

Resultados Emergentes no Desenvolvimento de um Sistema de Recomendação para Aprendizagem Autorregulada

Alana Viana Borges da Silva Neo^{1,2}, José Antônio Beltrão Moura¹,
Joseana Macêdo Fachine Régis de Araújo¹, Giseldo da Silva Neo^{1,3}

¹Universidade Federal de Campina Grande (UFCG) – Campina Grande – PB

²Instituto Federal de Mato Grosso do Sul (IFMS) – Corumbá – MS

³Instituto Federal de Alagoas (IFAL) – Viçosa – AL

alana.neo@ifms.edu.br, {antao, joseana}@computacao.ufcg.edu.br

giseldo.neo@ifal.edu.br

Abstract. *Self-regulated learning (SRL) is essential for academic performance, especially in Virtual Learning Environments (VLEs), where students require greater autonomy. However, many students have difficulty implementing effective SRL strategies. This paper presents the potential of personalized recommendation systems to assist higher education students in adopting these strategies. The paper presents significant emerging results, including: (i) the development and validation of two questionnaires to diagnose the SRL profile; (ii) the design and implementation of NeoSRL, a prototype recommendation system integrated with Google Classroom; and (iii) the modeling of SRL scenarios that support the recommendations. Initial findings indicate the feasibility of the approach and the positive acceptance of the developed tools, signaling a promising path for promoting SRL in VLEs.*

Resumo. *A Aprendizagem Autorregulada (ARA) é fundamental para o desempenho acadêmico, especialmente em Ambientes Virtuais de Aprendizagem (AVA), onde os estudantes necessitam de maior autonomia. Contudo, muitos estudantes apresentam dificuldades em aplicar estratégias de ARA eficazes. Este artigo apresenta o potencial de sistemas de recomendação personalizadas para auxiliar estudantes do ensino superior na adoção dessas estratégias. O artigo apresenta resultados preliminares significativos, incluindo: (i) o desenvolvimento e a validação de dois questionários para diagnóstico do perfil de ARA; (ii) a concepção e implementação do NeoAVA, um protótipo de sistema de recomendação integrado ao Google Sala de Aula; e (iii) a modelagem de cenários de ARA que fundamentam as recomendações. Os achados iniciais indicam a viabilidade da abordagem e a aceitação positiva das ferramentas desenvolvidas, sinalizando um caminho promissor para o fomento da ARA em AVAs.*

1. Introdução

A eficácia da aprendizagem em Ambientes Virtuais de Aprendizagem (AVA) está intrinsecamente ligada à capacidade dos estudantes de gerenciar seu próprio processo de estudo, uma competência conhecida como Aprendizagem Autorregulada

(ARA) [Zimmerman 2002]. A ARA envolve o planejamento, monitoramento e avaliação das próprias estratégias de aprendizagem. No entanto, a transição para o ensino online evidenciou que muitos estudantes do ensino superior carecem dessas habilidades, resultando em desafios como procrastinação, baixo engajamento e desempenho acadêmico insatisfatório [Kuo et al. 2014].

Os AVAs, como o Google Sala de Aula, geram um grande volume de dados sobre as interações dos alunos, que podem ser aproveitados para oferecer suporte personalizado. Nesse contexto, os Sistemas de Recomendação (SR) educacionais surgem como uma ferramenta promissora para fornecer orientação individualizada, sugerindo recursos e estratégias de estudo adaptadas às necessidades de cada aluno [Ricci et al. 2010].

O objetivo desta pesquisa é investigar o potencial de recomendações personalizadas para auxiliar estudantes do ensino superior na adoção de estratégias eficazes de ARA. Este artigo foca na apresentação e discussão de resultados preliminares que já foram alcançados, os quais demonstram o progresso e a viabilidade da pesquisa. Estes resultados incluem a criação e validação de instrumentos de diagnóstico de ARA, o desenvolvimento de um protótipo de sistema de recomendação (NeoAVA) e a modelagem de cenários de ARA.

O restante deste artigo está organizado da seguinte forma: A Seção 2 descreve a revisão realizada e a metodologia da pesquisa. A Seção 3 detalha e discute os resultados. A Seção 4 apresenta uma breve revisão de trabalhos relacionados. A Seção 5 delinea os próximos passos da pesquisa. A Seção 6 descreve as ameaças à validade, e por fim, a Seção 7 apresenta as considerações finais.

2. Metodologia

Uma revisão sistemática da literatura conduzida como parte desta pesquisa analisou o uso da ARA em SRs no contexto de AVAs [Neo et al. 2024a]. A revisão indica que, embora haja um reconhecimento crescente da importância da ARA, ainda existem lacunas significativas na forma como os SRs atuais incorporam e promovem ativamente estratégias de autorregulação. Além disso, observa-se que muitos sistemas focam na recomendação de conteúdo, mas poucos oferecem suporte explícito ao desenvolvimento de habilidades metacognitivas, motivacionais e comportamentais da ARA. A revisão também apontou para a necessidade de instrumentos validados para medir a ARA em contextos online e de sistemas que integrem esses perfis para personalizar as recomendações de forma mais holística. Esses achados reforçam a justificativa para a presente pesquisa e orientam o desenvolvimento das soluções propostas.

A pesquisa adota uma abordagem de *Design Science Research* (DSR) [Wieringa 2014], que envolve a construção e avaliação de artefatos computacionais. A metodologia combina técnicas quantitativas e qualitativas e é composta pelas seguintes fases principais:

1. **Identificação do Problema e Motivação:** Baseada na literatura e na necessidade prática de apoiar a ARA.
2. **Definição dos Objetivos da Solução:** Desenvolver um sistema que forneça recomendações personalizadas para ARA.
3. **Design e Desenvolvimento do Artefato:** Criação dos questionários de ARA, do sistema NeoAVA e dos cenários de recomendação.

4. **Demonstração:** Aplicação dos questionários e uso do NeoAVA em estudos piloto.
5. **Avaliação:** Validação estatística dos questionários, análise de aceitação do NeoAVA (e.g., via TAM [Davis et al. 1989]) e, futuramente, avaliação do impacto das recomendações no desempenho e na ARA dos estudantes.
6. **Comunicação:** Disseminação dos resultados através de publicações.

Os resultados apresentados neste artigo correspondem principalmente às fases de design, desenvolvimento, demonstração e avaliação inicial dos artefatos.

3. Resultados

A mensuração do perfil de ARA dos estudantes é um passo fundamental para a personalização das recomendações. Dois questionários foram desenvolvidos para isso, o v1 e v2. Além disso o NeoAVA foi construído como prova de conceito, por fim, foram modelados cenários a partir da literatura que são adaptados parcialmente no NeoAVA.

3.1. Questionário ARA v1 (Baseado no MSLQ)

Um primeiro questionário foi desenvolvido adaptando o *Motivated Strategies for Learning Questionnaire* (MSLQ) [Pintrich et al. 1991]. A versão adaptada continha 44 assertivas e 13 construtos. Foi aplicado a 43 estudantes do ensino superior.

- **Validação:** A análise fatorial confirmatória apresentou um X^2 normado (NC) de 2,37 (aceitável), mas outros índices como CFI (0,41) e RMSEA (0,18) indicaram limitações, possivelmente devido ao tamanho da amostra.
- **Confiabilidade:** A maioria dos construtos, como "Controle do Aprendizado" ($\alpha = 0,852$) e "Autoeficácia para Aprendizado" ($\alpha = 0,853$), mostrou boa confiabilidade (Alfa de Cronbach). Contudo, os construtos "Organização" ($\alpha = 0,153$) e "Elaboração" ($\alpha = 0,470$) apresentaram baixa confiabilidade, sugerindo necessidade de revisão.
- **Contribuição:** Este estudo forneceu um instrumento inicial e um algoritmo para envio automatizado de recomendações textuais básicas [Neo et al. 2024b]. As limitações apontaram para a necessidade de um questionário mais robusto.

3.2. Questionário ARA v2 (Baseado em Oito Questionários)

Visando maior abrangência e robustez, um segundo questionário foi desenvolvido a partir da combinação de assertivas de oito questionários de ARA reconhecidos na literatura (MSLQ [Pintrich et al. 1991], MAI [Schraw and Dennison 1994], LS [Warr and Downing 2000], OSLQ [Barnard et al. 2009], EMSR-Q [Alonso-Tapia et al. 2014], SOLQ [Jansen et al. 2017], EAREL [Cosnefroy et al. 2020], SRL-O [Broadbent et al. 2023]).

- **Estrutura:** O questionário resultante possui 34 assertivas e avalia seis construtos principais: Motivação, Metacognição, Estratégias de Aprendizado, Autocontrole Emocional, Ambiente de Estudo e Autonomia/Autodisciplina.
- **Validação Preliminar:** Aplicado a 105 estudantes, o questionário demonstrou boa consistência interna geral ($\alpha = 0,894$). Os construtos individuais também apresentaram boa confiabilidade, como sumarizado na Tabela 1.

Tabela 1. Alfa de Cronbach para Construtos do Questionário ARA v2

Construto	Alfa de Cronbach
Motivação	0,808
Metacognição	0,861
Estratégias de Aprend.	0,739
Autocontrole Emocional	0,887
Ambiente de Estudo	0,842
Autonomia/Autodisciplina	0,892

- **Correlação com Desempenho:** Uma análise preliminar indicou correlações fracas, porém positivas e significativas, entre a nota da disciplina e os construtos Autonomia ($r=0,31$), Motivação ($r=0,25$) e Ambiente ($r=0,23$). Notavelmente, estudantes com notas acima da média tenderam a apresentar maior autonomia (Teste-t: 2,88; $p=0,005$).
- **Contribuição:** Este questionário oferece um instrumento mais refinado e validado para diagnóstico da ARA em ambientes online, servindo de base para as recomendações do NeoAVA [Neo et al. 2025b].

3.3. Desenvolvimento do NeoAVA

O NeoAVA é um protótipo de Ambiente Virtual de Aprendizagem com funcionalidades de recomendação para ARA, integrado ao Google Sala de Aula [Neo et al. 2024c].

**Figura 1. Fluxo de dado do NeoAVA**

- **Arquitetura e Integração:** O NeoAVA é uma aplicação web (desenvolvida em Python com Streamlit) que se conecta ao Google Sala de Aula via API <http://autorregulacao.streamlit.app>. Ele coleta dados de interação dos alunos (notas, participação, acesso a materiais) e os combina com os perfis de ARA obtidos pelos questionários. As recomendações geradas são enviadas como mensagens no mural do aluno no Google Sala de Aula. A Figura 1 ilustra a arquitetura com a inclusão do professor no *loop* que avalia a recomendação antes do envio.

- **Funcionalidades:**
 - Cálculo e visualização dos perfis de ARA e Big Five.
 - Dashboard para professores acompanharem o progresso da turma e perfis individuais.
 - Geração de recomendações automáticas baseadas em cenários.
 - Permissão para professores personalizarem ou criarem novas recomendações.
- **Avaliação de Aceitação (TAM):** Um estudo piloto [Neo et al. 2024c] com 8 usuários avaliou a aceitação do NeoAVA usando o *Technology Acceptance Model* [Davis et al. 1989]. Os resultados (escala de 1 a 5) foram positivos: Utilidade Percebida (Média 4,6), Facilidade de Uso Percebida (Média 4,4), Intenção de Uso Contínuo (Média 4,0). Estes resultados, embora de uma amostra pequena, sugerem boa aceitação da ferramenta.

3.4. Framework com Cenários com Estratégias de ARA

Para que as recomendações sejam pedagogicamente relevantes, foram modelados 37 cenários de ARA, agrupados nos seis construtos do Questionário ARA v2, resultando em 58 recomendações textuais distintas [Neo et al. 2025a].

- **Base Teórica:** Os cenários foram construídos com base nas estratégias de ARA identificadas na literatura e nos questionários de referência.
- **Funcionamento:** As recomendações são tipicamente acionadas quando um estudante apresenta indicadores de dificuldade em um ou mais construtos da ARA.
- **Exemplo de Regra de Cenário (Motivação - Estabelecer Metas):** SE (Interação do aluno na semana $\leq 60\%$) E (Nenhuma atividade da semana realizada) ENTÃO Recomendar: "Olá [Nome do Aluno], percebemos que você não interagiu muito esta semana. Que tal definir algumas metas pequenas usando nosso [Quadro de Metas] ou criar um [Plano de Estudos] para organizar suas tarefas? Isso pode ajudar a aumentar sua motivação!"
- **Exemplo de Regra de Cenário (Metacognição - Planejamento Estruturado):** SE (Desempenho do aluno na atividade $\leq 60\%$) OU (Interação com os materiais da atividade $\leq 60\%$) ENTÃO Recomendar: "Olá [Nome do Aluno], notamos que você pode estar precisando de um apoio extra no planejamento. Sugerimos utilizar nosso [Plano de Estudos Detalhado] para organizar melhor suas próximas atividades e revisões."

A implementação desses cenários no NeoAVA permite que o sistema ofereça sugestões contextuais e acionáveis para os estudantes. Um exemplo de recomendação é apresentado na Figura 2a. Na Figura 2b a tela de recomendação personalizada e na Figura 3a a tela de recomendação automática. Na Figura 3b o perfil de autorregulação de um estudante.

Os resultados parciais apresentados demonstram avanços concretos na pesquisa. A validação dos questionários de ARA, especialmente a versão v2, fornece instrumentos mais confiáveis para o diagnóstico das necessidades dos estudantes. O desenvolvimento do NeoAVA e sua avaliação inicial positiva indicam que a abordagem de integrar recomendações de ARA a um AVA existente é tecnicamente viável e bem recebida pelos usuários. A modelagem de cenários de ARA cria uma base sólida para a geração de recomendações personalizadas e pedagogicamente embasadas.

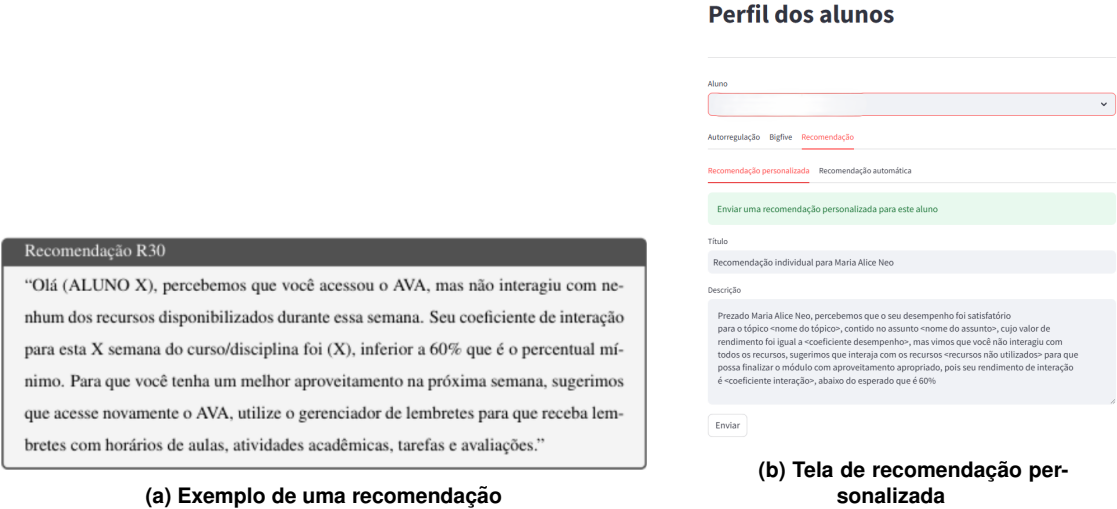


Figura 2. Recomendações automáticas e personalizadas no sistema



Figura 3. Interface do sistema: recomendação automática e perfil de autorregulação

Esses resultados parciais são importantes, pois validam etapas intermediárias importantes para a pesquisa. Eles mostram que é possível não apenas medir diferentes facetas da ARA, mas também começar a construir sistemas que utilizam essa informação para intervir positivamente no processo de aprendizagem. A correlação encontrada entre autonomia e desempenho, mesmo que fraca inicialmente, reforça a tese de que fomentar a ARA pode impactar positivamente os resultados acadêmicos. As limitações identificadas em cada etapa estão sendo endereçadas nos próximos passos da pesquisa.

4. Comparação com trabalhos da literatura

A Tabela 2 resume as principais abordagens utilizadas para geração de recomendações textuais voltadas à autorregulação da aprendizagem em ambientes virtuais. Destacam-se os *sistemas baseados em regras*, como o caso deste estudo (o NeoAVA), que oferecem simplicidade e clareza nas recomendações, embora sejam limitados em adaptabilidade. Já os *modelos preditivos com aprendizado de máquina*, como propostos por [Afzaal et al. 2021], permitem identificar padrões complexos de comportamento estudantil e gerar intervenções personalizadas. Abordagens como *análise metacognitiva das ações dos estudantes*, utilizadas por [Odilinye and Popowich 2020], e o *scaffolding metacognitivo adaptativo* de [Hidayah et al. 2019], também contribuem para intervenções mais eficazes e situadas. Cada abordagem apresenta vantagens e limitações, e a escolha da técnica mais adequada depende do contexto, dos objetivos pedagógicos e da infraestrutura tecnológica disponível.

Tabela 2. Quadro comparativo das abordagens para recomendações textuais de autorregulação

Abordagem	Descrição	Características	Exemplos/Referências
Sistemas baseados em regras	Regras do tipo <i>if-then</i> definem quando e qual recomendação gerar	Simples, transparente, fácil de ajustar; Rígido, dependente do design pedagógico inicial	[Neo et al. 2024c]
Modelos preditivos (ML supervisionado)	Algoritmos analisam dados dos alunos para prever necessidades e gerar intervenções	Alta personalização, detecta padrões complexos; Exige grande volume de dados e pré-processamento	[Afzaal et al. 2021]
Análise metacognitiva de comportamento	Monitora interações como anotações e marcações para inferir estratégias de ARA	Baseado em evidência concreta do comportamento estudantil; Dados podem ser escassos ou inconsistentes	[Odilinye and Popowich 2020]
<i>Scaffolding</i> metacognitivo adaptativo	Recomenda estratégias com base em dificuldades detectadas no progresso do aluno	Apoio contextualizado, centrado no aluno; Dificuldade de adaptação a múltiplas disciplinas	[Hidayah et al. 2019]

5. Trabalhos Futuros

A pesquisa continuará com foco na validação e refinamento dos artefatos desenvolvidos, bem como na avaliação do seu impacto. Como trabalhos futuros, será necessário conduzir estudos experimentais com turmas regulares do ensino superior para avaliar o impacto das recomendações em níveis de ARA, desempenho acadêmico e engajamento; explorar Aprendizado de Máquina e Modelos de Linguagem de Grande Escala (LLMs) para refinar a personalização e gerar recomendações mais dinâmicas e o desenvolvimento de Novas Formas de Recomendação, investigando recomendações visuais e outros formatos interativos.

6. Ameaças à validade

Os sistemas de recomendação textuais para autorregulação da aprendizagem em ambientes virtuais de aprendizagem representam uma área promissora, mas ainda em desenvolvimento. A integração com Learning Analytics e a exploração de novas técnicas, como algoritmos genéticos, são caminhos para avançar o campo. A falta de métricas específicas para avaliar o impacto na autorregulação permanece um desafio significativo, sugerindo a necessidade de mais pesquisas focadas nesse aspecto.

7. Considerações Finais

Este artigo apresentou resultados preliminares de uma pesquisa focada no desenvolvimento de um sistema de recomendação para fomentar a Aprendizagem Autorregulada em estudantes do ensino superior. Os principais avanços incluem a criação e validação de questionários de ARA, o desenvolvimento do protótipo NeoAVA com integração ao Google Sala de Aula, e a modelagem de um conjunto robusto de cenários de recomendação.

Os resultados iniciais são promissores, indicando a viabilidade técnica da solução proposta e uma boa aceitação por parte dos usuários. Mais importante, eles fornecem uma base sólida para as próximas etapas da pesquisa. Espera-se que esta pesquisa contribua com um modelo computacional e estratégias eficazes para apoiar a autonomia e a aprendizagem ao longo da vida no contexto da educação online.

Disponibilidade dos Artefatos

O código-fonte para reprodução da pesquisa e dos experimentos está disponível em https://github.com/giseldo/app_autorregulacao.

Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

Referências

- Afzaal, M., Haq, I. U., Waqas, A., and Khan, S. U. (2021). Explainable ai for data-driven feedback and intelligent action recommendations to support students' self-regulation. *Frontiers in Artificial Intelligence*, 4:1–17.
- Alonso-Tapia, J., Calderón, E. P., and Ruiz, M. A. D. (2014). Development and validity of the emotion and motivation self-regulation questionnaire (emsr-q). *The Spanish Journal of Psychology*, 17:E55.
- Barnard, L., Lan, W. Y., To, Y. M., Paton, V. O., and Lai, S. L. (2009). Measuring self-regulation in online and blended learning environments. *Internet and Higher Education*, 12(1):1–6.
- Broadbent, J., Panadero, E., Lodge, J., and Fuller-Tyszkiewicz, M. (2023). The self-regulation for learning online (srl-o) questionnaire. *Metacognition and Learning*, 18(1):135–163.
- Cosnefroy, L., Fenouillet, F., and Heutte, J. (2020). Construction et validation de l'échelle d'autorégulation des apprentissages en ligne (earel). *Canadian Journal of Behavioural Science/Revue canadienne des sciences du comportement*, 52(3):255.
- Davis, F. D., Bagozzi, R., and Warshaw, P. (1989). Technology acceptance model. *J Manag Sci*, 35(8):982–1003.
- Hidayah, I., Adj, T. B., and Setiawan, N. A. (2019). Development and evaluation of adaptive metacognitive scaffolding for algorithm-learning system. *IET Software*, 13(5):427–435.

- Jansen, R. S., Van Leeuwen, A., Janssen, J., Kester, L., and Kalz, M. (2017). Validation of the self-regulated online learning questionnaire. *Journal of computing in higher education*, 29(1):6–27.
- Kuo, Y.-C., Walker, A. E., Schroder, K. E., and Belland, B. R. (2014). Interaction, internet self-efficacy, and self-regulated learning as predictors of student satisfaction in online education courses. *The internet and higher education*, 20:35–50.
- Neo, A., Moura, J., Araújo, J., Neo, G., Filho, K. G., and Júnior, O. F. (2025a). Framework de cenários baseados em estratégias de autorregulação da aprendizagem para ambientes virtuais de aprendizagem. In *Anais do XXXIII Workshop sobre Educação em Computação*, pages 1218–1227, Porto Alegre, RS, Brasil. SBC.
- Neo, A., Moura, J. A. B., de Araújo, J. M. F. R., da Silva Neo, G., and Júnior, O. F. (2024a). The use of self-regulation of learning in recommender systems: State-of-the-art and research opportunities. In *Proceedings of the 16th International Conference on Computer Supported Education - Volume 2: CSEDU*, pages 525–532. INSTICC, SciTePress.
- Neo, A. V. B. S., Antão, J., Moura, B., Macêdo, J., Régis, F., and Neo, G. S. (2024b). Modelagem de Autorregulação da Aprendizagem no Ensino Superior: Uma Ferramenta para Automatizar Levantamento de Perfis e Recomendações Personalizadas. (Cbie):58–71.
- Neo, A. V. B. S., Antão, J., Moura, B., Macêdo, J., Régis, F., and Neo, G. S. (2024c). NeoAVA: A virtual learning environment for Self-Regulated Learning to be used by students and teachers. *XIII Congresso Brasileiro de Informática na Educação (CBIE 2024)*, pages 1890–1903.
- Neo, A. V. B. S., Moura, J., Araújo, J., Neo, G., Filho, K. G., and Júnior, O. F. (2025b). Construção de um instrumento de autorregulação online: Uma abordagem unificada a partir de oito questionários. In *Anais do XXXIII Workshop sobre Educação em Computação*, pages 1207–1217, Porto Alegre, RS, Brasil. SBC.
- Odilinye, L. and Popowich, F. (2020). Personalized recommender system using learners' metacognitive reading activities. In *Methodologies and Intelligent Systems for Technology Enhanced Learning, 10th International Conference*, pages 195–205. Springer.
- Pintrich, P. R. et al. (1991). A manual for the use of the motivated strategies for learning questionnaire (mslq). *ERIC*.
- Ricci, F., Rokach, L., and Shapira, B. (2010). Introduction to recommender systems handbook. In *Recommender systems handbook*, pages 1–35. Springer.
- Schraw, G. and Dennison, R. S. (1994). Assessing metacognitive awareness. *Contemporary educational psychology*, 19(4):460–475.
- Warr, P. and Downing, J. (2000). Learning strategies, learning anxiety and knowledge acquisition. *British journal of Psychology*, 91(3):311–333.
- Wieringa, R. J. (2014). *Design science methodology for information systems and software engineering*. Springer.
- Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory into practice*, 41(2):64–70.