



Proposta para Grupo de Trabalho 2022

GT-LANSE - Learning Analytics como Serviço para Predição de Risco Acadêmico

Cristian Cechinel

26 de Julho de 2021

(a) Título

GT-LANSE - Learning Analytics como Serviço para Predição de Risco Acadêmico

(b) Coordenador Acadêmico

Cristian Cechinel. Professor do Centro de Ciências Tecnologias e Saúde da Universidade Federal de Santa Catarina - Campus Araranguá. Atua como professor permanente no Programa de Pós-Graduação em Tecnologias da Informação e Comunicação da UFSC e no Programa de Computação da Universidade Federal de Pelotas. É bolsista de Produtividade em Desenvolvimento Tecnológico DT2 do CNPq.

<https://scholar.google.com.br/citations?user=cristiancechinel> (Plataforma Google Scholar)

https://researchgate.net/profile/Cristian_Cechinel/ (Plataforma Research Gate)

<http://lattes.cnpq.br/2782164252734586> (Plataforma Lattes)

contato: contato@cristiancechinel.pro.br, cristian.cechinel@ufsc.br ou +55 48 99805 3412

(c) Assistente de Inovação

Tiago Thompsen Primo, Universidade Federal de Pelotas. Atua no Centro de Engenharias e no Programa de Pós-Graduação em Ciência da Computação UFPel, É Co-Fundador da Startup Elimu Social <https://www.linkedin.com/in/tiago-primo-347b1a8/> (Plataforma LinkedIn) https://www.researchgate.net/profile/Tiago_Primo (Plataforma Research Gate) <http://lattes.cnpq.br/5641514282351546> (Plataforma Lattes) contato: tiago.primo@inf.ufpel.edu.br ou +55 53 991313061

(d) Tema(s)

Inteligência Artificial, Educação a Distância

(e) Parcerias e respectivas contrapartidas

Instituição	Contrapartida	Papéis Principais	Responsável
Univ. Fed. de Pelotas (UFPel)	Bolsas PIBIC PIBIT Mestrado e Doutorado (Se aprovadas internamente), Horas de pesquisa dos professores envolvidos	Gerenciamento do Projeto; Pesquisa e Desenvolvimento do componentes relacionados a hardware a infraestrutura	Tiago Thompsen Primo
Univ. Fed. de Santa Catarina (UFSC)	Bolsas PIBIC PIBITI (já aprovadas internamente). Bolsas de Mestrado (se aprovadas internamente)	Gerenciamento do Projeto; Pesquisa e Desenvolvimento de Algoritmos; Inteligentes e Dashboards; Suporte a execução dos pilotos	Cristian Cechinel
Inst. Fed. Sul-Riograndens e (IFSUL)	Horas de pesquisa dos pesquisadores envolvidos (Emanuel Marques Queiroga)	Pesquisa e Desenvolvimento de Algoritmos Inteligentes e Dashboards; Personalização e adaptação do Moodle; Suporte a execução dos pilotos	Emanuel Queiroga
Elimu Social	Horas de Pesquisadores e Desenvolvedores	Suporte no desenvolvimento da solução e busca de clientes para futuros casos de uso.	Kelen Silveira Bernardi

(f) Descrição da proposta, identificando o problema e a solução com destaque para as inovações

f.1) Sumário Executivo

O objetivo desta proposta é oferecer uma solução tecnológica para a execução de serviços de predição de risco acadêmico (evasão e/ou reprovação) apoiada por uma infraestrutura na nuvem que pré processa dados, treina e executa algoritmos de machine learning. Para isso, um Learning Record Store (LRS) é implementado para o armazenamento padronizado dos diferentes tipos de interações de estudantes recolhidas por um cliente, permitindo que dados oriundos de diferentes plataformas utilizadas pelos clientes possam ser consumidos pelos serviços oferecidos na nuvem. Do lado do cliente, um dashboard para visualização de dados educacionais será o responsável por oferecer aos educadores e administradores uma visão panorâmica

sobre os dados educacionais disponibilizados, por coletar os dados crus para armazenamento no LRS e envio ao serviço de Learning Analytics, e por apresentar os resultados das predições do risco acadêmico.

Se por um lado, o campo de pesquisa em mineração de dados educacionais já vem explorando de maneira exaustiva o tema de identificação de acadêmicos em risco, é certo também que os resultados dessas pesquisas ainda não foram definitivamente traduzidos em ferramentas e serviços que possam ser utilizadas pelas instituições educacionais e seus profissionais (professores e gestores). Isso se dá sobretudo porque os resultados publicados normalmente são restritos a experimentos realizados com conjuntos de dados bastante específicos e cujos modelos não podem ser extrapolados para outros contextos. De maneira geral, os resultados das pesquisas sobre identificação de acadêmicos em risco de evasão e reprovação param na publicação dos artigos científicos e não são transferidos como produtos para o setor interessado nesses resultados.

O GT-LANSE nasce da sinergia entre as pesquisas e protótipos de seus proponentes na área de predição de risco acadêmico combinando técnicas de inteligência artificial e o conhecimento sobre as especificidades dos dados acadêmicos e educacionais, e que possibilitaram testar e desenvolver metodologias e técnicas já consolidadas nessa área. Especificamente na identificação de risco, planejamos inicialmente a utilização de uma metodologia baseada na contagem de interações dos alunos dentro do Ambiente Virtual de Aprendizagem (AVA). Essa metodologia vem sendo desenvolvida pelo grupo há alguns anos, apresentando bons resultados na predição precoce de estudantes em risco (com desempenhos compatíveis com o estado da arte da área) e tendo gerado diversas publicações científicas em conferências e revistas nacionais e internacionais: [1] [2] e [3].

Do ponto de vista científico e de inovação, a proposta está alinhada com o estado da arte em Learning Analytics e Mineração de Dados Educacionais e permitirá que o público-alvo (instituições de ensino dos variados níveis e seus professores, e futuramente seus estudantes) possam identificar antecipadamente estudantes em risco de reprovação e/ou evasão em tempo hábil de mitigar essas situações de risco.

(f.2) Desenvolvimento Tecnológico

Contexto e justificativa: A possibilidade de identificação de acadêmicos com alto risco de evasão e reprovação a partir de modelos automáticos foi apontada como um dos potenciais problemas a serem atacados pela comunidade brasileira que atua na área de mineração de dados educacionais. Nos últimos anos, uma grande gama de trabalhos vem sendo desenvolvida nesse sentido dentro da comunidade científica nacional e internacional. Um dos grandes desafios dos pesquisadores é desenvolver métodos capazes de prever antecipadamente o comportamento dos acadêmicos visando identificar aqueles que estão em risco, de maneira a possibilitar alguma intervenção antes que os mesmos reprovem ou evadam. Atualmente não existem produtos nacionais para a predição de acadêmicos em risco, e as iniciativas internacionais são ainda bastante incipientes e recentes (quando são livremente disponibilizadas), ou relativamente caras (no caso das soluções pagas). Ainda, os modelos de predição testados na literatura são normalmente dependentes de contexto, e os resultados quase sempre limitados a experimentos restritos a algumas disciplinas e cursos. Por conta disso, existe uma grande dificuldade em transformar os resultados das pesquisas realizadas em produtos e serviços que possam ser utilizadas pelas instituições de

ensino. Uma das fontes de dados mais utilizadas para esse o problema da predição de risco acadêmico são os Ambientes Virtuais de Aprendizagem (AVA), que são largamente utilizados pelas instituições de ensino em seus cursos presenciais (apoiados semi-presencialmente) e também na modalidade a distância e remota. A presente proposta desenvolverá o primeiro protótipo de cliente focado em uma solução voltada para funcionar para o AVA Moodle, entretanto, por meio da utilização de um LRS padronizado (utilizando Experience API - xAPI), a solução permitirá que outros AVA clientes sejam futuramente integrados (Canvas, D2L, Google Classroom, etc).

Estado da arte: Ainda, como prova de teste inicial para o produto, será utilizada uma abordagem de contagem de interações dentro do AVA e que já foi previamente validada por meio de pesquisas científicas já publicadas [1][2][3]. Nos últimos anos, a equipe de pesquisa coordenada pelo proponente deste projeto avaliou a possibilidade de gerar modelos extrapoláveis a diversos contextos, comparando os desempenhos de tais modelos com outros que utilizem informações mais específicas e que eventualmente não estão disponíveis em qualquer cenário, ou que tenham custo computacional alto para serem extraídas. A estratégia de predição em questão é inicialmente restrita ao uso de dados de AVA (precisamente seus logs) e utiliza como base a contagem de interações dos usuários (estudantes) nesses ambientes ao longo das semanas de um curso. Essa metodologia é facilmente aplicável em qualquer AVA e pode ser transferida para um produto que possa ser utilizado por diferentes instituições e cenários. Importante ressaltar que a solução de negócio futuro não estará restrita ao uso de informações provenientes exclusivamente de AVA, sendo expansível para outras fontes de dados educacionais, como sistemas acadêmicos (inclusive proprietários), surveys, etc. Os membros da equipe proponente já possuem experiência de desenvolvimento de modelos de predição de risco utilizando outras estratégias que não envolvam dados oriundos do AVA e que podem ser futuramente implementadas nas fases seguintes da proposta [4][5][6].

Visão geral da solução proposta: A Figura 1 apresenta uma visão geral da solução tecnológica proposta pelo GT-LANSE. A solução é formada por um dashboard que é executado do lado do cliente e que apresenta visualizações sobre as interações dos acadêmicos no AVA. Esse dashboard é responsável por coletar as informações que serão utilizadas na predição e enviar as informações para o serviço de Learning Analytics. Os dados são pré-processados e armazenados no LRS para posteriormente serem consumidos pelos algoritmos de machine learning. Após o treinamento dos modelos e sua execução, os resultados da predição são devolvidos para o dashboard.

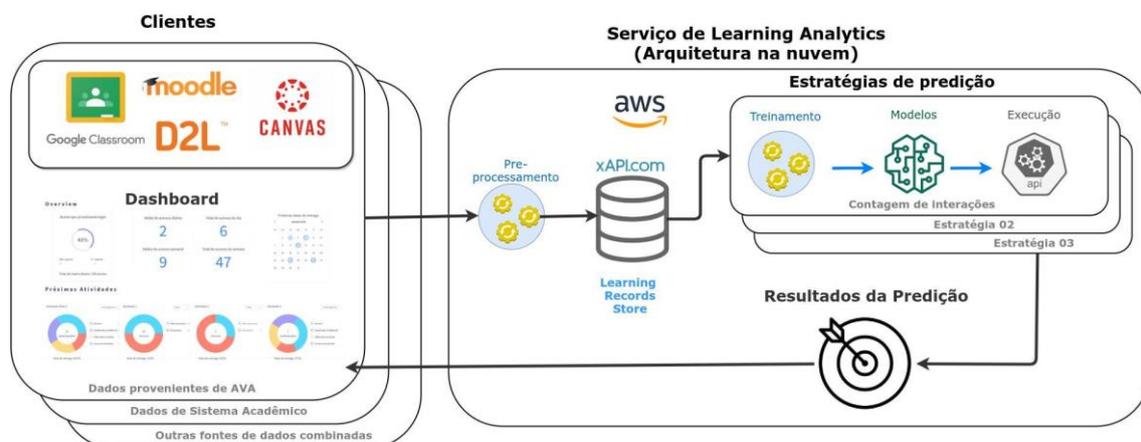


Figura 1 - Arquitetura da Solução do GT-LANSE

O dashboard deve ser desenvolvido de maneira customizada para cada tipo de AVA para o qual se deseja oferecer o serviço. Para essa etapa inicial será desenvolvido um dashboard para o Moodle em forma de plugin (bloco). Esse plugin possuirá um pooling que irá verificar novas informações de tempos em tempos e realizará a coleta de dados para processamento e fará uma notificação via push para o serviço de Learning Analytics. O envio de batches será assíncrono, com envio diário (uma ou duas vezes por dia) e que serão armazenados em uma fila.

Tecnologias que serão utilizadas: Será utilizado um provedor em cloud entre AWS, Microsoft Azure, Google Cloud Platform e Huawei (podendo utilizar instâncias VPS para hospedar os serviços ou utilizar o serviço da aws chamado de lambda, para hospedar nosso microsserviços). A predição será realizada de maneira assíncrona com uma arquitetura contendo sistema de eventos de mensageria garantindo a idempotência do sistema e não precisando recalculando solicitações já realizadas. O sistema será capaz de rastrear as mensagens já enviadas (e também as que falharam), possibilitando detectar bugs mais facilmente uma vez que será possível replicar as mensagens que entraram no sistema. A parte de maior processamento poderá ser executada dentro da EC2 e as outras partes poderão ir para o AWS lambda. As informações pré-processadas serão armazenadas na nuvem disponibilizada pela AWS (aqui poderíamos utilizar RDS que são bancos relacionais, ou também DynamoDB que são bancos e documentos). Uma das preocupações do projeto será a de garantir a segurança das informações e o respeito à LGPD. Para isso, todos os dados sensíveis serão trafegados anonimizados e criptografados. Será utilizado Python para o desenvolvimento dos modelos de predição e PHP para o plugin Moodle. O desenvolvimento total da proposta prevê 3 fases com desafios específicos, a saber: 1) Desafios de Implementação do MVP, 2) Desafios de Expansão, e 3) Desafios de Sustentabilidade e Consolidação.

Fase 1 - Desafios de Implementação do MVP: Nesta fase será implementada a solução inicial para clientes que utilizam o AVA Moodle. Essa arquitetura contempla principalmente um plugin Moodle responsável pelo recolhimento das interações que estão armazenadas nos logs do sistema, de enviar esses logs para serem pré-processados pelo serviço de Learning Analytics, de receber os resultados das predições, e de apresentar essas predições para o usuário (para esse MVP o usuário é o professor do curso Moodle). Para que os modelos de predição possam ser treinados e gerados para serem utilizados em um determinado curso, o plugin também deverá repassar informações relacionadas ao cronograma do mesmo (início e fim), além de permitir a seleção de cursos semelhantes que já tenham sido ministrados anteriormente e que sirvam como base para o treinamento e geração dos modelos de predição. Do lado do serviço de Learning Analytics serão desenvolvidos os scripts o pré-processamento dos dados, para o treinamento dos modelos de predição, e para a execução desses modelos. Também será implementado o Learning Record Store (LRS) para o armazenamento das interações em um formato padronizado. Resultados de pesquisas anteriores realizadas pela equipe coordenadora apontaram que o algoritmo Adaboost apresenta resultados satisfatórios e que de modo geral não há diferença estatística significativa quando comparamos os desempenhos dos diferentes modelos (RandomForest, Naive Bayes, MLP) quando se está trabalhando com a estratégia de predição de risco utilizando contagem de interações e atributos derivados. Considerando isso, nesta fase, é possível implementar uma solução que já utilize diretamente o Adaboost como algoritmo de predição. Testes de aceitação da tecnologia de predição

por parte dos usuários devem complementar os trabalhos desta fase, permitindo descobrir novas funcionalidades necessárias e a satisfação com o uso das ferramentas.

Fase 2 - Desafios de Expansão: Nesta fase a solução pode ser expandida de diferentes maneiras, a depender dos resultados obtidos na etapa anterior e do amadurecimento da solução durante esse período. A primeira expansão promissora da solução é a adaptação da estratégia de predição para detecção do risco de evasão de estudantes de um curso. Em situações que se está lidando com dados de cursos de graduação, por exemplo, isso envolve em utilizar dados das disciplinas que um determinado estudante está cursando e não somente de uma das disciplinas (como na solução para o desempenho). Essa solução já foi abordada pela equipe proponente em trabalhos anteriores [6]. Outra expansão possivelmente promissora é permitir que a solução seja utilizada por clientes que adotem outros AVA que não o Moodle. Isso implica no desenvolvimento de dashboards específicos para o recolhimento dos dados dessas outras plataformas (Canvas, GoogleClassroom, etc). Outra possível expansão está nas funcionalidades disponíveis no dashboard (plugin) do lado do cliente. Enquanto na versão inicial está previsto somente uma “simples entrega” da predição do risco acadêmico dos estudantes com algumas estatísticas básicas de acesso, em um segundo momento é possível adicionar novas funcionalidades a essa ferramenta (gráficos de barra das interações, mapas de calor da semana, estatísticas de atividades concluídas, etc). O oferecimento de dados analíticos para os estudantes e para gestores também é outra possibilidade de expansão da ferramenta, já que a versão da fase 1 está voltada para o uso por parte dos professores. Por último, a depender da captação de clientes interessados em outras soluções de predição, também é possível expandir a solução para a incorporação de novas estratégias de predição que não envolvam apenas dados provenientes do AVA. Essa última expansão envolveria um forte desafio de P&D uma vez que toda a solução de predição precisaria ser desenhada e customizada.

Fase 3 - Desafios de sustentabilidade e consolidação: A Fase 3 deve focar na consolidação dos serviços que estão sendo oferecidos e na sustentabilidade da proposta a longo prazo, com a prospecção de clientes reais e o estabelecimento de contratos que garantam a manutenção dos serviços.

Inovações do projeto: O projeto oferece forte potencial para dois tipos de inovação tecnológica, a saber: inovação incremental de produto, e inovação radical de processo. A inovação incremental de produto se dá no desenvolvimento propriamente dito de todo o ecossistema para a oferta de serviços de Learning Analytics. O desenvolvimento da ferramenta e dos serviços de predição são baseados em pesquisas científicas já largamente difundidas e que vem sendo conduzidas pela equipe executora desde 2013. Os indícios iniciais de que a utilização de dados de contagem de interações e atributos derivados podem ser utilizados na geração dos modelos de predição contribuem ainda mais para a inovação do produto, que poderá funcionar de maneira mais independente do desenho instrucional dos cursos. O potencial da proposta para a inovação radical de processo está diretamente relacionado com a implantação e uso contínuo da solução por parte dos professores e gestores das instituições de ensino. A predição com antecedência de acadêmicos em risco de repetência (e evasão) pode auxiliar de maneira decisiva o trabalho desses stakeholders que terão a oportunidade de ajustar seus procedimentos pedagógicos de maneira personalizada para esses acadêmicos. A oferta desse serviço permitirá a adoção de estratégias educacionais e de gestão para interferir nessas situações em tempo real e antes de seu desfecho. Ainda que o projeto esteja inicialmente voltado para identificação de acadêmicos em risco de repetência, a

ferramenta também poderá ser futuramente adaptada e direcionada para identificação de acadêmicos em risco de evasão (na fase 2), podendo ser utilizada por coordenadores de curso e demais gestores.

Outras soluções tecnológicas existentes: Dentre as soluções atualmente existentes que competem de maneira direta com a proposta pode-se citar o produto da empresa IntelliBoard (<https://intelliboard.net/>) que permitem um acompanhamento detalhado do progresso dos acadêmicos e dos cursos dentro de um AVA (mapa de calor de acessos, acessos diários, atividades realizadas, cursos mais acessados, estatísticas de navegador, atividades mais acessadas, etc). A visualização dos dados dentro do IntelliBoard é bastante completa e com uma enorme gama de opções, porém a solução parece restrita aos relatórios e não oferece serviços de predição baseados em aprendizado de máquina (somente relatórios de atividades cumpridas)[7]. Os preços para utilização do IntelliBoard não estão disponíveis abertamente no seu site, mas em contatos com empresas do setor estima-se um custo anual de 1 dólar por aluno para utilização da solução. Existe, especificamente para o Moodle, uma solução desenvolvida pela sua comunidade chamado de Moodle Learning Analytics (<https://docs.moodle.org/35/en/Analytics>). Este oferece modelos de predição baseado nos três tipos de presença em AVA (cognitiva, social e pedagógica) do modelo de Garrison [8]. Essa solução necessita de um forte envolvimento e treinamento das equipes de TI que administram os servidores Moodle das instituições, além de não oferecer visualizações integradas ao processo de predição e ser de difícil customização. Ainda, atualmente, o sistema não possui um modelo pré-treinado, sendo necessário o treinamento e geração de modelo a partir de cursos antigos, quando estes existirem.

Parceiros: A Elimu Social terá participação fundamental no desenvolvimento de software, no setup da infraestrutura tecnológica, e na prospecção dessa solução junto a instituições de ensino. A experiência da empresa junto ao mercado educacional e o seu envolvimento direto com ações de empreendedorismo social nessa área facilitarão a articulação de possíveis futuros clientes. O IFSul, a UFSC e a UFPel entrarão com o expertise em machine learning e desenvolvimento de algoritmos de predição de risco acadêmico. A experiência dos proponentes é essencial para o desenvolvimento da proposta, uma vez que já atuaram em conjunto na solução de problemas e tecnologias diretamente relacionados ao tema. UFSC e IFSul, por exemplo, participam atualmente de um projeto financiado pelo BID junto a Universidad de la República (UDELAR) para a geração de modelos de predição para os estudantes de todo o ensino secundário do país em uma iniciativa fAIRLAC (<https://fairlac.iadb.org/>) [9].

(f.3) Modelo de Negócios

A solução do GT-LANSE destina-se (nessa primeira fase) a: 1) instituições de ensino que utilizem o AVA Moodle como apoio aos processos de ensino-aprendizagem, 2) corporações que utilizam o Moodle em cursos de treinamento, e 3) empresas de prestação de serviços de hosting para Moodle. O modelo de negócio inicial pensado é o de SaaS ou Software como Serviço. Nesse modelo, o cliente contrata o serviço da empresa prestadora por meio de uma mensalidade, ou pagamento periódico. Para a solução do GT-LANSE o cálculo do serviço poderia estar relacionado à quantidade de estudantes para os quais o serviço irá realizar a predição de risco. Outra fonte de recursos pode ser a customização de informações do dashboard instalado do lado do cliente.

A solução pode ser integrada ao serviço de Moodle da RNP

(<https://www.rnp.br/servicos/gestores-de-ti/moodle>) agregando valor aos serviços de hospedagem Moodle que são oferecidos atualmente e permitindo que os clientes tenham acesso às funcionalidades do dashboard e de predição de risco acadêmico. A RNP também pode utilizar a solução dentro de seus próprios cursos que são oferecidos via Moodle (<https://esr.rnp.br/cursos>)

A startup envolvida na proposta dará suporte pedagógico na utilização das ferramentas de predição por parte dos professores, e também realizará testes de campo para a validação do plano de negócios através de ensaios junto aos protótipos desenvolvidos. A startup Elimu também realizará pesquisas de campo junto aos players educacionais para análise da viabilidade da solução como produto comercial.

(g) Ambiente de validação da solução proposta e documentação dos aprendizados

Prevemos utilizar as linguagens de programação Javascript, Python, PHP, Clojure ou Typescript. Também serão utilizadas técnicas de desenvolvimento de software para garantir a qualidade do nosso código, desenvolvendo testes de integração e testes unitários para evitarmos erros de desenvolvimento. Teremos como base para o projeto a utilização da metodologia ágil a partir de um fluxo de desenvolvimento baseado em Scrum e Kanban. Prevemos que o versionamento de código será utilizando um sistema de versão baseado em git e utilizaremos o Jira para documentar e acompanhar o projeto.

(j) Cronograma de marcos

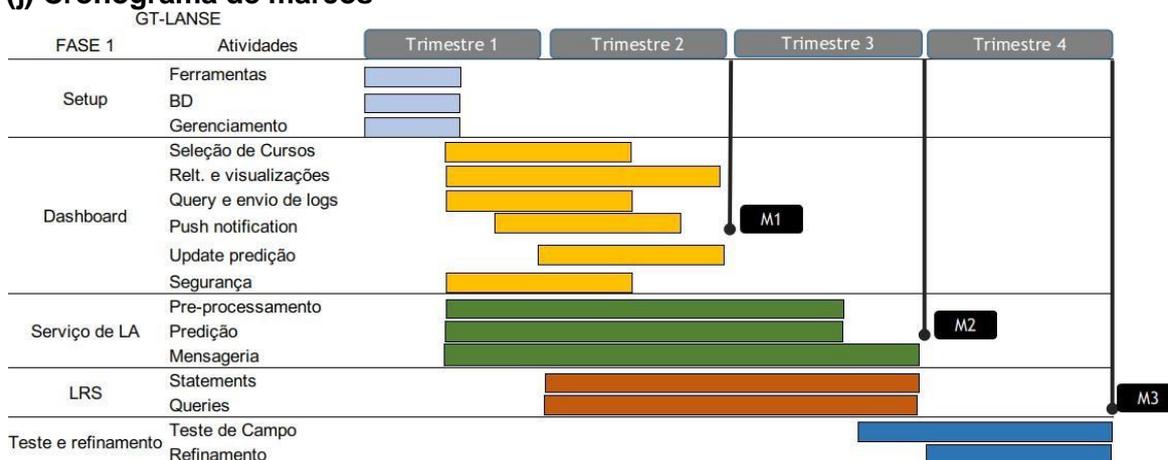


Figura 2 - Cronograma de Marcos

A Figura 2 apresenta o cronograma de marcos (Milestones) para a Fase 1 do GTLANSE. Cada Milestone é identificado com MX onde X é uma identificação numérica desse marco. Em M1 o projeto estará com o dashboard (plugin Moodle) desenvolvido com todas as funcionalidades básicas. Em M2 o serviço de Learning Analytics estará completo com os módulos de pré-processamento, predição e mensageria desenvolvidos, além do Learning Record Store pronto para uso e armazenamento das interações dos usuários. Em M3 o MVP é finalizado após testes de campo e refinamentos.

(k) Recursos financeiros k.1 j. Infraestrutura

Descrição	Qtd.	Valor Unitário	Valor em R\$ estimado
SERVIDOR VIRTUAL TIPO 3.2 vCPUs (2 vCPUs, 15 GB de RAM, HD 50GB, 150 IOPs)	12	750.4	9004.8
VOLUME DE ARMAZENAMENTO EM BLOCOS - OTIMIZADO. Deve fornecer taxa de desempenho mínima de 2.000 IOPS	12	286.8	3441.6
IP PÚBLICO IPV4	12	5.44	65.28
SERVIÇO DE VIRTUAL PRIVATE NETWORK (VPN)	12	3.13	37.56
Subtotal			R\$ 12.549.24

j.1 Equipamentos

Descrição	Instituições de Destino	Qtd.	Valor Unitário	Valor em R\$ estimado
Modelo D10 - Processador Intel Core i7 Memória RAM 16GB - HD SSD 256GB Kit teclado e mouse sem fio	UFSC/UFPEL	2	5305.97	10611.94
Monitor 24"	UFSC	1	1337.67	1337.67
Subtotal				R\$ 11949.61

I. Referências

- [1] Buschetto Macarini, L. A., Cechinel, C., Batista Machado, M. F., Faria Culmant Ramos, V., & Munoz, R. (2019). Predicting students success in blended learning—evaluating different interactions inside learning management systems. *Applied Sciences*, 9(24), 5523.
- [2] Detoni, D., Cechinel, C., Matsumura, R. A., & Brauner, D. F. (2016). Learning to identify at-risk students in distance education using interaction counts. *Revista de Informática Teórica e Aplicada*, 23(2), 124-140.
- [3] Einhardt, L., Tavares, T. A., & Cechinel, C. (2016, October). Moodle analytics dashboard: A learning analytics tool to visualize users interactions in Moodle. In 2016 XI Latin American Conference on Learning Objects and Technology (LACLO) (pp. 1-6). IEEE.
- [4] Macarini, L. A., Lemos dos Santos, H., Cechinel, C., Ochoa, X., Rodés, V., Pérez Casas, A., ... & Díaz, P. (2020). Towards the implementation of a countrywide K-12 learning analytics initiative in Uruguay. *Interactive Learning Environments*, 28(2), 166-190.
- [5] Costa, A. G., Queiroga, E., Primo, T. T., Mattos, J. C., & Cechinel, C. (2020, October). Prediction analysis of student dropout in a Computer Science course using Educational Data Mining. In 2020 XV Conferencia Latinoamericana de Tecnologias de Aprendizaje (LACLO) (pp. 1-6). IEEE.
- [6] Queiroga, E. M., Lopes, J. L., Kappel, K., Aguiar, M., Araújo, R. M., Munoz, R., ... & Cechinel, C. (2020). A learning analytics approach to identify students at risk of dropout: A case study with a technical distance education course. *Applied Sciences*, 10(11), 3998.
- [7] Relatórios Avançados no Moodle. Notícias EAD. <https://www.noticiasead.com.br/tutoriais-e-dicas/5023relatorios-avancados-no-moodle>. Acessado em 22 de julho de 2021
- [8] Garrison, D. R., Anderson, T., & Archer, W. (1999). Critical inquiry in a text-based environment: Computer conferencing in higher education. *The Internet and Higher Education*, 2(2), 87–105.

[9] Contrato RG-T3450-P004. Universidad de la República-Banco Interamericano de Desarrollo, Desarrollo de un modelo predictivo de riesgos de desvinculación educativa. 17 de Agosto de 2020. Disponível em https://www.colibri.udelar.edu.uy/jspui/bitstream/20.500.12008/26781/5/6645_Contrato%20a%20suma%20alzada%20Banco%20Interamericano%20de%20Desarrollo.pdf Acessado em 22 de Julho de 2021.

1. FICHA CADASTRAL DA STARTUP

RAZÃO SOCIAL DA MATRIZ: Bernardi Primo & CIA LTDA
NOME FANTASIA: Elimu

CNPJ: 29689060/0001-45	INSCRIÇÃO MUNICIPAL:
INSCRIÇÃO ESTADUAL:	INSCRIÇÃO NO CADASTRO NACIONAL DE ATIVIDADES (CNAE): 85.50-3-02; 47.51-2-01; 47.61-003; 62.01-5-01; 62.02-3-00; 62.03-1-00; 62.04-0-00
DATA DA FUNDAÇÃO: 15/02/2018	
CÓDIGO:	
RAMO DE ATIVIDADE: Atividade de apoio a educação, exceto caixas escolares	

SITE: www.elimusocial.com.br

ENDEREÇO: Rua Cacequi	Nº 167	COMPL.:
------------------------------	---------------	----------------

BAIRRO: Laranjal	CIDADE: Pelotas	UF: RS
-------------------------	------------------------	---------------

CEP: 96090-090	FONE (DDD): (53) 991299693	FAX (DDD):
-----------------------	-----------------------------------	-------------------

RAZÃO SOCIAL DA FILIAL:
NOME FANTASIA:

CNPJ:	INSCRIÇÃO MUNICIPAL:
INSCRIÇÃO ESTADUAL:	INSCRIÇÃO NO CADASTRO NACIONAL DE ATIVIDADES (CNAN):
DATA DA FUNDAÇÃO:	
CÓDIGO:	
RAMO DE ATIVIDADE:	

ENDEREÇO:

BAIRRO:	CIDADE:	UF:
----------------	----------------	------------

CEP:	FONE (DDD):	FAX (DDD):
NOME DO REPRESENTANTE LEGAL: Kelen Silveira Bernardi		
CARGO DO REPRESENTANTE: CEO e Diretora de produção de conteúdo		
NACIONALIDADE: brasileira		
ESTADO CIVIL: casada		
FORMAÇÃO: superior incompleto		
PROFISSÃO: Diretora de produção de conteúdo da Elimu		
RG: 4067181001		
ÓRGÃO EMISSOR DO RG: SJS		
CPF: 00541238019		
E-MAIL: kelenbernardi@gmail.com		
ENDEREÇO COMPLETO DO REPRESENTANTE: Rua Cacequi, 167 Laranjal , Pelotas/RS		

2. PRINCIPAIS PRODUTOS

Nome do produto	Descrição
Kit de Computação Criativa	Componentes eletrônicos e ferramentas para o desenvolvimento de projetos de Computação Criativa alinhados com competências da BNCC
Programa CrIE para Professores de EB	O programa CrIE para professores é composto por 8 oficinas de 8 horas cada, totalizando 64 horas de formação. Oficinas: Introdução a Aprendizagem Criativa Ferramentas do Google para professores - Sala de aula virtual Design de Aprendizagem - Criando aulas criativas Eletrônica básica - Criando projetos com componentes eletrônicos Eletrônica avançada - Criando chatbots com componentes eletrônicos e material reciclado Introdução a projetos de programação com o Scratch Aprofundando os conhecimentos em programação com o Scratch Criando uma horta inteligente com o BBC Micro:bit

3. PRINCIPAIS CLIENTES

Listar os clientes
Secretaria Municipal de Educação de Pelotas/RS
Secretaria Municipal de Educação de Campo Bom/RS
SEBRAE RS
Escola Santa Mônica de Pelotas/RS

4. RESPONSÁVEL PELAS INFORMAÇÕES

NOME: Kelen S. Bernardi
LOCAL E DATA: Pelotas, 23 de Julho de 2021.

Na sequência segue o restante da documentação Requerida da Startup:

- Estatuto ou Contrato Social, em vigor e última alteração devidamente registradas;
- Prova de Inscrição no Cadastro Nacional de Pessoa Jurídica (CNPJ)
- Prova de regularidade com o Fundo de Garantia por Tempo de Serviço (FGTS), comprovada pela Certidão de Regularidade de Situação (CRS), e
- Certidão de Débitos Relativos a Créditos Tributários Federais e à Dívida Ativa da União.

- Declaração de receita dos últimos 12 (doze) meses (01/06/2020 até 31/05/2021) assinada pelo contador e representante legal da startup;