

Adriano Alonso Veloso

e-mail: adrianov@dcc.ufmg.br

UNIVERSIDADE FEDERAL DE MINAS GERAIS
DEPARTAMENTO DE CIÊNCIA DA COMPUTAÇÃO

NOVOS ALGORITMOS E ARQUITETURAS PARA
APRENDIZADO PROFUNDO

Projeto apresentado como requisito à renovação da
Bolsa de Produtividade em Pesquisa do CNPq.

Projeto Anterior (Agosto 2014 – Julho 2017)

O proponente tem bolsa de produtividade em curso, e portanto a seguir são descritas as metas referentes à proposta anterior, bem como os resultados obtidos.

Metas do Projeto Anterior: (i) projetar, implementar e validar novos algoritmos de aprendizado de máquina baseados em supervisão limitada para modelagem de linguagem natural; (ii) avaliar a efetividade prática dos algoritmos desenvolvidos em aplicações relevantes e desafiadoras; (iii) formar 3 doutores, 8 mestres e 8 alunos de iniciação científica; (iv) publicar 6 artigos em periódicos, 8 artigos em conferências internacionais e 6 artigos em conferências nacionais; e (v) publicar e transferir toda a tecnologia produzida durante o projeto para fins de pesquisa e desenvolvimento tecnológico.

Resultados Alcançados: (i), (ii) e (v) métodos e algoritmos baseados em supervisão limitada para modelagem de linguagem natural foram projetados, implementados e validados. A transferência da tecnologia foi realizada seguindo o modelo adotado pela UFMG e foram base para a criação de duas empresas: Stella (<http://www.stella.mobi>) e Kunumi (<http://kunumi.ai>); (iii) duas doutoras (Evelin Amorin e Mariane Souza) passaram pela qualificação de tese, e serão doutoras até 2018. Formamos 11 mestres (Alison Marczewski [9], André Lloyd [8], Vinícius Melo [7], André Costa [2], Cristiano Carvalho [4], Carlos Freitas [5], Edgard de Freitas Jr. [6], Alexandre Davis [3], Keiller Nogueira [10], Alberto Albuquerque [1], Gianlucca Zuin [11]), e 8 alunos de iniciação científica (Dan Valle, Alex Barros, Érico Pereira, Igor Marques, Isabella Brito, André Lloyd, Eduardo Nigri, Sérgio Barbosa); (iv) publicamos 10 artigos em periódicos [26–33, 35, 54], 7 artigos em conferências internacionais [12, 14, 15, 17, 18, 43, 49] (outros 6 artigos estão submetidos e em processo de avaliação por pares com desfecho até o próximo mês), e 7 artigos em conferências nacionais [19, 21–24, 62].

Atuação no Período

De acordo com a Chamada CNPq No 12/2017 – Bolsas de Produtividade em Pesquisa, ANEXO I – Critérios dos Comitês Assessores, o item “Critérios Específicos” do documento CC – Ciência da Computação, menciona: *“De forma complementar, têm sido levados em consideração outros indicadores objetivos tais como orientações concluídas, total de recursos obtidos em projetos de pesquisa, prêmios e distinções recebidas e participação em comitês científicos. Nas atividades de orientação, alguns aspectos analisados são: quantos alunos de mestrado/doutorado concluíram suas dissertações/teses sob sua orientação no período relevante para o julgamento? Que trabalhos associados a essas orientações foram publicados ou submetidos para publicação em periódicos e/ou eventos nacionais e/ou internacionais? Qual a importância dessas publicações na área de pesquisa da pós-graduação em questão? Quantas orientações de mestrado e doutorado estão em andamento? Que tipos de cursos de pós-graduação relacionados à sua pesquisa o proponente tem lecionado? Com que regularidade? Em que tipo de programa ou circunstância (e.g. cursos convidados em outras instituições, tutoriais em eventos relevantes, etc.)?”*

Assim sendo, apresentamos a seguir, de forma mais detalhada, indicadores objetivos a respeito da atuação acadêmica do proponente no período Agosto 2014 – Julho 2017.

Orientações Concluídas: Foram defendidas 11 dissertações de mestrado, detalhadas a seguir.

1. Alison Marczewski – Learning transferable features from multiple source domains for speech emotion recognition, 17/07/2017. Banca examinadora: Adriano Veloso (UFMG, orientador), Nivio Ziviani (UFMG), Hani Camille (UFMG). Artigos publicados: [49].
2. André Lloyd – Extending Markov models through gradient descent optimization, 30/03/2017. Banca examinadora: Adriano Veloso (UFMG, orientador), Leandro Balby (UFCG), Renato Assunção (UFMG), Renato Ferreira (UFMG). Artigo submetido e em avaliação por pares.
3. Gianlucca Zuin – Question-Answering with domain-adaptive nets, 30/07/2017. Banca examinadora: Adriano Veloso (UFMG, orientador), Nivio Ziviani (UFCG), Renato Assunção (UFMG). Artigo submetido e em avaliação por pares.
4. Vinícius Melo – JSFY: um modelo objetivo para compreensão de linguagem natural, 17/03/2017. Banca examinadora: Adriano Veloso (UFMG, orientador), Adriano Pereira (UFMG), Fernando Magno (UFMG). Artigo submetido e em avaliação por pares.
5. Alberto Albuquerque – Recodificação de atributos para learning to rank usando autoencoders, 23/06/2017. Banca examinadora: Renato Ferreira (UFMG, orientador), Adriano Veloso (UFMG, coorientador), Edleno de Moura (UFAM), Leandro Balby (UFCG), Nivio Ziviani (UFMG). Artigo submetido e em avaliação por pares.
6. André Costa – Mental disorder characterization from social media through deep learning, 05/04/2016. Banca examinadora: Adriano Veloso (UFMG, orientador), Cilene Rodrigues (PUC-RJ), Nivio Ziviani (UFMG), Pedro Olmo (UFMG). Artigos publicados: [19].
7. Edgard de Freitas Jr. – A robust deep convolutional neural network model for text categorization, 30/03/2016. Banca examinadora: Adriano Veloso (UFMG, orientador), Marco Cristo (UFAM), Wagner Meira Jr. (UFMG), Renato Ferreira (UFMG), Nivio Ziviani (UFMG). Artigo submetido e em avaliação por pares.
8. Alexandre Davis – Subject classification through context-enriched language models, 23/02/2015. Banca examinadora: Adriano Veloso (UFMG, orientador), Renato Assunção (UFMG), Wagner Meira Jr. (UFMG). Artigos publicados: [29].
9. Keiller Nogueira – Abordagens de aprendizado estatístico e profundo para os problemas de decomposição e anotação de peças de roupas em fotografias de moda, 23/02/2015. Banca examinadora: Adriano Veloso (UFMG, orientador), Jefersson Santos (Coorientador, UFMG), Nivio Ziviani (UFMG), Renato Ferreira (UFMG). Artigos publicados: [62] e [33].

10. Carlos Freitas – Robôs sociais: implicações na segurança e na credibilidade de serviços baseados em microblogs, 05/08/2014. Banca examinadora: Adriano Veloso (UFMG, orientador), Fabricio Benevenuto (UFMG, coorientador), Dorgival Guedes (UFMG), Marco Cristo (UFAM). Artigos publicados: [20], [30] e [14].
11. Cristiano Carvalho – Detecção de réplicas de sítios web usando aprendizado semi-supervisionado baseado em maximização de expectativas, 19/09/2014. Banca examinadora: Nivio Ziviani (UFMG, orientador), Adriano Veloso (UFMG, coorientador), Edleno de Moura (UFAM), Rodrygo Santos (UFMG). Artigos publicados: [27].

Orientações em Andamento: Há 4 orientações de doutorados e 6 orientações de mestrados em curso, detalhadas a seguir.

1. Mariane Souza, doutorado, Searching images in semantic spaces, defesa prevista para novembro de 2017. Artigos publicados: [17].
2. Evelin Amorim, doutorado, Automatic scoring of essays, defesa prevista para dezembro de 2017. Artigos publicados: [12].
3. Tiago Amador, doutorado, Generative adversarial networks for Information Retrieval, defesa prevista para janeiro de 2019.
4. Anderson Bessa, doutorado, Anticipating the quality of steel, defesa prevista para março de 2019.
5. Túlio Loures, mestrado (coorientador), Descrevendo entidades a partir de comentários online, defesa prevista para setembro de 2017. Artigos publicados: [22, 23].
6. Tiago Alves, mestrado (coorientador), Learning representations for intensive patients, defesa prevista para março 2018.
7. Alex Barros, mestrado (coorientador), Learning contextual language models, defesa prevista para março de 2018.
8. Vaux Gomes, mestrado (coorientador), Boosting associative classifiers, defesa prevista para setembro de 2017.
9. Tiago Pimentel, mestrado, Machine translation with reinforcement learning, defesa prevista para março de 2018. Artigos publicados: [18].
10. Dan Valle, mestrado, Representing the evolution of Alzheimer Dementia with deep convolutional networks, defesa prevista para março de 2019.

Recursos Obtidos/Projetos de Pesquisa: No período, o proponente atuou/atua como coordenador de 4 projetos de pesquisa, que são detalhados a seguir.

1. Laboratório de Inteligência Artificial – Projeto de Parceria de Pesquisa com a empresa Kunumi. Valor: R\$1.650.000,00.

2. Plataforma Big Data para Computação Cognitiva – Projeto de Pesquisa e Desenvolvimento em Parceria com a empresa Kunumi. Valor: R\$180.000,00.
3. Algoritmos de Aprendizado Profundo Reconhecimento e Identificação de Faces em Tempo Real – Fapemig Universal. Valor: R\$31.673,00.
4. Cont-Class: Algoritmos de Aprendizado para Classificação (Quasi-)Contígua – CNPq Universal. Valor: R\$46.200,00.
5. Aprendizado Pragmático com Supervisão Limitada para Modelagem de Linguagem Natural em Textos Curtos, CNPq Bolsa de Produtividade em Pesquisa, nível 2. Valor: R\$39.600,00.

No período, o proponente também participa/participou de outros 6 projetos, que são detalhados a seguir:

1. Arquitetura e Algoritmos Big Data para a Análise de Perícias Médicas – Projeto de Pesquisa e Desenvolvimento em Parceria com a empresa Dataprev. Valor: R\$888.695,00.
2. MASWEB, Modelos, Algoritmos e Sistemas para a Web – CNPq/Fapemig/Pronex. Valor: R\$330.000,00.
3. Desenvolvimento de Sistemas para Adaptabilidade à Carga e Condições de Operação em Data-Centers Corporativos – Projeto de Pesquisa e Desenvolvimento em Parceria com a empresa Engetron. Valor: R\$505.270,00.
4. EUBRA, BIGSEA, Europe Brazil Collaboration of Big Data Scientific Research through Cloud-Centric Applications – RNP/CNPq. Valor: R\$620.000,00.
5. INWeb, Instituto Nacional de Ciência e Tecnologia para a Web – MCT/CNPq. Valor: R\$2.300.000,00.
6. Observatório da Web para Saúde: Um estudo de Usuários, Comportamentos e Tendências – Projeto de Pesquisa e Desenvolvimento em Parceria com a empresa LG Electronics (LGE). Valor: R\$630.396,00.

Como detalhado, ao longo dos últimos três anos o proponente participou de projetos de pesquisa que totalizam R\$7.175.634,00, dos quais R\$1.901.273,00 são relativos a projetos coordenados pelo proponente.

Atuação na Comunidade Nacional: O proponente tem atividades relevantes na comunidade científica da Computação no país. Durante o período em questão o proponente foi membro afiliado da Acadêmica Brasileira de Ciências (Engenharias). Além disso, o proponente atuou ativamente como membro do comitê de programa de conferências nacionais e como revisor de periódicos nacionais:

- Revisor para JIDM (Journal of Information and Data Management),

- Revisor para JBCS (Journal of the Brazilian Computer Society),
- Revisor para REIC (Revista Eletrônica de Iniciação Científica da SBC),
- Revisor para RITA (Revista de Informática Teórica e Aplicada).
- Membro do comitê de programa da BRASNAM 2017, 2016, 2015, (Brazilian Workshop on Social Network Analysis and Mining),
- Membro do comitê de programa do CTD 2016, 2015 (Concurso de Teses e Dissertações da Sociedade Brasileira de Computação),
- Membro do comitê de programa do Bracis 2016, 2015, 2014 (Brazilian Conference on Intelligent Systems),
- Membro do comitê de programa do SBBD 2017, 2016, 2015, 2014, 2013, 2012, 2011, 2010, 2009, 2008, 2007 (Simpósio Brasileiro de Banco de Dados),
- Membro do comitê de programa da WebMedia 2017, 2016, 2015 (Simpósio Brasileiro de Sistemas Multimídia e Web),
- Membro do comitê de programa do CTIC 2017, 2016, 2015, 2014, 2013, 2012 (Concurso Nacional de Trabalhos de Iniciação Científica da Sociedade Brasileira de Computação).
- Membro do comitê de programa do KDMile 2016, 2015, 2014 (Brazilian Symposium on Knowledge Discovery, Mining and Learning).
- Membro do comitê de programa do SIBGRAPI 2017 (Brazilian Conference on Graphics, Patterns and Images).

O proponente também tem atuado como revisor de projeto de fomento para as agências: Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Fundação de Amparo à Pesquisa do Estado do Amazonas (FAPEAM), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG), Fundação de Amparo à Pesquisa do Estado da Bahia (FAPESB), e Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq).

Atuação na Comunidade Internacional: O proponente tem trabalhado como revisor dos mais importantes periódicos das áreas de Aprendizado de Máquina e Mineração de Dados:

- Data & Knowledge Engineering – Elsevier,
- Distributed and Parallel Databases – Springer,
- Information Sciences – Elsevier,
- Information Systems – Elsevier,
- Information Processing & Management – Elsevier,

- The VLDB Journal – VLDB Endowment,
- Transactions on Knowledge and Data Engineering – IEEE,
- Transactions on Parallel and Distributed Systems – IEEE,
- Data Mining and Knowledge Discovery – Springer,
- Journal of Autonomous Agents and Multi-Agent Systems – Springer,
- Transactions on Intelligent Systems and Technology – ACM,
- Transactions on Knowledge Discovery from Data – ACM,
- Knowledge Engineering Review – Cambridge,
- Security and Communication Networks – Wiley

O proponente tem sido membro do comitê de programa dos seguintes eventos científicos internacionais:

- Internation Joint Conference on Artificial Intelligence, desde 2015.
- IEEE Big Data Conference, desde 2014,
- ACM CIKM Conference on Information and Knowledge Management, desde 2014,
- SIAM International Conference on Data Mining, desde 2014,
- AAAI International Conference on Web and Social Media, desde 2014,
- International Joint Conference on Natural Language Processing, desde 2014,
- ACM Web Science Conference, desde 2013,
- IEEE International Conference on Data Mining, desde 2012,
- String Processing and Information Retrieval Conference, desde 2012,
- World Wide Web Conference, desde 2012,
- European Conference on Machine Learning and Principles and Practice of Knowledge Discovery in Databases, desde 2010,
- ACM SIGKDD Conference on Knowledge Discovery and Data Mining, desde 2012,
- ACM SIGIR Conference on Research and Development in Information Retrieval, desde 2011,

Também apresentamos na Tabela 1 o sumário de indicadores de produtividade do proponente nos últimos 3 anos e nos últimos 10 anos. Informações mais detalhadas e atualizadas podem ser encontradas no currículo Lattes do proponente¹. Como pode ser visto na Figura 1, nos últimos anos o proponente vem focado em publicações no extrato superior. Cerca de 80% das publicações do proponente estão no extrato superior. Além disso, o número de publicações sem qualificação cresce porque o proponente vem publicando em conferências novas (a despeito delas ainda não terem entrada no Qualis).

Indicador	3 anos	10 anos
H-Index (<i>Publish or Perish</i>)	19	23
Citações (<i>Publish or Perish</i>)	805	1621
Periódicos	10	23
Artigos em conferências	15	56
Orientações concluídas	19	19
Doutorado	—	1
Mestrado	11	22
Iniciação Científica	8	16
Orientações em andamento	15	—
Doutorado	4	—
Mestrado	6	—
Iniciação Científica	5	—
Projetos de pesquisa na própria instituição	8	16
Coordenação	5	8
Participação	3	8
Projetos de pesquisa multi-institucional	3	6
Participação	3	6
Projetos de pesquisa de cooperação internacional	1	3
Participação	1	3
Projetos de pesquisa com org. públicas ou privadas	5	11
Coordenação	2	4
Participação	3	7
Revisor de periódicos	18	22
Nacionais	4	5
Internacionais	14	17
Eventos	21	23
TPC de conferências nacionais	8	8
TPC de conferências internacionais	13	15

Tabela 1: Sumários dos indicadores de pesquisa.

Cursos de Pós-Graduação: O proponente leciona regularmente os cursos de Aprendizado de Máquina/Aprendizado Profundo (desde 2010), e de Processamento de Linguagem

¹<http://buscatextual.cnpq.br/buscatextual/visualizacv.do?id=K4762232P7>

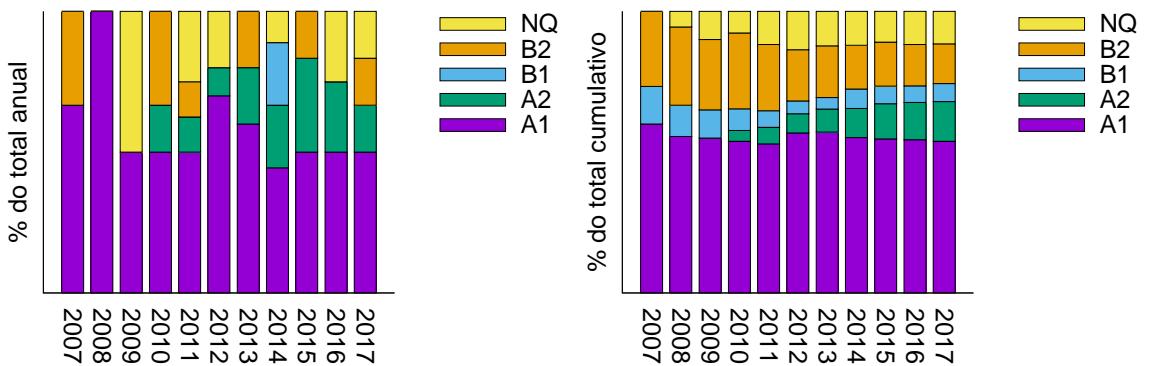


Figura 1: Qualificação das publicações por ano e cumulativo (tendência).

Natural (desde 2015). A Tabela 2 mostra o número de alunos matriculados nessas disciplinas anualmente.

Tabela 2: Disciplinas lecionadas por semestre e com tamanho de cada turma.

Semestre	Nome da disciplina	Matriculados
2010.2	Aprendizado de Máquina (PG)	35 (grad) + 41 (pós)
2012.1	Aprendizado de Máquina (PG)	17 (grad) + 28 (pós)
2013.1	Aprendizado de Máquina (PG)	21 (grad) + 36 (pós)
2014.1	Aprendizado de Máquina (PG)	27 (grad) + 31 (pós)
2015.1	Aprendizado de Máquina (PG)	30 (grad) + 33 (pós)
2015.2	Processamento de Linguagem Natural (PG)	7 (grad) + 14 (pós)
2016.1	Aprendizado de Máquina (PG)	34 (grad) + 26 (pós)
2016.2	Processamento de Linguagem Natural (PG)	5 (grad) + 17 (pós)
2017.1	Aprendizado de Máquina (PG)	28 (grad) + 44 (pós)
2010.1–2017.1		194 (grad) + 270 (pós)

Dissertações Defendidas

- [1] Alberto Albuquerque. Recodificação de atributos para learning to rank usando autoencoders (Mestrado), 2017.
- [2] André Costa. Mental disorder characterization from social media through deep learning (Mestrado), 2016.
- [3] Alexandre Davis. Subject classification through context-enriched language models (Mestrado), 2015.

- [4] Cristiano Rodrigues de Carvalho. Detecção de réplicas de sítios web usando aprendizado semi-supervisionado baseado em maximização de expectativas (Mestrado), 2014.
- [5] Carlos Alessandro Sena de Freitas. Robôs sociais: implicações na segurança e na credibilidade de serviços baseados em microblogs (Mestrado), 2014.
- [6] Edgard de Freitas Jr. A robust deep convolutional neural network model for text categorization (Mestrado), 2016.
- [7] Vinicius Garcia. Jspy: um modelo objetivo para compreensão de linguagem natural (Mestrado), 2017.
- [8] André Lloyd Dwight Perlee Harder. Extending markov models through gradient descent optimization (Mestrado), 2017.
- [9] Alison Marczewski. Learning transferable features from multiple source domains for speech emotion recognition (Mestrado), 2017.
- [10] Keiller Nogueira. Abordagens de aprendizado estatístico e profundo para os problemas de decomposição e anotação de peças de roupas em fotografias de moda (Mestrado), 2015.
- [11] Gianlucca Zuin. Sistemas pergunta-resposta com adaptação de domínio (Mestrado), 2017.

Conferências Internacionais

- [12] Evelin Amorim and Adriano Veloso. A multi-aspect analysis of automatic essay scoring for brazilian portuguese. In *Conference of the European Chapter of the Association for Computational Linguistics, EACL*, pages 94–102, 2017.
- [13] Roberto Lourenço de Oliveira Jr., Adriano Veloso, Adriano C. M. Pereira, Wagner Meira Jr., Renato Ferreira, and Srinivasan Parthasarathy. Economically-efficient sentiment stream analysis. In *37th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 637–646, 2014.
- [14] Carlos A. Freitas, Fabrício Benevenuto, Saptarshi Ghosh, and Adriano Veloso. Reverse engineering socialbot infiltration strategies in twitter. In *2015 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining, ASONAM*, pages 25–32, 2015.
- [15] Anísio Lacerda, Adriano Veloso, Rodrygo L. T. Santos, and Nívio Ziviani. Context-aware deal size prediction. In *21st International Symposium String Processing and Information Retrieval SPIRE*, pages 256–267, 2014.
- [16] Alison Marczewski, Adriano Veloso, and Nívio Ziviani. Learning transferable features for speech emotion recognition. In *30th ACM MM Multimedia Conference*, pages 490–510, 2017.

- [17] Mariane Moreira, Jefersson Alex dos Santos, and Adriano Veloso. Learning to rank similar apparel styles with economically-efficient rule-based active learning. In *International Conference on Multimedia Retrieval, ICMR*, page 361, 2014.
- [18] Tiago Pimentel, Adriano Veloso, and Nivio Ziviani. Unsupervised and scalable algorithm for learning node representations. In *5th International Conference on Learning Representations*, 2017.

Conferências Nacionais

- [19] André Costa and Adriano Veloso. Employee analytics through sentiment analysis. In *XXX Simpósio Brasileiro de Banco de Dados, SBBD*, pages 101–112, 2015.
- [20] Carlos Alessandro Sena de Freitas, Fabrício Benevenuto, and Adriano Veloso. Soci-albots: Implications on the safety and reliability of twitter-based services. In *2014 Brazilian Symposium on Computer Networks and Distributed Systems, SBRC*, pages 302–309, 2014.
- [21] Anísio Lacerda, Adriano Veloso, and Nivio Ziviani. Adding value to daily-deals recommendation: Multi-armed bandits to match customers and deals. In *2015 Brazilian Conference on Intelligent Systems, BRACIS 2015, Natal, Brazil, November 4-7, 2015*, pages 216–221, 2015.
- [22] Túlio Loures, Pedro Olmo Vaz de Melo, and Adriano Alonso Veloso. Generating entity representation from online discussions: Challenges and an evaluation framework. In *23rd Brazilian Symposium on Multimedia and the Web, WebMedia*, pages 341–344, 2017.
- [23] Túlio Loures, Pedro Vaz de Melo, and Adriano Veloso. É possível descrever episódios de séries de televisão a partir de comentários online? In *6th Brazilian Workshop on Social Network Analysis and Mining*, 2017.
- [24] Johnnatan Messias, Gabriel Magno, Fabrício Benevenuto, Adriano Veloso, and Virgílio A. F. Almeida. Brazil around the world: Characterizing and detecting brazilian emigrants using google+. In *21st Brazilian Symposium on Multimedia and the Web, WebMedia*, pages 85–91, 2015.
- [25] Adriano Alonso Veloso, Jefersson Alex dos Santos, and Keiller Nogueira. Learning to annotate clothes in everyday photos: Multi-modal, multi-label, multi-instance approach. In *27th SIBGRAPI Conference on Graphics, Patterns and Images, SIBGRAPI*, pages 327–334, 2014.

Periódicos

- [26] Aline Bessa, Rodrygo Santos, Adriano Veloso, and Nivio Ziviani. Exploiting item co-utility to improve collaborative filtering recommendations. *JASIST*, 2017.
- [27] Cristiano Carvalho, Edleno Moura, Adriano Veloso, and Nivio Ziviani. Website replica detection with distant supervision. *Inf. Retr. Journal*, 2017.
- [28] Gessé Dafé, Adriano Veloso, Mohammed J. Zaki, and Wagner Meira Jr. Learning sequential classifiers from long and noisy discrete-event sequences efficiently. *Data Min. Knowl. Discov.*, 29(6):1685–1708, 2015.
- [29] Alexandre Davis and Adriano Veloso. Subject-related message filtering in social media through context-enriched language models. *Trans. Computational Collective Intelligence*, 21:97–138, 2016.
- [30] Carlos Alessandro Sena de Freitas, Fabrício Benevenuto, Adriano Veloso, and Saptarshi Ghosh. An empirical study of socialbot infiltration strategies in the twitter social network. *Social Netw. Analys. Mining*, 6(1):23:1–23:16, 2016.
- [31] Anísio Lacerda, Rodrygo L. T. Santos, Adriano Veloso, and Nivio Ziviani. Improving daily deals recommendation using explore-then-exploit strategies. *Inf. Retr. Journal*, 18(2):95–122, 2015.
- [32] Christian Masdeval and Adriano Veloso. Mining citizen emotions to estimate the urgency of urban issues. *Inf. Syst.*, 54:147–155, 2015.
- [33] Keiller Nogueira, Adriano Alonso Veloso, and Jefersson Alex dos Santos. Pointwise and pairwise clothing annotation: combining features from social media. *Multimedia Tools Appl.*, 75(7):4083–4113, 2016.
- [34] Marco Túlio Ribeiro, Nivio Ziviani, Edleno Silva de Moura, Itamar Hata, Anísio Lacerda, and Adriano Veloso. Multiobjective pareto-efficient approaches for recommender systems. *ACM TIST*, 5(4):53:1–53:20, 2014.
- [35] Rodrigo M. Silva, Marcos André Gonçalves, and Adriano Veloso. A two-stage active learning method for learning to rank. *JASIST*, 65(1):109–128, 2014.

NOVOS ALGORITMOS E ARQUITETURAS PARA APRENDIZADO PROFUNDO

Sumário Executivo

Objetivos: O principal objetivo deste projeto é desenvolver métodos e algoritmos de Aprendizado Profundo utilizando novas arquiteturas aprimoradas a partir de redes recorrentes, convolucionais, adversariais, sequência-sequência, treinadas através de supervisão e adaptação de domínio, ou por reforço. Objetivos secundários incluem a exploração de diferentes cenários de aplicação, envolvendo tarefas de Processamento de Linguagem Natural e Visão Computacional, tais como tradução automática, análise semântica, análise de emoções a partir da fala, sistemas de pergunta-resposta, reconhecimento de padrões e objetos em imagens, busca por imagens em espaços semânticos, entre outras.

Motivação: Uma grande ambição da comunidade de Aprendizado de Máquina é prover soluções a tarefas complexas com níveis de precisão próximos ou superiores à inteligência humana. Recentemente tal ambição vem sendo atingida em decorrência de avanços na área de Aprendizado Profundo. Algumas tarefas complexas em Processamento de Linguagem Natural e Visão Computacional, por exemplo, já possuem soluções baseadas em arquiteturas profundas que mostram resultados superiores aos atingidos por humanos. Arquiteturas profundas também já superam os humanos em diversos jogos complexos. Neste projeto propomos novos algoritmos de Aprendizado Profundo, sejam eles baseados em arquiteturas recorrentes, convolucionais, adversariais, sequência-sequência, e treinados via reforço ou através de supervisão e adaptação de domínio. Tais algoritmos devem avançar o estado-da-arte, seja em termos de precisão da solução ou em termos de custo computacional ou complexidade de treinamento.

Descrição: O projeto é organizado em três camadas. Na primeira camada iremos definir as fontes de dados, coletar e preparar os dados com as características de nosso interesse. A segunda camada envolve a elaboração de novos algoritmos e arquiteturas de Aprendizado Profundo. Finalmente, na terceira camada iremos avaliar as arquiteturas e os algoritmos desenvolvidos em diversas tarefas de Processamento de Linguagem Natural e Visão Computacional.

Resultados Esperados: Ao fim deste projeto (36 meses) espera-se obter os seguintes resultados: (i) projetar, implementar e validar novos algoritmos de Aprendizado Profundo baseados em arquiteturas de redes recorrentes, convolucionais, adversariais, sequência-sequência, treinadas por reforço ou através de supervisão e adaptação de domínio; (ii) avaliar a efetividade prática dos algoritmos desenvolvidos em tarefas relevantes e desafiadoras relacionadas ao Processamento de Linguagem Natural e Visão Computacional; (iii) formar 2 doutores, 8 mestres e 8 alunos de iniciação científica; (iv) publicar 6 artigos em periódicos, 10 artigos em conferências internacionais e 6 artigos em conferências nacionais; e (v) publicar e prover acesso ao estado-da-arte a academia e empresas para que essas possam se beneficiar de oportunidades abertas pelo Aprendizado Profundo.

Relação com o Projeto Anterior (Agosto 2014 – Julho 2017): O projeto anterior foi focado no desenvolvimento de algoritmos de Aprendizado de Máquina baseados em supervisão limitada para modelagem de linguagem natural. Os algoritmos desenvolvidos foram avaliados em diferentes cenários de aplicação, mostrando-se especialmente efetivos em aplicações relacionadas à Linguística Computacional, tais como análise de sentimentos, avaliação automática de redações, detecção de viés em correções, produção de texto em redes sociais online, e remoção de ambiguidade em comunicação baseada em pequenos textos. Desta forma, pretendemos aprimorar nossos algoritmos de Aprendizado Profundo, bem como projetar e desenvolver novos algoritmos, e explorar outros desafios computacionais e cenários de aplicação, especialmente os relacionados ao Processamento de Linguagem Natural e à Visão Computacional.

Recursos Solicitados: Solicitamos a manutenção da bolsa de produtividade em pesquisa nível 2, ou a progressão para a bolsa de produtividade em pesquisa nível 1D, considerando a nossa produção técnico-científica e atuação acadêmica.

1 Introdução

A Inteligência Artificial mostrou grandes avanços ao longo das últimas cinco décadas ao propor soluções para tarefas intelectualmente difíceis para os humanos, mas relativamente fáceis de serem descritas por regras formais ou matemáticas. Atualmente, o grande desafio na área consiste em encontrar soluções automáticas para tarefas consideradas fáceis para os humanos, mas ao mesmo tempo difíceis de serem descritas formalmente. Nós, humanos, geralmente solucionamos essas tarefas de maneira intuitiva, aparentemente automática, como acontece com o entendimento de fala ou reconhecimento de objetos em imagens. Embora essas sejam tarefas que lidamos a todo o momento, não sabemos explicar bem como as realizamos.

As áreas de Processamento de Linguagem Natural e Visão Computacional são repletas de tarefas intuitivas, mas que raramente têm soluções que possam ser descritas formalmente. Uma abordagem em particular vem mostrando-se altamente eficaz para realizar tais tarefas, e consiste basicamente em programar o computador para que ele simule algum processo de aprendizado. Na prática, o computador extrai padrões a partir de grandes quantidades de dados para construir um modelo — um processo conhecido como Aprendizado de Máquina. Modelos obtidos através do processo de Aprendizado de Máquina substituem a necessidade de descrever formalmente a solução, e há diferentes tipos de modelos. Um tipo de modelo em especial é dado em termos de uma hierarquia de conceitos na qual cada conceito é definido em termos de conceitos mais simples. Redes neurais profundas são modelos baseados nessa abordagem e correspondem a uma hierarquia de conceitos com diversos níveis de abstração.

Há atualmente uma grande diversidade de arquiteturas para redes neurais profundas. Dentre as arquiteturas mais conhecidas podemos incluir as redes totalmente conectadas, as redes convolucionais, as redes recorrentes, as redes auto-associativas, e as redes adversariais. A escolha da arquitetura é dada em termos da tarefa a ser solucionada, bem como em termos do tipo, qualidade e quantidade de dados disponíveis para o treinamento. A estratégia de treinamento também varia bastante, incluindo treinamento por reforço ou por supervisão com adaptação de domínio. O treinamento ocorre pela minimização de uma função de perda adequada, que por sua vez se traduz em um processo de busca pelos parâmetros ótimos da rede neural. O sobreajuste do modelo é tipicamente evitado com a utilização de regularização. As redes neurais podem ser utilizadas para prever rótulos ou objetos estruturados, como arranjos ou sequências de rótulos.

Aparentemente, nos próximos anos a escolha pelo Aprendizado Profundo será cada vez mais frequente em diversas áreas de estudo, bem como na indústria. Ainda assim, há diversos desafios relacionados ao treinamento e utilização de redes neurais profundas:

- O quanto mais abstrata é a tarefa a ser solucionada, mais parâmetros precisam ser ajustados. Redes neurais com mais parâmetros requerem mais dados para treinamento. Atualmente, o número de parâmetros em redes profundas geralmente chega à ordem de alguns ou muitos milhões. De forma geral, para se assegurar a generalização, a demanda por dado de treinamento cresce quadraticamente em relação ao número de parâmetros da rede neural. Como treinar uma rede neural profunda de maneira eficaz quando a quantidade de treinamento é insuficiente?
- Dados podem ser dinâmicos, ou seja, são coletados e armazenados continuamente.

Como treinar uma rede neural profunda de maneira progressiva, quando novos dados são adicionados ao treinamento?

- Predições podem ser mutualmente associadas. Como se beneficiar da associação entre as possíveis predições?
- As instâncias de entrada podem ter diferentes níveis de dificuldade. Como controlar a relação entre precisão e revocação, para por exemplo, garantir altíssimos níveis de precisão?
- A memória de uma rede neural é dada em termos da conformação de seus parâmetros, que vão sendo atualizados iterativamente durante o treinamento. A atualização dos parâmetros ocorre sempre de maneira local, ou seja, os parâmetros são alterados ao processar cada instância de entrada no treinamento. Como utilizar informação global dos dados, e não apenas informação local, de forma a obter melhores modelos?

Neste projeto vamos propor novos algoritmos e arquiteturas para Aprendizado Profundo que produzam modelos para solucionar tarefas nas quais os desafios mencionados acima estejam presentes. Notoriamente, são tarefas de solução intuitiva, frequentemente relacionadas ao Processamento de Linguagem Natural e à Visão Computacional. Especificamente, vamos propor algoritmos e arquiteturas para Aprendizado Profundo que serão avaliados nas seguintes tarefas:

- Busca por imagens em espaços semânticos.
- Reconhecimento de emoções pela análise da fala.
- Sistemas de pergunta-resposta.
- Análise semântica.
- Tradução automática.
- Diagnóstico precoce de Alzheimer pela análise de imagens de cérebros.
- Avaliação automática de redações.
- Geração de modelos de linguagem contextuais.
- Representação da evolução de pacientes em unidades de terapia intensiva.
- Predição de conexões através da representação de grafos.

Os algoritmos a serem propostos farão uso de novas arquiteturas, mais dinâmicas, que ofereçam maiores possibilidades, e que produzam redes profundas mais rápidas e eficazes. O proponente pretende que a condução da pesquisa seja amparada pelo projeto e construção de pacotes de software que sirvam como bancada de teste para experimentos, obtendo resultados aferíveis através de publicações e formação de recursos humanos altamente qualificados nos níveis de iniciação científica, mestrado e doutorado. Posteriormente, alguns desses resultados poderão ser repassados para a indústria. São identificáveis nesta proposta quatro tópicos de pesquisa, a saber:

- Arquiteturas dinâmicas.
- Arquiteturas incrementais.
- Arquiteturas cientes de risco.

As seções a seguir apresentam nossa visão e nossas abordagens sobre os tópicos listados acima. Em cada seção, apresentam-se a motivação, trabalho pregresso, metodologia, e objetivos específicos.

2 Algoritmos e Arquiteturas

Este projeto de pesquisa versa sobre a elaboração, desenvolvimento e avaliação de novos algoritmos de Aprendizado Profundo baseados em arquiteturas dinâmicas, incrementais, e cientes de risco. A escolha por desenvolver algoritmos de Aprendizado Profundo baseados em arquiteturas com tais características aconteceu em virtude de alguns fatores. O primeiro deles é a tendência em se produzir dados cada vez mais dinâmicos, ao passo em que a maioria das arquiteturas existentes atuam em dados estacionários ou estáticos. O segundo fator é o desafio em se produzir modelos através da utilização não apenas de informações locais, mas também informações globais. O terceiro fator é a necessidade crescente de controle sobre a precisão atingida em operações críticas, ou seja, o modelo precisa ser ciente de risco ao realizar previsões. Por último, destacamos a tendência crescente em produzir arquiteturas cada vez mais complexas, sem a preocupação em efeitos indesejados como o aumento do tempo de treinamento ou até mesmo tempo de resposta.

2.1 Arquiteturas Dinâmicas

Muitas tarefas de nosso interesse devem realizar previsões estruturadas. Isso significa que a saída da rede neural será dada em termos de um arranjo ou uma sequência de rótulos. Nesse caso, é de grande importância a observação da associação existente entre os rótulos. Tome como exemplo o reconhecimento de peças de roupas em imagens postadas em blogs relacionados à moda. Um desafio comum nessa tarefa é que as peças de roupa são frequentemente sujeitas à deformação e oclusão [63], diferentes condições de iluminação [48]. Por esses motivos, uma rede neural treinada para essa tarefa pode se confundir ao prever as peças de roupa mostradas na imagem. Felizmente, há claras associações entre as peças de roupas — a ocorrência certos conjuntos de peças são mais comuns que a ocorrência de outros. A mesma ideia pode ser generalizada para outras tarefas e cenários e aplicação. A Figura 2 esboça a arquitetura dinâmica proposta: os parâmetros da rede neural são atualizados levando em conta informação local (i.e., a entrada) bem como informação global (i.e., associação entre os rótulos).

Trabalho Pregresso. Previsões estruturadas são relacionadas à classificação multi-rótulo, que estudamos anteriormente em [60, 62]. Especificamente, em [60] propomos abordagens para classificação associativa multi-rótulo. Nesse caso, o modelo consiste em padrões chamado regras de associação [36, 67]. Aqui, também propomos utilizar regras de associação para modelar a informação global no dado de treinamento. Tal

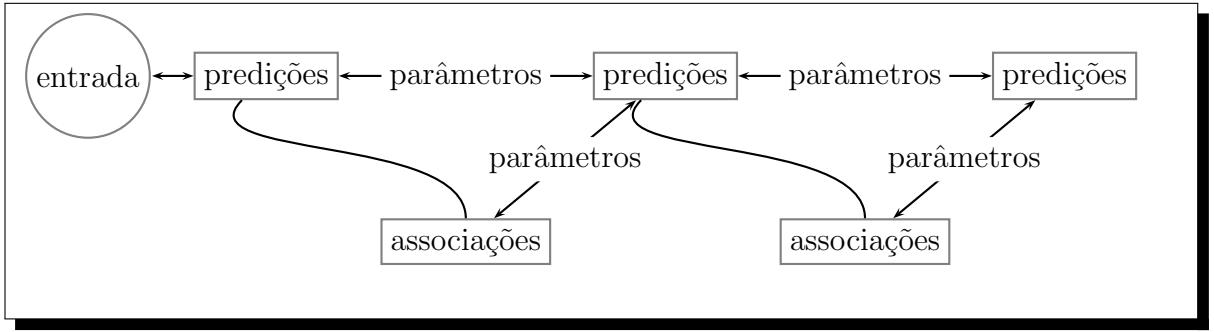


Figura 2: Arquitetura dinâmica. No exemplo, a entrada é uma informação local. As associações entre os rótulos são informações globais. As associações entre os rótulos preditos são concatenadas aos rótulos, e o processo repete-se iterativamente com a atualização dos parâmetros da rede neural.

informação consiste nas associações entre rótulos e conjunto de rótulos. No entanto, a grande diferença para [60, 62], é que a arquitetura dinâmica aprenderá a ponderar a importância das associações entre rótulos seguindo o processo de minimização da função de perda, podendo assim alterar inclusive parâmetros em níveis mais baixos da arquitetura.

Outros trabalhos que propuseram a exploração da relação entre rótulos incluem [40, 65]. Em [40], os autores capturaram dependências entre rótulos de forma a alcançar previsões mais precisas. Em [65] os autores também exploraram a ideia de quantificar dependências e associações entre rótulos de forma a realizar previsões mais precisas. Ambos os trabalhos, no entanto, empregam um modelo separado que quantifica as dependências. O que estamos propondo é a construção de um modelo único, no qual a descida de gradiente é empregada de forma a lidar diretamente com informação local e global.

Metodologia. Para o desenvolvimento de nossa arquitetura dinâmica utilizaremos o pacote Pytorch 2.7, disponível em <http://pytorch.org>. O Pytorch oferece suporte para reuso de estruturas e otimização em GPUs. Para avaliar nossa arquitetura dinâmica vamos utilizar dados provenientes de diferentes tarefas nas quais há algum tipo de relação entre os rótulos. Tarefas alvo de nossa avaliação incluem:

- Análise semântica: essa tarefa visa mapear um texto em linguagem natural em uma expressão lógica, que possa por sua vez ser executada diretamente pelo computador. Tipicamente esse processo é ilustrado por uma pergunta ou comando feitos em linguagem natural, e o resultado é uma consulta SQL que pode ser facilmente executada. Os rótulos são os tokens que compõem a expressão lógica, e portanto há relação de co-ocorrência ou associações entre os rótulos. A base de dados referente à essa tarefa que usaremos foi obtida em parceria com um grande banco Brasileiro, e consiste em um conjunto de amostras obtidas de seu agente conversacional, contendo as perguntas feitas por seus clientes acompanhadas da consulta SQL correspondente que foi realizada pelo operador.
- Tradução automática: essa tarefa visa mapear um texto em linguagem natural escrito em uma certa língua, para um texto com mesmo significado escrito em outra

língua. Nesse caso, os rótulos são palavras que compõem a tradução, e portanto há relação de co-ocorrência entre os rótulos. A base de dados referente à essa tarefa é obtida dos corpora paralelos das Nações Unidas, que contêm traduções nas seis línguas oficial das Nações Unidas: inglês, francês, chinês (mandarim), espanhol, árabe e russo.

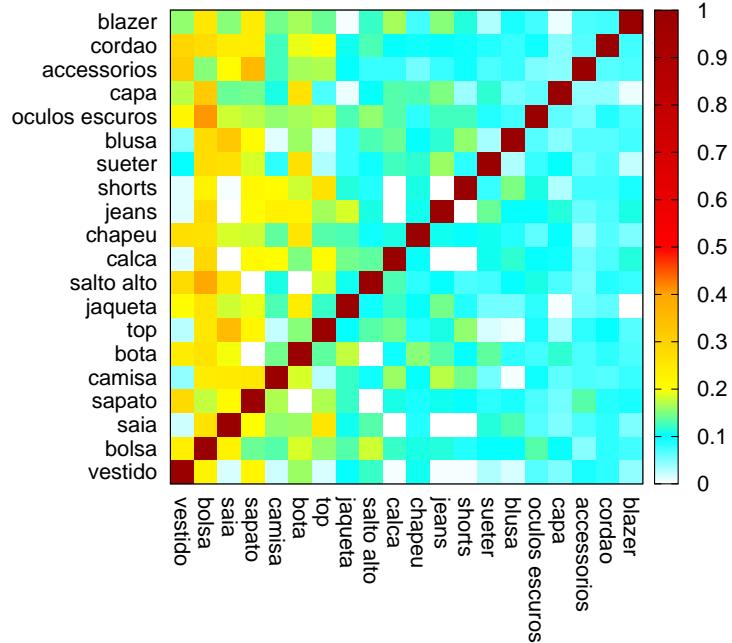


Figura 3: Matriz de associação entre rótulos. A ocorrência de óculos-escuros é uma boa evidência da ocorrência de bolsa. A ocorrência de sapato inviabiliza a ocorrência de botas.

- Busca por imagens em espaços semânticos: essa tarefa visa representar imagens com base em seus contituintes. No contexto de moda, por exemplo, uma imagem pode ser representada por um vetor de peças de roupa, ou seja, a imagem é representada pelas peças de roupa que a compõem. Intuitivamente, certos conjuntos de peças de roupa são mais prováveis que outros. De outra forma, alguns conjuntos de peças de roupa são muito improváveis. A Figura 3 ilustra essa intuição ao mostrar as associações entre as diferentes peças de roupa que podem ser reconhecidas em uma imagem. A base de dados referente à essa tarefa foi coletada a partir de um conjunto de blogs de moda, agrupado em www.chictopia.com, e consiste em cerca de 80.000 imagens, todas rotuladas com as peças de roupa que compõem cada imagem.

A avaliação sempre se dará com base na realização de experimentos controlados, com resultados comparados ao estado-da-arte, de acordo com medidas de eficácia apropriadas.

Objetivos Específicos. Os principais objetivos são:

- Aprimorar, estender e propor novos algoritmos de Aprendizado Profundo baseados em arquiteturas dinâmicas. Alunos de mestrado e doutorado estarão envolvidos nesta etapa.

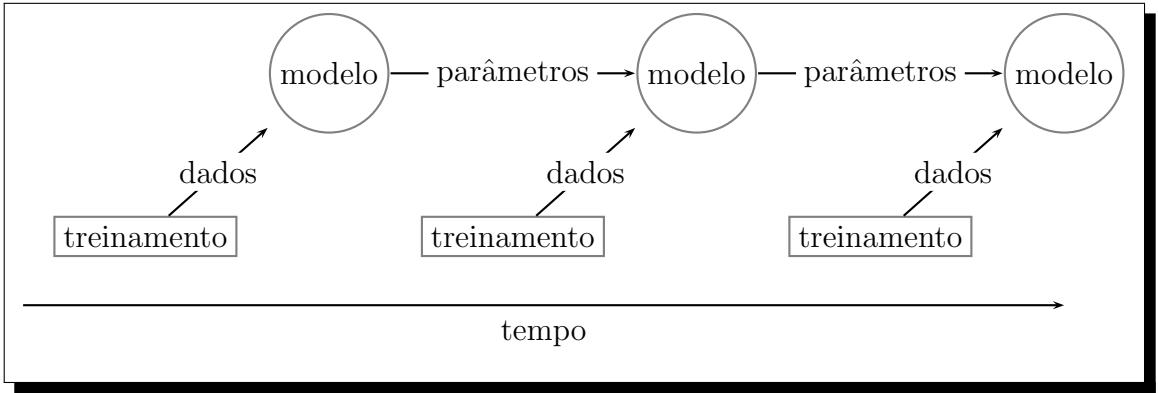


Figura 4: Arquitetura incremental. No exemplo, dados de treinamento chegam continuamente, e ficam disponíveis em diferentes momentos no tempo. O novo modelo é atualizado com os novos dados e através da transferência dos parâmetros antigos.

- Elaborar novas soluções baseadas em nossos algoritmos para as tarefas de análise semântica, tradução automática e busca por imagens em espaços semânticos. Alunos de mestrado e doutorado estarão envolvidos nesta etapa.
- Avaliar os algoritmos propostos, discutir e divulgar os resultados alcançados. Contamos com a participação de alunos de iniciação científica nesta etapa.

2.2 Arquiteturas Incrementais

Muitas tarefas de nosso interesse operaram com dados dinâmicos. Isso significa que novos dados devem ser continuamente incluídos na base de treinamento. Contudo, a inclusão de novos dados na base de treinamento pode invalidar o modelo produzido. A abordagem ingênuo consiste em re-treinar a rede neural, de forma que o modelo produzido esteja em consonância com o treinamento novamente. Tal abordagem, embora simples, é inviável na prática, tendo em vista o alto custo computacional de produzir redes profundas. Propomos duas alternativas:

- Propomos atualizar o modelo utilizando técnicas de transferência de aprendizado [45], na qual o novo modelo é produzido a partir do novo treinamento e dos parâmetros antigos. Essa abordagem elimina a necessidade de acessar treinamentos antigos, evitando o aumento tanto de tempo de treinamento e no consumo de memória. Dessa forma, nossa arquitetura incremental pode ser efetiva para aprendizado contínuo em dados não-estacionários. A Figura 4 esboça a arquitetura incremental proposta: os parâmetros da rede neural são atualizados levando em conta os novos dados de treinamento bem como os parâmetros antigos. A transferência de aprendizado é realizada de maneira contínua: o novo modelo é pré-treinado a partir do treinamento antigo (a inicialização do novo modelo é dada pelos parâmetros obtidos durante o último treinamento), e então os parâmetros são ajustados finamente com os novos dados de treinamento. Como a tarefa continua a mesma, não há risco de esquecimento catastrófico [47] durante o processo de atualização do modelo.

- Propomos atualizar o modelo utilizando técnicas de combinação de modelos [52], na qual o novo modelo é produzido a partir de modelos independentes obtidos a partir de treinamentos diferentes. Essa abordagem também elimina a necessidade de acessar treinamentos antigos, evitando o aumento tanto de tempo de treinamento e no consumo de memória. Dessa forma, nossa arquitetura incremental pode ser efetiva para aprendizado contínuo em dados não-estacionários. A Figura 5 esboça a arquitetura incremental proposta: o novo modelo é produzido pela combinação de dois modelos independentes.

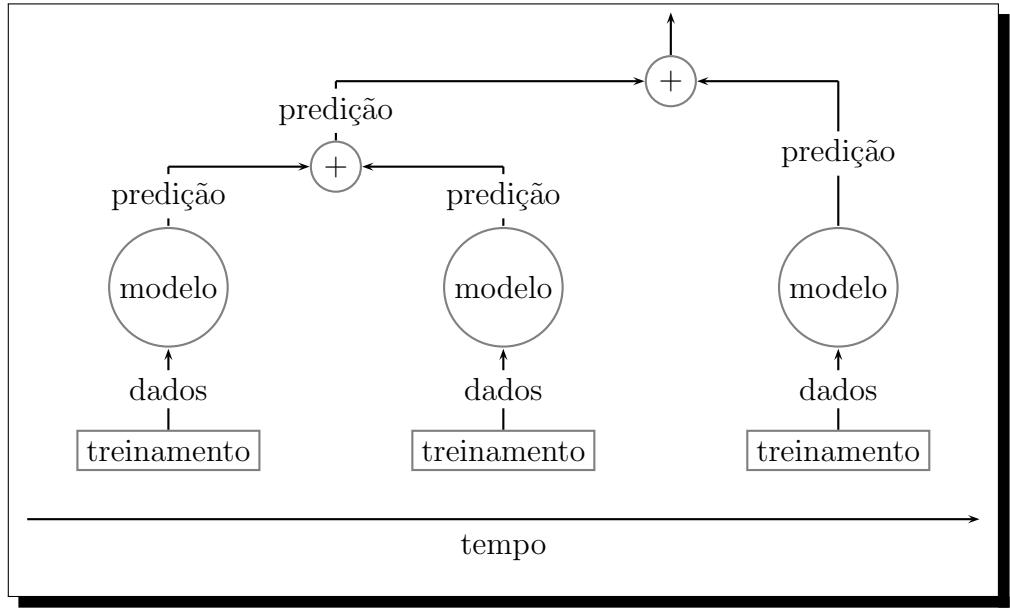


Figura 5: Arquitetura incremental. No exemplo, dados de treinamento chegam continuamente, e ficam disponíveis em diferentes momentos no tempo. O novo modelo é atualizado com os novos dados e através da combinação de modelos antigos.

Trabalho Pregresso. Nossas arquiteturas incrementais são relacionadas a trabalhos em transferência de aprendizado [66] e combinação de modelos preditivos [68]. Outros tipos de estratégias incrementais de atualização de modelos foram propostas em [51, 59, 61], e estratégias de atualização que levam em conta mudanças na distribuição dos dados foram propostas [43, 55, 56, 58]. A abordagem baseada em transferência de aprendizado que propomos segue a mesma linha da abordagem que propomos recentemente em [49]. Nesse caso, o processo de atualização do novo modelo é baseado em descida de gradiente, porém os parâmetros são simplesmente inicializados com os parâmetros do modelo antigo.

Metodologia. Para o desenvolvimento de nossas arquiteturas incrementais também utilizaremos o pacote Pytorch 2.7. Para avaliar nossas arquiteturas incrementais vamos utilizar dados provenientes de diferentes tarefas nas quais dados de treinamento são adquiridos continuamente. Tarefas alvo de nossa avaliação incluem:

- Reconhecimento de emoções pela análise da fala: essa tarefa visa identificar diferentes emoções a partir de características na fala, como entonação, rapidez, força e energia. Nesse caso, consideramos emoções e fala como dados dinâmico, tanto do ponto de vista de chegada contínua de dados, quanto do ponto de vista de mudança de emoção com o tempo. Utilizaremos dados disponíveis para pesquisa, tais como:
 - AFEW [44]: esse conjunto de dados é composto por segmentos de 37 filmes em Inglês. Os filmes foram escolhidos de forma que o conjunto de dados contenha cenários acusticamente realísticos e com diversidade em termos de idade e gênero dos participantes.
 - Emo-DB [38]: esse conjunto de dados é composto por falas de atores com emoções pré-estabelecidas em um roteiro. O conjunto de dados contém diferentes sentenças expressas por dez atores diferentes.
 - EMOVO [41]: esse conjunto de dados é composto por sentenças gravadas da fala de seis atores diferentes. Cada um deles leu 14 sentenças em Italiano.
 - eINTERFACE [50]: esse conjunto de dados é composto por gravações de pessoas de 14 nacionalidades diferentes, porém todas falando em Inglês.
 - IEMOCAP [39]: esse conjunto de dados é composto por falas em Inglês, improvisadas por atores.

- Representação da evolução de pacientes em unidades de terapia intensiva: essa tarefa visa antecipar situações de pacientes internados em unidades de terapia intensiva. Para tanto representamos a trajetória desses pacientes utilizando sinais vitais coletados a cada hora e prevendo o desfecho associado ao paciente. A rede neural aprende uma representação para a situação do paciente, e com isso podemos separar regiões de risco de morte, bem como regiões de sobrevivência, como mostra a Figura 6. Novos pacientes são continuamente internados, e adicionados ao conjunto de treinamento. Inicialmente utilizaremos dados obtidos do desafio Physionet, disponível em <https://physionet.org/challenge/2012>, contendo informação sobre 4.000 internações. Adicionalmente, estamos em processo de parceria com o hospital Sírio-Libanês, de forma a possibilitar o uso de dados mais completos.

A avaliação sempre se dará com base na realização de experimentos controlados, com resultados comparados ao estado-da-arte, de acordo com medidas de eficácia apropriadas.

Objetivos Específicos. Os principais objetivos são:

- Aprimorar, estender e propor novos algoritmos de Aprendizado Profundo baseados em arquiteturas incrementais. Alunos de mestrado e doutorado estarão envolvidos nesta etapa.
- Elaborar novas soluções baseadas em nossos algoritmos para as tarefas de reconhecimento de emoções pela análise da fala e representação de pacientes em unidades de terapia intensiva. Alunos de mestrado e doutorado estarão envolvidos nesta etapa.
- Avaliar os algoritmos propostos, discutir e divulgar os resultados alcançados. Contamos com a participação de alunos de iniciação científica nesta etapa.

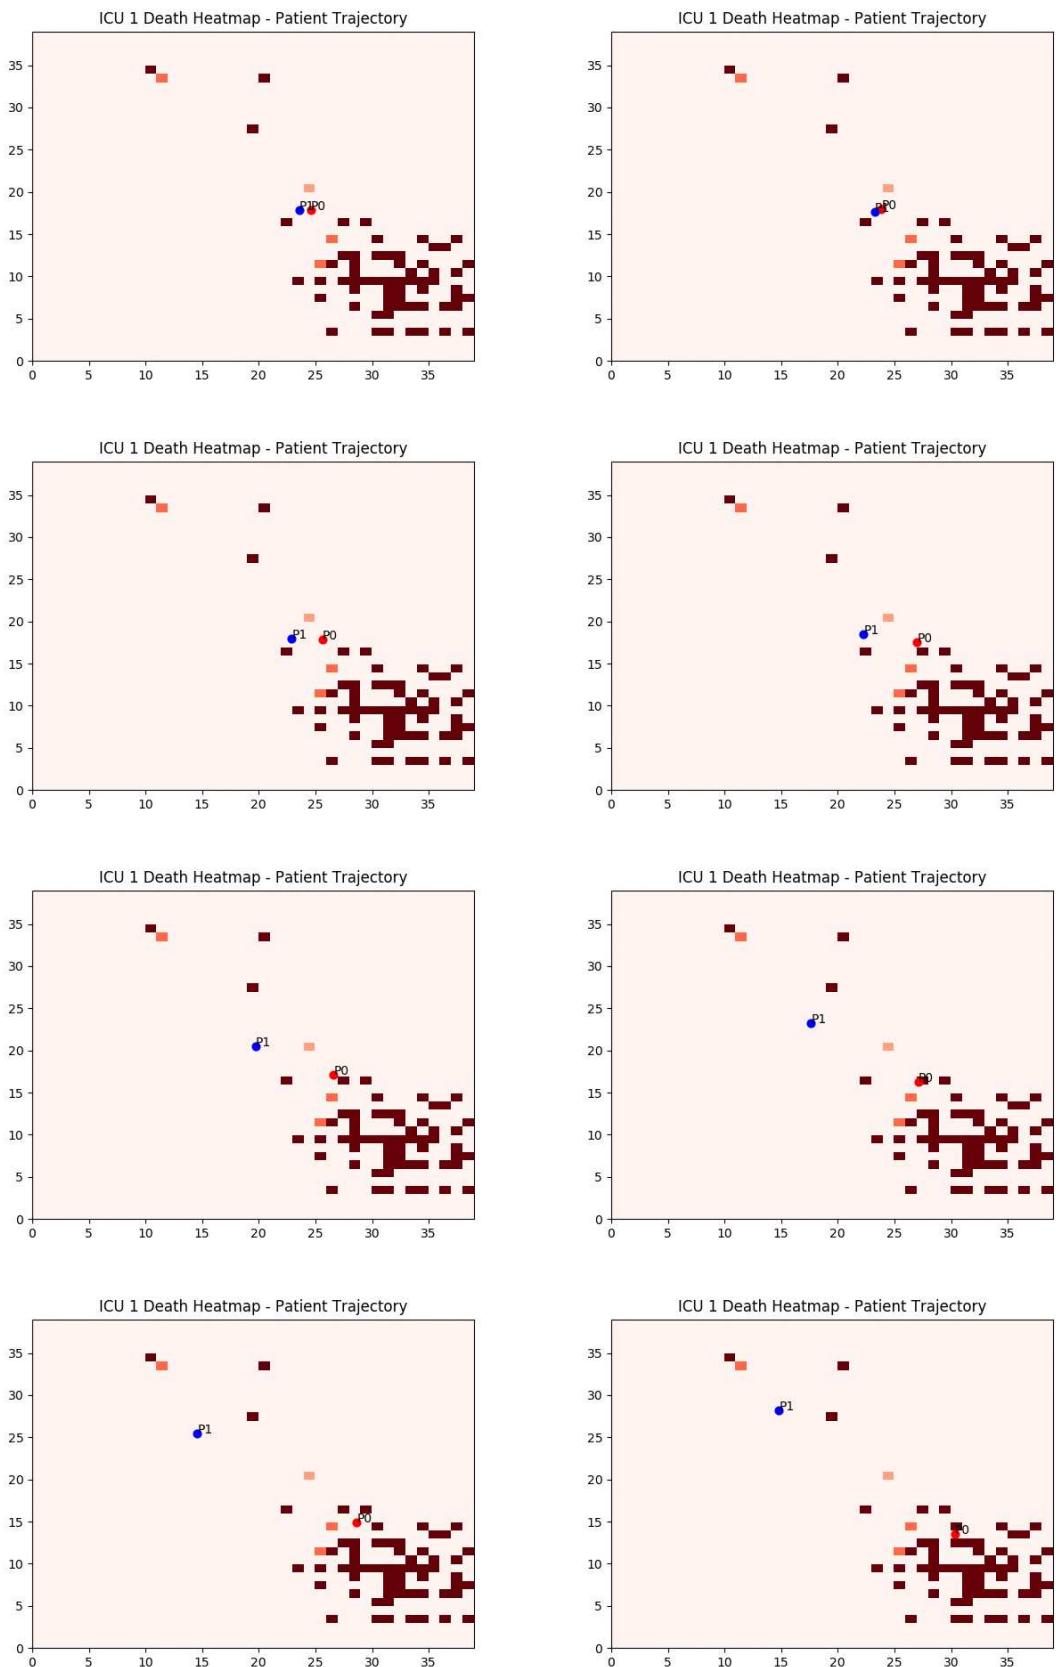


Figura 6: Trajetória de pacientes intensivos (esquerda-direita). P0 veio a óbito. P1 é um sobrevivente. Quanto mais escura a região mais associada a óbito ela é.

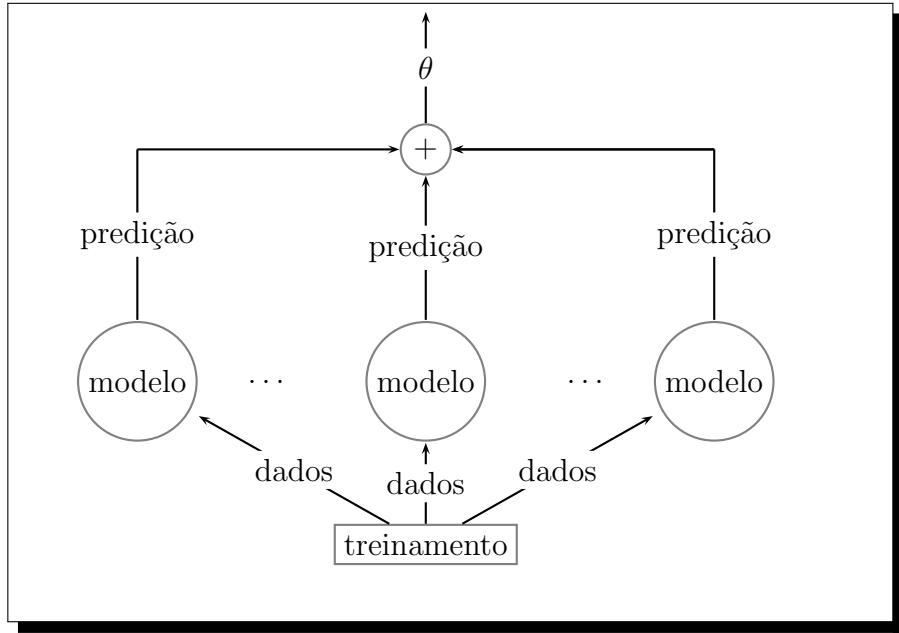


Figura 7: Arquitetura ciente de risco. No exemplo, dados de treinamento produzem diferentes modelos. Os modelos são combinados de forma a retornar a certeza θ de uma predição conjunta. Caso o valor de θ seja suficientemente alto, a predição é realizada. Caso contrário, o modelo abstém-se da predição.

2.3 Arquiteturas Cientes de Risco

Para muitas tarefas de nosso interesse é importante que a arquitetura forneça controle sobre a precisão das previsões realizadas. Ou seja, dada uma entrada específica, o modelo treinado deve ser capaz de abster, ou então retornar uma previsão garantidamente correta. A arquitetura proposta é baseada na previsão conjunta de diferentes modelos. A previsão conjunta é associada à uma certeza θ que adiciona o controle de abstenção ou previsão. Sendo assim, a escolha do valor aceitável para θ define uma relação entre precisão e revocação. A Figura 7 esboça a arquitetura ciente de risco proposta: redes neurais treinadas de maneira dependente ou independente, ou seja, os parâmetros das redes neurais são atualizados baseados no respectivo erro de cada rede neural, ou no erro conjunto. Finalmente, suas previsões são combinadas de forma a produzir a certeza da previsão conjunta.

Trabalho Pregresso. Nossa arquitetura ciente de risco é relacionada a trabalhos que realizamos anteriormente [37, 42, 53, 54, 57]. A principal diferença é que a arquitetura sendo proposta é baseada na combinação de diferentes modelos, enquanto nossos modelos anteriores foram baseados na quantificação direta da dificuldade da entrada. Uma abordagem mais próxima da que estamos propondo é [46], na qual a previsão só é realizada caso haja certeza sobre sua corretude. Para tanto, os autores aplicam o conceito de unanimidade entre os diferentes modelos.

Metodologia. Para o desenvolvimento de nossa arquitetura ciente de risco também utilizaremos o pacote Pytorch 2.7. Para avaliar nossa arquitetura vamos utilizar dados provenientes de diferentes tarefas nas quais deve-se ter controle sobre a precisão das previsões. Tarefas alvo de nossa avaliação incluem:

- Sistemas de pergunta-resposta: essa tarefa visa entender uma pergunta fornecida em texto-livre, e encontrar a resposta correta em uma base de respostas, tipicamente a Wikipedia ou outra base de conhecimento. Perguntas podem ter diferentes níveis de dificuldade. Por exemplo, perguntas como “*Quais os restaurantes mineiros na Pampulha?*” são facilmente respondidas por máquinas. De outra forma, há perguntas bem mais complexas, como “*Quantos analgésicos deve tomar?*” Na dúvida o sistema de pergunta-resposta pode requerer uma paráfrase, ou simplesmente se abster de responder a pergunta. Há diversos conjuntos de dados para a avaliação de sistemas pergunta-resposta. Utilizaremos dados disponíveis em <https://rajpurkar.github.io/SQuAD-explorer>, que correspondem a mais de 100.000 perguntas e respostas em Inglês.
- Avaliação automática de redações: essa tarefa visa fornecer notas para redações sobre temas pré-definidos e geralmente polêmicos. Idealmente, a nota fornecida pelo sistema de avaliação deve ser confiável, sendo assim o sistema deve ser ciente de risco ao escolher avaliar apenas redações para as quais a nota seja confiável. Para essa tarefa obtemos cerca de 3.000 redações do ENEM (O Exame Nacional do Ensino Médio) e suas correções comentadas, juntamente com as notas obtidas.
- Diagnóstico precoce de Alzheimer pela análise de imagens de cérebros: essa tarefa visa identificar padrões relacionados à doença de Alzheimer a partir da análise de imagens de cérebros. Aparelhos de ressonância modernos resultam em imagens altamente nítidas do cérebro, com milhares de tons de cinza. Grande espectro dessas imagens não são visíveis ao olho humano, mas continuam sendo processáveis pela máquina. Por consequência, acreditamos na possibilidade de existirem padrões ainda desconhecidos, e a análise desses padrões podem levar ao diagnóstico precoce da doença. Como o diagnóstico deve ser confiável, consideramos essa tarefa como alvo de nossa arquitetura para Aprendizado Profundo ciente de risco. Recentemente tornamo-nos colaboradores de um grande consórcio de pesquisa chamado Alzheimer’s Disease Neuroimaging Initiative (ADNI) [64], com o objetivo de desenvolver técnicas de Aprendizado Profundo para a análise de imagens de cérebros. O consórcio oferece acesso ao resultado de um estudo longitudinal com mais de 1.000 exames, o que corresponde a mais de 3.000 imagens de cérebros saudáveis, em processo de degeneração, ou doentes.

A avaliação sempre se dará com base na realização de experimentos controlados, com resultados comparados ao estado-da-arte, de acordo com medidas de eficácia apropriadas.

Objetivos Específicos. Os principais objetivos são:

- Aprimorar, estender e propor novos algoritmos de Aprendizado Profundo baseados em arquiteturas cientes de risco. Alunos de mestrado e doutorado estarão envolvidos neste etapa.

- Elaborar novas soluções baseadas em nossos algoritmos para as tarefas de análise semântica, sistemas de pergunta-resposta, avaliação automática de redações, e diagnóstico precoce de Alzheimer pela análise de imagens de cérebros. Alunos de mestrado e doutorado estarão envolvidos nesta etapa.
- Avaliar os algoritmos propostos, discutir e divulgar os resultados alcançados. Contamos com a participação de alunos de iniciação científica nesta etapa.

3 Resultados

Ao fim deste projeto (36 meses) espera-se obter os seguintes resultados:

- Projetar, implementar e validar novos algoritmos para Aprendizado Profundo baseados em arquiteturas dinâmicas, incrementais, e cientes de risco.
- Avaliar a efetividade prática dos algoritmos desenvolvidos em aplicações relevantes e desafiadoras.
- Formar 3 doutores, 8 mestres e 8 alunos de iniciação científica.
- Publicar 6 artigos em periódicos, 10 artigos em conferências internacionais e 6 artigos em conferências nacionais.
- Publicar e transferir a tecnologia produzida durante o projeto para fins de pesquisa e desenvolvimento tecnológico.

4 Recursos

Nesta seção discutimos a demanda e disponibilidade de recursos necessários para a execução do projeto proposto.

4.1 Bolsa de Produtividade

Este projeto tem por objetivo principal a renovação da bolsa de produtividade em pesquisa do proponente, a qual é um pilar fundamental para a execução do projeto.

4.2 Recursos de Pessoal

Os demais recursos de pessoal para a realização do projeto estão disponíveis. Os alunos que trabalham nas linhas de pesquisa já estão cursando doutorado, mestrado ou atuando como bolsistas de iniciação científica. Acreditamos que eventuais substituições não afetarão significativamente o trabalho.

4.3 Recursos de Equipamento

Em termos de equipamentos, acreditamos que estejamos em condições de suprir as demandas de desenvolvimento e avaliação inerentes ao projeto. A infra-estrutura do laboratório SPEED foi recentemente renovada e estendida com recursos de projetos do CNPq e Fapemig. Mais ainda, o proponente coordena o laboratório LIA (Laboratório de Inteligência Artificial), sediado no DCC-UFMG.

Referências

- [36] Rakesh Agrawal, Tomasz Imielinski, and Arun N. Swami. Mining association rules between sets of items in large databases. In *1993 ACM SIGMOD International Conference on Management of Data*, pages 207–216, 1993.
- [37] Fabrício Benevenuto, Tiago Rodrigues, Adriano Veloso, Jussara M. Almeida, Marcos André Gonçalves, and Virgílio A. F. Almeida. Practical detection of spammers and content promoters in online video sharing systems. *IEEE Trans. Systems, Man, and Cybernetics, Part B*, 42(3):688–701, 2012.
- [38] Felix Burkhardt, Astrid Paeschke, M. Rolfes, Walter F. Sendlmeier, and Benjamin Weiss. A database of german emotional speech. In *European Conference on Speech Communication and Technology*, pages 1517–1520, 2005.
- [39] Carlos Busso, Murtaza Bulut, Chi-Chun Lee, Abe Kazemzadeh, Emily Mower, Samuel Kim, Jeannette N. Chang, Sungbok Lee, and Shrikanth Narayanan. IEMOCAP: interactive emotional dyadic motion capture database. *Language Resources and Evaluation*, 42(4):335–359, 2008.
- [40] Huizhong Chen, Andrew C. Gallagher, and Bernd Girod. Describing clothing by semantic attributes. In *ECCV European Conference on Computer Vision*, pages 609–623, 2012.
- [41] Giovanni Costantini, Iacopo Iaderola, Andrea Paoloni, and Massimiliano Todisco. EMOVO corpus: an italian emotional speech database. In *International Conference on Language Resources and Evaluation*, pages 3501–3504, 2014.
- [42] Alexandre Davis, Adriano Veloso, Altigran Soares da Silva, Alberto H. F. Laender, and Wagner Meira Jr. Named entity disambiguation in streaming data. In *50th Annual Meeting of the Association for Computational Linguistics ACL*, pages 815–824, 2012.
- [43] Roberto Lourenço de Oliveira Jr., Adriano Veloso, Adriano C. M. Pereira, Wagner Meira Jr., Renato Ferreira, and Srinivasan Parthasarathy. Economically-efficient sentiment stream analysis. In *37th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 637–646, 2014.
- [44] Abhinav Dhall, Roland Goecke, Simon Lucey, and Tom Gedeon. Collecting large, richly annotated facial-expression databases from movies. *IEEE MultiMedia*, 19(3):34–41, 2012.

- [45] Pedro Henrique Calais Guerra, Adriano Veloso, Wagner Meira Jr., and Virgílio A. F. Almeida. From bias to opinion: a transfer-learning approach to real-time sentiment analysis. In *17th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pages 150–158, 2011.
- [46] Fereshte Khani, Martin C. Rinard, and Percy Liang. Unanimous prediction for 100% precision with application to learning semantic mappings. In *54th Annual Meeting of the Association for Computational Linguistics, ACL*, 2016.
- [47] James Kirkpatrick, Razvan Pascanu, Neil C. Rabinowitz, Joel Veness, Guillaume Desjardins, Andrei A. Rusu, Kieran Milan, John Quan, Tiago Ramalho, Agnieszka Grabska-Barwinska, Demis Hassabis, Claudia Clopath, Dharshan Kumaran, and Raia Hadsell. Overcoming catastrophic forgetting in neural networks. *CoRR*, abs/1612.00796, 2016.
- [48] Ziwei Liu, Ping Luo, Shi Qiu, Xiaogang Wang, and Xiaoou Tang. Deepfashion: Powering robust clothes recognition and retrieval with rich annotations. In *2016 IEEE Conference on Computer Vision and Pattern Recognition, CVPR*, pages 1096–1104, 2016.
- [49] Alison Marczewski, Adriano Veloso, and Nivio Ziviani. Learning transferable features for speech emotion recognition. In *30th ACM MM Multimedia Conference*, pages 490–510, 2017.
- [50] Olivier Martin, Irene Kotsia, Benoit M. Macq, and Ioannis Pitas. The enterface'05 audio-visual emotion database. In *International Conference on Data Engineering Workshops*, page 8, 2006.
- [51] Matthew Eric Otey, Chao Wang, Srinivasan Parthasarathy, Adriano Veloso, and Wagner Meira Jr. Mining frequent itemsets in distributed and dynamic databases. In *Proceedings of the 3rd IEEE International Conference on Data Mining (ICDM 2003), 19-22 December 2003, Melbourne, Florida, USA*, pages 617–620, 2003.
- [52] Zhiqian Qi, Bo Wang, Yingjie Tian, and Peng Zhang. When ensemble learning meets deep learning: a new deep support vector machine for classification. *Knowl.-Based Syst.*, 107:54–60, 2016.
- [53] Marco Túlio Ribeiro, Anísio Lacerda, Adriano Veloso, and Nivio Ziviani. Pareto-efficient hybridization for multi-objective recommender systems. In *6th ACM Conference on Recommender Systems RecSys*, pages 19–26, 2012.
- [54] Marco Túlio Ribeiro, Nivio Ziviani, Edleno Silva de Moura, Itamar Hata, Anísio Lacerda, and Adriano Veloso. Multiobjective pareto-efficient approaches for recommender systems. *ACM TIST*, 5(4):53:1–53:20, 2014.
- [55] Ismael Santana Silva, Glívia A. R. Barbosa, Adriano Veloso, Wagner Meira Jr., and Renato Ferreira. Análise adaptativa de fluxo de sentimento baseada em janela deslizante ativa. In *XXVI Simpósio Brasileiro de Banco de Dados*, pages 49–56, 2011.

- [56] Ismael Santana Silva, Janaína Gomide, Adriano Veloso, Wagner Meira Jr., and Renato Ferreira. Effective sentiment stream analysis with self-augmenting training and demand-driven projection. In *34th International ACM SIGIR Conference on Research and Development in Information Retrieval*, pages 475–484, 2011.
- [57] Adriano Veloso, Anderson A. Ferreira, Marcos André Gonçalves, Alberto H. F. Laneder, and Wagner Meira Jr. Cost-effective on-demand associative author name disambiguation. *Inf. Process. Manage.*, 48(4):680–697, 2012.
- [58] Adriano Veloso, Wagner Meira Jr., and Márcio de Carvalho. Mining reliable models of associations in dynamic databases. In *XVII Simpósio Brasileiro de Banco de Dados*, pages 263–277, 2002.
- [59] Adriano Veloso, Wagner Meira Jr., Márcio de Carvalho, Bruno Pôssas, Srinivasan Parthasarathy, and Mohammed Javeed Zaki. Mining frequent itemsets in evolving databases. In *2nd SIAM International Conference on Data Mining*, pages 494–510, 2002.
- [60] Adriano Veloso, Wagner Meira Jr., Marcos André Gonçalves, and Mohammed Javeed Zaki. Multi-label lazy associative classification. In *11th European Conference on Principles and Practice of Knowledge Discovery in Databases (ECML-PKDD)*, pages 605–612, 2007.
- [61] Adriano Veloso, Bruno Gusmão Rocha, Wagner Meira Jr., Márcio de Carvalho, Srinivasan Parthasarathy, and Mohammed Javeed Zaki. Efficiently mining approximate models of associations in evolving databases. In *6th European Conference on Principles of Data Mining and Knowledge Discovery (PKDD)*, pages 435–448, 2002.
- [62] Adriano Alonso Veloso, Jefersson Alex dos Santos, and Keiller Nogueira. Learning to annotate clothes in everyday photos: Multi-modal, multi-label, multi-instance approach. In *27th SIBGRAPI Conference on Graphics, Patterns and Images, SIBGRAPI*, pages 327–334, 2014.
- [63] Nan Wang and Haizhou Ai. Who blocks who: Simultaneous clothing segmentation for grouping images. In *IEEE ICCV International Conference on Computer Vision*, pages 1535–1542, 2011.
- [64] M. W. Weiner, J. C. Bis, M. A. Ikram, V. Smith, A. V. and Gudnason, C. Tzourio, M. W. Vernooij, L. J. Launer, C. Decarli, S. Seshadri, O. A. Andreassen, L. G. Apostolova, M. E. Bastin, J. Blangero, H. G. Brunner, R. L. Buckner, S. Cichon, G. Coppola, G. I. de Zubiray, I. J. Deary, G. Donohoe, E. J. de Geus, T. Espeseth, G. Fernandez, D. C. Glahn, H. J. Grabe, J. Hardy, M. Jenkinson, R. S. Kahn, C. McDonald, A. M. McIntosh, F. J. McMahon, K. L. McMahon, A. Meyer-Lindenberg, D. W. Morris, B. Muller-Myhsok, T. E. Nichols, R. A. Ophoff, T. Paus, Z. Pausova, B. W. Penninx, S. G. Potkin, P. G. Samann, A. J. Saykin, G. Schumann, J. W. Smoller, J. M. Wardlaw, M. E. Weale, N. G. Martin, B. Franke, M. J. Wright, and P. M. Thompson. Identification of common variants associated with human hippocampal and intracranial volumes. *Nature Genetics*, 2012.

- [65] Kota Yamaguchi, Takayuki Okatani, Kyoko Sudo, Kazuhiko Murasaki, and Yukinobu Taniguchi. Mix and match: Joint model for clothing and attribute recognition. In *BMVC British Machine Vision Conference*, pages 1–12, 2015.
- [66] Jason Yosinski, Jeff Clune, Yoshua Bengio, and Hod Lipson. How transferable are features in deep neural networks? In *Advances in Neural Information Processing Systems 27: Annual Conference on Neural Information Processing Systems 2014 (NIPS)*, pages 3320–3328, 2014.
- [67] Mohammed Javeed Zaki, Srinivasan Parthasarathy, Mitsunori Ogihara, and Wei Li. New algorithms for fast discovery of association rules. In *3rd International Conference on Knowledge Discovery and Data Mining (KDD)*, pages 283–286, 1997.
- [68] Zhi-Hua Zhou, Jianxin Wu, and Wei Tang. Ensembling neural networks: Many could be better than all. *Artif. Intell.*, 137(1-2):239–263, 2002.