de Aprendizagem de Kolb da seguinte forma:

Experiência Concreta (EC): é o ponto de partida do processo; nesta fase os aprendizes precisam se envolver completa e imparcialmente em novas experiências.

Observação Reflexiva (OR): nesta fase os aprendizes refletem sobre as novas informações e experiências, examinando-as a partir de diferentes perspectivas.

Conceituação Abstrata (CA): envolve mais o uso da lógica e das ideias do que sentimentos para o entendimento dos problemas e situações. Nesta fase os aprendizes criam conceitos que integrem suas observações em teorias sólidas em termos de lógica.

Experimentação Ativa (EA): nesta fase os aprendizes experimentam ativamente as situações, usando as teorias citadas anteriormente para resolver problemas e tomar decisões. (KURI; NÉLSON, 2006, pag. 117)

Segundo Kolb são formados quatro estilos de aprendizagem (FIG. 1): tipo I – Divergente (concreto e reflexivo); tipo II – Assimilador (abstrato e reflexivo); tipo III – Convergente (abstrato e ativo); e o tipo IV – Acomodador (concreto e ativo).

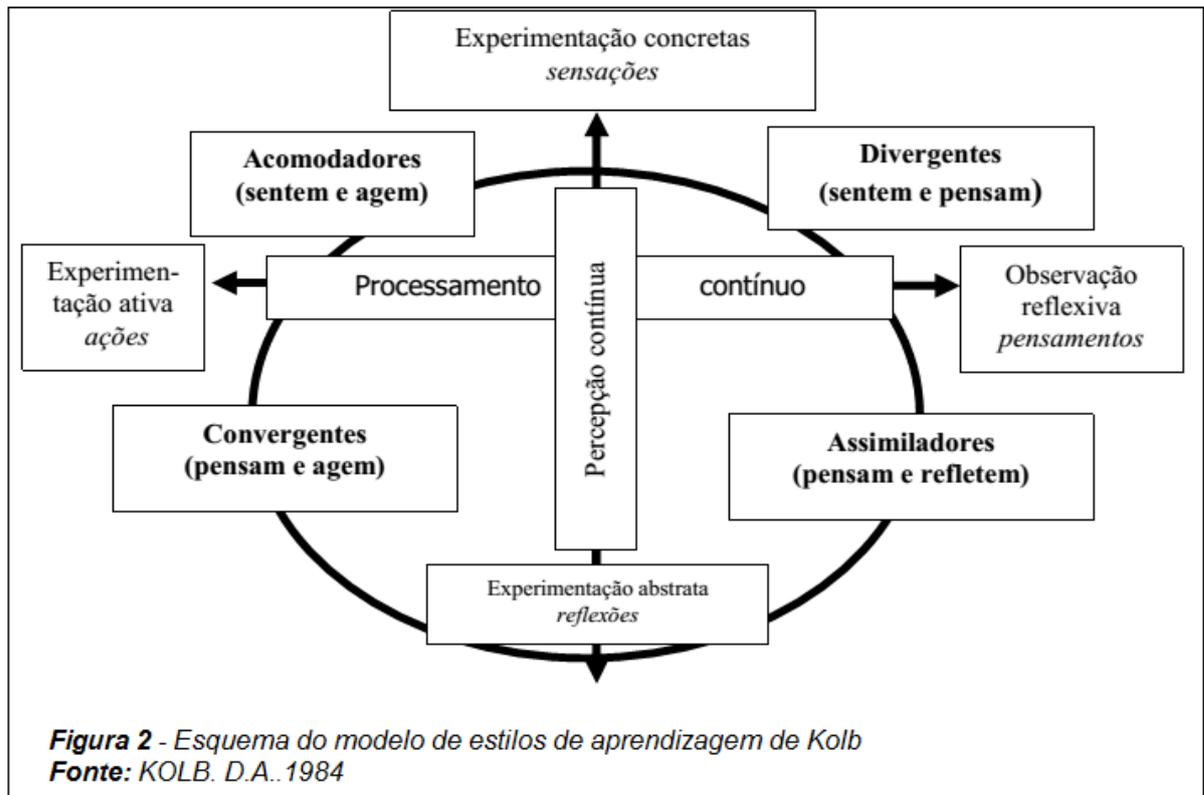
Indivíduos que aprendem experimentando, criando ideias e teorias, relacionando conteúdo do curso com sua vivência e observando e ouvindo são os Divergentes. A pergunta característica desse tipo é “Por que?” e para obter um efeito melhor sobre o aprendizado, o tutor deve fazer o papel de “motivador”.

Os assimiladores são os que aprendem ouvindo, refletindo, criando teorias e observando. Preocupam-se pouco com aplicações mas são bons em criar teorias. O tutor deve ser um “especialista”. Por apresentarem uma organização lógica, sua pergunta típica é “O que?”.

Estudantes que aprendem por tentativa e erro, aplicações práticas das ideias e teorias são os Convergentes. Tem facilidade para definir problemas e nas tomadas de decisões devido ao seu raciocínio dedutivo. Para um melhor rendimento, seus tutores devem ser como um “treinador”. Devido a sua praticidade, sua pergunta é “como?”, já que trabalham melhores com tarefas ou projetos já bem encaminhados.

Acomodadores aprendem por meio de experimentação a aplicação do conhecimento em novas situações de aprendizagem. O educador deve mostrar ao estudante uma forma do próprio desenvolver e descobrir o novo conhecimento. Sua

pergunta principal é “De que maneira?”, já que dependendo do contexto os alunos agirão de uma maneira diferente.



Ainda segundo Kolb, uma aprendizagem de forma eficaz requer um movimento circular passando por esses estados, embora cada pessoa possua uma proximidade maior por algum deles.

2.2.2 MODELO DE FELDER-SILVERMAN

Esse modelo classifica o indivíduo quanto às suas maneiras de perceber e processar as informações. O modelo especificado foi aplicado a área da Engenharia a princípio, e abrange quatro dimensões de aprendizagem: Entrada (Visual/Verbal), Percepção (Sensorial/Intuitiva), Processamento (Ativo/Reflexivo) e Entendimento (Sequencial/Global) como em (FELDER; BRENT, 1994).

Visual e Verbal são estilos relacionados a como o indivíduo capta a informação. Visuais captam melhor a informação que se apresenta com gravuras, figuras, esboço, ou seja, qualquer forma que chegue via visual. Já os verbais são os que captam as informações por meio de palavras.

A percepção possui os sensoriais e os intuitivos. Geralmente indivíduos intuitivos terminam mais rapidamente suas tarefas, já que sua capacidade de interpretar símbolos e textos são mais aguçadas quando comparados com os sensoriais, que são mais metódicos e precisam de informações mais concretas para realizar determinada tarefa.

Alunos ativos, como o próprio termo diz, são os que aprendem agindo sobre algo, testando, manipulando, explicando o conteúdo para os outros e por isso tem mais facilidade em trabalhar em equipe. Já os reflexivos preferem a individualidade e pensar sobre o assunto de forma introspectiva.

Sequenciais gostam de aprender um passo de cada vez, de forma que haja uma sequência lógica entre a informação atual e a anterior, como a construção progressiva de conhecimento. Já os aprendizes globais conseguem adquirir as informações de forma praticamente aleatória, porém se juntando como um quebra cabeça em suas mentes, são capazes portanto de resolver problemas complexos, porém tem dificuldades em dar uma ordem lógica de etapas de algum processo.

<i>Sistema favorito de Aprendizado do Aluno</i>		<i>Estilo de ensino correspondente</i>	
Sensitivo } Intuitivo }	Perceptivo	Concreto } Abstrato }	Conteúdo
Visual } Verbal }	Entrada	Visual } Verbal }	Apresentação
Ativo } Reflexivo }	Processamento	Ativo } Reflexivo }	Participação do Aluno
Sequencial } Global }	Entendimento	Sequencial } Global }	Perspectiva

Tabela 1: Dimensões do aprendizado e estilos de ensino Fonte: (FELDER; SILVERMAN, 1988)
Traduzida

A tabela 1 mostra um resumo dos estilos de aprendizado e de ensino correspondente. Para chegar a essa conclusão (FELDER; SILVERMAN, 1988) consideram as respostas de cinco questões para o aluno:

- 1) Qual o tipo de informação que o estudante prefere receber: *sensitivo* (externo) – sinais, sons, sensações físicas, ou *intuitivo* (interna) – possibilidades, ideias, palpites?
- 2) Através de qual canal sensorial a informação que vem de fora é melhor percebida: *visual* – figuras, diagramas, gráficos, demonstrações, ou *auditiva* – palavras, sons? (Claro que existem os outros sentidos como tato, gosto e cheiro, mas como não são relativamente importantes na maioria dos ambientes de aprendizagem, não serão levados em consideração aqui.)
- 3) Como o estudante prefere processar a informação recebida: *ativamente* – através de um engajamento de atividade física ou discussão, ou *reflexivo* – por meio de introspecção?

- 4) Como acontece de melhor forma a construção de conhecimento do estudante: *sequencialmente* – em passos contínuos, pouco a pouco, ou *globalmente* em grandes quantidades, de forma mais geral?

A segunda coluna, apresenta os tipos correspondentes de aprendizado levando em consideração o estilo de ensino correspondente. Para organizá-la, também são respondidas cinco questões:

- 1) Qual o tipo de informação deve ser enfatizado pelo instrutor: *concreta* – baseada em fatos, prática, ou *abstratas* – conceitual, teórica?
- 2) Qual o modo da apresentação é ideal: *visual* – figuras, diagramas, vídeos, demonstrações, ou *verbal* – literatura, leitura, discussão?
- 3) Qual forma de participação do estudante é facilitada para a apresentação do conteúdo: *ativa* – o estudante fala, se move, reflete, ou *passiva* – o estudante assiste e escuta?
- 4) Qual o tipo de perspectiva que providencia uma apresentação do conteúdo de forma boa para o estudante: *sequencial* – progressão passo-a-passo, o processo é construído de forma constante, como uma árvore, ou *global* – analisa o contexto e a relevância do tema, como uma floresta?

2.3 DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZAGEM

Segundo (DORÇA et al., 2009), uma avaliação eficaz e um currículo bem estruturado são atividades complexas de serem feitas em sistemas de educação a distância. Essas atividades estariam diretamente relacionadas desde que a estrutura curricular possa interferir no desempenho do aluno. Sendo assim, um sistema de Detecção automática de estilos de aprendizagem deve ser capaz de alterar dinamicamente a forma como o aluno irá decorrer durante o curso, já que as suas características de aprendizagem podem mudar no decorrer da graduação.

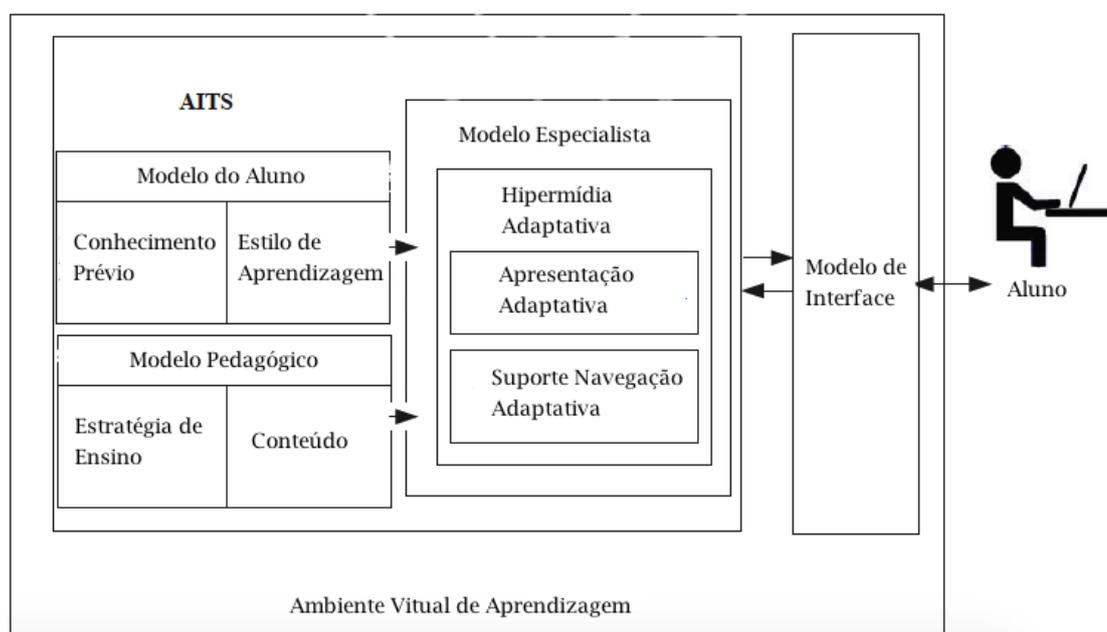


Figura 3 – Sistema de tutoria Inteligente adaptativa (HOCKEMEYER; ALBERT, 1999)

Seguindo o modelo apresentado na figura 2 apresentado por (HOCKEMEYER; ALBERT, 1999), podemos perceber que o ambiente virtual de tutoria inteligente é composto por vários modelos e cada modelo é composto por módulos. A proposta desse trabalho é trabalhar no Modelo do Aluno no módulo de Estilo de Aprendizagem, visando identificar em qual Combinação de Estilos de Aprendizagem (CEA) o aluno obtém a melhor nota, por meio da Detecção automática dos EA.

Existem diferentes trabalhos que abordam a Detecção Automática dos Estilos de Aprendizagem (DAEA), que utilizam Cadeia de Markov (DORÇA, 2012a), Redes Bayesianas e Aprendizagem por Reforço (KALATZIS, 2008), podendo mesclar ou não alguns desses métodos (DORÇA et al., 2012).

2.3.1 MODELO DO ESTUDANTE

O modelo do estudante (ME) é utilizado para avaliar o nível de conhecimento do estudante e para que se possa fazer inferências a respeito de suas características, concepções e estratégias de raciocínio empregadas para atingir o nível de conhecimento atual. Além disto, o ME permite mudar vários aspectos do sistema, em resposta a características específicas do estudante. Estas características representam o conhecimento e as preferências que o sistema assume que o estudante possui. Desta maneira, o ME definido nesta abordagem considera de forma eficiente estilos de aprendizagem, objetivos de aprendizagem e nível de conhecimento do estudante (LIMA; LOPES, 2011).

Como (BOTELHO et al., 2009), uma das formas de se definir Modelo do Estudante é:

[...] o Modelo do Estudante é uma representação explícita do que se acredita saber sobre o estudante a respeito do conhecimento já adquirido anteriormente, do progresso na abordagem do conteúdo, estilo preferido de aprendizagem e outros tipos de informação sobre o estudante. (BOTELHO et al., 2009)

2.3.2 FORMAS DE DETECTAÇÃO AUTOMÁTICA DOS ESTILOS DE APRENDIZAGEM

Nessa seção, serão tratados alguns modelos de Detecção Automática dos Estilos de Aprendizagem que foram usadas pela literatura para encontrar uma forma mais eficaz de encontrar a melhor forma de aprendizado para o estudante. São descritos o Processo Estocástico e Cadeia de Markov, as Redes Bayesianas e o Aprendizado por Reforço, bem como suas características e funcionamento além dos autores que as utilizaram.

2.3.2.1 PROCESSOS ESTOCÁSTICO E CADEIAS DE MARKOV

De acordo com (LIMA; LOPES, 2011), pode-se definir um processo estocástico como uma coletânea de variáveis probabilísticas que descrevem o processo que está sendo executado por um sistema durante um tempo determinado. Ou seja, é um fenômeno que utiliza uma variável X aleatória de forma imprevisível durante um tempo t .

Esta proposta é contrária aos tradicionais processos determinísticos comumente implementados, e vem a possibilitar que sistemas adaptativos para educação existentes possam, de forma eficiente, automaticamente detectar os estilos de aprendizagem dos estudantes com alto índice de precisão. Em face do exposto, é preciso lembrar que a eficiência obtida por esta abordagem se deve em grande parte ao fato desta ser baseada em um processo estocástico, que se caracteriza principalmente pela representação da variabilidade e das incertezas inerentes ao processo de aprendizagem de cada estudante. Dá-se o nome de processo de Markov a um dado fenômeno que possa ser classificado em estados finitos e discretos, e cuja probabilidade de transição entre tais estados, num intervalo de tempo também discreto, dependa apenas do estado corrente e do estado seguinte, como definido em (BUENO, 2009).

Uma CEA (combinação de estilos de aprendizagem) é uma tupla formada por 4 estilos de aprendizagem, cada um pertencente a uma dimensão de (FELDER; SILVERMAN, 1988). Desta forma, existem 16 (24) possíveis CEA's, conforme apresentado a seguir (considere S=Sensitivo; I = Intuitivo; Vi = Visual; Ve = Verbal; A = Ativo; R = Reflexivo; Seq=Sequencial; G = Global):

CEA's = {(S, Vi, A, Seq), (S,Vi, A, G), (S, Vi, R, Seq), (S,Vi,R,G), (S,Ve,A,Seq), (S,Ve,A,G), (S,Ve,R,Seq), (S,Ve,R,G), (I,Vi,A,Seq), (I,Vi,A,G), (I,Vi,R,Seq), (I,Vi,R,G), (I,Ve,A,Seq), (I,Ve,A,G), (I,Ve,R,Seq), (I,Ve,R,G)}

Isto posto, o estudante será submetido a um conjunto de objetos de aprendizagem que atendam a uma CEA específica, gerada estocasticamente de acordo com os valores dos estilos de aprendizagem armazenados no Modelo do Estudante (ME). Ou seja, a CEA é uma combinação de 4 variáveis probabilísticas, definidas pelas 4 dimensões do FSLSM, e cada variável possui 2 valores possíveis, e

cada valor representa um estilo de aprendizagem, cuja probabilidade é dada pelo grau de preferência armazenado no ME (FELDER; SILVERMAN, 1988).

2.3.2.2 REDES BAYESIANAS

Segundo MARQUES e DUTRA (2002), são grafos acíclicos dirigidos que mostram as dependências entre variáveis em um modelo probabilístico. Esta abordagem representa uma boa estratégia para lidar com problemas que tratam incertezas, onde as conclusões não podem ser construídas apenas baseando-se no conhecimento prévio a respeito do problema.

Matematicamente, uma Rede Bayesiana é uma representação compacta de uma tabela de conjunção de probabilidades do universo do problema. Por outro lado, do ponto de vista de um especialista, Redes Bayesianas constituem um modelo gráfico que representa de forma simples as relações de causalidade das variáveis de um sistema. Uma Rede Bayesiana consiste do seguinte:

- Um conjunto de variáveis e um conjunto de arcos ligando as variáveis.
- Cada variável possui um conjunto limitado de estados mutuamente exclusivos.
- As variáveis e arcos formam um grafo dirigido sem ciclos (DAG).
- Para cada variável A que possui como pais B_1, \dots, B_n , existe uma tabela $P(A|B_1, \dots, B_n)$.

Repare que, caso A não possua um pai, a tabela de probabilidades é reduzida para uma probabilidade incondicional $P(A)$. Uma vez definida a topologia da rede, basta especificar as probabilidades dos nós que participam em dependências diretas, e utilizar estas para computar as demais probabilidades que se deseje.

Todas as entradas da tabela de conjunção de probabilidades podem ser calculadas a partir das informações disponíveis em uma rede Bayesiana. Uma tabela de conjunção de probabilidades representa a descrição completa de um domínio. Cada entrada da tabela de conjunção de 8 probabilidades pode ser calculada a partir da conjunção das variáveis atribuídas aos devidos valores, $P(X_1=x_1 \wedge \dots \wedge X_n=x_n)$, ou $P(x_1, \dots, x_n)$. O valor de uma entrada é então dado por:

$$P(x_1, \dots, x_n) = \prod_{i=1}^n P(x_i | \text{Pais}(X_i)) \text{ para } 0 \leq i \leq n$$

Assim, cada entrada da tabela é representada pelo produto dos elementos apropriados das tabelas de probabilidades condicionais (CPT). As CPTs constituem então uma representação distribuída da tabela de conjunção de probabilidades do problema.

Um exemplo de trabalho relacionado nessa área, é o (GARCÍA et al., 2007), que utilizaram o sistema usando Redes Bayesianas e testaram num ambiente com dez usuários chamado SAVER (um acrônimo para “*Software de Asistencia Virtual para Educación Remota*”). Para fins de comparação, eles realizaram um questionário utilizando o modelo proposto por Felder e compararam o resultado com os obtidos pelo SAVER. Por ser um trabalho menor, foi trabalhado apenas na esfera de percepção Global ou Sequencial, deixando assim brechas para desenvolver e testar seu método nas outras esferas de conhecimento definidas por (FELDER; SILVERMAN, 1988).

2.3.2.3 APRENDIZAGEM POR REFORÇO

Na seção 3.1 será dado um enfoque maior no Aprendizado por Reforço (AR), aqui temos uma explicação mais geral e alguns exemplos de autores que utilizaram esse método.

Aprendizado por Reforço é uma técnica de aprendizado de máquina onde um agente aprende por sucessivas interações em um ambiente dinâmico (Kaelbling et al. 1996). Ele é responsável por escolher possíveis ações para uma situação determinada apresentada pelo ambiente. O ambiente responde às ações e apresenta novas situações ao agente. A cada ação, é fornecida ao agente uma recompensa ou penalidade que indica o quanto o novo estado é desejado (MARTINS et al., 2007).

Segundo Sutton & Barto [Sutton and Barto 1998], a definição de AR baseia-se no problema e, não, no método de aprendizado. São problemas onde o agente deve aprender a escolher as ações disponíveis, que alteram o estado do ambiente e utilizam uma função de recompensa para definir a qualidade da sequência de ações [Mitchell 1997]. Neste caso, o agente pode ou não ter um conhecimento prévio sobre o efeito de suas ações sobre o ambiente.

Além de (DORÇA, 2012a) que terá uma seção dedicada ao seu método nesse trabalho, quem também trabalhou com Aprendizagem por Reforço foi (GUELPELLI;

RIBEIRO; OMAR, 2004) onde foi desenvolvido um sistema baseado em C, que segundo o artigo, apresenta como algumas das vantagens, o fato de não depender do conteúdo apresentado pelo Tutor, poder ser facilmente alterado para utilização em outras áreas da psicologia. Em contra partida, necessidade de um grande número de ações para conseguir definir o estado cognitivo do estudante além de que há uma lentidão na parte de desempenho do algoritmo, novamente pontos destacados citados como negativos pelos autores.

CAPÍTULO 3

SISTEMA DE DETECÇÃO AUTOMÁTICA DE ESTILOS DE APRENDIZADO

Neste capítulo será abordado o Sistema de Detecção Automática de Estilos de Aprendizado proposto por (DORÇA, 2012). Será apresentado o algoritmo Q-learning e sua utilização em sistemas de Detecção de Estilos de Aprendizado. O Aprendizado por Reforço terá alguns parâmetros modificados para buscar uma melhora em obter o melhor estilo de aprendizagem do aluno. Como (DORÇA, 2012) aborda a Cadeia de Markov, uma breve explicação do método também será apresentada. Enfim teremos a abordagem proposta por (DORÇA, 2012), que busca mesclar o Q-Learning até certo ponto do algoritmo para então usar a aproximação do Aprendizado por Reforço.

3.1 ABORDAGEM PROPOSTA POR DORÇA (2012)

Para compreender melhor o algoritmo 3.1 é necessário definir alguns conceitos propostos por (DORÇA, 2012):

- Conjunto de estados (S): É um estado definido como a descrição dos Estilos de Aprendizagem armazenados como distribuições pelo ME, cujos valores são definidos no intervalo $[0,1]$;
- Conjunto de ações (A): Ações que o sistema pode executar visando melhorar a qualidade da performance de aprendizagem, assemelhando a estratégias pedagógicas aplicadas para melhorar o desempenho do estudante, as CEAs.
- Percepção do Ambiente ($I : S \rightarrow S$): Como o ambiente percebe o estado do estudante
- Reforço ($R : S \times A \rightarrow \mathfrak{R}$): Função define a recompensa fornecida pelo ambiente. Esta função fornece um valor máximo quando o estudante aprende a totalidade dos conteúdos em uma determinada área de aprendizagem, mostrando que houve uma performance/nota de alta qualidade, esta função é apresentada à frente;
- Função valor-ação, ou ganho ($Q : S \times A \rightarrow \mathfrak{R}$): Esta função estima a utilidade de se utilizar uma determinada estratégia pedagógica, que é

definida por uma CEA considerando um estado dado pelo ME, fornecendo um método de avaliação para as ações do sistema. Ou seja, essa é a função que unifica.

A proposta então é que dado um par $Q(s, a)$ de estado, ação, dê um retorno do quanto uma CEA é a ideal para um estudante. O sinal do reforço é dado em função da qualidade da performance (PFM) obtida pelo estudante na seção de aprendizagem, levando o agente a atualizar o Modelo de Estudante e por consequência calcular o valor $Q(s, a)$. O principal objetivo de (DORÇA, 2012) é que o algoritmo *Q-learning* que ele propôs “estimar, autonomamente, em cada estado s em que o sistema se encontra, o valor $Q(s, a)$ para cada possível ação a , e a partir daí permitir a obtenção da melhor ação, ou seja, a ação com maior valor de utilidade.”

Na abordagem proposta por (DORÇA, 2012),

[...] a técnica de AR tem como função modificar o ME baseado em quão boa ou ruim percebe-se uma determinada ação, que no contexto deste trabalho define a forma de apresentar o material instrucional ao estudante (estratégia pedagógica), forma esta descrita pela CEA que representa a ação. Um desafio, então, é escolher a melhor ação, ou seja, a melhor estratégia pedagógica, levando-se em consideração as incertezas relacionadas à modelagem de EA apresentadas anteriormente neste trabalho.

(DORÇA, 2012, pag. 99)

O reforço então, é aplicado a todos os Estilos de Aprendizagem no Modelo Estudante, visto que o programa não sabe onde estão os problemas que causaram problema de aprendizagem. Considerando que cada dimensão do Modelo de Felder e Silverman (FSLSM) possui dois EA, representados nas regras R1 e R2 como A e B, temos:

$R1 : (CEA[d_i] = A) \rightarrow$

$$ME[d_i]_A := ME[d_i]_A - \alpha \times R,$$

$$ME[d_i]_B := ME[d_i]_B + \alpha \times R.$$

$R2 : (CEA[d_i] = B) \rightarrow$

$$ME[d_i]_A := ME[d_i]_A + \alpha \times R,$$

$$ME[d_i]_B := ME[d_i]_B - \alpha \times R.$$

Em que:

- $ME[d_i]_A$ representa o valor armazenado no ME na dimensão i para o EA A , para $i = 1 \dots 4$.
- $ME[d_i]_B$ representa o valor armazenado no ME na dimensão i para o EA B , para $i = 1 \dots 4$.
- $CEA[d_i]$ representa o EA que constitui a CEA considerando a dimensão i , com $i = 1 \dots 4$.
- R é o reforço recebido pela realização da ação pedagógica no estado corrente.
- α é a taxa de aprendizagem do agente.

Pode-se observar que $R1$ e $R2$ podem reduzir ou aumentar a distância entre os EA (DEA), dependendo de como ficou a configuração da CEA, de acordo com a figura 4. Cada vez que um problema de performance ou de aprendizado fica aquém do esperado, todos os EA são atualizados, mesmo aqueles já consistentes no ME, já que não é possível saber quais estão bem conceituados e quais não estão.

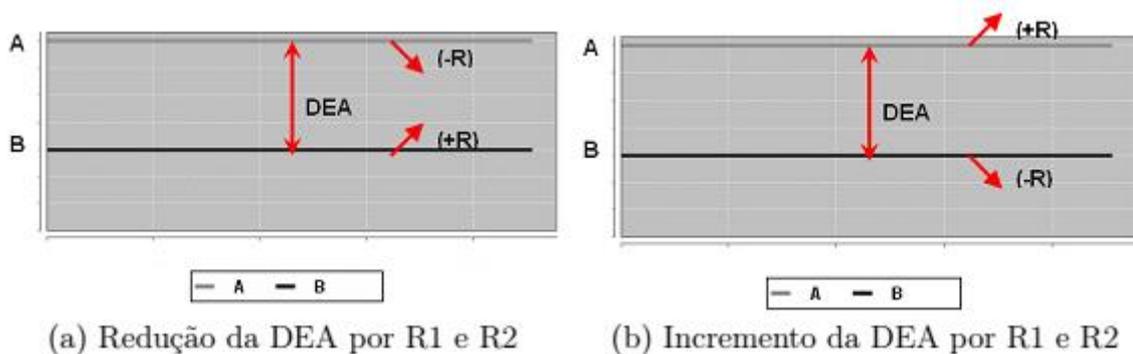


Figura 4: Atualização do ME durante o processo de aprendizagem (DORÇA, 2012)

É importante ainda ressaltar que a eficiência do processo de diagnóstico de EA é influenciada pela qualidade do reforço utilizado. O reforço R , dado por (3.1), é calculado considerando-se a distância entre os EA p dentro de uma dimensão específica no ME, e a performance do estudante (PFM) obtida na seção de aprendizagem.

A DEA é calculada por (3.2). O reforço R é calculado para cada uma das quatro dimensões de EAs e aplicado sempre que $PFM < m$, considerando-se a DEA específica em cada uma, em que m é a performance mínima esperada, de forma que $PFM < m$ indica um problema de aprendizagem. O valor de PFM é considerado no intervalo real $[0,100]$ e o valor da DEA é considerado no intervalo real $[0,1]$.

$$R = \frac{1}{PFM \times DEA} \quad (3.1)$$

$$DEA = |ME[di]A - ME[di]B| \quad (3.2)$$

(DORÇA, 2012b)

Em (2.1), espera-se que quanto menor o PFM, maior seja o reforço aplicado. Visto que quanto menor a nota/desempenho do estudante, maior será a necessidade de reforço. Para compensar, é desejável que quanto maior o DEA, menor o reforço, para evitar reforços desnecessários em EA já consideradas boas.

A variação de α segundo (DORÇA,2012) é ideal que não permaneça muito alta para evitar conversões abruptas do Estilo de Aprendizagem. Também não é bom que α seja muito baixa para que aprendizagem reduza seu ritmo e demora a ensinar o estudante. Por isso, na seção 4.2, o valor de $\alpha = 0,5$ nos experimentos efetuados aqui.

O algoritmo 3.1 implementa o processo de Aprendizado por Reforço (AR) baseado no *Q-Learning* que foi apresentado por (Dorça, 2012) e está explicado na sessão 3.2. O algoritmo é executado a cada seção de aprendizagem, até que sejam atingidos todos os objetivos de aprendizagem presentes no Modelo de Estudante (ME). Dada a inicialização do ME com parâmetros já pré-definidos, configuram um estado inicial s . A execução se encerra quando todos os objetivos de aprendizagem estiverem satisfeitos. Cada iteração do representa uma seção de aprendizagem.

As entradas da tabela de valores de ganho Q para cada par (s, a) , é dada pela distribuição das probabilidades de cada uma das dezesseis CEA's ocorrerem e que deve ter como resultado da soma de possibilidades 1, e são atualizados

automaticamente quando os Estilos de Aprendizagem (EA) do estudante no ME são atualizados. Nesta tabela, cada valor $Q(s, a)$ estima a necessidade de se executar uma determinada estratégia pedagógica a considerando o estado aula s do estudante, dado pelo ME.

Algoritmo 3.1 *Q-learning* aplicado à modelagem automática e dinâmica de EA

```
Inicialize o ME;
while  $s$  não seja o estado final do
    Selecione um conceito  $C$  a ser apresentado ao estudante;
    Selecione, através do MP, uma CEA  $a$ ;
    Execute  $a$ , apresentando adequadamente os objetos de aprendizagem que
    ensinam o conceito  $C$  ao estudante;
    Avalie a performance do estudante no conceito  $C$ ;
    Atualize o estado cognitivo do estudante no ME em relação a  $C$ ;
    Receba a recompensa  $r$ , dada por  $PFM$ ;
    Calcule o reforço  $R$  de acordo com 2.2;
    Atualize os EA
     $p$  através de R1 e R2;
    Faça de  $s$  o próximo estado, dado por  $s'$ ;
end while
```

A cada iteração, os valores de Q , convergem para os valores ótimos automaticamente, possibilitando ao sistema escolher qual a melhor forma pedagógica com a maior frequência possível para cada aluno.

3.1 Q-LEARNING

Uma destas técnicas é o conhecido algoritmo Q-learning desenvolvido por Watkins [Watkins. 1989], é considerada uma das mais importantes contribuições em aprendizagem por reforço. O Q-learning é classificado como um método de diferença temporal off-policy uma vez que a sua convergência para valores ótimos de Q não depende da política que está sendo utilizada, através de atualizações dos pares estado-ação, que são feitas a medida que estes pares são visitados. Sendo assim, uma melhor forma de se denotar seria dizer que “cada valor $Q(s, a)$ representa a soma de reforços esperada ao se executar a ação a no estado s , seguindo-se uma política ótima a partir de então.” (DORÇA, 2012, pag. 77).

Uma função definida como ótima $Q^*(s,a)$, representa o reforço esperado de se tomar a ação ótima a no estado s, e então continuar escolhendo ações ótimas, e é definido recursivamente por (2.1), em que γ , é um parâmetro de desconto que controla a importância relativa de recompensas de ações futuras em relação a novas ações, tal que $0 \leq \gamma < 1$.

(DORÇA 2012, pág 77)

$$Q^*(s, a) = R(s, a) + \gamma \sum_{s' \in S} T(s, a, s') \max_{a'} Q^*(s', a') \quad (2.1)$$

Com algumas alterações baseadas em 2.1 usam informações relativas a todos os possíveis estados sucessores. A usada por (Dorça, 2012), seleciona um s' a distribuição $T(s,a,s')$. Nesse caso, a regra do Q-Learning é mostrada em (2.2) onde α é a taxa de aprendizagem do aluno, indicando o quão rápido o sistema aprende, sendo que α varia de 0 a 1.

$$Q(s, a) := Q(s, a) + \alpha(R(s, a) + \gamma(\max_{a'} Q(s', a') - Q(s, a))) \quad (2.2)$$

Na equação (2.2), s representa o estado antes da transição, a é a ação escolhida, $R(s,a)$ é o reforço recebido e s' é o próximo estado. A regra leva em consideração o melhor valor de $Q(s',a')$ a ser obtido no próximo estado, s' , de forma que quanto maior este valor, maior é a recompensa para $Q(s,a)$.

Como a função Q torna a ação explícita, pode-se estimar os valores de Q dinamicamente e utilizá-los para definir a política, já que uma ação pode ser escolhida apenas tomando-se o maior Q para o estado corrente s .

O algoritmo *Q-learning*, iterativamente, seleciona uma ação a , seguindo uma estratégia de exploração/exploração e a executa, recebe a recompensa r , e atualiza os valores $Q(s,a)$ de acordo com a equação (2.2). Com base nos valores de $Q(s,a)$, o algoritmo de AR estima dinamicamente a ação de maior valor de utilidade.

(DORÇA, 2012, pag. 78)

No Algoritmo 3.1 é apresentado de forma simplificada o procedimento Q-learning. Os detalhes sobre a implementação do algoritmo Q-learning utilizado neste trabalho serão discutidos na seção 4.3. Maiores informações sobre o algoritmo Q-learning podem ser encontrados em [Watkins. 1989].

Algoritmo 3.2 Q-Learning

Para cada par ($s \in \mathcal{S}$, $a \in \mathcal{A}$), inicialize a tabela de valores $Q(s, a)$

Observe o estado corrente, s

while s não seja o estado final **faça do**

 Selecione uma ação, a , e execute-a

 Receba a recompensa, r

 Observe o novo estado, s'

 Atualize a entrada da tabela para $Q(s, a)$ conforme 2.2

 Atribua s' a s

end while

3.2 APRENDIZADO POR REFORÇO

A arquitetura descrita neste trabalho utiliza uma técnica de Inteligência Artificial que é o AR, para modelar o aprendiz de forma dinâmica e autônoma.

AR permite ao agente adquirir uma capacidade de conhecimento do ambiente que não estava disponível em tempo de projeto [Sutton & Barto, 1998]. AR é baseada na existência de um crítico externo ao ambiente, que avalia a ação tomada, mas sem indicar explicitamente a ação correta. Formalmente, AR utiliza uma estrutura composta de estados, ações e recompensas.

Uma consideração importante a ser feita quando se lida com AR é conflito exploração X exploração. O agente deve lidar com o problema de haver um compromisso entre escolher a exploração de estados e ações desconhecidos, de modo a coletar nova informação, ou a exploração de estados e ações que já foram aprendidos e que irão gerar altas recompensas, de modo a maximizar seus reforços acumulados [Bellman, 1959]. Sendo assim, por um lado o agente deve aprender quais ações maximizam os valores das recompensas obtidas no tempo, e, por outro, deve agir de forma a atingir esta maximização, explorando ações ainda não executadas ou regiões pouco visitadas do espaço de estados.

No contexto deste trabalho, a técnica de AR terá como função modificar parâmetros e armazená-los em “esquemas de planos”, que definem a forma de apresentar o material instrucional ao aprendiz. O grande desafio, neste caso, é escolher a melhor ação que - baseada no estado do aprendiz - possa mudar a estratégia de ensino, para obter resultados significativos, fornecedores de parâmetros

indicativos de quão boa ou ruim está sendo uma determinada estratégia. O algoritmo utilizado (Q-learning) é baseado em estimativas de utilidades de pares estado-ação, e com estas estimativas podem-se gerar alternativas de novas estratégias pedagógicas. Neste caso, a aprendizagem das estratégias mais adequadas, que indicam a ação a escolher para cada estado do aprendiz, dar-se-á por reforço, através de uma estrutura de parâmetros adaptativos sobre os quais o algoritmo opera.

Formalmente, AR procura aproximar uma função que define a utilidade relativa dos pares estado-ação. Esta função de utilidade fornece indicações estimativas, mapeando os pares estado-ação em uma medida baseada na soma dos reforços esperados a longo prazo.

Para cada par estado-ação (s, a) , é definido o reforço $r(s, a)$, indicando uma consequência imediata da execução da ação a no estado s . O problema em AR é achar uma política ótima de ações (μ^*), ou seja, um conjunto de ações que maximizem, para cada estado s , os valores de utilidade $Q(s, a)$. Com base nesses valores, o algoritmo de AR estima a ação de maior valor de utilidade – a ação que deverá ser executada pelo agente tutor.

Como já visto no início da seção 2.3, na aprendizagem por reforço existe a presença de um agente aprendiz que interage com o ambiente buscando estimar a ação de melhor resultado para cada estado, com o objetivo de estabelecer uma política ótima de atuação. Quando o agente não conhece o modelo de transição de estados do ambiente, torna-se impossível a utilização de programação dinâmica para a determinação da política ótima. Felizmente, nem todos os algoritmos de aprendizagem por reforço necessitam de uma modelagem completa do ambiente, ou seja, não necessitam conhecer a matriz de probabilidades de transição e valores esperados do sinal de reforço para todos os possíveis estados e ações do ambiente. Este é o caso das técnicas de aprendizagem por reforço baseadas em diferenças temporais.

3.3 CADEIA DE MARKOV

A abordagem utilizada por (DORÇA, 2012a) para diagnóstico automático e dinâmico de Estilos de Aprendizagem, é, em sua essência, um processo estocástico que opera em um Modelo de Estudante probabilístico adjacente. A princípio pode parecer que um processo aleatório ou estocástico não poderá realizar o trabalho de forma coerente, mas mesmo com essa característica, nada afirma que os resultados, mesmo com condições praticamente inalteradas serão iguais. E embora os resultados possam parecer erráticos nas primeiras tentativas, após um grande número de repetições, aparecem as regularidades (GARDINER, 1983).

A imprevisibilidade nos processos estocásticos significa que ao se observar sequências inteiras do processo em diversas ocasiões diferentes, mas sob condições idênticas, as sequências resultantes da execução do processo são, em geral diferentes. Desta forma, a probabilidade aparece, mas não no sentido de que cada resultado de uma experiência aleatório determine um valor único. Ao invés disto, o resultado do processo estocástico é uma sequência ou série de valores, uma função, e não apenas um valor único, e em cada instante de tempo t existe uma família de valores que a série pode assumir, aos quais estão associadas probabilidades de ocorrência (CLARKE e DISNEY, 1979).

Para constatar que a probabilidade de transição entre estados que evoluem de maneira estocástica, as cadeias de Markov, desenvolvidas pelo matemático Andrei Andreiyeovich Markov, foram criadas. Utilizando-as, é possível prever estados de um processo em andamento, conhecendo o estado atual e não sua trajetória, considerando-se um processo em que a sequência de variáveis aleatórias toma valores num alfabeto finito, funcionando como uma máquina de estados em que as transições são estocásticas. Desta forma, uma cadeia de Markov (Meyn et al. 2009) é um processo markoviano com as seguintes propriedades (Papoulis et al., 2002; Meyn et al., 2009):

- Cada resultado pertence a um conjunto finito de estados ($x_1, x_2, x_3, \dots, x_k$), chamado de estados de sistema. Se o estado resultante da n -ésima tentativa é x_j , então o sistema se encontra no estado x_j , no momento n .

- O resultado de um ensaio depende apenas do resultado do ensaio imediatamente anterior. Desta forma, a cada par de estados (x_i, x_j) está associada a probabilidade $p(x_j/x_i)$ de ocorrer x_j no instante n imediatamente após ter ocorrido x_i no instante $n - 1$, ou seja, $P(X_n = x_j | X_{n-1} = x_i)$.

Para entender a ideia dos modelos estocásticos, pode-se considerar que eles são o oposto dos modelos determinísticos, onde a solução para um problema pode ter apenas uma resposta correta, e o gráfico de uma função pode ter apenas um conjunto específicos de valores. Por outro lado, modelos estocásticos permitem variações em um problema matemático complexo para que se possa ver como a solução é afetada, e como converge em diversas repetições. Estas variações representam o aspecto aleatório ou a imprevisibilidade de eventos do mundo real e seus efeitos.

CAPÍTULO 4

METODOLOGIA

Neste capítulo serão abordadas as ferramentas utilizadas nesse trabalho para o desenvolvimento da aplicação, sendo a linguagem escolhida para ser trabalhada e a plataforma de desenvolvimento (IDE) e porque foram escolhidas. Será apresentado também o novo algoritmo pensado para a resolução da proposta desse trabalho, com o seu pseudocódigo explicado e analisado.

4.1 FERRAMENTAS

Para o desenvolvimento de aplicações, as opções disponíveis de Linguagens de Programação são as mais variadas, como C++, Python, C e mais uma grande quantidade de novas linguagens que ainda são criadas e desenvolvidas. Por ser uma linguagem de fácil portabilidade (JUNIOR; VIRTUOSO; MARTINS, 2012) e que possui um vasto material de pesquisa e funcionalidades que atendem as necessidades desse trabalho.

A ambientação de desenvolvimento escolhida foi a Eclipse IDE, por apresentar uma ambientação já familiar e intuitiva de ser trabalhada, apresentando ajuda com recursos gráficos que auxiliam o programador no desenvolvimento (MURPHY, G.C.; KERSTEN, M.; FINDLATER, L., 2006).

4.1.1 LINGUAGEM DE PROGRAMAÇÃO JAVA

Java é uma linguagem de programação orientada a objeto desenvolvida na década de noventa na empresa Sun Microsystems. Um dos principais objetivos da Sun Microsystems ao criar a linguagem era que ela tivesse grande portabilidade, isto é, que ela fosse independente de plataforma, utilizando o paradigma de escrever uma única vez e executar em qualquer lugar. Isto ocorre utilizando-se do conceito de máquina virtual, onde existe, entre o sistema operacional e a aplicação, uma camada

extra, responsável por “traduzir” o que a aplicação deseja fazer para as respectivas chamadas do sistema operacional onde ela está sendo executada no momento. Dessa forma, a maneira com a qual as chamadas ao sistema são feitas em diferentes sistemas operacionais é a mesma.

Nesse trabalho foi escolhido como linguagem de programação o Java, devido a sua integração multiplataforma com os principais sistemas operacionais o que torna mais fácil a portabilidade do algoritmo desenvolvido nesse trabalho em diversas plataformas.

4.1.2 ECLIPSE IDE

Uma IDE (*Integrated Development Environment*) ou Ambiente de Desenvolvimento Integrado é um programa de computador que reúne características e ferramentas de apoio ao desenvolvimento de software com o objetivo de agilizar este processo. (DEITEL, 2010), afirma que um IDE fornece muitas ferramentas que suportam o processo de desenvolvimento de software, incluindo editores para escrever e editar programas e depuradores para localizar erros de lógica em programas. Entre os vários IDEs populares para desenvolvimento em Java, destacam-se o NetBeans (www.netbeans.org), o jEdit (www.jedit.org), o Eclipse (www.eclipse.org), o JBuilder (www.borland.com), o JCreator (www.jcreator.com), o BlueJ (www.bluej.org) e o jGRASP (www.jgrasp.org).

Por ser gratuita e oferecer alguns auxílios na implementação do algoritmo, além de suporte nativo para o JAVA, a IDE Eclipse foi a escolhida para ser utilizada nesse trabalho como ferramenta de desenvolvimento de software.

4.2 SELEÇÃO DE CEA POR MEIO DE CLASSIFICAÇÃO DAS NOTAS

A proposta desse trabalho é apresentar um método de Detecção de Estilo de Aprendizagem que funciona baseando-se na seleção das CEA's com melhores resultados de performance/notas. Usando um conceito novo de seleção das CEA's dentro da execução de uma simulação do modelo de estudante, o algoritmo leva em

consideração as notas obtidas por cada CEA após a avaliação, denominado Algoritmo Almeida.

São definidas três categorias de notas e após a análise de cada uma das CEA's, estas são categorizadas devidamente em seu grupo. Para categorizar os grupos, suponhamos uma CEA com nota n , caso n , possua uma nota maior que b , que para fins didáticos representa a classe de CEA's boas, esta será armazenada no grupo I. Se o valor n da CEA estiver entre o valor b e o valor r , onde r será o valor de notas ruins, então ela será armazenada no grupo II. E por fim, caso n seja menor que r , ela pertencerá ao grupo III.

A definição de qual CEA será escolhida para ser analisada é dada por uma forma aleatória guiada, utilizando uma função do próprio Java é gerado um número aleatório associado a uma variável a . Cada grupo que armazena os valores de CEA's possui um intervalo de valores para ser escolhido, valores estes que são alterados a cada m iterações para ser ajustada a seleção da CEA simulando uma melhora de desempenho do aluno no decorrer do processo.

Algoritmo 1 Algoritmo Almeida

```
1 Inicialize o ME;  
2 while  $s$  não seja o estado final do  
3   if  $p$  não satisfaça sua condição de parada  
4     Selecione uma CEA baseada na seleção de CEA conforme (Dorça, 2012);  
5   else  
6     Escolha um grupo para selecionar a CEA;  
7     Selecione aleatoriamente uma CEA do grupo;  
8     Calcule a nota da CEA escolhida;  
9     Insira a CEA no grupo que condiz com a sua nota;  
10    Verifique se está na iteração  $t$ ;  
11    if sim: Atualize os valores das probabilidades;  
12    else não: Siga a execução normal do programa;  
13    Incremente  $p$  e  $t$ ;  
14    Faça de  $s$  o próximo estado, dado por  $s'$ ;  
15 end while
```

O algoritmo 4.1 apresenta o pseudocódigo do sistema modificado, no qual a seleção de CEA inicialmente é feita a partir do sistema original proposto por Dorça (2012) (linha 3-4). Após um determinado número de iterações o algoritmo passa a selecionar uma CEA de acordo com o grupo. Primeiro ele escolhe o grupo de acordo com as probabilidades de cada um e depois, aleatoriamente, seleciona uma CEA

deste grupo (linha 6 e 7). A probabilidade de cada grupo é modificada no decorrer das iterações, aumentando gradativamente a probabilidade de seleção de CEAs do grupo de notas boas e reduzindo gradativamente a probabilidade de seleção de CEAS do grupo de notas ruins (linha 10-12). Este processo é repetido até que todos as seções de aprendizado sejam apresentadas ao aluno. É importante ressaltar que, conforme o algoritmo de Dorça (2012), quando o aluno retira uma nota menor que 60, então a iteração não é computada e o conteúdo é novamente apresentado ao aluno.

CAPÍTULO 5

RESULTADOS COMPUTACIONAIS

Este capítulo trata da verificação da proposta defendida neste trabalho. Para isso, serão comparados os resultados. Por se tratar de um trabalho experimental, os parâmetros usados nos testes serão os mesmo usados por (GONÇALVES, 2015).

5.1 MÉTODOS DE EXPERIMENTAÇÃO

Esta seção está direcionada à descrição, análise e conclusão dos resultados obtidos na execução dos testes. Para isso, foram definidos alguns casos de testes, simulando estudantes reais com diferentes características de Estilos de Aprendizado (EA) em um processo de aprendizagem.

Para efeitos de comparação serão utilizadas quatro abordagens, a Abordagem I com os resultados obtidos por (DORÇA, 2012a), a Abordagem II que utiliza uma seleção aleatória das CEA's, a Abordagem III que utiliza uma seleção sequencial das CEA's.e por último a abordagem IV que é a do Algoritmo Almeida. A análise e avaliação das quatro abordagens foi organizada segundo Dorça e a forma de critérios descrita por (GONÇALVES, 2015), visto que ambos os dados precisam ser os mesmo a título de termos uma comparação de forma mais próxima possível, as informações passadas ao sistema foram:

- a) Definição do Sistema e Determinação dos objetivos: definido o problema, modelagem automática e dinâmica de EA, o objetivo é comparar as duas abordagens e descobrir se o método apresentado pode ser útil para futuros trabalhos.
- b) Escolha da métrica: Para realizar a comparação, serão utilizadas as seguintes métricas: Problema de Aprendizagem e Desempenho. A primeira é a quantidade de ocorrências em que o desempenho esteve abaixo do mínimo exigido no processo avaliativo. A segunda está relacionada com nota média obtida ao longo de todas as sessões de aprendizagem. Ambas variáveis estão relacionadas com a consistência do modelo, ou seja, relacionado à convergência efetiva do EA_p para os EA_r durante o processo simulativo de aprendizagem. O fator tempo não foi medido nos testes, pois

ele não representa um questão crítica do sistema. Todas as técnicas descritas utilizam apenas processamentos simples, cálculos matemáticos básicos que não provocam grandes sobrecargas.

c) Para utilizar os Parâmetros de Sistemas, alguns dos critérios foram os mesmos de (GONÇALVES, 2015). Parâmetros de Sistemas:

- Taxa de aprendizagem: $\alpha = 0, 5$. Este parâmetro define a intensidade do reforço. Se for um valor alto, favorece a convergência. Entretanto, se for um valor baixo, possibilita maior exploração do espaço de busca. Dorça (2012) estabelece esta configuração através de observações empíricas.
- R_{max} : $\alpha = 0, 2$. Este parâmetro limita o impacto do reforço. Caso seja muito pequeno pode inibir a convergência, contudo se for muito grande pode gerar mudanças repentinas nas preferências de uma mesma dimensão. Dorça et al. (2013b) sugere empiricamente o percentual de 20%, mas alerta que se trata de um problema de otimização a ser investigado em trabalhos futuros.
- Desempenho mínimo no processo de aprendizagem para atualização: 60%. Este percentual é adotado pela maioria dos processos de ensino e está diretamente ligado ao ajuste das preferências do ME realizado pelo CME.
- Desempenho de excelência no processo de aprendizagem para atualização: 90%. Este percentual também está diretamente ligado ao ajuste das preferências do ME realizado pelo CME, quando ocorre um aproveitamento acima do esperado.
- Modelo Estudante: Foi inicializado com valores seguindo o modelo de Dorça.

d) Carga de Trabalho: Para fins de comparação, como estabelecido anteriormente, será usado o mesmo número de conceitos do Dorça.

5.2 TESTE

Como o foco será na performance obtida com relação ao aprendizado do aluno. A comparação será feita com os 16 experimentos apresentados por Dorça, sendo eles organizados na tabela 2. Utilizando as 4 abordagens definidas nesse trabalho e verificando a quantidade de passos de aprendizagem realizados pelo algoritmo em cada um dos testes e analisando também a quantidade média de perda de performance do aluno, ou seja, qual a média de notas de CEA que ficaram com menos de 60% de aproveitamento.

Experimento	CEA relacionada
Experimento 1	Ativo (Forte), Sensitivo(Forte), Visual(Moderado), Sequencial(Leve)
Experimento 2	Reflexivo (Forte), Sensitivo (Forte), Visual(Moderado), Sequencial(Leve)
Experimento 3	Ativo (Forte), Intuitivo(Forte), Visual(Moderado), Sequencial(Leve)
Experimento 4	Ativo (Forte), Sensitivo (Forte), Visual(Moderado), Sequencial(Leve)
Experimento 5	Ativo (Forte), Sensitivo (Forte), Visual(Moderado), Global(Leve)
Experimento 6	Reflexivo (Forte), Intuitivo(Forte), Visual(Moderado), Sequencial(Leve)
Experimento 7	Ativo (Forte), Intuitivo(Forte), Verbal(Moderado), Sequencial(Leve)
Experimento 8	Ativo (Forte), Sensitivo (Forte), Visual(Moderado), Global(Leve)
Experimento 9	Reflexivo (Forte), Sensitivo (Forte), Verbal(Moderado), Sequencial(Leve)
Experimento 10	Reflexivo (Forte), Sensitivo (Forte), Visual(Moderado), Global(Leve)
Experimento 11	Ativo (Forte), Intuitivo(Forte), Visual(Moderado), Global(Leve)
Experimento 12	Reflexivo (Forte), Intuitivo(Forte), Verbal(Moderado), Sequencial(Leve)
Experimento 13	Ativo (Forte), Intuitivo(Forte), Verbal(Moderado), Global(Leve)
Experimento 14	Reflexivo (Forte), Intuitivo(Forte), Visual(Moderado), Global(Leve)
Experimento 15	Reflexivo (Forte), Sensitivo(Forte), Verbal(Moderado), Global(Leve)
Experimento 16	Reflexivo (Forte), Intuitivo(Forte), Verbal(Moderado), Global(Leve)

Tabela 2: Relação de experimentos e CEA's com intensidade que os representam

Na tabela 3, são apresentados os resultados comparados dos Experimentos nas quatro abordagens, com relação ao número de passos necessários para o aluno chegar no estado final de aprendizagem de conceitos. Bem como o gráfico 1 traz a comparação das quatro de forma mais visual.

Como pode ser visto no gráfico, as abordagens I e IV apresentam resultados parecidos entre si, com a vantagem em relação ao desempenho de passos pertencendo a Abordagem I, o que já é esperado. Vale notar que em alguns casos a abordagem IV é melhor que a I, por levar em conta um fator aleatório isso pode ter interferido nesse ponto. Já as abordagens que são mais Força Bruta, II e III, fica bem pra trás intercalando quem apresenta um pior desempenho.

Experimento/ Abordagem	Abordagem I	Abordagem II	Abordagem III	Abordagem IV
Experimento 1	372	472	486	380
Experimento 2	384	450	456	386
Experimento 3	387	462	468	397
Experimento 4	387	467	462	384
Experimento 5	389	461	477	406
Experimento 6	389	467	459	390
Experimento 7	397	470	471	400
Experimento 8	389	460	476	394
Experimento 9	391	488	476	392
Experimento 10	389	479	474	397
Experimento 11	390	457	466	392
Experimento 12	386	478	474	395
Experimento 13	386	458	457	405
Experimento 14	386	474	462	405
Experimento 15	389	492	452	402
Experimento 16	396	485	460	389
Média dos Experimentos	388	470	467	395

Tabela 3: Comparação dos resultados obtidos nos Experimentos referentes ao número de iterações

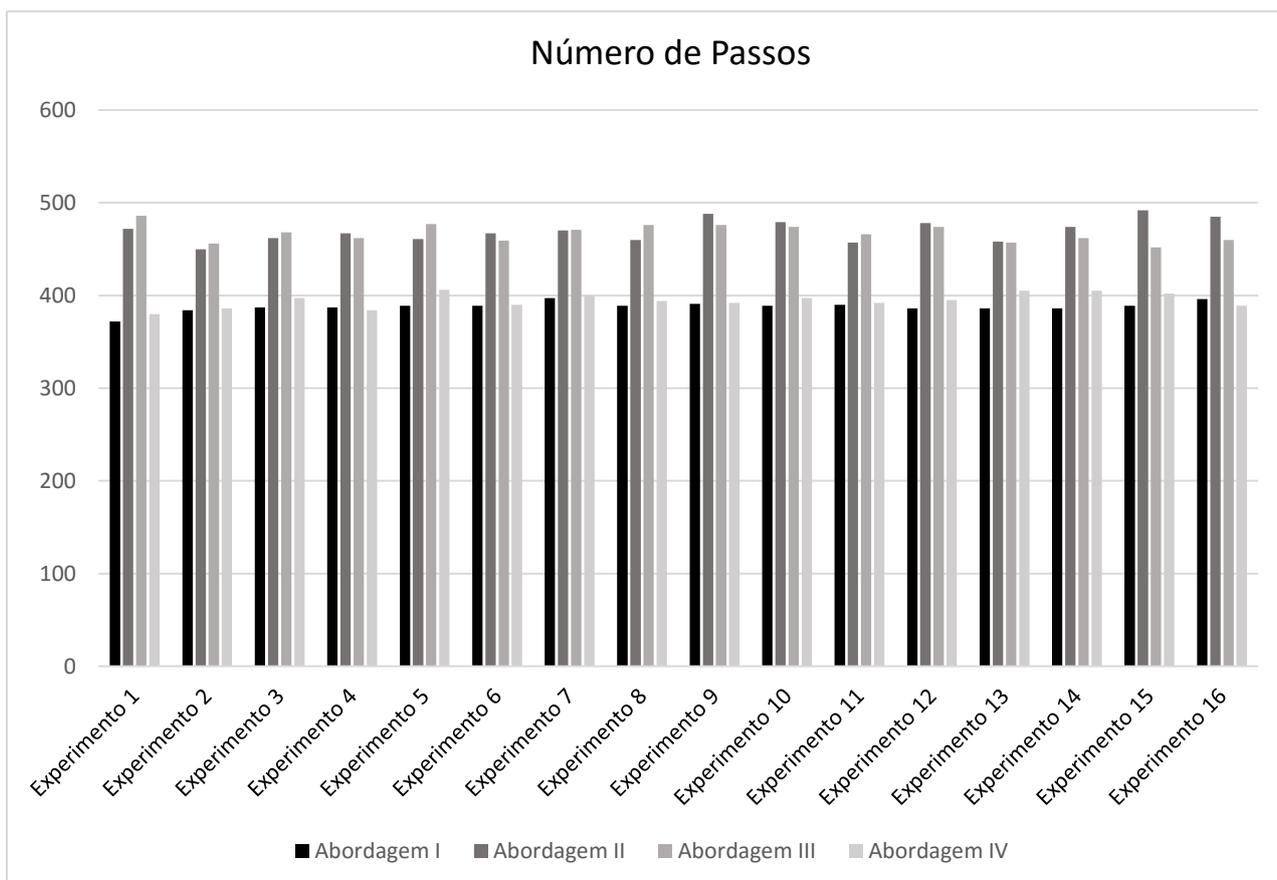


Gráfico 1: Número de passos realizados pela abordagem para a aprendizagem do aluno por Experimento

Na tabela 4, temos a quantidade de passos do algoritmo que ficaram abaixo da média de performance e em seguida a porcentagem desses passos em comparação a quantidade de passos executados no total. Já o gráfico 2, apresenta os mesmos dados porém em forma mais ilustrativa.

Após análise dos dados e do gráfico, vemos que disparadamente as Abordagens II e III são nitidamente piores, embora nesse quesito de médias perdidas, a abordagem II seja muito pior no Experimento 13 por exemplo. Já as abordagens I e IV intercalam em melhor desempenho. Como a porcentagem na tabela está relacionada a execução daquele método isolado, não faz sentido visual aplicar a porcentagem graficamente, visto que a quantidade de passos finais da execução do algoritmo são a razão da comparação.

Experimento/ Abordagem	Abordagem I	Abordagem II	Abordagem III	Abordagem IV
Experimento 1	17 ~ 0,05%	115 ~ 0,24%	106 ~ 0,22%	25 ~ 0,06%
Experimento 2	29 ~ 0,07%	108 ~ 0,23%	105 ~ 0,23%	33 ~ 0,08%
Experimento 3	22 ~ 0,05%	89 ~ 0,20%	97 ~ 0,21%	26 ~ 0,06%
Experimento 4	30 ~ 0,07%	129 ~ 0,26%	128 ~ 0,26%	26 ~ 0,06%
Experimento 5	30 ~ 0,07%	108 ~ 0,23%	100 ~ 0,21%	30 ~ 0,07%
Experimento 6	24 ~ 0,06%	111 ~ 0,24%	115 ~ 0,24%	30 ~ 0,08%
Experimento 7	31 ~ 0,07%	102 ~ 0,22%	111 ~ 0,23%	34 ~ 0,08%
Experimento 8	37 ~ 0,09%	100 ~ 0,22%	97 ~ 0,21%	28 ~ 0,07%
Experimento 9	35 ~ 0,09%	113 ~ 0,23%	130 ~ 0,26%	35 ~ 0,09%
Experimento 10	30 ~ 0,07%	113 ~ 0,24%	108 ~ 0,23%	27 ~ 0,07%
Experimento 11	20 ~ 0,05%	115 ~ 0,24%	110 ~ 0,23%	31 ~ 0,08%
Experimento 12	35 ~ 0,09%	142 ~ 0,28%	91 ~ 0,20%	38 ~ 0,09%
Experimento 13	36 ~ 0,09%	127 ~ 0,26%	96 ~ 19,53%	37 ~ 0,09%
Experimento 14	33 ~ 0,08%	102 ~ 0,22%	117 ~ 0,24%	32 ~ 0,08%
Experimento 15	39 ~ 0,09%	119 ~ 0,24%	99 ~ 0,21%	31 ~ 0,07%
Experimento 16	29 ~ 0,07%	98 ~ 0,21%	110 ~ 0,23%	45 ~ 0,11%
Média	30	112	107,5	32

Tabela 4: Relação de médias perdidas, abaixo de 60 pontos ao final da execução do algoritmo

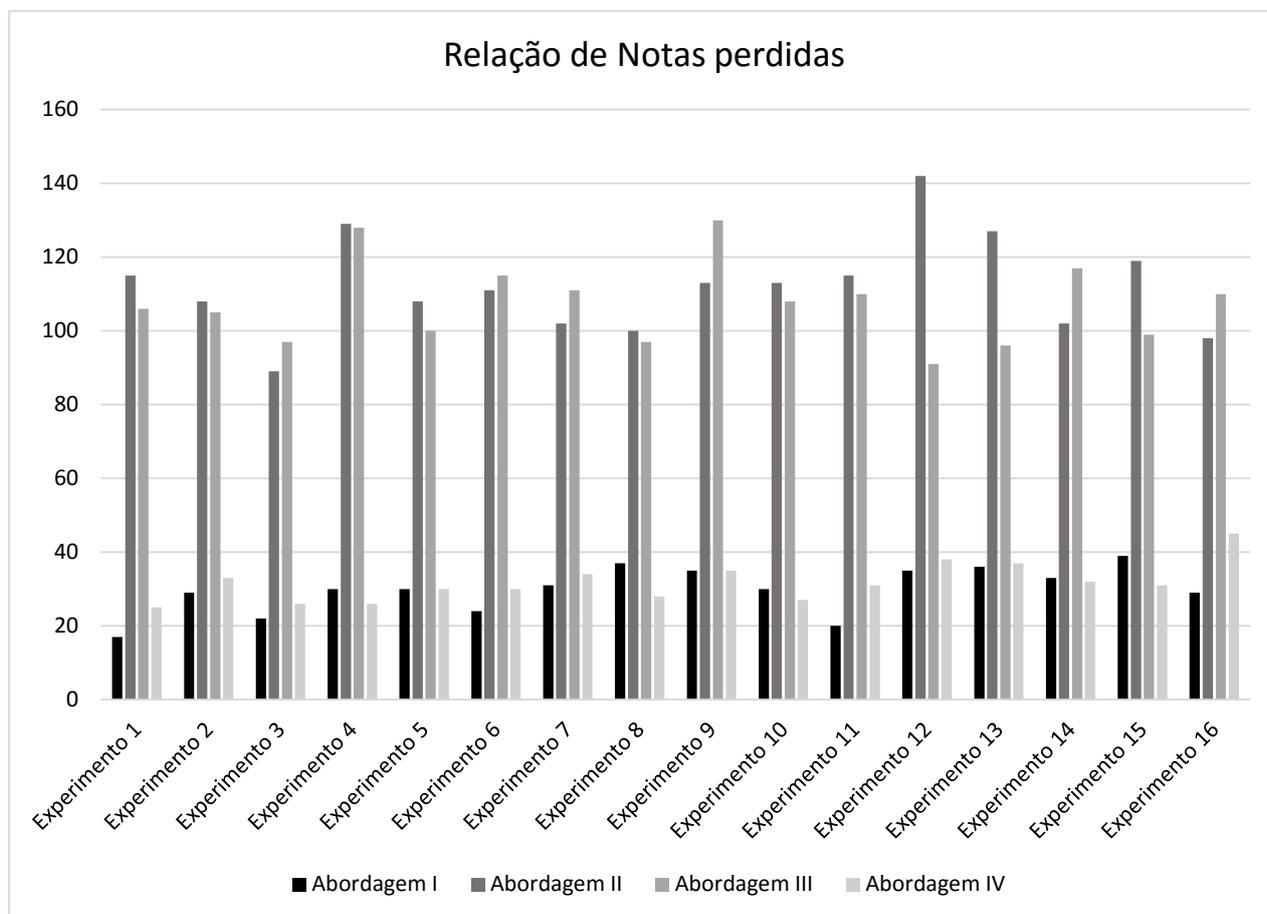


Gráfico 2: Relação de Notas perdidas

A última tabela a ser analisada, é a tabela de média de desempenho do aluno ao final da execução do programa, como o foco desde trabalho é selecionar CEA's com boas notas, a tabela 5, mostra a diferença de notas entre as diferentes abordagens, incluindo o desvio padrão de cada abordagem para também ser analisada. O gráfico 3 apresentará a relação de média de notas nas quatro abordagens.

Como pode ser visto no gráfico 3, a média de notas das abordagens segue o mesmo padrão dos gráficos 1 e 2, com as abordagens I e IV se saindo melhor, com o melhor desempenho se mantendo com a Abordagem I de (DORÇA, 2012), e a IV que é o Seleção de CEA por meio de classificação das notas. As Abordagens II, aleatório, e III, sequencial, têm um desempenho muito inferior as outras abordagens.

Experimento/ Abordagem	Abordagem I	Abordagem II	Abordagem III	Abordagem IV
Experimento 1	86,7 ~ 13,4	73,09 ~ 20,10	73,3 ~ 20,83	87,84 ~ 13,89
Experimento 2	84,87 ~ 14,01	73,36 ~ 19,75	73,83 ~ 20,22	86,10 ~ 14,47
Experimento 3	86,15 ~ 13,67	75,72 ~ 19,20	75,07 ~ 19,85	87,00 ~ 13,60
Experimento 4	85,57 ~ 14,57	72,24 ~ 21,52	73,65 ~ 20,60	87,00 ~ 14,21
Experimento 5	86,03 ~ 13,86	74,03 ~ 20,95	74,89 ~ 19,26	85,86 ~ 14,77
Experimento 6	87,03 ~ 13,06	75,09 ~ 20,10	73,85 ~ 19,97	85,49 ~ 15,45
Experimento 7	84,86 ~ 14,54	73,52 ~ 20,14	73,40 ~ 20,66	85,53 ~ 15,04
Experimento 8	84,22 ~ 15,22	75,59 ~ 20,04	75,40 ~ 19,53	85,86 ~ 15,30
Experimento 9	84,35 ~ 14,86	74,51 ~ 20,19	73,13 ~ 20,69	84,86 ~ 15,41
Experimento 10	86,48 ~ 14,36	74,47 ~ 20,34	74,47 ~ 20,05	84,48 ~ 14,04
Experimento 11	85,05 ~ 13,37	73,23 ~ 20,72	74,29 ~ 19,63	85,90 ~ 15,86
Experimento 12	84,60 ~ 15,64	73,00 ~ 21,40	75,56 ~ 20,67	84,22 ~ 16,30
Experimento 13	83,47 ~ 14,97	73,41 ~ 20,32	75,61 ~ 19,54	82,76 ~ 15,02
Experimento 14	83,96 ~ 15,15	74,82 ~ 20,35	73,54 ~ 20,42	85,20 ~ 16,02
Experimento 15	83,79 ~ 15,50	73,51 ~ 20,67	73,70 ~ 20,01	84,46 ~ 15,78
Experimento 16	84,09 ~ 15,31	75,69 ~ 19,70	74,13 ~ 19,54	83,59 ~ 16,87
Média	85,07	74,08	74,23	85,34

Tabela 5: Médias de notas com Desvio Padrão

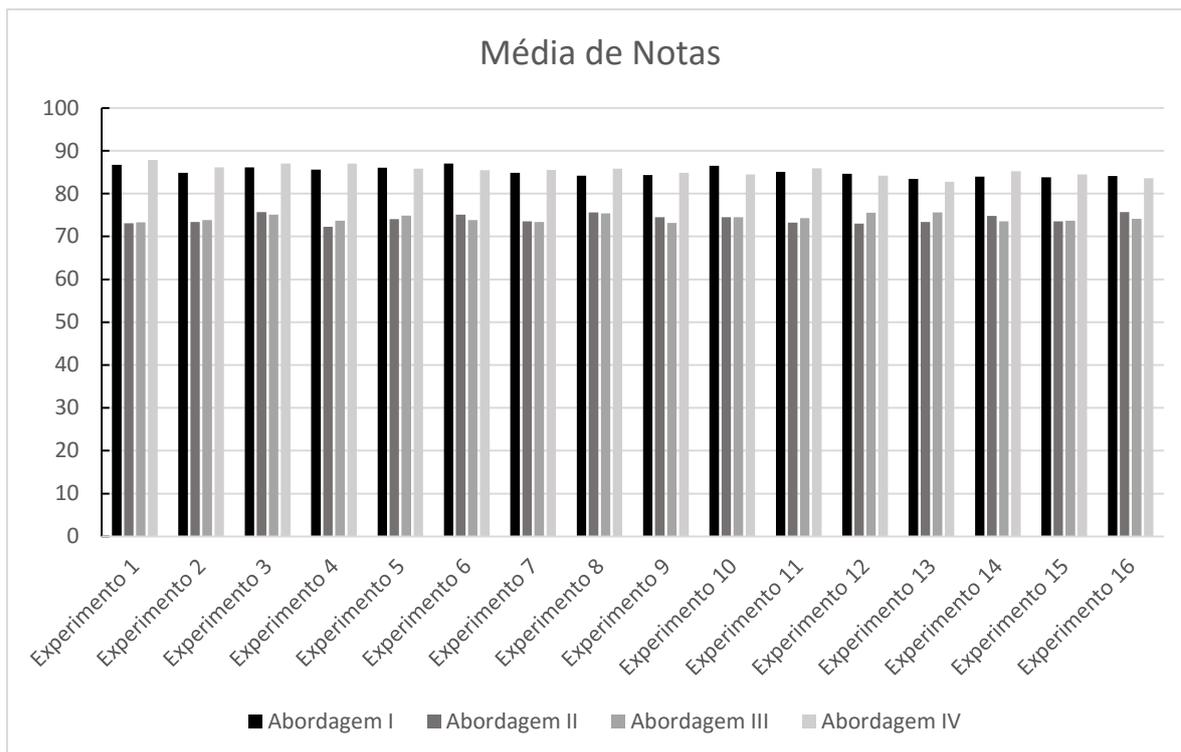


Gráfico 3: Média de Notas

5.3 ANÁLISE DE RESULTADOS

Como visto nos gráficos 1, 2, 3 e 4, a Abordagem I, que é o modelo proposto por (DORÇA, 2012) é o sistema mais eficiente nas categorias e parâmetros avaliados e utilizados nos testes. Já a Abordagem IV apresentada nesse trabalho, apresenta um desempenho satisfatório, pois em alguns testes ela foi melhor que a Abordagem I que é a referencia principal. As Abordagens II e III, aleatória e sequencial respectivamente, não apresentaram resultado satisfatório ou próximo disso em nenhum teste, o que já era esperado, visto que elas não fazem uso de nenhum tipo de método de inteligência para selecionar a CEA.

No primeiro teste em 87,5% dos casos a Abordagem I (Dorça), foi superior as outras, os outros 12,5% pertencem a Abordagem IV (Algoritmo Almeida) e em nenhum dos casos as Abordagens II (Sequencial) e III (Aleatória), se saíram melhor. Já no segundo teste, referente a médias perdidas, em 62,5% dos casos a Abordagem I apresentou melhores resultados que a Abordagem IV que complementou com os outros 37,5% dos Experimentos, novamente as Abordagens II e III não apresentaram nenhum resultado satisfatório. E o último teste comparativo, relacionando melhores

notas com o Desvio padrão, há um desempenho melhor por parte da Abordagem IV, com 62,5% de melhores resultados contra 37,5% da Abordagem I.

CAPÍTULO 6

CONCLUSÃO

Este trabalho apresentou uma nova abordagem que foi comparada com a proposta por Dorca (2012) para a modelagem automática e dinâmica de EA para SAIE baseada em cadeias de Markov. O objetivo de apresentar um método de seleção de CEA baseado em nota, foi cumprido e apresentou um resultado bem satisfatório.

O estudo no trabalho de (DORÇA, 2012) foi realizado e desenvolvido no capítulo 3, onde há uma explicação geral sobre os termos principais tratados por ele e que seriam úteis a esse trabalho, além de servir como base de comparação do Método de Seleção de CEA Baseado em Nota. Além do método apresentado, foram também definidos e usados na comparação os algoritmos que selecionam as CEA's de forma Aleatória e Sequencial, estes que não apresentam um desempenho muito bom em comparação aos outros dois, mas que por serem simples de implementar podem servir para trabalhos futuros para uma otimização tanto um deles como base.

Uma questão fundamental neste contexto é a identificação dinâmica e contínua dos Estilos de Aprendizagem do usuário e a adaptação do conteúdo didático seguindo suas preferências. Mas para isso é preciso conhecer o perfil do estudante com o máximo de detalhes e, em seguida, propor as interferências necessárias de ajustes no ambiente de aprendizagem.

Desta forma, sistematizar o processo está diretamente ligado a capacidade de modelar suas características, concepções e estratégias de raciocínio do estudante.

Diante deste assunto, foi pesquisado através do referencial teórico as novas tendências da área. Os trabalhos Dorca (2012) e Gonçalves (2015) despertaram grande interesse e foram objetos de pesquisa deste trabalho.

Assim sendo, o trabalho propôs algumas mudanças. Ao utilizar um algoritmo novo que mesclou as cadeias de Markov feitas por Dorça (2012) com a metodologia explicada na sessão 3.1 e ajustada devidamente após uma série de testes e comparando os melhores valores fixados com os resultados obtidos por Dorça (2012).

Para trabalhos futuros ficam aqui algumas sugestões:

- O teste de comparação usando algum outro algoritmo para preencher os três vetores inicialmente;
- Definir mais vetores de notas das CEA's e testar se fará alguma diferença no desempenho do aluno.
- Realizar simulações reais com alunos para verificar se o método implementado realmente tem algum impacto positivo sobre o aprendizado dos alunos.
- Utilizar uma mescla da Seleção de CEA's baseadas em nota e redes Bayesianas, Algoritmo Genético ou outro método que possua um embasamento teórico.
- Otimizar os algoritmos de Seleção Aleatória e Seleção Sequencial para melhorar seus desempenhos.

REFERENCIAS BIBLIOGRÁFICAS:

AZEVEDO, W. Panorama Atual da Educação a Distância no Brasil Wilson Azevêdo. p. 5, 2003.

BOTELHO, C. A. et al. Personalização em Sistemas de Gerenciamento da Aprendizagem em Conformidade com o Padrão SCORM. **Anais do Simpósio Brasileiro de Informática na Educação**, v. 1, n. 1, 2009.

BUENO, F. Cadeias de Markov: práticas e aplicações. **Resumos**, p. <https://wiki.ifsc.edu.br/mediawiki/images/d/d9/Cad>, 2009.

DEITEL. **Java Como Programar - Deitel - 4ª edição**, 2010.

DORÇA, F. et al. Adaptativity supported by neural networks in web-based educational systems. **Journal of Education**, ..., 2009.

DORÇA, F. A et al. Avaliação de Políticas de Aprendizagem por Reforço para Modelagem Automática e Dinâmica de Estilos de Aprendizagem: Uma Análise Experimental. **Anais do 23º Simpósio Brasileiro de Informática na Educação (SBIE 2012)**, n. Sbie, p. 26–30, 2012.

DORÇA, F. A. Fabiano Azevedo Dorça. 2012a.

DORÇA, F. A. Fabiano Azevedo Dorça. p. 207, 2012b.

FELDER, R. M.; BRENT, R. Cooperative Learning in Technical Courses: Procedures, Pitfalls and Payoffs. **Reproduction**, v. 377038, n. 2, p. 1–26, 1994.

FELDER, R.; SILVERMAN, L. Learning and teaching styles in engineering education. **Engineering education**, v. 78, n. June, p. 674–681, 1988.

FRIGO, L. B.; POZZEBON, E.; BITTENCOURT, G. O Papel dos Agentes Inteligentes nos Sistemas Tutores Inteligentes. p. 667–671, 2004.

GARCÍA, P. et al. Evaluating Bayesian networks' precision for detecting students' learning styles. **Computers and Education**, v. 49, n. 3, p. 794–808, 2007.

GIRAFFA, L. M. M.; VICCARI, R. M. Estratégias de Ensino em Sistemas Tutores Inteligentes Modelados através da Tecnologia de Agentes. **Revista Brasileira de Informática na Educação**, p. 260–269, 1999.

GONÇALVES, A. V. MODELAGEM AUTOMÁTICA E DINÂMICA DE ESTILOS DE APRENDIZAGEM EM SISTEMAS ADAPTATIVOS E INTELIGENTES PARA

EDUCAÇÃO A DISTÂNCIA: ESTUDO COMPARATIVO ENTRE DUAS ABORDAGENS. n. 1, p. 1–5, 2015.

GOULART, R.; GIRAFFA, L. Utilizando a tecnologia de agentes na construção de Sistemas Tutores inteligentes em ambiente interativo. **XII Simpósio Brasileiro de Informática na Educação**, p. 419–430, 2001.

GUELPELI, M. V. C.; RIBEIRO, C. H. C.; OMAR, N. Utilização de aprendizagem por reforço para modelagem autônoma do aprendiz em um tutor inteligente. **Revista Brasileira de Informática na Educação, SBC**, p. 69–77, 2004.

HOCKEMEYER, C.; ALBERT, D. **The Adaptive Tutoring System RATH** (M. E. Auer, U. Ressler, Eds.) ICL99 Workshop Interactive Computer aided Learning: Tools and Applications. **Anais...**Villach, Austria: Carinthia Tech Institute, 1999

JUAN, J. et al. Sistemas Tutores Inteligentes. **Heron**, p. 9, 2003.

JUNIOR, J. B. B.; COUTINHO, C. P. As ferramentas da web 2.0 no apoio à tutoria na formação em e-learning. **Tutoria e mediação em educação: novos desafios à investigação educacional: actas**, p. 1–11, 2008.

JUNIOR, M. A. C.; VIRTUOSO, G. H. F.; MARTINS, P. J. Propriedades Desejáveis a uma Linguagem de Programação: Uma Análise Comparativa entre as Linguagens C, C++ e Java. **Anais SULCOMP**, v. 1, n. 1, p. 0–3, 2012.

KAELBLING, L. P.; LITTMAN, M. L.; MOORE, A. W. Reinforcement Learning: A Survey. p. 237–285, 1996.

KALATZIS, A. A. C. A. Aprendizagem baseada em problemas em uma plataforma de ensino a distância com o apoio dos estilos de aprendizagem: uma análise do aproveitamento dos. p. 1–113, 2008.

KONZEN, A.; FROZZA, R. Uma estratégia de ensino híbrida para sistemas tutores inteligentes. **Santa Cruz do Sul: UNISC/DI/Curso de Ciência ...**, 1999.

KURI, N. P.; NÉLSON, A. Estilos de aprendizagem e recursos da hipermídia aplicados no ensino de planejamento de transportes. v. 19, n. 2, p. 111–137, 2006.

LIMA, L. V.; LOPES, C. R. Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. [s.d.].

LIMA, L. V.; LOPES, C. R. Detecção e Correção Automática de Estilos de Aprendizagem em Sistemas Adaptativos para Educação. **RITA**, v. 18, p. 179–204,

2011.

MARTINS, W. et al. Tutoriais Inteligentes Baseados em Aprendizado por Reforço : Concepção , Implementação e Avaliação Empírica. **Computer**, p. 550–559, 2007.

PINTO, C. A. S. ENSINO À DISTÂNCIA UTILIZANDO TICS - UMA PERSPECTIVA GLOBAL. **Journal of Chemical Information and Modeling**, v. 53, n. 9, p. 1689–1699, 2013.

PRETI, O. Educação a distância: uma prática educativa mediadora e mediatizada. **Educação a Distância: inícios e indícios de um ...**, p. 17–53, 1996.

SANTOS, C. T. DOS et al. DÓRIS - Um Agente de Acompanhamento Pedagógico em Sistemas Tutores Inteligentes. **Simpósio Brasileiro de Informática na Educação**, p. 97–105, 2001.

SILVA, D. H.; DORÇA, F. A. Uma Abordagem Automática para Personalização do Processo de Ensino Baseada em Estilos de Aprendizagem em Sistemas Adaptativos e Inteligentes para Educação a Distância. **Revista Brasileira de Informática na Educação**, v. 22, n. 02, p. 1, 2014.

SUTTON, R. and Barto, A. Reinforcement Learning: An Introduction. MIT Press, 1998.

WENGER, E.(1987) Artificial Intelligence and Tutoring Systems: Computational and Cognitive Approaches to the Communications of Knowledge. Los Altos, CA: Morgan Kaufmann Publishers.