

UNIVERSIDADE FEEVALE

ADONIS ANDRADES DIAS

INVESTIGAÇÃO SOBRE COMO DEEP LEARNING PODE SER EMPREGADO COM A
FINALIDADE DE ENSINO-APRENDIZADO DA TECNOLIGA (Título Provisório)

Anteprojeto de Trabalho de Conclusão

Novo Hamburgo, abril de 2016.

ADONIS ANDRADES DIAS
adonis.andradesdias@gmail.com

INVESTIGAÇÃO SOBRE COMO DEEP LEARNING PODE SER EMPREGADO COM A
FINALIDADE DE ENSINO-APRENDIZADO DA TECNOLIGA (Título Provisório)

Anteprojeto de Trabalho de Conclusão de
Curso, apresentado como requisito parcial
à obtenção do grau de Bacharel em
Ciência da Computação pela
Universidade Feevale

Professor orientador: Roberto Scheid

Novo Hamburgo, abril de 2016.

RESUMO

Nos últimos anos as maiores empresas de tecnologia do mundo, como Microsoft, Facebook e Google, estão investindo em pesquisas sobre novas tecnologias na área de inteligência artificial, como a tecnologia denominada *deep learning*. Deep learning pode ser definido como o conjunto de algoritmos e técnicas de aprendizado de máquina baseados na ideia de treinamento de redes camada por camada, possibilitando o aprendizado em diferentes níveis de representações. Esta tecnologia tem sido empregada em diversos sistemas de inteligência artificial. Em alguns casos os sistemas que se utilizam dessa técnica estão atingindo resultados melhores que os seres humanos, como no reconhecimento de imagens ou em partidas de jogos complexos como Go, que ocorreram em 2016. Desta forma, o presente trabalho propõe-se a investigar as principais técnicas de deep learning, suas aplicações e ferramentas disponíveis para empregá-la. Além disso, conceber a implementação de um software destinado ao ensino-aprendizado de deep learning, para demonstrar na prática o seu potencial.

Palavras-chave: Aprendizado de máquina. Deep learning. Inteligência artificial. Redes neurais.

SUMÁRIO

MOTIVAÇÃO.....	5
OBJETIVOS.....	9
METODOLOGIA.....	10
CRONOGRAMA.....	12
BIBLIOGRAFIA.....	13

MOTIVAÇÃO

Estudos sobre as redes neurais artificiais não são recentes, surgiram por volta de 1943 com o trabalho de Warren McCulloch e Walter Pitts (MCCULLOCH; PITTS apud RUSSEL; NORVIG, 2013), onde sugeriram um modelo de neurônios artificiais, que se definido adequadamente, seria capaz de aprender. Posteriormente em 1949, Donald Hebb retratou um estudo sobre uma regra de atualização para modificar a intensidade das conexões entre esses neurônios (HEBB apud RUSSEL; NORVIG, 2013). Marvin Minsky e Dean Edmonds (MINSKY; EDMONDS apud RUSSEL; NORVIG, 2013), criaram o primeiro computador de rede neural em 1950 em Harvard, o SNARC.

Na visão de Haykin (2001), uma rede neural é um sistema composto por unidades de processamento chamados neurônios, interligados através de conexões sinápticas. Esse tipo de sistema é projetado para modelar o funcionamento do cérebro humano, visto que o conhecimento é adquirido a partir do ambiente e utiliza-se de pesos sinápticos para armazená-lo. Utilizando-se desse modelo, uma rede neural desenvolve algumas características muito importantes para sua empregabilidade. Como, por exemplo, adaptação da rede de acordo com as mudanças do ambiente e na classificação de padrões, sendo que é capaz não só fornecer informações sobre qual padrão selecionar, mas também sobre a confiança na decisão tomada (HAYKIN, 2001).

Com relação à arquitetura de camadas das redes neurais Haykin (2001) frisa dois modelos. Primeiramente as redes de camada única, que possuem uma camada de entrada de neurônios de fonte (camada de entrada) e uma camada de neurônios de saída (nós computacionais). A camada de entrada de neurônios de fonte não é considerada, pois nenhuma computação é efetuada na mesma. Outro modelo de rede existente é a com múltiplas camadas. Essa rede caracteriza-se por possuir uma ou mais camadas ocultas de neurônios e quando adicionado uma ou mais camadas ocultas na rede, essa passa a possuir o poder de extrair estatísticas de ordem elevada (HAYKIN, 2001). Redes neurais com a característica de possuir duas ou mais camadas ocultas, são chamadas de *deep neural networks* ou redes neurais profundas (NIELSEN, 2015).

Sob a análise de Bengio (2009) por décadas pesquisadores tentaram treinar redes neurais profundas, porém antes de 2006 não houve relatos de sucesso nessa tarefa. Até então pesquisadores reportaram a utilização com sucesso de redes neurais com duas ou três camadas ocultas. No entanto, o treinamento de redes neurais com mais camadas ocultas forneciam

piores resultados. O que pode ser considerado um marco nessa área aconteceu em 2006, quando Geoffrey Hinton e seus colaboradores apresentaram as *Deep Belief Networks*, redes neurais profundas que podem ser treinadas camada por camada gradativamente (BENGIO, 2009).

Posteriormente algoritmos baseados em *auto-encoders* foram anunciados (LAMBLIN et al., 2007 apud BENGIO, 2009); (RANZATO et al., 2007 apud BENGIO, 2009), explorando as mesmas ideias divulgadas por Hinton, utilizando aprendizado não-supervisionado no treinamento das camadas intermediárias na rede. Outros algoritmos foram criados em 2009 com abordagens diferentes dos algoritmos anteriores (WESTON; RATLE; COLLOBERT, 2008 apud BENGIO, 2009); (MOBAHI; COLLOBERT; WESTON, 2009 apud BENGIO, 2009). Conforme Bengio (2009), esse conjunto de algoritmos e técnicas de aprendizado de máquina são conhecidos como *deep learning* e baseiam-se na ideia de treinamento da rede camada por camada, possibilitando o aprendizado em diferentes níveis de representações (BENGIO, 2009).

Em outubro de 2006, Geoffrey Hinton, publicou um artigo para demonstrar algoritmos para a solução de vários problemas enfrentados por pesquisadores, até então, no treinamento de redes neurais artificiais com várias camadas ocultas. Como exemplo desses problemas podem ser citados a inequação das *support vector machines* no reconhecimento de objetos 3D (LECUN et al., 2004 apud HINTON, 2006) e na utilização do algoritmo *backpropagation* (HINTON, 2006).

De acordo com Geoffrey Hinton (2006), no algoritmo *backpropagation*, o primeiro algoritmo a ser eficiente no ensinamento de redes neurais com mais de uma camada, existe o problema da necessidade de estabelecer valores aleatórios para os pesos sinápticos. Uma tarefa complexa, pois os valores dos pesos não podem ser baixos, pelo fato dos gradientes diminuírem na retro propagação pelas camadas ocultas e nem altos demais, selecionando aleatoriamente uma região particular da rede. Outro problema desse algoritmo é que para grandes redes neurais é necessária uma quantidade significativa de dados classificados para treinamento (HINTON, 2006).

Portanto, Geoffrey Hinton (2006) descreve uma nova estratégia para ser integrada nos treinamentos de redes neurais profundas. A estratégia baseia-se na realização de um pré-treinamento não supervisionado camada por camada da rede, fazendo com que as unidades ocultas de cada camada transmitam regras para os padrões de atividade da camada inferior a atual (HINTON, 2006).

Após as descobertas do grupo de pesquisadores do *Canadian Institute for Advanced Research*, o interesse nas pesquisas sobre redes neurais profundas foram renovados possibilitando vários avanços no campo da inteligência artificial (LECUN; BENGIO; HINTON, 2015). A seguir serão relatados quatro projetos que empregam deep learning para melhorar o desempenho de sistemas de inteligência artificial.

1. Pesquisadores da empresa Deep Mind, adquirida pelo Google, em artigo publicado na revista de ciência Nature em 28 de janeiro de 2016, anunciaram o primeiro sistema computacional GO, chamado AlphaGo, a vencer um jogador profissional. O jogo Go é considerado o mais desafiador para programas de inteligência artificial, contendo 250^{150} possibilidades de movimentos em comparação ao xadrez que possui cerca de 35^{80} . O programa AlphaGo utiliza redes neurais profundas combinadas para aprimorar a política de seleção de ações no jogo, bem como para prever o resultado de cada jogada. Também foi introduzido no sistema uma *Monte Carlo Tree Search* para ler sequências de jogadas futuras, sendo guiada pelas redes neurais para reduzir seu espaço de busca (SILVER et al., 2016).
2. Com o propósito de utilizar processamento de linguagem natural para criar uma máquina capaz de ler, entender o contexto do que foi lido e responder a perguntas sobre o texto processado, pesquisadores do Google empregaram deep learning em uma base de dados supervisionada gerada especificamente para o treinamento da rede. O sistema é composto por três redes neurais do tipo *long short term memory*, a primeira faz leitura dos documentos e das perguntas, a segunda rede deve realizar buscas de dependências para assimilar as respostas às perguntas e a terceira rede, tem o objetivo de reler os documentos a cada *token* lido da pergunta para regularmente acumular informações sobre a mesma e gerar uma representação da pergunta sobre os documentos (HERMANN et al., 2015).
3. Outro projeto desenvolvido pelos pesquisadores do Google visa o processamento de imagens. Uma das vantagens de modelagem generativa é que existe uma vasta quantidade de dados disponíveis de onde se pode aprender. Porém no caso das imagens, por serem altamente dimensionáveis e estruturadas, estimar a sua distribuição é extremamente desafiador. Neste projeto os pesquisadores elaboraram um sistema com duas *deep recurrent neural networks* para aplicá-las na modelagem de larga escala de imagens

naturais. O objetivo principal do projeto é estimar uma distribuição de imagens naturais que pode ser utilizada para processar a probabilidade de imagens ou a geração de novas (OORD; KALCHBRENNER; KAVUKCUOGLU, 2016).

4. Além do Google, a Microsoft também está investindo em deep learning. Recentemente a Microsoft venceu seu rival Google na disputa pelo melhor resultado na competição ImageNet de reconhecimento de imagens. Na competição o software desenvolvido pela Microsoft atingiu a taxa de erro de 3,57%, abaixo da taxa de erro estimada para humanos de 5,1% (RUSSAKOVSKY et al., 2015). Para atingir essa marca no teste, uma nova abordagem de deep learning foi empregada, baseada em *residual networks*. Nessa arquitetura de rede existem conexões de atalhos entre as camadas, paralelas com as conexões padrões, possibilitando o treinamento de redes com uma profundidade maior de camadas. (HE et al., 2015).

Atualmente as pesquisas sobre deep learning e suas possíveis aplicações são amplas, bem como no que diz respeito às tecnologias desenvolvidas para a sua implementação. Isso se deve ao fato de que deep learning, além de abranger técnicas de computação relativamente recentes, considerando a data de publicação do artigo de Geoffrey Hinton no ano de 2006, estão sendo realizadas diversas pesquisas e novas descobertas na área por equipes das maiores empresas de tecnologia do mundo, como Microsoft, Facebook e Google, com relação ao potencial da tecnologia e desenvolvimento de ferramentas e técnicas para a sua implementação.

Com base nas informações que foram apresentadas acima, surge a problemática da pesquisa: **Com relação ao conceito de deep learning, como implementá-lo para o desenvolvimento de uma ferramenta voltada ao ensino-aprendizado da tecnologia?**

Inerente à questão introduzida, o presente trabalho propõe-se a investigar as principais técnicas de deep learning, as suas atuais e possíveis aplicações, não obstante, explorar as ferramentas disponíveis para sua implementação, afim de gerar conhecimento sobre o assunto e tê-lo como base para futuros estudos. Ademais, neste trabalho será sugerido uma modelagem de implementação de um software destinado ao ensino-aprendizado, para demonstrar na prática o potencial do deep learning.

OBJETIVOS

Objetivo geral

Investigar como o conceito de aprendizado de máquina, deep learning, pode ser empregado como ferramenta de ensino-aprendizado da tecnologia.

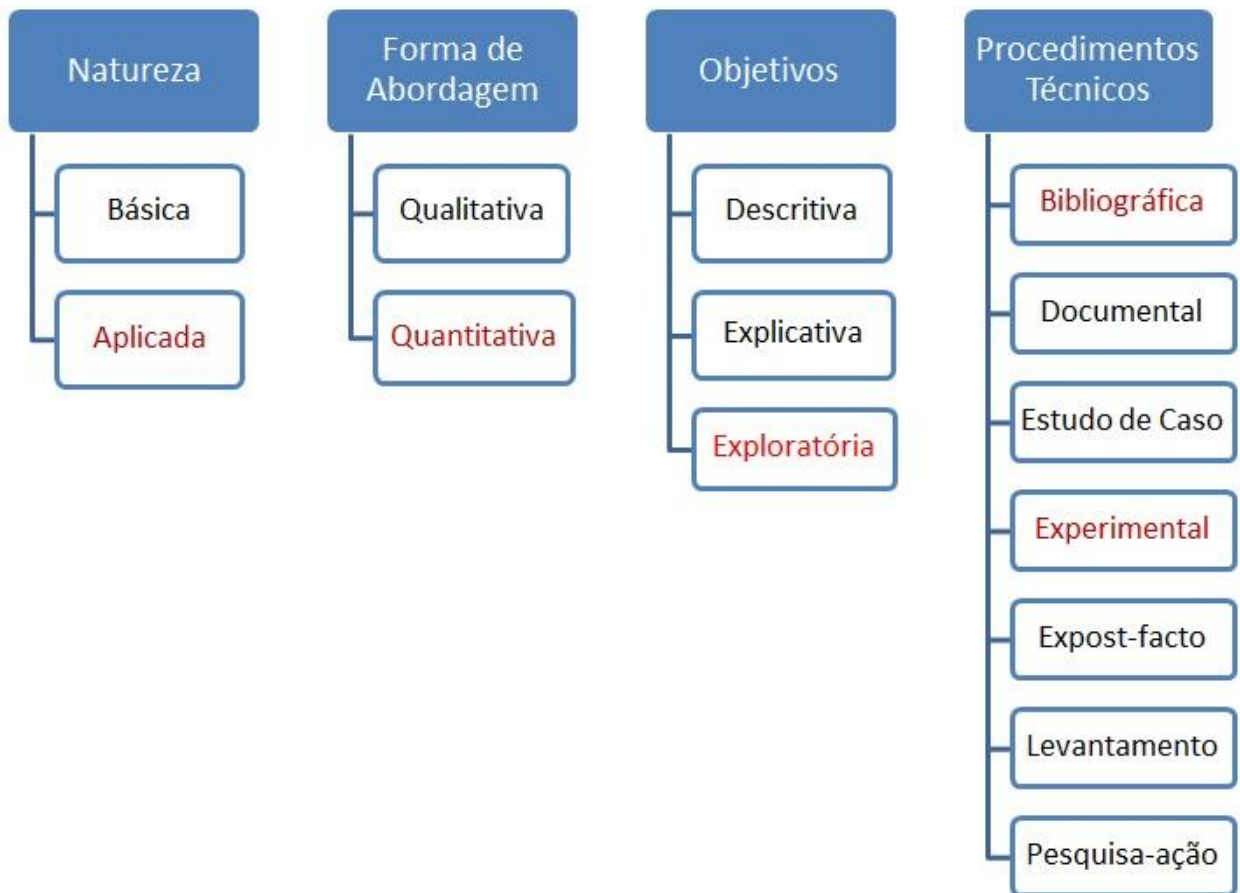
Objetivos específicos

- Realizar um estudo teórico sobre os principais métodos de aprendizado de máquina com base no conceito de deep learning;
- Pesquisar sobre as atuais e possíveis aplicações de deep learning;
- Pesquisar as ferramentas disponíveis para a implementação de deep learning;
- Apresentar uma implementação do conceito de deep learning em uma ferramenta voltada para o ensino-aprendizado da tecnologia;
- Realizar simulações com a implementação do conceito de deep learning conforme o modelo proposto.

METODOLOGIA

A figura abaixo ilustra a metodologia utilizada e o tipo de pesquisa que baseia-se este trabalho, onde os quadros destacados em vermelho indicam os procedimentos utilizados.

Figura 1 – Classificação da pesquisa



Fonte: adaptado de Bez (2011).

Conforme os conceitos metodológicos expostos por Prodanov e Freitas (2013). A natureza deste trabalho caracteriza-se como uma pesquisa aplicada, onde será empregado o conhecimento adquirido para a implementação de um novo conceito de inteligência artificial, utilizado para solucionar problemas específicos.

O objetivo do estudo é exploratório, para que se possa gerar conhecimento sobre um novo conceito de inteligência artificial e com isso auxiliar o desenvolvimento de futuros trabalhos na área. Segundo Prodanov e Freitas (2013) “tem como finalidade proporcionar

mais informações sobre o assunto que vamos investigar, possibilitando sua definição e seu delineamento, isto é, facilitar a delimitação do tema da pesquisa; orientar a fixação dos objetivos e a formulação das hipóteses ou descobrir um novo tipo de enfoque para o assunto”.

Por fim, seguindo os conceitos de Prodanov e Freitas (2013), quanto aos procedimentos técnicos, o presente trabalho compreenderá uma pesquisa bibliográfica, que significa a busca do referencial teórico necessário para o estudo, utilizando-se para isso livros, artigos científicos, teses e outros trabalhos de conclusão de graduação. Além disso, este trabalho trata-se de uma pesquisa experimental, visto que será realizado uma modelagem de implementação do conceito de deep learning.

CRONOGRAMA

Trabalho de Conclusão I

Etapa	Meses					
	Fev	Mar	Abr	Mai	Jun	Jul
Entrega do Aceite de Orientação	■	■				
Elaboração do Anteprojeto	■	■	■			
Estudo sobre redes neurais		■	■			
Estudo sobre deep learning			■	■		
Estudo sobre as diferentes técnicas de deep learning			■	■	■	
Estudo sobre trabalhos relacionados à deep learning			■	■	■	
Desenvolvimento do Trabalho de Conclusão I	■	■	■	■	■	■
Entrega do Trabalho de Conclusão I					■	■

Trabalho de Conclusão II

Etapa	Meses				
	Ago	Set	Out	Nov	Dez
Estudo sobre ferramentas para implementação de deep learning	■	■			
Implementação do software para simulação		■	■		
Simulação no software			■		
Desenvolvimento do Trabalho de Conclusão II	■	■	■	■	■
Entrega do Trabalho de Conclusão II					■
Apresentação do trabalho na Banca					■

BIBLIOGRAFIA

BARRETO, Jorge M. **Introdução às redes neurais artificiais**. Departamento de Informática e Estatística, UFSC, 2002. Disponível em: <https://intranet.dcc.ufba.br/pastas/mecateam/material_de_estudo/ia/iaconexionista/RedesNeurais.pdf>. Acessado em 05/03/2016.

BENGIO, Yoshua. **Learning deep architectures for AI**, 2009. Disponível em <[http://sanhv.com/download/soft/machine%20learning,%20artificial%20intelligence,%20mathematics%20ebooks/ML/learning%20deep%20architectures%20for%20AI%20\(2009\).pdf](http://sanhv.com/download/soft/machine%20learning,%20artificial%20intelligence,%20mathematics%20ebooks/ML/learning%20deep%20architectures%20for%20AI%20(2009).pdf)>. Acessado em 05/03/2016.

BEZ, M. R. **Uso de tecnologia para apoiar a implantação de métodos ativos nos currículos de medicina**. Proposta de Tese. Centro Interdisciplinar de Novas Tecnologias na Educação, Universidade Federal do Rio Grande do Sul, Porto Alegre. 2011.

HAYKIN, Simon. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HE, Kaiming, ZHANG, Xiangyu, REN Shaoqing, SUN, Jian. **Deep residual learning for image recognition**, 2015. Disponível em: <<http://arxiv.org/pdf/1512.03385v1.pdf>>. Acessado em 05/03/2016.

HERMANN, Karl Moritz, KOCISKY, Tomas, GREFFENSTETTE, Edward, ESPEHOLT, Lasse, KAY, Will, SULEYMAN, Mustafa, BLUNSOM, Phil. **Teaching machines to read and comprehend**, 2015. Disponível em: <<http://papers.nips.cc/paper/5945-teaching-machines-to-read-and-comprehend>>. Acessado em 05/03/2016.

HINTON, Geoffrey. **To recognize shapes, first learn to generate images**, 2006. Department of Computer Science, University of Toronto. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.443.8824&rep=rep1&type=pdf>>. Acessado em 05/03/2016.

LECUN, Yann, BENGIO, Yoshua, HINTON, Geoffrey. Deep learning. **Nature**, Volume 521, maio de 2015. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.436.894&rep=rep1&type=pdf>>. Acessado em: 05/03/2016.

NIELSEN, Michael A. **Neural networks and deep learning**, Determination Press, 2015. Disponível em: <<http://neuralnetworksanddeeplearning.com/index.html>>. Acessado em 15/01/2016.

OORD, Aaron van den, KALCHBRENNER, Nal, KAVUKCUOGLU, Koray. **Pixel recurrent neural networks**, 2016. Disponível em: <<http://arxiv.org/pdf/1601.06759>>. Acessado em 05/03/2016.

PRODANOV, Cleber Cristiano, FREITAS, Ernani Cesar de. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**, 2013. Disponível em: <<http://www.feevale.br/cultura/editora-feevale/metodologia-do-trabalho-cientifico---2-edicao>>. Acessado em: 05/03/2016.

RUSSAKOVSKY, Olga, DENG, Jia, SU Hao, KRAUSE Jonathan, SATHEESH, Sanjeev, MA Sean, HUANG, Zhiheng, KARPATHY, Andrej, KHOSLA, Aditya, BERNSTEIN, BERG, Michael Alexander C., FEI-FEI Li. **ImageNet large scale visual recognition challenge**, 2015. Disponível em: <<http://arxiv.org/pdf/1409.0575.pdf>>. Acessado em 05/03/2016.

RUSSELL Stuart, NORVIG, Peter. **Inteligência artificial**. Rio de Janeiro: Elsevier, 2013.

SILVER, David, SCHRITTWIESER, Julian, KALCHBRENNER, Nal, NHAM, John, GRAEPEL, Thore, HUANG, Aja, ANTONOGLU, Ioannis, HASSABIS, Demis, MADDISON, Chris J., SUTSKEVER, Ilya, GUEZ, Arthur, PANNEERSHELVAM, Veda, LILLICRAP, Timothy, SIFRE, Laurent, LANCTOT, Marc, LEACH, Madeleine, DRIESSCHE, George van den, DIELEMAN, Sander, KAVUKCUOGLU, Koray, GREWE, Dominik. **Mastering the game of Go with deep neural networks and tree search**, 2016. Disponível em: <<http://willamette.edu/~levenick/cs448/goNature.pdf>>. Acessado em 05/03/2016.