PAULO EMANUEL CENACCHI PEREIRA

# O uso de métodos computacionais em pesquisas de processo em psicoterapia: uma revisão sistemática de escopo.

São Paulo
2022

UNIVERSIDADE DE SÃO PAULO
INSTITUTO DE PSICOLOGIA

PAULO EMANUEL CENACCHI PEREIRA

# O uso de métodos computacionais em pesquisas de processo em psicoterapia: uma revisão sistemática de escopo

VERSÃO CORRIGIDA

Dissertação apresentada ao Instituto de Psicologia da Universidade de São Paulo para obter o título de Mestre em Ciências pelo Departamento de Neurociências e comportamento (NEC).
Orientador: Felipe D'Alessandro Ferreira Corchs

Assinatura do Orientador

São Paulo
2022

AUTORIZO A REPRODUÇÃO E DIVULGAÇÃO TOTAL OU PARCIAL DESTE TRABALHO, POR QUALQUER MEIO CONVENCIONAL OU ELETRÔNICO, PARA FINS DE ESTUDO E PESQUISA, DESDE QUE CITADA A FONTE.

Catalogação na publicação
Biblioteca Dante Moreira Leite
Instituto de Psicologia da Universidade de São Paulo
Dados fornecidos pelo(a) autor(a)

Cenacchi, Paulo
O uso de métodos computacionais em pesquisas de processo em psicoterapia: uma revisão sistemática de escopo / Paulo Cenacchi; orientador Felipe Corchs. -São Paulo, 2022.
75 f.
Dissertação (Mestrado - Programa de Pós-Graduação em Neurociências e Comportamento) -- Instituto de Psicologia, Universidade de São Paulo, 2022.
1. Computação. 2. Psicoterapia. 3. Pesquisa de processo. 4. Orientada por dados. 5. Orientada por teoria. I. Corchs, Felipe, orient. II. Título.

Resumo

Cenacchi, P. (2022). *O uso de métodos computacionais em pesquisas de processo em psicoterapia: uma revisão sistemática de escopo.* (Dissertação de Mestrado). Instituto de Psicologia, Universidade de São Paulo, São Paulo.

A psicoterapia tem por objetivo promover saúde psicológica e se desenvolveu a ponto de estar reconhecidamente entre os tratamentos mais importantes em saúde mental. Ainda que exista certo consenso sobre a sua efetividade geral, os processos por trás destas mudanças permanecem velados, deixando esta importante lacuna na área. Para investigar o desenvolvimento da mudança faz-se necessário pesquisar a atuação das variáveis internas à psicoterapia. A área de pesquisa que se propõe a estudar os processos internos à psicoterapia, os mecanismos pelos quais a psicoterapia funciona, é conhecida como pesquisa de processo em psicoterapia. Esta área enfrenta desafios metodológicos dada a natureza complexa, dinâmica, não linear e multivariada do fenômeno. Um caminho para transpor estes obstáculos é aliar a ciência computacional à pesquisa de processo em psicoterapia, aplicando duas das tradições da computação: orientada por dados e orientada por teoria. A primeira baseias em dados para realizar predições, a segunda em conhecimento prévio ou hipóteses mecanísticas. Esta revisão sistemática de escopo buscou organizar estudos que realizaram estes esforços para facilitar a progressão da área. Elegemos aprendizagem de máquina e processamento de linguagem natural como principais representantes da tradição orientada por dados e a teoria dos sistemas dinâmicos para representar a tradição orientada por teoria. Foram incluídos 39 estudos que utilizaram métodos computacionais para analisar dados em pesquisa de processo em psicoterapia, identificados por uma busca sistematizada realizada nas principais bases de ciência da computação, psiquiatria e psicologia. Os estudos tiveram sua metodologia classificada nas categorias orientada por dados (19 estudos), orientada por teoria (7 estudos) ou híbrida (usou técnicas da tradição abordada por dados e da orientada teoricamente; 13 estudos). A amostra usou um total de 90 técnicas computacionais distribuídas entre os 39 estudos, descritas de forma sistematizada nesta revisão. De forma geral, a área parece se encontrar numa fase incipiente, ainda desorganizada e com estudos pouco conectados, mas com resultados que parecem muito promissores. Descobertas futuras podem impactar a pesquisa, a clínica e a formação de terapeutas, especialmente se a área trabalhar de forma mais coesa.

Palavras-chave: Computação. Psicoterapia. Pesquisa de Processo. Metodologia orientada por dados. Metodologia orientada por teoria.

Abstract

Cenacchi, P. (2022). *Computational methods in psychotherapy process research: a systematic scoping review* (Dissertação de Mestrado). Instituto de Psicologia, Universidade de São Paulo, São Paulo.

Psychotherapy is considered an important therapeutic resource among evidence-based treatments on mental health. Despite the available evidence of the general effectiveness for the therapeutic modality, the exact mechanisms through which therapeutic change occurs are not completely understood. Psychotherapy process research pursues the investigation of those mechanisms of therapeutic change involved in psychotherapy. Given the complex, dynamical, non-linear and multivariate nature of the object under investigation, this field faces methodological challenges and demand a huge effort to be carried out, from the collection to the analysis of data, and, even so, the amount of information produced is usually not enough to represent and explore the variety of processes known to happen in psychotherapies. Computer sciences have developed tools, such as machine learning and dynamic systems modeling, that may be helpful to deal with these problems. This systematic scoping review sought to organize the studies that made these efforts. 39 studies that used computational methods to analyze data from psychotherapy process research were identified by a systematized search conducted in the major computer science, psychiatry, and psychology databases. The studies had their methodology classified into data-driven, theory-driven, or hybrid categories. The sample had 19 data-driven, 7 theory-driven, and 13 hybrid studies. The sample had a total of 90 computational techniques, 21 from natural language processing, 20 from dynamic systems, and 49 from machine learning, described systematically in this review. In general, the area seems to be in an incipient phase, still disorganized and with little connection between studies, but exploratory with some results that seem very promising. Future findings may impact research, clinical practice, and the training of therapists, especially if the field works more cohesively.

Keywords: Computation. Psychotherapy. Process Research. Data-driven methods. Theory-driven methods.

## LISTA DE FIGURAS E TABELAS

Figura 1 – Fluxo de seleção de estudos da amostra ..... 18

Figura 2 – Quantidade de artigos distribuída em anos ..... 19

Figura 3 – Quantidade de artigos produzidos em cada país..... 20

Figura 4 – Quantidade de estudos por tamanho amostral ..... 21

Tabela 1 – classificação dos estudos em métodos orientados teoricamente, métodos orientados por dados e métodos híbridos ..... 22

**SUMÁRIO**

1 INTRODUÇÃO ..... 5
1.1 OBJETIVO ..... 10
2 MÉTODO ..... 11
2.1 PROTOCOLO ..... 11
2.2 CRITÉRIOS DE ELEGIBILIDADE ..... 11
2.3 FONTES DE INFORMAÇÕES ..... 11
2.4 ESTRATÉGIA DE PESQUISA ..... 12
2.5 SELEÇÃO DAS FONTES DE EVIDÊNCIA ..... 13
2.5.1 Critérios de inclusão ..... 13
2.5.2 Critérios de exclusão ..... 14
2.6 TABULAÇÃO DOS DADOS ..... 14
2.7 SÍNTESE DOS RESULTADOS ..... 15
3 RESULTADOS ..... 17
3.1 Retorno dos registros ..... 17
3.2 Características demográficas dos estudos da amostra ..... 18
3.2.1 Produção anual dos estudos da amostra ..... 19
3.2.2 Distribuição dos estudos por países em que foram conduzidos ..... 20
3.2.3 Tamanhos das amostras dos estudos ..... 21
3.2.4 Classificação dos estudos em orientados por dados, teoricamente e híbridos ..... 21
3.3 DESCRIÇÕES DAS TÉCNICAS COMPUTACIONAIS UTILIZADAS ..... 23
3.3.1 Processamento de linguagem natural ..... 24
3.3.2 Sistemas dinâmicos ..... 31
3.3.3 Aprendizagem de máquina ..... 38
4 DISCUSSÃO ..... 54
REFERÊNCIAS ..... 59
APÊNDICES ..... 65

# 1 INTRODUÇÃO

A psicoterapia é o nome dado ao conjunto de técnicas e procedimentos que tem por objetivo promover saúde psicológica (APA, 2016). Brent & Kolko (1998) organizaram a definição de psicoterapia como uma modalidade de tratamento na qual o terapeuta e o(s) paciente(s) trabalham juntos para melhoria de saúde psicopatológica e redução de deficiência funcional através de foco sobre (1) a relação terapêutica; (2) as atitudes, os pensamentos, o afeto, o comportamento do paciente; e (3) o contexto social e o seu desenvolvimento (trad. nossa). O campo se desenvolveu a ponto de ser recomendação primária para vários transtornos mentais e, junto com psicofármacos, ela está reconhecidamente entre os tratamentos mais importantes em saúde mental (Holmes et al., 2018). Dados sobre seu tamanho de efeito sobre redução de sintomas foram e são produzidos para diversos transtornos mentais (e.g., depressão, transtornos de ansiedade, estresse pós traumático, transtorno obsessivo compulsivo, transtornos psicóticos, transtorno bipolar) (Cuijpers, 2019). A maioria dos ensaios clínicos randomizados realizados para evidenciar a eficiência da terapia mensura a diferença do grau dos sintomas antes e depois do tratamento, mas não contempla o desenvolvimento dessa mudança ao longo do tratamento (Kazdin, 2007). Ainda que sua efetividade tenha sido demonstrada, os processos por trás destas mudanças permanecem velados, deixando esta importante lacuna na área (Holmes et al., 2018; Johansson & Høglend, 2007; Kazdin, 2007, 2014; Mohr et al., 2014; Mohr et al., 2009). Para investigar o desenvolvimento da mudança faz-se necessário pesquisar a atuação das variáveis independentes internas à psicoterapia.

A área de pesquisa que se propõe a estudar tais processos internos à psicoterapia, os mecanismos pelos quais a psicoterapia funciona, é conhecida como pesquisa de processo em psicoterapia (Crits-Christoph, Gibbons, & Mukherjee, 2013; Hardy & Llewelyn, 2015; D. Orlinsky, Heinonen, & Hartmann, 2015). As principais variáveis de interesse atual deste campo são aspectos da relação (e.g., aliança), intervenções (exposição, escuta reflexiva) e variáveis do paciente (e.g *insights*, estados emocionais) (D. Orlinsky et al., 2015). Historicamente, a pesquisa de processo passou por algumas fases de desenvolvimento (D. E. Orlinsky, Ronnestad, & Willutzki, 2004). Hoje, a sua principal pergunta é “como as mudanças acontecem?” em um processo psicoterápico (para uma revisão pormenorizada ver Braakmann

(2015)). Seus objetivos são quatro: (a) entender os mecanismos do tratamento e da mudança; (b) melhorar a qualidade do tratamento; (c) refinar e desenvolver teorias; (d) suplementar o desenvolvimento de treinos efetivos para formação de terapeutas (Hardy & Llewelyn, 2015). Assim, a pesquisa de processo é fundamental se tivermos interesse em ir além de entender os produtos da psicoterapia e quisermos entender como é seu funcionamento.

Alguns resultados foram derivados desta linha de investigação, por exemplo: (a) O conceito de aliança terapêutica, por exemplo, tem sido amplamente estudado e ganhado relevância entre os processos que compõem a psicoterapia no que diz respeito ao seu tamanho de efeito sobre desfecho terapêutico (Crits-Christoph et al., 2013) (b) a expectativa do paciente, seus sentimentos positivos sobre o processo terapêutico e seu engajamento também são aspectos importantes (Bohart & Wade, 2013). A isso somam-se (c) a autocompreensão do paciente promovida em terapia psicodinâmica (Crits-Christoph et al., 2013) e o nível de excitação emocional durante terapia de exposição da terapia comportamental para ansiedade (Crits-Christoph et al., 2013), com relação ao comportamento do terapeuta, (d) intervenções específicas têm sido relacionadas a um desfecho positivo quando aplicadas habilmente (D. E. Orlinsky et al., 2004), como, por exemplo, o uso de técnicas da terapia cognitiva para tratamento de depressão (Crits-Christoph et al., 2013).

Apesar destes avanços, os achados são limitados e carecem de mais pesquisas (Crits-Christoph et al., 2013). No momento, as pesquisas de processo em psicoterapia têm recebido menos atenção do que pesquisas de resultado por algumas razões. Uma delas é o interesse econômico, visto que ter dados somente sobre a eficácia de certa abordagem terapêutica já seria suficiente para sustentar a recomendação da mesma. Neste contexto, pesquisas de processo sobre o tratamento em questão tornam-se menos atrativas. Outro grande desafio é metodológico. O levantamento de dados e análise devem ser minuciosos e exigem uma equipe de psicoterapeutas treinados. Além de complexo, o material produzido pode ser muito numeroso. As pesquisas que investigam processos intrasessão e longitudinais envolvem um material imenso para cada sujeito de pesquisa. Estas barreiras têm limitado a produção de pesquisas desta natureza.

Um caminho para transpor estes obstáculos é aliar a ciência computacional à pesquisa de processo em psicoterapia (Holmes et al., 2018), uma vez que possuem técnicas capazes de analisar grandes conjuntos de dados e de automatizar certos

procedimentos da pesquisa de processo em psicoterapia. A ciência da computação tem desenvolvido ferramentas capazes de coletar, processar e analisar dados e essas ferramentas têm potencial para serem aplicadas na pesquisa em psicoterapia (Dwyer, Falkai, & Koutsouleris, 2018). Dois braços da computação têm contribuições relevantes: (a) a abordagem orientada por dados, que tem como principais ferramentas o processamento de linguagem natural (*NLP* – do inglês *natural language processing*) e aprendizagem de máquinas (*ML* – do ingês *machine learning*); e (b) a abordagem orientada teoricamente, que usa como ferramenta principal a modelagem de sistemas dinâmicos. A primeira constrói seu modelo a partir do comportamento dos dados da amostra e é agnóstica à teoria, a segunda constrói seu modelo a partir de conhecimentos prévios que descrevem os mecanismos dos processos modelados. A abordagem orientada por dados permite identificar preditores de desfechos desejados e indesejados, a abordagem orientada teoricamente oferece modelos explicativos de interações complexas de variáveis ou contém hipóteses de investigação que endereçam elementos teóricos e investigam a dimensão mecanística do fenômeno (Bennett, Silverstein, & Niv, 2019; Huys, Maia, & Frank, 2016).

O processamento de linguagem natural, como o nome sugere, é o processo pelo qual a máquina interpreta ou gera linguagem humana textual (Chowdhury, 2003; Liddy, 2001), por exemplo, reconhecimento de contexto, semântica, léxica e os sentimentos contidos em um texto.

O processamento de linguagem natural é muito utilizado, por exemplo, em serviços de atendimento ao paciente automatizados, neste caso o paciente descreve o seu problema e a ferramenta lê as palavras e emite uma resposta adequada ao significado das palavras utilizadas pelo paciente.

No contexto da pesquisa de processo em psicoterapia Syzdek (2020) utilizou processamento de linguagem natural para identificar sentimentos positivos e negativos na interação entre paciente e terapeuta. Posteriormente, construíram um modelo linear hierárquico para identificar mudanças nos sentimentos e na relação entre paciente e terapeuta. Os resultados indicaram que os sentimentos de terapeuta e paciente covariam, em movimento crescente entre as sessões ao longo do processo e decrescente dentro das sessões. Essa metodologia permitiu analisar aproximadamente 114 sessões de terapia automaticamente e a detecção do comportamento de sentimentos em 20 trajetórias de terapia distintos, codificação que demandaria um trabalho hercúleo se fosse realizada manualmente.

A aprendizagem de máquinas é a construção de um modelo capaz de realizar reconhecimento de padrões e/ou predições a partir de dados de uma amostra (Dwyer et al., 2018; Murphy, 2012). O aprendizado pode ocorrer principalmente de duas formas, supervisionada e não supervisionada. Na primeira, e mais comum, a varável resposta é previamente determinada; na última, o próprio algoritmo determina a variável resposta (Murphy, 2012).

Em instituições financeiras a aprendizagem de máquina é amplamente empregada na análise de crédito. Um modelo previamente treinado é capaz de investigar a probabilidade de inadimplência de novos pacientes com base em suas características (i.e., preditores) e assim definir o crédito a ser concedido. Algumas pesquisas desta natureza já vêm sendo realizadas em pesquisas de processo em psicoterapia e dado frutos. Laskoski, Serralta, Passos, & Hauck (2019) utilizaram aprendizagem de máquina para identificar variáveis preditoras de estresse na clínica. Inicialmente, os autores coletaram dados sobre estresse de pacientes e sobre comportamentos do terapeuta (e.g., intervenções) em um conjunto de 62 sessões de terapia. Em seguida, buscou-se identificar possíveis efeitos do comportamento do terapeuta sobre o nível de estresse dos pacientes. O modelo detectou, dentre os comportamentos do terapeuta, 6 preditores de estresse, sendo o mais relevante o comportamento do terapeuta de ajudar o paciente a evitar ou suprimir conteúdo perturbador. Dada a alta acurácia e validade clínica, futuras pesquisas podem suplementar a importância dessa variável, impactando futuramente na forma como terapeutas são treinados e a psicoterapia é aplicada (Laskoski et al., 2019).

Já a teoria dos sistemas dinâmicos (TSD), principal ferramenta usada pelas abordagens orientadas teoricamente, produz modelos contínuos, por meio de equações diferenciais, ou discretos, através de equações de diferença (Salvatore & Tschacher, 2012; Thelen, 2005; Thelen & Smith, 1998). Esta abordagem utiliza medidas sensíveis a interações complexas distribuídas no tempo (Salvatore & Tschacher, 2012; Thelen, 2005; Thelen & Smith, 1998), sua natureza dinâmica considera como o estado atual ou passado de um sistema influência estados seguintes, e permite responder perguntas explanatórias como, por exemplo, a flutuação de escores de aliança entre sessões modula os sintomas da escala de desfecho.

Um exemplo de aplicação da teoria dos sistemas dinâmicos é a modelagem do comportamento de uma mola. Em um primeiro momento, pode-se considerar a mola

como um sistema estático em que a aplicação de uma força externa resulta instantaneamente em seu deslocamento. Entretanto, esse modelo também pode ser abordado como um sistema dinâmico visto que a resposta do sistema não depende só das condições iniciais, mas também do tempo. Assim, a resposta do sistema depende tanto das entradas externas ao modelo quanto das entradas passadas que resultam em seu estado atual. Por exemplo, uma mesma quantidade de força (entrada) utilizada para comprimir a mola pode ter efeitos diferentes, como um maior tempo de resposta ou maior deslocamento, a depender do estado da mola, sendo uma mola antiga ou nova. Logo, a memória contida na mola pode resultar em respostas diferentes à mesma quantidade de força aplicada.

A teoria dos sistemas dinâmicos pode oferecer insights interessantes em pesquisa de processo em psicoterapia. Em um primeiro momento um estudo classificou 153 trechos de sessões de psicoterapia em episódios de mudança e episódios de ruptura de aliança, os primeiros são episódios em que mudanças ocorreram e os segundos são episódios com instabilidade na relação terapeuta e paciente (os critérios de classificação foram subjetivos e podem ser conferidos em Krause et al. (2007) e Safran & Muran (2006)). Posteriormente, os autores investigaram se episódios de mudança e ruptura estariam associados a determinados comportamentos do paciente e do terapeuta nomeados como posturas de discurso (tipo de relação do falante com o ouvinte, e.g., professor) e qualidades vocais (características da fala, e.g., expressivo, conectado, reflexivo). Ou seja, observaram se as posturas de discurso e qualidades vocais seriam mais ou menos frequentes a depender da natureza do episódio (mudança ou ruptura), para isso modelaram essas variáveis como a atividade de um sistema dinâmico (Tomicic et al., 2015). De acordo com o estudo, o paciente tem maior tendência de assumir postura reflexiva (distância emocional da situação, porém não desconectada) e qualidade vocal “conectada” (estar sensível ao outro) em contexto de mudança do que ruptura. O terapeuta por sua vez, tem maior tendência de assumir uma postura de proponente (terapeuta se mostra como alguém que está observando e oferece uma nova perspectiva) e qualidade vocal “conectada” (estar sensível ao outro) em contexto de mudança do que ruptura (Tomicic et al., 2015). Estes comportamentos foram dependentes uns dos outros, funcionando como um sistema no qual terapeuta e paciente regularam um ao outro moldando o episódio. Esta lente permitiu abordar o fenômeno da psicoterapia contemplando as suas qualidades dinâmica, multivariada, complexa e não linear.

Por meio deste sobrevoo, evidencia-se que métodos computacionais podem produzir dados relevantes para a prática clínica e para a pesquisa de processo em psicoterapia. No entanto, essa produção científica está muito dispersa, de forma que a comunidade tem acesso reduzido aos métodos aplicados nessa área e às descobertas recentes. Nesse contexto, faz-se necessário revisar sistematicamente os estudos conduzidos nesta abordagem que usa métodos da computação para analisar o processo psicoterápico. Uma visão panorâmica da área pode orientar futuras tomadas de decisões metodológica, teórica e prática nesta área.

## 1.1 OBJETIVO

Realizar uma revisão sistemática de escopo dos estudos que utilizaram métodos computacionais para analisar dados de pesquisa de processo em psicoterapia.

# 2 MÉTODO

O desenho deste trabalho foi moldado cumprindo as diretrizes para revisões sistemáticas de escopo cunhadas por Munn et al. (2018) e Tricco et al. (2018). As revisões sistemáticas de escopo aproximam-se de revisões sistemáticas por seu rigor, sistematicidade e replicabilidade, mas, enquanto as revisões sistemáticas investigam estudos homogêneos, procuram responder uma pergunta específica e produzir diretrizes aplicadas, a revisão sistemática de escopo abrange estudos mais heterogêneos em sua metodologia, podem endereçar perguntas mais amplas e não ambicionam recomendar diretrizes clínicas, mas proporcionar uma visão geral de uma área, incluindo seu estado de maturação, estágio de produção atual, conceitos, métodos e lacunas. A revisão de escopo é especialmente útil para sumarizar e disseminar um corpo de conhecimento disperso, coerente com nossos objetivos, de mapear um conjunto amplo e complexo de pesquisas.

## 2.1 PROTOCOLO

Em conformidade com a indicação de especialistas (Peters et al., 2020), de que protocolos desta natureza devem ser desenvolvidos *a priori* para garantir transparência e reduzir a duplicidade de trabalhos, a condução da pesquisa respeitou um protocolo desenvolvido pelos autores e publicado em domínio digital, em língua inglesa disponível em: https://figshare.com/articles/online_resource/Computational_methods_in_psychotherapy_process_research_a_systematic_scoping_review/14605050.

## 2.2 CRITÉRIOS DE ELEGIBILIDADE

Foram incluídos estudos que utilizaram métodos computacionais para analisar dados em pesquisa de processo em psicoterapia. Os estudos deveriam ter sido revisados por pares, estarem disponíveis em língua inglesa e cadastrados em uma das bases pesquisadas.

## 2.3 FONTES DE INFORMAÇÕES

As bases de pesquisas nas quais a busca foi realizada são: ACM, IEEE, PubMed, PsychInfo e Web Of Science. Estas bases constituem os principais repositórios das áreas de ciências da psiquiatria, psicologia e computação.

## 2.4 ESTRATÉGIA DE PESQUISA

A estratégia de pesquisa foi desenvolvida com base em diretrizes para busca eletrônicas (McGowan et al., 2016). A estrutura de palavras de busca utilizada contemplou dois grandes grupos, psicoterapia e computação:

(psychotherap* OR "clinical psychology" OR "counseling" OR "behavior therapy" OR "behaviour therapy" OR "behavioral therapy" OR "behavioural therapy" OR "cognitive therapy" OR psychodynamic* OR psychoanal*)

AND

(computation* OR "machine learning" OR "neural network" OR "neural networks" OR "deep learning" OR "data mining" OR "dynamic system" OR "dynamic systems" OR "dynamical system" OR "dynamical systems" OR "natural language process" OR "natural language processing" OR "NLP" OR "sentiment analysis" OR "difference equation" OR "difference equations" OR "differential equation" OR "differential equations")

Cada uma das bases de dados citadas anteriormente (ver seção “fontes de informações”) possui peculiaridades na configuração da busca, isso exigiu que os autores desta revisão adaptassem os termos de busca de acordo com estas peculiaridades. Os termos de busca utilizados em cada base podem ser encontrado no apêndice I.

Dado o fato de que as possibilidades de métodos que poderiam ser considerados computacionais são inúmeras, optamos por termos que cubram as principais técnicas representativas das duas tradições computacionais aqui consideradas: aprendizagem de máquinas e o processamento de linguagem natural como os principais representantes da abordagem orientada por dados e a modelagem de sistemas dinâmicos como principal representante da abordagem orientada teoricamente este cuidado foi importante para que a revisão não focasse excessiva e

exclusivamente em uma tradição computacional orientada teoricamente ou por dados, mas sim tatear o estado da arte de ambas as tradições.

## 2.5 SELEÇÃO DAS FONTES DE EVIDÊNCIA

Os registros retornados foram imputados em uma plataforma digital online desenvolvida especialmente para facilitar a realização de revisões sistemáticas nomeada “Rayyan QCRI” (Ouzzani, Hammady, Fedorowicz, & Elmagarmid, 2016) e filtrados por critérios preestabelecidos de inclusão e exclusão listados a seguir.

Primeiramente, os estudos foram selecionados ou excluídos com base nos títulos e resumos de cada entrada. Os estudos com informações insuficientes prosseguiram para a fase dois. Em segundo lugar, os estudos selecionados tiveram sua seleção final definida com base na leitura do texto completo. A seleção foi feita por dois pesquisadores independentemente (o primeiro autor: Paulo Cenacchi e a pesquisadora colaboradora Luísa Medina), e os conflitos serão resolvidos pela discussão entre os dois árbitros ou, quando eles não puderem chegar a uma decisão segura, pela avaliação de um terceiro pesquisador, que será sempre selecionado com base em sua experiência no tópico da consulta. Além de 3 especialistas em computação contamos também com um especialista em pesquisa de processo em psicoterapia.

### 2.5.1 Critérios de inclusão

Foram incluídos estudos que utilizaram métodos computacionais para analisar dados reais de pesquisas de processo em psicoterapia.

#### 2.5.1.1 População, conceito e contexto

Os participantes dos estudos incluídos deveriam ser competentes verbalmente e ter idade igual ou superior a 18 anos.

Os principais conceitos implicados nesta revisão foram três: (a) ter seguido os moldes da pesquisa de processo em psicoterapia (i.e., investigar variáveis internas ao processo terapêutico); (b) ter usado abordagem computacional orientada por dados

ou c) abordagem computacional orientada teoricamente, para analisar os dados do processo psicoterápico.

Quanto ao contexto, os processos deveriam ser provenientes de psicoterapia individual, com configuração tradicional ou adaptada (e.g., atendimento online por vídeo chamada).

### 2.5.2 Critérios de exclusão

a) Não ser pesquisa de processo em psicoterapia
b) Envolver processo psicoterápico virtual por mensagem de texto
c) Envolver psicoterapia exclusivamente extra consultório
d) Artigo teórico
e) Artigo de revisão
f) Artigos não revisado por pares
g) Não usar método computacional na análise do processo psicoterápico
h) Envolver processo psicoterápico com terapeuta artificial
i) Artigo não disponível em língua inglesa
j) Processos psicoterapêuticos não convencionais: psicoterapia extra consultório, método da análise comportamental aplicada (*ABA* – do inglês *Applied behavior analysis*), psicoterapia para pacientes com déficits cognitivos graves e comprometimento da fala.
k) Processo psicoterápico envolvendo outra população:
    - crianças
    - casais
    - grupos

## 2.6 TABULAÇÃO DOS DADOS

Os registros selecionados foram reinseridos em uma nova revisão criada no “Rayyan QCRI” (Ouzzani et al., 2016) para facilitar a extração dos dados. Foi elaborada uma tabela na ferramenta Google Planilhas (Oualline & Oualline, 2018), as colunas da planilha são os itens listados a seguir.

Os itens extraídos dos artigos foram organizados em uma grande planilha com três grupos de colunas: (a) informações gerais (comum a todos os estudos); (b)

específicas para estudos com abordagem orientada por dados; e (c) específicas para estudos com abordagem orientada teoricamente. Desta forma, os estudos com técnica(as) orientada(s) por dados tiveram extraídos os itens dos grupos um e dois, já os estudos com técnica(s) orientada(s) teoricamente tiveram extraídos os grupos um e três e os estudos com técnicas de ambas as abordagens tiveram extraídos os itens de todos os grupos.

*Primeiro grupo:* índice; autor; data; título; jornal; volume; edição; páginas; país; contexto; participantes (N); tipo de participante; tipo de dado; detalhes dos participantes; objetivo primário; outros objetivos; medidas de processo; constructos de processo; medidas de desfecho; observações; pré-processamento. *Segundo grupo:* abordagem orientada por dados; objetivo primário; outros objetivos; técnicas; dados analisados; método de validação; medida; desempenho (melhor); outros. *Terceiro grupo:* abordagem orientada teoricamente; modelo matemático, objetivo primário; outros objetivos; análise de equilíbrio e estabilidade; predição ou evolução temporal; resultado principal; método de análise final; resultado de análise final; conclusão; outros; notas.

## 2.7 SÍNTESE DOS RESULTADOS

Para sintetizar os resultados obtidos, os estudos foram classificados em orientados por dados, orientados teoricamente ou híbridos. Estudos que continham método influenciado apenas por dados ou teoricamente e ou hipótese construída com base em conhecimentos prévios foram classificadas de acordo, estudos que utilizaram de ambas as abordagens foram considerados híbridos.

A seção de resultados oferece também uma descrição das aplicações das técnicas utilizadas nos estudos. Para tal descrição, as técnicas foram agrupadas por semelhança, ou seja, se um estudo utilizou mais de uma técnica computacional, cada técnica será citada na ocasião adequada de forma que o estudo será abordado mais de uma vez. Desta forma o leitor pode identificar diferentes aplicações de técnicas da mesma natureza.

A organização das técnicas e dos estudos foi realizada pelo autor e um colega e, em casos de dificuldade, a um especialista na área na qual houve a dúvida avaliava o estudo e dava sua posição. Participaram desse processo, além do autor da presente

dissertação e seu orientador, dois especialistas em aprendizagem de máquina e um em sistemas dinâmicos.

Os resultados foram representados por figuras, gráficos, tabelas e narrativa descritiva. A tabela digital com todos os elementos extraídos está disponível online no endereço: https://docs.google.com/spreadsheets/d/18jgXg6h_o-MCWdByD_B7IpBOnX81XGhK9eRJuyZN0JA/edit?usp=sharing

Ao longo desta dissertação a palavra “método” foi usada para representar o conjunto de técnicas ou modelos utilizados em todo o estudo em questão.

Para descrever cada técnica da forma descrita acima e organizar internamente os três classes (estudos orientados por dados, por teoria e híbridos), a organização das técnicas nos tipos de aprendizagem de máquina respeitou as definições descrita na obra *Machine Learning: A Probabilistic Perspective (Murphy, 2012)*. A organização das técnicas de processamento de linguagem natural foi orientada pela obra *Handbook of Natural Language Processing* (Indurkhya & Damerau, 2010). As áreas aprendizagem de máquina e processamento de linguagem natural são próximas e algumas técnicas utilizadas no processamento de linguagem natural são de aprendizagem de máquina. Ainda assim, optamos por dedicar uma sessão separada para processamento de linguagem natural para facilitar a leitura e futuras consultas. Neste sentido, técnicas de aprendizagem de máquinas que envolveram interpretação de linguagem foram incluídas na seção de processamento de linguagem natural. As técnicas de detecção de ativação de voz não interpretam significado, que é a definição de processamento de linguagem natural, no som. No entanto, estas técnicas são indispensáveis no pré-processamento dos dados que serão imputados nas técnicas de processamento de linguagem natural e, por este motivo, técnicas de detecção de ativação de voz estão dentro da seção de processamento de linguagem natural. A organização da seção ”DESCRIÇÕES DAS TÉCNICAS COMPUTACIONAIS UTILIZADAS” em resultados considerou a sequência mais frequente de apresentação das técnicas nos próprios estudos da amostra.

# 3 RESULTADOS

Os resultados da revisão estão dispostos na seguinte ordem: retorno da busca, características gerais (e.g., ano e país de publicação) e descrição das técnicas computacionais empregadas nos estudos. As técnicas foram ordenadas em métodos orientados por dados e orientados teoricamente, bem como seus subtipos.

## 3.1 Retorno dos registros

O número de registros que retornou da estratégia de busca foi 2318, a data de execução do mecanismo de busca foi 19 de março de 2021. Estes estudos foram selecionados por dois dos autores do estudo com o auxílio dos especialistas de cada área envolvidos nesta revisão, o fluxo de seleção realizado de acordo com os critérios de exclusão resultou em uma amostra de 39 estudos, como detalhado na figura 1.

Figura 1 – Fluxo de seleção de estudos da amostra

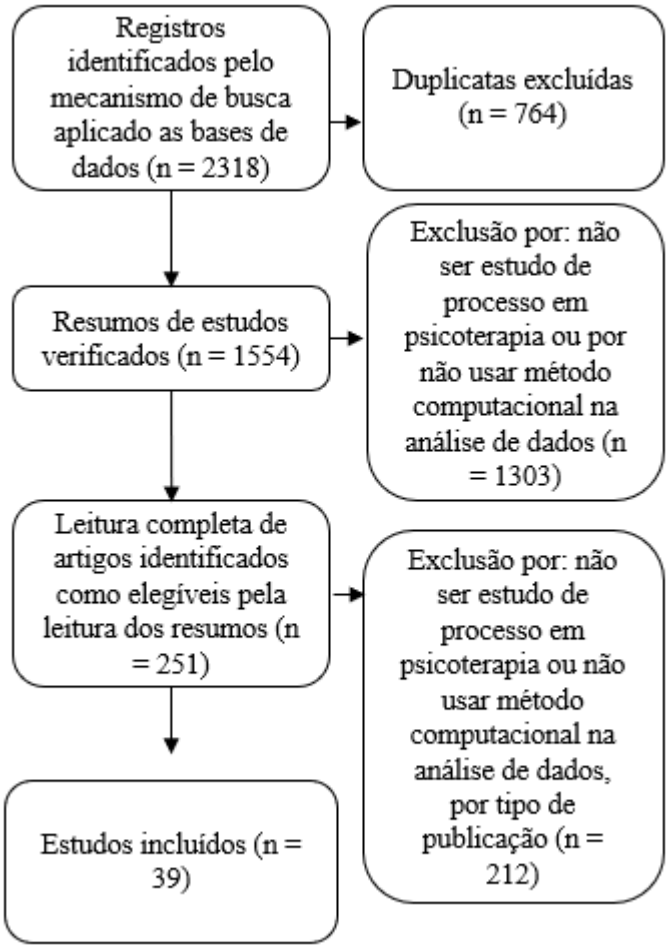


De acordo com a figura 1, 2318 registros foram identificados pelo mecanismo de busca, o algoritmo de identificação de duplicatas resultou identificou possíveis duplicatas que foram verificadas pelo primeiro autor implicando na exclusão de 764 duplicatas, 1554 estudos tiveram os seus resumos lidos e analisados pelos autores, a leitura dos resumos resultou na exclusão de 1303 estudos que se encaixaram em um ou mais critérios de exclusão. Os 251 estudos restantes foram lidos integralmente e destes 212 estudos foram excluídos por apresentarem um ou mais critérios de exclusão. A amostra final de estudos incluídos foi de 39 artigos.

## 3.2 Características demográficas dos estudos da amostra

O contingente de artigos da amostra terá alguns de seus dados demográficos como ano de publicação, país de publicação, tamanho da amostra e tipo de participantes descritos nas subseções seguintes.

### 3.2.1 Produção anual dos estudos da amostra

Figura 2 – Quantidade de artigos distribuída em anos

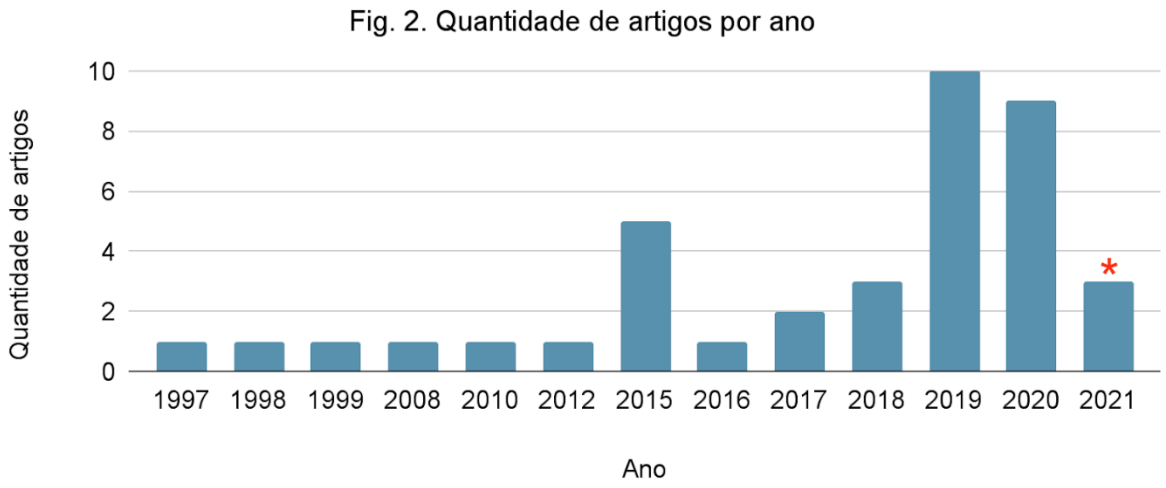


* Vale ressaltar que as publicações de 2021 foram incluídas apenas até 19 de março de 2021.

A figura 2 demonstra aumento gradual de publicações de estudos desta área de conhecimento (intersecção da computação com a pesquisa de processo em psicoterapia), é importante destacar que o ano de 2021 teve 3 estudos publicados até março e que a expectativa é que o número de publicações exceda a quantidade de publicações dos anos anteriores de 2019 e 2020.

### 3.2.2 Distribuição dos estudos por países em que foram conduzidos

Figura 3 – Quantidade de artigos produzidos em cada país

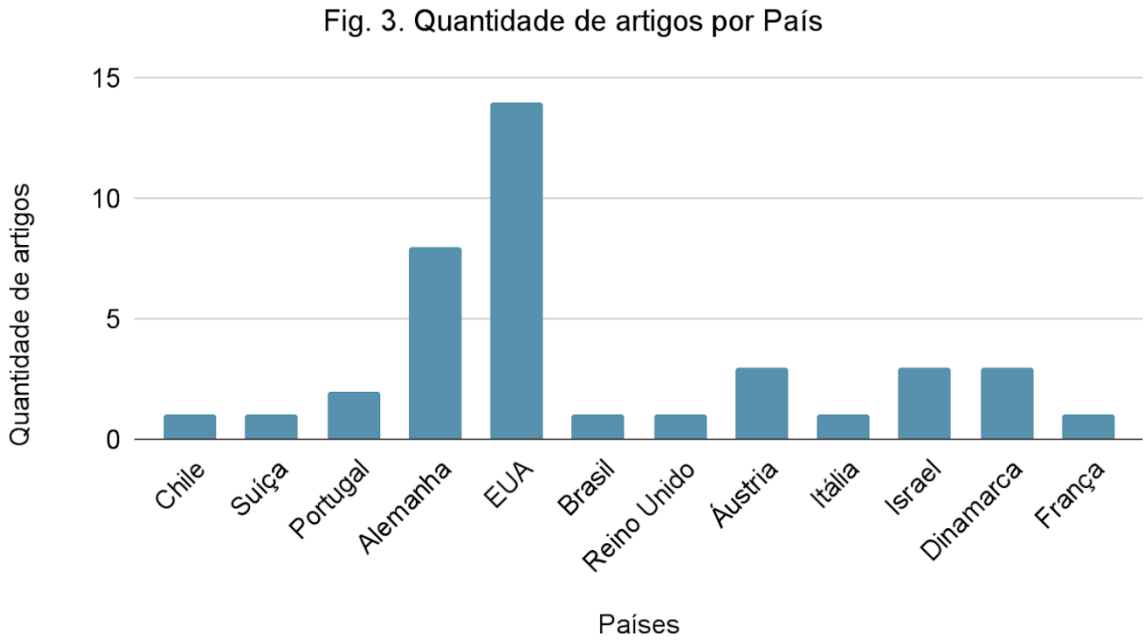


A figura 3 indica que a produção destas pesquisas tem sido distribuída com certa homogeneidade com a exceção de dois expoentes que foram a Alemanha com 8 publicações e Estados Unidos da América com 14.

### 3.2.3 Tamanhos das amostras dos estudos

Figura 4 – Quantidade de estudos por tamanho amostral

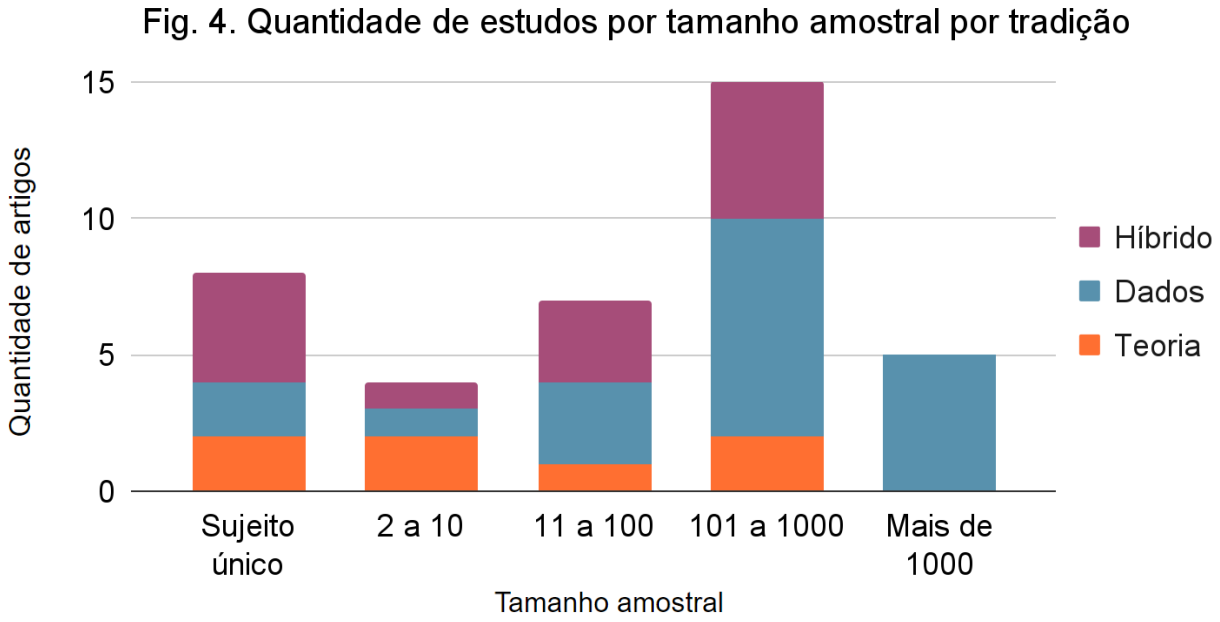


Como podemos observar na figura 4, há uma tendência de aumento do uso de metodologia orientada por dados quanto maior o tamanho amostral. Nota-se que em pesquisas com sujeito único a metodologia híbrida teve o dobro de ocorrência do que as outras metodologias.

### 3.2.4 Classificação dos estudos em orientados por dados, teoricamente e híbridos

Como descrito na seção “síntese dos resultados”, durante a classificação dos 39 estudos incluídos, as técnicas e os modelos matemáticos empregados nas metodologias desenvolvidas pelos autores de cada estudo nortearam a identificação das categorias de métodos orientados por dados e métodos orientados teoricamente. A composição de métodos com técnicas e modelos influenciados por ambas as abordagens foi considerada hibrida. No contingente de 39 estudos, foram encontrados 19 estudos (49%) com o método principal orientado por dados, 7 (18%) com método principal orientado teoricamente e 13 (33%) híbridos.

Tabela 1 – classificação dos estudos em métodos orientados teoricamente, métodos orientados por dados e métodos híbridos

| Autor (ano) | Método orientado teoricamente | Método orientado por dados | Método híbrido |
|---|---|---|---|
| Gumz (2012) | X | | |
| Schiepek (1997) | X | | |
| Schiepek (2020) | X | | |
| Schöller (2018) | X | | |
| Soma (2019) | X | | |
| Strunk (2019) | X | | |
| Touboul (2017) | X | | |
| Atzil-Slonim (2021) | | X | |
| Bruijniks (2021) | | X | |
| Gaut (2015) | | X | |
| Goldberg (2020) | | X | |
| Imel (2015) | | X | |
| Laskoski (2019) | | X | |
| Levis (2020) | | X | |
| Lutz (2018) | | X | |
| Lutz (2019) | | X | |
| Malandrakis (2015) | | X | |
| Nitti (2010) | | X | |
| Rubel (2019) | | X | |
| Sadeh-Sharvit (2020) | | X | |
| Shapira (2021) | | X | |
| Solomonov (2020) | | X | |
| Syzdek (2020) | | X | |
| Wiegersma (2020) | | X | |
| Xiao (2015) | | X | |

Continua...

Continuação...

| Autor (ano) | Método orientado teoricamente | Método orientado por dados | Método híbrido |
|---|---|---|---|
| Zilcha-Mano (2019) | | X | |
| Barbosa (2020) | | | X |
| Basto (2018) | | | X |
| Hartkamp (1999) | | | X |
| Hayes (1998) | | | X |
| Hayes (2015) | | | X |
| Li (2019) | | | X |
| Li (2020) | | | X |
| Olthof (2019ª) | | | X |
| Olthof (2019b) | | | X |
| Orsucci (2016) | | | X |
| Tomicic (2015) | | | X |
| Tschacher (2019) | | | X |
| Villmann (2008) | | | X |

## 3.3 DESCRIÇÕES DAS TÉCNICAS COMPUTACIONAIS UTILIZADAS

Assim como anunciamos na seção “síntese dos resultados”, dividimos as técnicas computacionais em três grandes grupos de técnicas. A soma de técnicas computacionais utilizadas nas 39 publicações selecionadas foi de 90. Na seção processamento de linguagem natural temos 21 (23%) técnicas descritas, na seção de sistemas dinâmicos 20 (22%) e na seção de aprendizagem de máquinas 49 (55%) técnicas. Vale comentar que uma menção ao uso de técnicas de aprendizagem de máquina e processamento de linguagem natural sem a devida descrição de sua aplicação não foi suficiente para inclusão nesta contagem, como foi o caso do estudo de Sadeh-Sharvit & Hollon (2020).

A média de técnicas por estudos foi de 2,4. A média de técnicas por estudos por tipo de abordagem foi: orientada por teoria 1,28; orientada por dados 3,2; e híbrida

2,06. O estudo com maior número de técnicas da amostra foi Xiao, Imel, Georgiou, Atkins, & Narayanan (2015) com 4 técnicas de processamento de linguagem natural e 2 técnicas de aprendizagem de máquina, somando 6 técnicas ao todo.

Observamos que no método de cada um dos estudos as técnicas de processamento de linguagem natural tenderam a vir antes, seguidas por sistemas dinâmicos e por fim por técnicas de aprendizagem de máquinas. Dos 39 estudos, 9 estudos utilizaram técnicas dos sistemas dinâmicos seguidas por aprendizagem de máquina e 10 estudos utilizaram técnicas de processamento de linguagem natural seguidas por aprendizagem de máquina.

### 3.3.1 Processamento de linguagem natural

#### 3.3.1.1 Pré-processamento

Nesta seção foram agrupadas técnicas de análise de som e de transformação de áudio em texto, normalmente utilizadas como etapas anteriores à aplicação de outras técnicas de processamento de linguagem natural.

##### *3.3.1.1.1 Método de detecção de ativação de voz (VAD – do inglês voice activity detection)*

Goldberg et al. (2020) realizaram um estudo para predizer aliança terapêutica a partir de gravações de sessões. Este exercício buscou exemplificar a aplicação de aprendizagem de máquina e processamento de linguagem natural para automatizar procedimentos da pesquisa de processo em psicoterapia. Para isso, transformaram áudios de sessões em texto e como uma das etapas dessa transformação utilizaram uma técnica de processamento de linguagem natural conhecida como <u>detecção de ativação de voz</u> para detectar momentos de fala e silêncio. Esta técnica performou com taxa de revocação (*recall* – do inglês) de 82,7%. Em seguida, foram aplicadas outras técnicas de processamento de linguagem natural (identificador de falantes e reconhecimento automático de fala, descritos nas respectivas seções) e por fim, algoritmos de aprendizagem de máquina que podem ser vistos na seção “análise de n gramas”, predisseram escores de alianças a partir do conteúdo linguístico analisado.

Este estudo evidenciou o potencial da combinação de técnicas de processamento de linguagem natural e aprendizagem de máquina.

Xiao et al. (2015) classificaram sessões em baixa e alta empatia (definida no estudo como interesse do terapeuta pela fala do paciente). Para isso, foi necessário transformar áudios em texto e, como parte deste processo, também empregaram a técnica de detecção de ativação de voz para transformar longos áudios em trechos menores ou de silencio, com taxa de erro de 12,6%. Passos subsequentes do processamento de linguagem natural aplicado no estudo estão disponíveis nas seções “reconhecimento automático de fala”. A técnica de classificação e sua performance estão descritas na seção “máquina de vetores de suporte” (*SVM* – do inglês *Support Vector Machine*).

3.2.4.2.5 Identificador de falantes (*Speaker Diarization System* – do inglês)

O mesmo estudo de Goldberg et al. (2020) aplicou um identificador de falantes para rotular falas do paciente e do terapeuta como parte do processo de transformação das gravações de áudio em textos separados em turnos de fala (trechos em que o terapeuta ou paciente está falando, quando para de falar e o outro começa, este é o início de um novo turno de fala). Xiao et al. (2015) também fizeram uso de identificação de falantes para identificar falas do paciente e do terapeuta. Os estudos tiveram as seguintes performances: taxa de erro de 6,4% (Goldberg et al., 2020) e média de erro 18,1% (Xiao et al., 2015).

*3.3.1.1.2 Reconhecimento automático de fala (ASR – do inglês Automatic Speech Recognition)*

Feitas as transformações dos arquivos de áudio descritas anteriormente, Goldberg et al. (2020) e Xiao et al. (2015) utilizaram ASR para transcrever as gravações de sessões. O reconhecimento automático da fala fez uso do programa “*Kaldi*”, de código aberto, disponível gratuitamente, e, em termos de performance, a taxa de erro por palavra foi de 36,43% para o ASR e 44,6% para o “*Kaldi”*. O uso destas transcrições para predição de escores de aliança pode ser visto na seção “análise de n gramas” e para detecção de empatia em “máquina de vetores de

suporte". Nos estudos, a precisão do ASR foi mediana, ainda assim em Xiao et al. (2015) apesar do desempenho sub ótimo do ASR, a precisão de classificação final foi bastante alta, aproximando-se da confiabilidade humana.

#### 3.3.1.2 Análise sintática e semântica

##### *3.3.1.2.1 Árvore de análise sintática*

Imel, Steyvers, & Atkins (2015) usaram um rotulador de partes de discurso (*part-of-speech tagger* – do inglês) para analisar classes gramaticais de palavras utilizados em cada turno de fala. Foram mantidos todos os substantivos, adjetivos e verbos. Uma série de classes de palavras tais como, "o", "a" e pronomes foram identificadas e removidas. O objetivo desse passo foi remover palavras desnecessárias da amostra.

Wiegersma et al. (2020) utilizaram uma amostra com gravações de sessões de terapia de exposições imaginadas que tiveram *hotspots* (pontos de maior tensão emocional) e suas características previamente rotuladas por especialistas. Os autores desenvolveram um modelo para realizar reconhecimento automático de *hotspots* baseado em texto e fala e utilizar esses *hotspots* como preditores de eficácia de tratamento. A construção do modelo envolveu etapas de preparação do material, uma destas foi utilizar um rotulador de partes de discurso (*part-of-speech tagger* – do inglês) para extrair 24 rótulos associados a construtos operacionais (emoções, afeto, cognições, dissociações, evitação, coesão, organização, fragmentação e complexidade) que, por sua vez, seriam processados para identificação dos *hotspots* (ver seção "máquina de vetores de suporte") em momentos da psicoterapia.

Um outro estudo, de Malandrakis & Narayanan (2015), consistiu em analisar a linguagem de sessões de psicoterapia utilizando normas psicolinguísticas (proximidade de significados de palavras) geradas automaticamente. Em um segundo momento, esta análise foi utilizada para comparar a linguagem de terapeuta e paciente controlando a variável "orientações psicoterápicas" (i.e., psicanálise e terapia centrada na pessoa). Para tratar o áudio das sessões gravadas, um dos passos foi aplicar um rotulador de partes de discurso . Esta ferramenta identificou palavras sem conteúdo, que foram removidas. A partir desse processamento, o vocabulário das palavras de conteúdo também foi criado.

*3.3.1.2.2 Analisador linguístico (YAP – do inglês Yet Another Parser)*

Shapira et al. (2021) utilizaram um analisador linguístico para extrair frequência de palavras no singular e em primeira pessoa em transcrições de sessões (apenas falas do paciente). Esta técnica obteve uma média de 588 palavras singulares em primeira pessoa por sessão. Este dado foi utilizado para passos subsequentes na pesquisa, como pode ser visto nas seções “análise semântica” e “modelos hierárquicos ou mistos lineares”.

Atzil-Slonim et al. (2021) utilizaram alocação latente de Dirichlet (ver seção correspondente) para predizer níveis de sintomas dos pacientes, aliança terapêutica e rupturas na aliança terapêutica. Para realizar essa análise, precisaram preparar as transcrições das sessões e um dos passos deste processamento foi classificar as palavras das transcrições em categorias léxicas (verbo, adjetivo, preposições etc.) com uma técnica conhecida como analisador linguístico e fazer uma limpeza da informação textual. Como resultado, foram omitidas palavras semanticamente vazias, raras e não-informativas. Este procedimento excluiu da amostra palavras com baixa probabilidade de associação com as características investigadas (escores de sintomas e níveis de aliança terapêutica).

*3.3.1.2.3 Investigação linguística e contagem de palavras (LIWC – do inglês Linguistic Inquiry and Word Count)*

Shapira et al. (2021) extraiu palavras com valência emocional negativa e positiva de transcrições de sessões de psicoterapia com a técnica de investigação linguística e contagem de palavras. Em média, foram 185 palavras emocionais positivas e 327 negativas por sessão. Das palavras mais frequentemente utilizadas, 15% foram palavras emocionais. Estes dados foram imputados em um modelo multinível descrito na “modelos hierárquicos ou mistos lineares”.

Wiegersma et al. (2020) utilizou o investigação linguística e contagem de palavras para processar texto e identificar construtos referentes a afeto, emoções, dissociação, cognições, organização e conteúdo. Em seguida estes construtos foram

usados para classificação de trechos relevantes (ver seção “máquina de vetores de suporte”).

*3.3.1.2.4 Análise de sentimentos (Sentiment analysis – do inglês)*

Syzdek (2020) examinou sentimentos negativos e positivos na linguagem de paciente e terapeuta em sessões de psicoterapia. Os objetivos dos autores foram: investigar a evolução dos escores de sentimentos (a) ao longo de uma sessão e (b) ao longo de sessões. Para isso, utilizaram um método de análise de sentimentos nomeado “Syuzhet” para quantificar o sentimento contido em transcrições de sessões. Esta técnica extrai sentenças das transcrições e atribui um escore de sentimento para cada uma delas. Estes escores foram utilizados como variáveis dependentes em modelos hierárquicos (ver seção “modelos hierárquicos ou mistos lineares”).

Levis, Westgate, Gui, Watts, & Shiner (2020) empregou um programa para análise de sentimentos e cognições denominado “*SÉANCE*” (Crossley, Kyle, & McNamara, 2017), que é um programa de código aberto análogo à técnica de investigação linguística e contagem de palavras. Esta ferramenta foi utilizada para calcular índices linguísticos (escores derivados de análises de sentimento, cognição social e ordem social contidos nos trechos de transcrição de sessões) em grupos de 3, 6, 9 e 12 meses de tratamento a serem imputados em modelos preditivos (ver seção “*LASSO*”). O objetivo dos autores foi identificar se estes índices eram preditores de risco de suicídio. Cada grupo da amostra teve características mais predominantes. As características na amostra de 3 meses, por exemplo, foram alimentação e problemas de rotina.

*3.3.1.2.5 Análise de N gramas*

Wiegersma et al. (2020) produziu um método de classificação de *hotspots* (pontos de maior tensão emocional) em sessões de psicoterapia. Primeiramente, foram identificados construtos operacionais como emoções, afeto, cognições etc. (ver seções “árvore de análise sintática” e “investigação linguística e contagem de palavras”). O método de classificação utilizou múltiplas entradas (ver seção “máquina

de vetores de suporte”). Uma delas foi a análise de n-gramas [unigramas (ocorrência de uma única palavra), bigramas (ocorrência de uma sequência de duas palavras) e trigramas (ocorrência de uma sequência de três palavras)]. O algoritmo foi treinado com rótulos previamente estabelecidos e, no treino, o algoritmo aprende como um conjunto de n-gramas aumenta ou diminui a probabilidade de aquele documento (trecho de transcrição de sessão) ser de determinada classe, no caso *hotspot* ou não *hotspot*. Na fase teste, a técnica classifica documentos novos em *hotspots* ou não *hotspots* de acordo com a frequência dos n-gramas no documento. Esta análise, que considera o conteúdo da linguagem, fez parte, junto com análise de sentimentos, características de áudio e uma máquina de vetores de suporte, de um método para identificar *hotspots* em transcrições psicoterapia (ver seção “máquina de vetores de suporte”).

Goldberg et al. (2020) usaram uma forma de aprendizagem de máquina não supervisionada que faz análise de N-gramas, no caso unigramas e bigramas, em busca de preditores de aliança. O melhor modelo foi o uso de características extraídas das falas do terapeuta (*MSE* = 0,67, p = 0,15 p < 0,001). Em linhas gerais, o estudo sugere que com essa metodologia é possível prever uma aliança terapêutica com o paciente utilizando o conteúdo de sessão ainda que modestamente.

Xiao et al. (2015) fizeram análise de N-gramas com unigramas, bigramas ou trigramas. Esta técnica produziu escores de 0 a 1 (coeficiente da probabilidade de alta empatia dividido pela soma das probabilidades de alta e baixa empatia) que significavam a probabilidade de um trecho da transcrição da fala do terapeuta ter alta empatia. Esta técnica teve como entrada uma, duas ou três palavras e como saída este escore de empatia. Em seguida os autores fizeram uma regressão linear destes escores (ver seção “regressões lineares”).

Sadeh-Sharvit & Hollon (2020) desenvolveram uma plataforma nomeada *Eleos* e trazem um caso exemplo da aplicação da plataforma no atendimento de um paciente no curso de 10 sessões. Segundo os autores, essa plataforma utiliza processamento de linguagem natural e aprendizagem de máquina para identificar evolução dos escores de ansiedade e depressão ao longo das sessões, proporção de tempo de fala do paciente e terapeuta durante a sessão, taxa de fala, e identifica alguns comportamentos do terapeuta emitidos em sessão. Ainda que os autores não detalhem a forma que a plataforma aplica as técnicas para produzir os dados, seus resultados mostram-se bem interessante, a aplicação desta plataforma oferece um

panorama das técnicas utilizadas nas sessões e evidência elementos da dinâmica do discurso do paciente e terapeuta, proporcionando *insights* para prática clínica. Vale observar que este estudo não detalha a forma como as técnicas participam do modelo, apenas as menciona, por este motivo estas técnicas estão dispostas no início desta seção.

*3.3.1.2.6 Modelagem de tópicos*

A modelagem de tópicos é uma técnica utilizada para identificar estruturas semânticas (tópicos) em um corpo de texto (Neogi, Das, Goswami, & Mustafi, 2020).

Imel et al. (2015) usaram um modelo tópico com 200 tópicos para explorar os assuntos falados pelos terapeutas e pacientes. O modelo selecionou de forma não supervisionada 20 dos 200 tópicos. Os tópicos foram organizados em 4 áreas: emoções ou sintomas, relacionamentos, tratamento e outros. O modelo tópico foi capaz de identificar intervenções e linhas da psicologia utilizadas a partir dos trechos. A acurácia destas classificações foi verificada por florestas aleatórias (ver seção correspondente).

*3.3.1.2.7 Alocação latente de Dirichlet*

A Alocação latente de Dirichlet é exemplo de modelagem de tópicos, no caso, é um modelo generativo probabilístico (Blei, Ng, & Jordan, 2003), que irá produzir classes e deduzir a qual classe um determinado dado pertence, a partir de suas características.

Gaut, Steyvers, Imel, Atkins, & Smyth (2015) utilizaram alocação latente de Dirichlet rotulada para aprender associações entre textos (turnos de fala de transcrições de sessões) e códigos (rótulos de assuntos ou sintomas discutidos), para classificar códigos em sessões de psicoterapia e para localizar passagens que representativas dos códigos. A performance do modelo (área sob a curva = 0,79) foi superior quando comparada à regressão logística de *LASSO.* Essa técnica foi capaz de identificar turnos de fala representativos de códigos com performance semelhante à codificação realizada por humanos.

Para detectar agrupamento de termos recorrentes, Atzil-Slonim et al. (2021) empregaram a alocação latente de Dirichlet. Os autores definiram que 200 tópicos

semânticos latentes na amostra era o número mais vantajoso. Estes tópicos identificados foram imputados em um modelo de regressão logística (ver seção correspondente).

### 3.3.2 Sistemas dinâmicos

#### 3.3.2.1 Análise de quantificação de recorrência

Orsucci et al. (2016) fizeram análises de quantificação de recorrência, para modelar respostas de condutância da pele de terapeuta e paciente e padrões linguísticos ao longo de uma sessão. Posteriormente, os autores realizaram análise de quantificação de recorrência cruzada para identificar a evolução da sincronia dos padrões de medidas do paciente e terapeuta. Os resultados demonstraram a sincronização emocional expressa fisiologicamente vem primeiro e a sincronização linguística a acompanha com atraso.

#### 3.3.2.2 Maior expoente de Lyapunov

Schiepek et al. (1997) estimou o maior expoente de Lyapunov para identificar caos determinístico no sistema formado pelo terapeuta e o paciente com dados (classes de comportamentos intrasessão codificados por observadores especializados) imputados em séries temporais. Os resultados da análise do maior expoente de Lyapunov argumentam que o comportamento do paciente é nitidamente mais imprevisível do que o comportamento do terapeuta. Sobre haver ou não padrão caótico no sistema, ainda que pouco consistentes, os resultados indicam a existência de propriedades caóticas no sistema estudado.

Strunk & Lichtwarck-Aschoff (2019) analisaram séries temporais com dados de de comportamentos verbais e não verbais do paciente e do terapeuta separadamente procurando identificar padrões caóticos: complexidade, flutuações críticas e padrões de auto-organização. Para isso estimaram o maior expoente de Lyapunov. Os grupos de comportamentos foram classificados em categorias mais amplas (e.g., pedir ajuda). As variações no valor do maior expoente de Lyapunov apontaram a presença de flutuações críticas. As flutuações foram identificadas em uma janela de 50 pontos na

série temporal. Os resultados apontaram que parte das flutuações é sincronizada entre paciente e terapeuta e parte é independente. Os padrões de comportamento dos dados foram distintos entre os dois pacientes da amostra. Ainda assim, foi possível fazer predições curtas na série temporal. Em ambos os casos foram encontradas evidências que apoiam a existência de padrões caóticos e mudanças de fases marcadas por flutuações críticas.

Touboul, Romagnoni, & Schwartz (2017) modelaram matematicamente o balanço dinâmico entre afetos positivos e negativos de um paciente. O modelo teve como entrada eventos positivos e negativos e como saída escores de afetos positivos e negativos. Estas saídas foram analisadas à luz de medidas de sistemas dinâmicos (e.g., estabilidade e atratores). Touboul et al. (2017), calcularam o maior expoente de Lyapunov a fim de mostrar que as órbitas periódicas associadas com o a bifurcação de *Hopf* (ponto crítico em que a estabilidade de um sistema muda e uma solução periódica emerge) eram estáveis. Os resultados da análise apontaram que este coeficiente é negativo em todos os pontos testados, indicando que a bifurcação era supercrítica no espaço das medidas, assim, as órbitas periódicas associadas eram estáveis. Ou seja, de acordo com os resultados, o estado atual do sistema (paciente) é estável (tende a se manter no tempo), no caso de um quadro de depressão, sendo necessários eventos externos de alta magnitude para alterar o estado do sistema. O papel da psicoterapia é agir como este evento externo para produzir uma transição de um estado de depressão para um estado de saúde mental.

#### 3.3.2.3 Dimensionalidade fractal

Schiepek et al. (1997) calculou dimensionalidade fractal para detectar a presença de caos determinístico no comportamento do sistema terapeuta e paciente representado em séries temporais. A partir desta técnica, não foi possível tirar conclusões consistentes sobre a medida de dimensionalidade fractal. É possível que a dimensionalidade do sistema seja alta demais para padrões serem identificados em séries temporais curtas.

#### 3.3.2.4 Modelagem por equações diferenciais

Li & Kivlighan Jr (2019) usaram equações diferenciais e dois modelos hierárquicos para investigar a relação entre as dinâmicas da terapia (flutuações de escores de aliança do paciente) e avaliação de sessão feita pelo paciente. Como primeiro passo de uma série de técnicas computacionais usadas nesse estudo e descritos em suas correspondentes seções, utilizaram equações diferenciais ordinárias para estimar coeficientes dinâmicos (i.e., fator multiplicativo que varia a depender do estado do sistema) que quantificassem os padrões de influência mútua e receptividade entre terapeutas e pacientes. Estas medidas foram extraídas de escores de escalas de aliança de terapeutas e pacientes e analisados por meio de modelos hierárquicos (ver seção “modelos hierárquicos ou mistos lineares”).

De forma semelhante a Li & Kivlighan Jr (2019); os autores Li, Kivlighan Jr, & Hill (2020) usaram equações diferenciais e um modelo hierárquico (ver seção correspondente) para investigar dinâmicas da aliança terapêutica em uma primeira sessão de psicoterapia. Li et al. (2020) empregaram equações diferenciais ordinárias para derivar coeficientes dinâmicos de responsividade interpessoal. A responsividade interpessoal correspondia a duas posturas possíveis do terapeuta: dominação ou submissão. Em um segundo momento, investigaram se estes coeficientes poderiam ser preditores da avaliação de aliança do paciente em sua primeira sessão de psicoterapia. Neste estudo, apenas os coeficientes correspondentes a responsividade do terapeuta ao paciente e a si mesmo foram utilizados. Em seguida estas medidas foram desagregadas usando um modelo de desagregação hierárquico que transformou estas 2 medidas em 4, por fim as 4 medidas foram analisadas por um modelo hierárquico final (ver seção “modelos hierárquicos ou mistos lineares”).

Touboul et al. (2017) utilizaram equações diferenciais estocásticas para modelar matematicamente o equilíbrio dinâmico entre os estados de afetos positivos e negativos em função de ocorrência de eventos externos positivos e negativos. Os resultados apontaram que o paciente pode passar de um estado normal para um estado deprimido se muitos eventos negativos ocorrerem. Quando as ocorrências de eventos positivos e negativos voltam ao normal, o paciente permanece no estado que chegou e, então, é muito difícil escapar deste equilíbrio sem qualquer intervenção externa. Aqui é onde a terapia é realizada.

### 3.3.2.5 Equação de Fokker-Planck

Tschacher & Haken (2019) produziram um modelo baseado na equação de Fokker-Planck para identificar componentes determinísticos, atrator ou atratores, e componentes estocásticos no processo de psicoterapia representado em séries temporais de dados fisiológicos (frequência cardíaca e frequência respiratória) de paciente, terapeuta e da interação entre eles. O modelo produziu funções *V*(x) e Q(x) representando componentes causais (determinísticos) e componentes de acaso (estocásticos) respectivamente. Destas duas variáveis foram computadas: média de V(x), mínima V(x), desvio padrão de V(x) e média de Q(x). Posteriormente, uma regressão (ver seção correspondente) verificou quais destas 4 medidas foram preditoras de mudanças nos processos da psicoterapia (e.g., aliança terapêutica progresso, bem-estar, cooperação). Os resultados apontaram que as medidas derivadas de ingredientes estocásticos não foram preditores e que os ingredientes determinísticos predisseram níveis de cooperação, aliança e progresso.

#### *3.3.2.5.1 Grade de espaço-estado*

Tomicic et al. (2015) investigaram se combinações de padrões de discurso e qualidades vocais poderiam ser preditores de tipos de eventos relevantes: eventos de mudança no processo terapêutico ou ruptura na relação terapêutica; em interações entre terapeuta e paciente em sessões de psicoterapia. O estudo teve três etapas: identificar padrões de discurso e qualidades vocais, identificar atratores, e por fim, classificar episódios em episódios de mudança ou episódios de ruptura a partir da combinação de padrões de discurso e qualidades vocais. Os autores usaram a técnica de grade de espaço-estado para identificar estratégias regulatórias em padrões de qualidade vocal. A grade de espaço-estado é uma ferramenta gráfica para analisar sistemas dinâmicos que produz um gráfico com dois eixos cujos valores formam células, as células uma grade e cada célula corresponde a um estado possível do sistema. Esta técnica pode ser utilizada para identificar quais são os estados mais frequentes e estáveis (i.e. atratores). Neste estudo, a técnica teve 24 estados possíveis para os pacientes e 14 estados possíveis para os terapeutas. O estado mais estável e frequente para o terapeuta foi proponente-conectado e para o paciente

reflexivo-conectado (proponente: terapeuta se mostra como alguém que está observando e oferece uma nova perspectiva; conectado: estar sensível ao outro; reflexivo: paciente se distancia do conteúdo emocional, mas sem se desconectar).

Hayes & Yasinski (2015) utilizaram grade de espaço-estado para identificar escores de padrões de desestabilização (variação dos pacientes entre os estados possíveis da grade) durante duas fases do tratamento: inicial (sessões 1 a 10) e avançada (11 a 34). O método mapeou 25 espaço-estados possíveis em ambas as fases. O comportamento de mudança entre os espaço-estados foi imputado em um modelo de regressão hierárquica múltipla para relacionar processamento emocional e padrões de comportamento dos espaço-estados com desfecho de tratamento (ver seção “modelos hierárquicos ou mistos lineares”).

#### 3.3.2.6 Técnica de escolha (*Winnowing technique* – do inglês)

Para identificar atratores o padrão de estratégias regulatórias identificados na seção anterior foram analisados com a técnica de escolha por Tomicic et al. (2015). A técnica de escolha possibilitou identificar 5 atratores, os atratores eram modificados à medida que os padrões de interação dos agentes terapeuta e paciente se transformavam. Posteriormente as combinações de padrões de discurso com qualidades vocais foram utilizadas para classificação de eventos em mudança ou ruptura (ver seção “modelos hierárquicos ou mistos para classificação”).

#### 3.3.2.7 Algoritmo de complexidade dinâmica

Olthof et al. (2019b) derivaram uma medida de desestabilização de escores de escalas de processos terapêuticos (e.g., aliança terapêutica, intensidade do problema, progresso da terapia, disforia, relação com outros pacientes) utilizando o algoritmo de complexidade dinâmica. Uma vez calculada esta medida de instabilidade, picos de complexidade dinâmica foram imputados em modelos lineares mistos como variáveis independentes preditoras de níveis de intensidade do problema (ver seção “modelos hierárquicos ou mistos lineares”).

Gumz, Bauer, & Brähler (2012) analisaram dados de 8 díades ao longo de 29 a 35 sessões. O modelo matemático foi o algoritmo de complexidade dinâmica que permite identificar medidas de instabilidade em um sistema dinâmico através de

variações em escores de escalas de interação e relação. As instabilidades dos escores dos pacientes e terapeutas foram confrontadas, produzindo uma medida de sincronia e correspondência. Tanto sincronia quanto correspondência foram elevadas em díades com desfecho positivo, enquanto aquelas com desfechos negativos tiveram baixa sincronia ou correspondência. Os resultados mostraram o valor destas medidas ao longo do processo terapêutico e sugerem que extrair tais medidas pode ajudar os terapeutas a conduzirem sua prática clínica.

Olthof et al. (2019a) usaram um algoritmo de complexidade dinâmica para identificar instabilidade em escores de 18 itens de escalas de processos terapêuticos (e.g., aliança terapêutica, intensidade do problema, disforia, progresso terapêutico, relação com outros pacientes). Isto foi feito separadamente para cada processo, usando uma janela móvel de 7 dias, resultando em 18 séries temporais de complexidade dinâmica por paciente. Duas medidas foram calculadas a partir dos valores de complexidade dinâmica: a) complexidade dinâmica local e b) pico cumulativo de complexidade. Estas medidas foram utilizadas como variáveis independentes em um modelo linear misto para predizer perdas e ganhos repentinos em níveis de intensidade do problema (ver seção “modelos hierárquicos ou mistos lineares”).

Schiepek et al. (2020) analisaram 88 trajetórias de pacientes em processos de terapia, construídas imputando os dados em séries temporais. A partir do cálculo de complexidade dinâmica, os autores identificaram instabilidades críticas no sistema dinâmico. Três investigações foram realizadas: (a) se series temporais de alta resolução (frequência diária) evoluem de forma padrão; (b) se series temporais de alta resolução têm níveis diferentes de complexidade em relação a series com resolução menor; e (c) se series temporais com evolução fora do padrão estão relacionadas a desfechos negativos. Os autores identificaram que as séries temporais de alta frequência não evoluem de forma padrão e não estão necessariamente correlacionadas com desfecho negativo. Além disso, o aumento de uma das medidas de complexidade, a complexidade dinâmica local, foi correlacionado com redução de sintomas (i.e., desfecho positivo). Desta maneira, os autores recomendam olhar além de trajetórias esperadas para identificar desfechos.

Basto et al. (2018) analisaram dados mensurados por escalas de assimilação de experiências durante 16 sessões de terapia de uma paciente que teve desfecho positivo. O objetivo dos autores foi identificar relações entre instabilidades em níveis

de assimilação, progresso em assimilação e intensidade de sintomas, intra e entre sessões. Como um primeiro passo deste método, foi calculado um índice de flutuação de assimilação de progresso que foi baseado em amplitude e frequência de mudança em escores de assimilação (coletados pela Escala de Assimilação de Experiências Problemáticas; *APES* – do inglês *Assimilation of problematic experiences scale).* O índice de flutuação dos escores de assimilação foi imputado como variável independente em um modelo autorregressivo para detectar correlações imediatas e atrasadas do índice com desfecho positivo (ver seção “regressões lineares”).

3.3.2.8 Modelagem por equações de diferença

Schöller, Viol, Aichhorn, Hütt, & Schiepek (2018) modelaram o efeito de novas experiências e estados (cognição, emoção, comportamento) sobre as características (disposições ou competências de uma pessoa). Esta modelagem utilizou 16 funções distribuídas em 5 campos de variáveis: emoções, insights, motivação para mudança, sucesso e intensidade do problema. O modelo conta com 4 medidas de interação entre as variáveis, sendo eles: aliança terapêutica; competências cognitivas (e.g., regulação emocional); recursos comportamentais (e.g., habilidades de resolução de problemas); e motivação para mudança. O modelo tem entradas para escores de cada uma dessas variáveis mensuradas por escalas de autorrelato sobre o processo terapêutico preenchidas diariamente, uma vez imputadas são calculadas equações diferença acopladas que descrevem como intervenções modulam mudanças de curto prazo, flutuações de estados psicológicos e como estes podem influenciar traços, que são características mais estáveis. Os autores fizeram uma demonstração do modelo descrito acima com series temporais de um caso real que permitiu observar um ritmo lento de evolução do processo, mas sem transição de fase, os campos intensidade de problema e emoções estiveram sincronizados, enquanto o campo sucesso não.

3.3.2.9 Oscilador linear acoplado (CLO – do inglês Coupled Linear Oscilator)

Soma et al. (2019) analisaram 227 gravações de áudio. A partir de modelos de sistemas dinâmicos, avaliaram a dinâmica de corregulação emocional pela influência de flutuações no comportamento de um membro da díade sobre o outro membro. O método utilizado neste estudo é o oscilador linear acoplado, que tem por objetivo

identificar a rapidez com a qual o nível de excitação (ou labilidade emocional) de cada membro da díade retorna ao seu estado basal (aceleração). Neste modelo, os padrões de regulação emocional são operacionalizados como variações no movimento de retorno a linha de base, as medidas de nível de excitação e velocidade são preditoras de aceleração. Os resultados indicaram que, ao longo das sessões, quando os pacientes se tornaram mais lábeis emocionalmente (aumento no nível de excitação), os terapeutas retornaram ao seu nível basal de excitação mais rapidamente. Da mesma maneira, quando o nível de excitação do terapeuta aumentou, o paciente retornou ao seu nível basal de excitação mais rapidamente. Em relação à regulação individual, o nível máximo de excitação do paciente aumentava ao decorrer da sessão. Em contrapartida, o nível máximo de excitação do terapeuta diminuía ao decorrer da sessão. Quando o paciente tinha um aumento em seu nível de excitação a diminuição da excitação do terapeuta desacelerava. Em resumo, os resultados indicaram que paciente e terapeuta tiveram padrões semelhantes de regulação interpessoal e padrões distintos de regulação intrapessoal.

### 3.3.3 Aprendizagem de máquina

#### 3.3.3.1 Técnicas supervisionadas

##### *3.3.3.1.1 Regressões*

Hayes & Strauss (1998) analisaram como intervenções realizadas pelo terapeuta poderiam predizer melhor desfecho de tratamento (Beck, Ward, Mendelson, Mock, & Erbaugh, 1961; Hamilton, 1960) a partir de regressões múltiplas. Os resultados demonstraram que menos proteção ao paciente e mais desestabilização dos padrões depressivos predisseram mais melhorias no fim do tratamento.

Xiao et al. (2015) classificaram falas de terapeutas em níveis alto e baixo de empatia como mencionado anteriormente (ver seção “processamento de linguagem natural”). Esta classificação teve diversos passos, entre eles a análise de n gramas (ver seção “análise de n gramas”), os escores de alta empatia derivados a análise de n gramas foram imputados em uma regressão linear, que produziu um mapeamento dos escores de empatia das falas do terapeuta. Subsequentemente, este dado

(distribuição de escores de empatia das falas do terapeuta) foi utilizado para classificar a sessão toda como nível alto ou baixo de empatia, para essa classificação final foi utilizada uma técnica de máquina de vetores de suporte (ver seção correspondente, “máquina de vetores de suporte”).

Barbosa, Sousa, Montanha, Pinto-Gouveia, & Salgado (2020) analisaram 51 sessões de 17 pacientes em 3 momentos diferentes do processo terapêutico. Os autores mapearam duas posturas dos pacientes: perspectiva de distanciamento emocional e perspectiva de imersão. Em seguida procuraram identificar o efeito da frequência e magnitude da mudança entre as perspectivas sobre sintomas depressivos. Os autores calcularam a média dos quadrados das diferenças sucessivas (*MSSD* – do inglês *mean square sucessive difference*) que possibilita quantificar duas medidas no movimento de mudança entre perspectivas, frequência e magnitude. Posteriormente, foram utilizadas regressões lineares para mensurar a associação entre cada medida no meio do tratamento e o nível de sintomas depressivos no final. A partir dessas medidas foi observado que mudanças frequentes e com pequena magnitude no meio do tratamento foram preditoras de menores níveis nos sintomas de depressão ao final do tratamento.

Malandrakis & Narayanan (2015) estimaram normas de palavras para analisar conteúdo de sessões de psicoterapia. O procedimento para estimar as normas consistiu primeiramente em reduzir a quantidade de palavras e posteriormente identificar similaridade das palavras de entrada com outras palavras. As normas das palavras similares, uma vez criadas, foram então atribuídas às palavras de entrada. A redução do número de palavras iniciais foi feita com análise de componentes principais (ver seção correspondente), que resultou em 500 palavras. Estas palavras foram inseridas em uma equação que calculou os mínimos quadrados ordinários para comparar a similaridade dessas 500 palavras com outras palavras. O resultado foram 11 normas por sessão por interlocutor. A performance do modelo em estimar normas alcançou uma média dos coeficientes de *Pearson* de 0,8.

Na mesma pesquisa descrita no parágrafo acima, Malandrakis & Narayanan (2015) utilizaram as 11 normas de palavras de transcrições de sessões (ver o parágrafo anterior e seção “análise de componentes principais”) como variáveis independentes em duas regressões lineares. A primeira teve como variável dependente o tipo de abordagem terapêutica (terapia centrada na pessoa e psicanálise), a segunda teve como variável dependente os anos de experiência dos

terapeutas. Sobre a primeira regressão: os achados com relação as características de cada abordagem foram coerentes com a teoria. Segundo os autores, o discurso do terapeuta centrado no paciente mostrou-se mais simples, mais calmo e mais agradável. Sobre a segunda regressão: em relação à experencia do terapeuta, identificou-se que os psicanalistas mais experientes fizeram mais uso de palavras concretas e os terapeutas da terapia centrada na pessoa fizeram uso maior de palavras fáceis de serem pronunciadas, utilizaram as mesmas palavras em contextos diferentes, empregaram palavras agradáveis (palavras relacionadas a sentimentos positivos), palavras familiares, palavras com idade de aquisição menor (idade esperada que uma pessoa utilize a palavra corretamente).

Bruijniks et al. (2021) utilizaram um modelo de rede de regressão elástica para identificar preditores de sintomas de depressão (inventário de sintomas depressivos) a partir de qualidade de terapia (adesão ao protocolo da terapia, avaliada por terceiros) e mudanças no processo psicoterápico (questionários de habilidades da terapia e aliança terapêutica preenchidos pelos pacientes). Não foram encontradas preditores significativos entre a qualidade da terapia ou mudança nas variáveis do processo terapêutico e o resultado da terapia. Entretanto, sujeitos com escores maiores de resíduos, ou seja, com menor nível de predição do modelo, tiveram maior variação na mudança de processos terapêuticos, sugerindo que este grupo tenha sido mais responsivo.

Tschacher & Haken (2019) produziram um modelo matemático para identificar componentes determinísticos, atrator ou atratores, e componentes estocásticos no processo de psicoterapia (ver seção “Equação de Fokker-Planck”) representado em séries temporais de dados fisiológicos (frequência cardíaca e frequência respiratória) de paciente, terapeuta e da interação entre eles. Derivados estes componentes, os autores, realizaram regressões múltiplas para identificar possíveis associações entre os componentes e escalas de autorrelato pós-sessões de psicoterapia. Os resultados apontaram que as medidas determinísticas derivadas de batimento cardíaco e sincronia de respiração estiveram associadas aos escores das escalas. Menores valores das medidas de determinismo nos dados de respiração estiveram associados a maiores escores de progresso e de aliança. Esse tipo de regressão mostrou-se especialmente útil para selecionar as mais interessantes das múltiplas variáveis independentes disponíveis.

Levis et al. (2020) imputaram índices linguísticos (escores derivados de análises de sentimento, cognição social e ordem social contidos nos trechos de transcrição de sessões, ver seção “análise de sentimentos”) como variáveis independentes na técnica de *LASSO* a fim de predizer suicídio em avaliações realizadas em 3, 6, 9 e 12 meses de tratamento. Os resultados demonstraram que a precisão de cada um dos modelos não superou o acaso com exceção do recorte de 12 meses, que ofereceu contribuição significativa à predição, ainda que pequena.

Lutz et al. (2018) identificaram as variáveis preditoras de desistência mais relevantes a partir de dois modelos de *LASSO*. No primeiro, inseriram 7 variáveis na técnica e identificaram 2 variáveis significativas, sexo e índice de severidade global. No segundo, inseriram 10 preditores previamente selecionados por florestas aleatórias (ver seção “florestas aleatórias e arvores de decisão”) e obtiveram 4 preditores significativos.

Hartkamp & Schmitz (1999) investigaram a dominância (assimetria na predição de dois membros de um sistema) de comportamentos específicos do paciente e do terapeuta sobre outros comportamentos do paciente. Os dados da interação foram mensurados por escalas de processo terapêutico, que direciona as perguntas em dois contextos, os “melhores momentos” e os “piores momentos”, e, em cada um deles, investiga 8 grupos de itens: emancipar, afirmar, amar, proteger, autocontrole, culpar, atacar e negligenciar. Os grupos de itens do paciente e do terapeuta foram inseridos em modelos de regressões polinomiais como preditores dos grupos de itens dos pacientes. Como resultado, os preditores mais relevantes foram: nos melhores momentos o grupo “paciente negligenciar a si mesmo” foi preditor de “paciente proteger o terapeuta” e em piores momentos grupo “paciente demonstrar apreço pelo terapeuta” foi preditor de “paciente proteger o terapeuta”. Outro dado obtido foi uma divergência entre a visão do terapeuta e a do paciente a respeito de sua relação terapêutica. Isto pode indicar que ambas as partes têm ideias diferentes de como a relação acontece. Ainda que o efeito dos grupos entre si tenha sido estudado, o efeito dos grupos sobre desfecho terapêutico permanece em aberto.

Atzil-Slonim et al. (2021) utilizaram assuntos discutidos em sessão identificados previamente (ver seção “alocação latente de Dirichlet”) como preditores em um modelo de regressão logística multinominal esparsa para identificar níveis de bem-estar de pacientes (Miller, Duncan, Brown, Sparks, & Claud, 2003) e rupturas de aliança. Como resultado, os assuntos relacionados a nível baixo de bem-estar foram:

solidão, sofrimento, dificuldades físicas (saúde) e raiva. Os assuntos relacionados a alto bem-estar foram: celebração, lazer, prazer e escolha. Os assuntos relacionados a ocorrência de ruptura foram: comunicação, estabelecimento de objetivos, pedido de ajuda e problemas. A performance do modelo após treinamento foi substancialmente superior ao acaso. A acurácia do modelo na amostra de teste foi inferior a amostra de treinamento, mas a diferença foi relativamente pequena, o desempenho no teste foi de 75% para funcionamento do paciente e 65% para rupturas na aliança, ou seja, foi possível identificar níveis de bem-estar dos pacientes e rupturas na aliança terapêutica a partir dos assuntos discutidos em sessão.

*a) Modelo autorregressivo;*

Basto et al. (2018) utilizaram um modelo de análise fatorial dinâmica, que utiliza vetores autorregressivos para identificar correlações contemporâneas e atrasadas em séries temporais. Este método teve por objetivo identificar relações entre progresso na assimilação de experiências problemáticas e mudança em intensidade de sintomas entre e intrassessões. Os resultados mostraram que o nível de assimilação e a flutuação do escore de assimilação tenderam a aumentar com o tratamento, enquanto o nível dos sintomas tendeu a diminuir. No entanto, ao contrário das expectativas, o modelo do fator dinâmico não mostrou nenhuma associação significativa entre a flutuação da assimilação e o nível de sintomas intra ou entre sessões.

Rubel, Zilcha-Mano, Giesemann, Prinz, & Lutz (2019) aplicaram uma autorregressão individual para determinar o coeficiente de regressão de aliança e desfecho para cada um dos pacientes de sua amostra. Esta medida foi utilizada posteriormente como variável dependente de outros modelos (ver seções “florestas aleatórias e árvores de decisão” e “vizinho mais próximo”).

Solomonov et al. (2020) utilizaram aprendizagem de máquina para identificar preditores de trajetória de não resposta à psicoterapia em uma amostra de sujeitos com diagnostico de depressão tardia e disfunção executiva. O estudo consistiu em 3 etapas: a) identificar trajetórias de mudança (ver seção “modelos hierárquicos ou mistos lineares”), b) predizer desfecho negativo a partir de não resposta no meio do tratamento (descrito neste parágrafo) e c) identificar preditores de não resposta a partir de características de linha de base (ver seção “florestas aleatórias ou árvores de

decisão”). Subsequente ao primeiro passo, os autores imputaram os dois subgrupos: responsivo e não responsivo como preditores de desfecho de tratamento em regressões logísticas. Como esperado, o grupo responsivo teve maior chance de apresentar melhora ao final do tratamento.

Lutz, Rubel, Schwartz, Schilling, & Deisenhofer (2019) elaboraram uma ferramenta que produzia algumas informações para os terapeutas poderem oferecer um atendimento personalizado: (a) predição de desistência, (b) predição de tratamento recomendado, (c) recomendações adaptáveis de intervenções para pacientes com risco de falha de tratamento. Os autores tiveram enquanto um de seus objetivos predizer desistência de tratamento. O estudo teve 78 variáveis iniciais, uma correlação bivariada entre as 78 variáveis e desistência resultou em 30 variáveis correlacionadas. Em seguida os autores utilizaram as 30 variáveis como independentes em uma regressão logística de *LASSO* para identificar preditores de desistência dentre 30 variáveis previamente. O modelo de regressão logística de *LASSO* identificou 7 delas como as mais relevantes. A fim de identificar os pesos dos preditores, estas 7 variáveis foram inseridas em uma regressão generalizada linear. A acurácia de predição de desistência do modelo foi de 72%. De forma similar, a técnica de *LASSO,* foi utilizada para reduzir número de preditores de melhora (escala de sintomas de Hopkins-11, versão reduzida, a técnica foi capaz de reduzir de 5 para 4 preditores, que por sua vez foram utilizados junto com a técnica de vizinhos próximos para produzir recomendação de tratamento (ver seção “vizinhos próximos”). Ainda outro objetivo destes autores teve a participação de regressão logística, que foi classificar a trajetória de tratamento de cada paciente em promissora (do inglês – *on track*) e não promissora (do inglês – *not on track*) em cada sessão, fazendo uma regressão de sintomas (HSCL-11) em número da sessão, como resultado 40% dos pacientes saíram da trajetória promissora em algum momento do tratamento.

Gaut et al. (2017) testaram dois métodos de aprendizagem de máquina para classificação de conteúdos de transcrições de sessões. Foram comparados o classificador *LASSO* com a técnica de alocação latente de Dirichlet rotulada (ver seção “análise sintática e semântica”). A técnica de *LASSO* teve como variáveis independentes turnos de fala de transcrições de sessões e como dependentes códigos (rótulos de assuntos ou sintomas discutidos), este modelo apresentou um desempenho de área sob a curva de 0,79, inferior ao da técnica de alocação.

*b) Modelos hierárquicos, mistos ou de mistura;*

Li & Kivlighan Jr (2019) usaram equações diferenciais (ver seção correspondente) e dois métodos hierárquicos para investigar a relação entre as dinâmicas da terapia (flutuações de escores de aliança do paciente) e avaliação de sessão feita pelo paciente. Após uma primeira etapa, baseada em modelagem de sistemas dinâmicos e na qual são calculados alguns coeficientes dinâmicos, os autores utilizaram seu primeiro método hierárquico, um modelo de desagregação de dados multinível, para separar os 4 coeficientes em 8 componentes: a) receptividade do terapeuta a todos os seus pacientes, b) receptividade do terapeuta a um de seus pacientes, c) a influência do terapeuta sobre todos os pacientes, d) a receptividade do paciente ao terapeuta, e) consistência do terapeuta em relação a todos os seus pacientes, f) consistência do terapeuta em relação a um paciente g) consistência dos pacientes de um terapeuta, h) consistência de um paciente em relação a um terapeuta. Subsequente à tal desagregação, os dados desagregados com escores de qualidade de sessão avaliada pelo paciente foram imputados em um modelo linear hierárquico. Os resultados indicaram que terapeutas que foram consistentes em perceber o estado da relação terapêutica tenderam a receber avaliações de sessões mais positivas.

Li et al. (2020) realizaram procedimentos semelhantes a Li & Kivlighan Jr (2019) e, da mesma maneira, calcularam os 4 coeficientes dinâmicos (abertura do paciente e do terapeuta de ser influenciado pelo outro integrante da díade; consistência do paciente e do terapeuta em relação a si mesmo em um momento prévio). Neste caso, entretanto, utilizaram apenas o par de coeficientes relacionado ao comportamento do terapeuta (i.e., abertura do terapeuta em relação ao paciente e consistência do terapeuta em relação a si mesmo). Estes dois coeficientes foram decompostos em 4 outros (controle [exercer influência] ou afiliação [sofrer influência] do terapeuta sobre ele mesmo, controle ou afiliação do paciente sobre o terapeuta) por meio de um modelo multinível de desagregação. Subsequentemente, os autores aplicaram um modelo linear hierárquico que utilizou os 4 componentes como preditores de escores de aliança preenchidos pelos pacientes. Como resultado, o modelo linear hierárquico demonstrou os escores de aliança foram maiores em dois contextos: a) quando o terapeuta assumiu uma posição dominante diante de uma postura dominante do

paciente e b) quando o terapeuta assumiu uma posição submissa diante de uma postura submissa do paciente.

Hayes & Yasinski (2015) realizaram uma regressão hierárquica múltipla para relacionar processamento emocional (mudança de significado e ou perspectiva) e padrões de comportamento nos espaço-estados (e.g., mudança em escores de cognição, afeto, comportamento e somatização em uma sessão") com desfecho de tratamento. Os resultados indicaram que na primeira fase (sessões 1 a 10) nenhum preditor pode ser encontrado. Em contrapartida, maiores escores de dispersão (escore que representa quantidade de quadrados diferentes da grade ocupados durante cada fase, ou seja quanto o paciente variou entre diferentes estados) e processamento emocional foram preditores de desfechos de tratamento mais positivos.

Shapira et al. (2021) empregou um modelo multinível para predizer nível de distresse em sessão a partir de características linguísticas extraídas previamente de falas do paciente provenientes de transcrições. Os resultados indicaram que, no nível intrapaciente, menos palavras singulares em primeira pessoa, menos palavras emocionais negativas e mais palavras emocionais positivas foram associadas a menor nível de distresse na mesma sessão e menos palavras emocionais negativas foram associadas a menor nível de distresse na sessão seguinte. No nível entre pacientes, uma diminuição do uso de palavras singulares na primeira pessoa foi associada a um melhor resultado do tratamento.

Syzdek (2020) examinou sentimentos negativos e positivos na linguagem de paciente e terapeuta em sessões de psicoterapia. Os objetivos dos autores foram: investigar a evolução dos escores de sentimentos (a) ao longo de uma sessão e (b) ao longo de sessões. Inicialmente extraiu escores de sentimento (ver seção "análise de sentimentos") de transcrições de sessões de psicoterapia. Posteriormente, elaborou um modelo linear hierárquico para examinar o os escores de sentimento em algumas dimensões: intrassessões, entre sessões, entre terapeutas e entre pacientes. Os escores de sentimentos foram inseridos como variáveis dependentes do modelo e variáveis tempo de sessão ou número da sessão como independentes. Os resultados demonstraram aumentos de sentimentos positivos ao longo das sessões e diminuição de sentimentos positivos intrassessões. Foi encontrada uma associação significativa entre sentimentos do terapeuta e do paciente durante as sessões.

Olthof et al. (2019b) aplicaram modelos lineares mistos para identificar o poder preditivo da medida de complexidade dinâmica (medida de variabilidade e instabilidade em escalas de autorrelato de cada paciente) sobre intensidade do problema clínico. Três modelos foram criados: um com todos os participantes, outro com os pacientes responsivos ao tratamento e outro com os não responsivos. Os resultados do método preditivo como um todo apontam que os picos de complexidade dinâmica têm uma associação significativa com os escores de intensidade do problema. Em outras palavras, instabilidades nos escores de escalas que avaliam o processo terapêutico preenchidas diariamente estiveram associadas a melhor desfecho de tratamento. O modelo com pacientes não responsivos não demonstrou uma associação entre pico de complexidade dinâmica e desfecho de tratamento. Em contrapartida, o modelo com pacientes responsivos demonstrou associação entre pico de complexidade dinâmica e desfecho.

Atzil-Slonim et al. (2021) utilizaram modelos multiníveis de crescimento para detectar associações entre assuntos discutidos em sessões de psicoterapia (ver seção “Alocação latente de Dirichlet”) e desfecho do processo psicoterápico. De acordo com o modelo, as trajetórias de mudança nos tópicos foram associadas com trajetórias de mudança no resultado. Especificamente, um aumento assuntos sobre experiências positivas foi associado a uma diminuição nos sintomas dos pacientes ($r = 0,29$, $p = 0,03$), enquanto um aumento nos assuntos mais estreitamente associados à ocorrência de rupturas na aliança terapêutica estiveram associados a um aumento dos sintomas dos pacientes ($r = 0,32$, $p = 0,03$). Nenhuma associação foi encontrada entre os assuntos sobre experiências negativas e os sintomas dos pacientes ($r = 0,12$, $p = 0,34$).

Em uma análise de séries temporais composta por escores de escalas de afetos positivos e negativos coletados 4 vezes por dia durante duas semanas ou mais, Lutz et al. (2018) utilizaram um modelo multinível de vetor autorregressivo para construir duas redes dinâmicas a fim de identificar variáveis preditoras de desistência do tratamento. O modelo produziu uma rede (expressão gráfica de conexões causais entre variáveis de um sistema; Borsboom, 2017; Borsboom & Cramer, 2013; Stefan G Hofmann, Curtiss, & McNally, 2016) para pacientes que completaram o tratamento e outra para desistentes.

Solomonov et al. (2020) conduziu um estudo que consistiu em 3 etapas: a) identificar trajetórias de mudança (descrito neste parágrafo), b) predizer desfecho

negativo a partir de não resposta no meio do tratamento (ver seção “regressões”) e c) identificar preditores de não resposta a partir de características de linha de base (ver seção “florestas aleatórias ou árvores de decisão”). Com uma amostra de escalas de 221 casos de terapia utilizou um modelo de mistura com crescimento latente (*LGMM* – do inglês *Latent Growth Mixture Model)* para identificar subgrupos com trajetórias distintas de evolução de sintomas de depressão. Como resultado, foi possível identificar dois subgrupos, responsivos e não-responsivos ao início do tratamento.

Tomicic et al. (2015) utilizaram modelo hierárquico de regressão logística que classificasse trechos de sessões em eventos de mudança (e.g expressar esperança, aceitar a existência de um problema, reconhecer sua participação na manutenção do problema) ou ruptura de aliança terapêutica. As variáveis independentes foram as estratégias de regulação (combinação de postura de discurso que é o tipo de relação do falante com o ouvinte, e.g., professor com um padrão de qualidade vocal que são características da fala, e.g., expressivo, conectado, reflexivo). Os autores identificaram maiores chances de o terapeuta assumir a estratégia proponente-conectado e o paciente a estratégia reflexivo-conectado em eventos de mudança do que de em eventos de ruptura.

Olthof et al. (2019a) empregaram modelos lineares mistos para identificar ganhos ou perdas súbitas (aumento ou diminuição rápida em níveis de intensidade do problema) em pacientes durante o processo terapêutico. As variáveis de entrada do modelo foram sinais de alerta (medidas derivadas de flutuações nos escores de escala de processo; ver seção “algoritmo de complexidade dinâmica”). Entre os preditores derivados dos sinais de alerta, destacou-se o nível de complexidade dinâmica local, que aumentou em 55% a chance de ocorrência de um ganho ou perda súbito em uma janela de 4 dias.

A partir de 6 variáveis previamente selecionadas: sexo, índice de severidade global e mais quatro variáveis estados dos pacientes: nervoso, excitado, ativo e percepção de suporte social (para ver a seleção destas variáveis ver seção “*LASSO*”). Lutz et al. (2018) realizaram a análise de preditores de desistência de tratamento com um modelo hierárquico de regressão logística que identificou tal desfecho corretamente em 47 pacientes com área sob a curva de 0,85. Os desfechos de 11 pacientes (19%) foram classificados falsamente (6 falsos negativos e 5 falsos positivo), uma performance de predição excelente.

*c) Máquina de vetores de suporte;*

Wiegersma et al. (2020) utilizou máquina de vetores de suporte para identificar momentos relevantes da psicoterapia (*hotspots* – do inglês) a partir de um conjunto multimodal de variáveis, ou seja, características extraídas do áudio de sessões e também de transcrições (ver seção “análise sintática e semântica”). Os resultados do modelo desenvolvido demonstraram um alto desempenho de treinamento (F1 de 0,76) mas um baixo desempenho nos testes (F1 de 0,52). Isto significa que as características de texto e áudio foram capazes de distinguir claramente entre *hotspots* e não-*hotspots* nesta amostra, mas que provavelmente não terem o mesmo desempenho ao analisar dados novos. Vale ressaltar que as características extraídas dos áudios tiveram maior poder preditivo em relação às extraídas dos textos.

Xiao et al. (2015) aplicaram máquina de vetores de suporte para classificar sessões entre alta e baixa empatia. Alta empatia foi definida comportamento do terapeuta de se interessar pelo ponto de vista do paciente como e baixa como comportamento de desinteresse sobre a perspectiva do paciente (para maior detalhamento da mensuração de empatia ver Moyers, Martin, Manuel, Miller, & Ernst (2007). O modelo teve como entrada uma distribuição dos escores de empatia de falas do terapeuta (ver seção “regressões lineares”), e como saída a classificação da sessão em alta ou baixa empatia. As classificações de empatia de transcrições automáticas foram comparadas a classificação de transcrições realizadas por humanos. Todas as técnicas empregadas obtiveram performances satisfatórias e as classificações de empatia derivadas computacionalmente foram altamente precisas em relação a códigos e classificações feitas por humanos.

*d) Vizinho mais próximo (do inglês - K-nearest neighbours).*

Depois de levantar as 5 variáveis identificadas pela técnica de *LASSO* descrita na seção “regressão logística”, Lutz et al. (2019) utilizaram a abordagem de vizinho mais próximo para classificar sujeitos em grupos de acordo com o tamanho de efeito do tratamento (solução de problemas, motivacional ou mista) sobre escores de melhora (HSCL-11). De acordo com o modelo, pacientes com características semelhantes aos grupos que melhoraram com determinado tratamento, deveriam

receber o mesmo tratamento. Este método foi capaz de fazer prescrições bem-sucedidas de seleção de estratégia de tratamento para as primeiras 10 sessões. Em casos que a trajetória era classificada como de trajetória de não resposta, o terapeuta era avisado pela ferramenta e lhe fazia sugestões de intervenções.

Já Rubel et al. (2019) utilizaram a técnica do vizinho mais próximo como terceira etapa de uma série de técnicas computacionais, Em um primeiro momento, usaram um modelo autorregressivo (ver seção “modelo autorregressivo”) para identificar coeficientes de regressão positivos entre aliança terapêutica e desfecho para cada um dos pacientes de sua amostra. Como segundo passo, utilizaram florestas aleatórias para identificar características de linha de base moderadoras da associação entre aliança terapêutica e desfecho (ver seção “florestas aleatórias e árvores de decisão”). Finalmente, em um terceiro momento aplicaram a técnica de vizinho mais próximo para classificar os pacientes como semelhantes (a partir de 11 moderadores) aos indivíduos com coeficiente de regressão positivo. Esta classificação teve como objetivo predizer o nível de resposta ao tratamento. Ainda que os autores tenham tentado diferentes unidades de vizinhos próximos, de 1 a 300, independentemente do número de vizinhos próximos escolhido a correlação entre os escores previstos e os reais foi baixa e insignificante.

Levis et al. (2020) avaliaram se utilizar processamento de linguagem natural de notas de psicoterapia poderia melhorar a acurácia de modelos de predição de suicídio. Para identificar sujeitos e controles em uma amostra empregaram o modelo de vizinho mais próximo na proporção de 5:1 classificar casos em semelhantes e distintos de pacientes que se suicidaram. A aplicação da técnica identificou 1090 controles que compuseram a amostra junto com 252 casos de suicídio.

Lutz et al. (2019) utilizaram a técnica vizinho mais próximo em dois dos objetivos de sua pesquisa: predizer tratamento recomendado e fazer recomendações adaptáveis de acordo com a trajetória de evolução do paciente. No primeiro caso, com base em 4 variáveis selecionadas como preditoras de melhora no nível de sintomas (maior pontuação em escala de sintomas, maior expectativa de tratamento por parte dos pacientes, mais tratamentos anteriores e maior cronicidade), os autores identificaram os pacientes mais similares (vizinhos mais próximos) por estratégia de tratamento (solução de problemas, mista, orientada à motivação) para cada paciente, isso permitiu identificar quais abordagens teriam maior probabilidade de reduzir níveis de sintoma e assim fazer recomendações. Entre esses pacientes, aqueles que foram

tratados com a estratégia recomendada tiveram um tamanho de efeito significativamente maior nos resultados do tratamento do que pacientes tratados com uma estratégia não recomendada: 0,83 e 0,62 respectivamente. Em relação ao segundo objetivo, para realizar recomendações adaptáveis de intervenções, a técnica de vizinhos próximos considerou número da sessão e níveis de sintomas, casos que o paciente foi identificado como vizinho a um sujeito com trajetória de tratamento desfavorável foram classificados como trajetória desfavorável. Como resultado, pacientes identificados com trajetória favorável tiveram 62,15% de probabilidade de ter redução expressiva de níveis de sintomas e pacientes identificados com trajetória desfavorável tiveram 35% de probabilidade de ter redução expressiva nos níveis de sintomas medidos pela escala de sintomas de Hopkins-11. Esta diferença foi significativa, mas menor na escala de desfecho (OQ-45), 44% para pacientes em trajetória desfavorável e 56% para pacientes em trajetória favorável.

*3.3.3.1.2 Florestas aleatórias e arvores de decisão*

Com o objetivo de identificar preditores de desistência em psicoterapia, Lutz et al. (2018) utilizaram florestas aleatórias para ranquear 61 preditores em graus de importância. Os 10 preditores com maior relevância passaram por uma técnica de *LASSO* (ver seção “Regressões”).

Laskoski et al. (2019) teve por objetivo predizer distresse pós-sessão em atendimentos de uma paciente buscando identificar comportamentos do terapeuta que afetassem o estado mental do paciente durante uma sessão de psicoterapia. Para isso, utilizou o método computacional de florestas aleatórias para analisar escalas de desfecho e escala de processo terapêutico e gravações de sessões. O melhor modelo detectou 6 comportamentos relevantes, sendo que a mais importante foi a terapeuta intervir para ajudar o paciente a evitar ou reprimir ideias ou sentimentos perturbadores.

Para identificar a qual abordagem terapêutica as sessões de psicoterapia da amostra pertenciam, Imel et al. (2015) utilizaram 200 assuntos discutidos em sessão (ver seção “modelo tópico”) como preditores de abordagens de tratamento em florestas aleatórias. Como resultado observou-se uma performance de taxa de erro de 13,3%, demonstrando poder preditivo elevado.

Zilcha-Mano, Errázuriz, Yaffe-Herbst, German, & DeRubeis (2019) analisaram 3 tipos de dados (i.e., níveis de sintomas; aliança terapêutica e características demográficas e clínicas) de 547 pacientes com modelos de árvore de decisão para identificar ganhos repentinos (redução de níveis de sintomas), preditores de ganhos repentinos e efeito de ganhos repentinos sobre aliança. O modelo de árvore de decisão foi capaz de identificar ganhos repentinos em 12% da amostra, não foi possível encontrar nenhum preditor de ganhos repentinos e, por fim, identificou-se que ganhos repentinos tenderam a ser seguidos por aumento nos escores de aliança e os aumentos na aliança que, por sua vez, foram seguidos por desfechos mais positivos.

Rubel et al. (2019) aplicaram o algoritmo de Boruta, o qual utiliza florestas aleatórias, para identificar moderadores da associação entre aliança terapêutica e desfecho. De acordo com os resultados, de 95 moderadores imputados no modelo, os 11 mais relevantes foram selecionados. Estes 11 moderadores foram utilizados em análises subsequentes (ver seção “vizinho mais próximo”).

Olthof et al. (2019a) analisaram dados de escalas de processo terapêutico de 328 pacientes organizados em séries temporais com o objetivo de identificar sinais de alerta de ganhos ou perdas súbitas nos níveis de intensidade do problema. Ganhos ou perdas súbitas foram identificados por árvores de decisão e os resultados deste procedimento foram utilizados em uma análise de instabilidade (ver seção “algoritmo de complexidade dinâmica”).

O estudo de Solomonov et al. (2020) consistiu em 3 etapas: a) identificar trajetórias de mudança (ver seção “modelos hierárquicos ou mistos lineares”), b) predizer desfecho negativo a partir de não resposta no meio do tratamento (ver seção “regressões”) e c) identificar preditores de não resposta a partir de características de linha de base (descrito nessa seção). Na terceira etapa houve dois passos: florestas aleatórias e árvore de decisão. Os autores utilizaram florestas aleatórias para identificar características preditoras dos subgrupos de pacientes (responsivo e não responsivos) ao início do tratamento. Como resultado, as florestas aleatórias identificaram um conjunto de preditores ao início do tratamento (16 preditoras, entre elas dados demográficos e diversas escalas de avaliação psicométrica). Os três principais preditores (expectativa de tratamento [i.e., quão coerente e eficaz o tratamento é na visão do paciente], neuroticismo e suporte social percebido) identificados pelas florestas aleatórias, por sua vez, foram imputados em uma árvore

de classificação a fim de terem seus pesos analisados. A técnica identificou como melhores preditores de pertencimento ao grupo de resposta rápida ou não ao tratamento a percepção de suporte social, a expectativa do tratamento e neuroticismo respectivamente.

3.3.3.2 Técnicas não supervisionadas

*3.3.3.2.1 Análise de componentes principais*

Orsucci et al. (2016) fizeram uso de análise de componente principal (*PCA* – do inglês *Principal Component Analysis*), para agrupar conjuntos de dados em 7 estados possíveis de organização, a serem interpretados como espaço-estados de um sistema complexo. O produto deste procedimento foi imputado em uma matriz de transição de Markov, descrita na seção correspondente.

Malandrakis & Narayanan (2015) reduziram o número de componentes (os componentes eram inicialmente as 10 mil palavras mais frequentes) através de uma análise de componentes principais. Como resultado, foram utilizados os 500 primeiros componentes (palavras) ranqueados por importância. Em outro momento regressões lineares foram utilizadas para investigar o uso de palavras pelo paciente e pelo terapeuta a depender da orientação terapêutica e da experiência do terapeuta (ver seção “regressões lineares”).

*3.3.3.2.2 Análise do fluxo de fala (DFA – do inglês Discourse Flow Analysis)*

Nitti, Ciavolino, Salvatore, & Gennaro (2010) aplicaram a análise de fluxo de fala para identificar os principais significados (i.e., perspectivas, pressupostos do paciente) em 43 sessões de terapia de um paciente. Os significados são extraídos de transcrições que passam por uma análise de texto que considera a distribuição dos conteúdos no tempo e sua quantidade. Os produtos desta técnica foram os seguintes índices: de atividade, conectividade e frequência das categorias encontradas. Os resultados foram imputados, posteriormente, em uma rede neural (ver seção seguinte).

*3.3.3.2.3 Redes neurais*

Villmann, Liebers, Bergmann, Gumz, & Geyer (2008) empregaram redes neurais artificiais, mais especificamente um mapa auto organizável de crescimento, para identificar se níveis de dados fisiológicos do paciente e do terapeuta (frequência cardíaca, respiratória, tensão muscular, nível de condutância galvânica, resposta de condutância galvânica) poderiam predizer ocorrência de ciclos de posturas do paciente (relaxar, seguido por experienciar, por refletir e por fim conectar-se). Os autores identificaram que a variabilidade de paciente e terapeuta estão correlacionadas. Padrões detectados nesta variabilidade podem indicar ocorrência de eventos durante as sessões, como a ocorrência dos ciclos de posturas. Dois ciclos de posturas do paciente puderam ser identificados em momentos distintos do tratamento, entre as sessões 5 e 22 e um menor entre as sessões 22 e 34.

Nitti et al. (2010) imputaram os índices provenientes da análise de discurso (ver seção anterior) em uma rede neural artificial para identificar momentos distintos na psicoterapia. A rede neural artificial construída foi capaz de detectar regularidades que permitem distinguir duas classes, correspondendo à hipótese dos autores sobre a existência de duas etapas (limitação e recombinação) no processo psicoterapêutico.

*3.3.3.2.4 Matriz de transição de Markov*

Orsucci et al. (2016) utilizaram uma matriz de transição de Markov para calcular as probabilidades de transições entre os espaço-estados (células, ou pontos, que correspondem a estados possíveis de sistema) do sistema dinâmico complexo produzidas pela análise de componentes principais descritos (ver secção correspondente). A matriz possibilitou identificar que o sistema oscila entre dois atratores (estado no qual um sistema dinâmico eventualmente se estabiliza) e possui dinâmicas de transição.

# 4 DISCUSSÃO

Os avanços metodológicos que o poder computacional tem atingido nestes últimos tempos podem ser uma forma de atender a necessidade da pesquisa de processo em psicoterapia de novas ferramentas capazes de abraçar a alta complexidade e a grande quantidade de dados. Neste contexto faz-se necessária uma organização do conhecimento produzido no campo de intersecção destas duas áreas. Esta revisão teve por objetivo realizar um levantamento das técnicas computacionais utilizadas para análise de dados de pesquisas de processo em psicoterapia e produzir uma descrição sistematizada dos achados. A partir de uma busca sistemática nas principais bases de artigos das áreas da saúde e da computação, foram identificados 19 estudos da tradição orientada por dados, 7 da tradição orientada por teoria e 13 estudos híbridos (que usaram ambas as tradições), totalizando 39 estudos desta área de intersecção entre pesquisa de processo em psicoterapia e computação, com predomínio da tradição orientada por dados. A frequência de estudos híbridos sugere que a aliança entre as tradições tem sido considerada e utilizada.

As técnicas de processamento de linguagem natural mostraram-se capazes de automatizar algumas etapas da pesquisa de processo em psicoterapia como, por exemplo, a transcrição de sessões e a classificação dos conteúdos transcritos e categorias e a quantificação de partes do processo psicoterápico em aspectos como contexto, sentimentos, intervenções e abordagem terapêutica, permitindo o uso dessas variáveis em outras técnicas computacionais que exigem variáveis quantitativas. Por exemplo, temas como solidão, família e finanças identificadas processamento de linguagem natural podem ser imputadas como preditores de processos da psicoterapia como aliança terapêutica (e.g., Atzil-Slonim et al., 2021) ou utilizados para classificar trechos de sessões (e.g., Wiegersma et al., 2020; Xiao et al., 2015). Estes esforços, de automatizar passos da pesquisa de processo identificados em nossa revisão, principalmente pela aplicação de processamento de linguagem natural, foram coerentes com a sugestão de Imel, Caperton, Tanana, & Atkins (2017). Em contrapartida, deve-se ressaltar que a performance do reconhecimento automático de fala demonstrou desempenho inferior no contexto de psicoterapia (taxa de erro por palavra de 36,43%; Goldberg et al., 2020; e 43,1% Xiao et al., 2015) quando comparado à transmissão de rádio e televisão (taxa de erro por palavra de 15%, comentado por Xiao et al., 2015). Provavelmente isso se dá pelo fato

de que o emprego desta tecnologia performa melhor quando o material analisado possui alta resolução (boa qualidade), de forma que os pesquisadores interessados em utilizar tais técnicas deverão priorizar bons equipamentos de gravação e configuração de ambiente.

Já a abordagem dos sistemas dinâmicos foi usada principalmente para modelar mecanismos que ocorrem em psicoterapia, encontrando partes do processo psicoterápicos que funcionam ou se comportam como os observados em outros sistemas dinâmicos (e.g., nível de instabilidade em escores de aliança, transições de ordem ou sincronia de dados fisiológicos de paciente e terapeuta) e, muitas vezes, usando tais formulações como preditores de desfecho da terapia (e.g., Basto et al., 2018; Gumz et al., 2012; Olthof et al., 2019b; Olthof et al., 2019a; Schiepek et al., 2020). Esta abordagem mostrou-se eficiente, também, em mapear a evolução das variáveis ao longo do tempo, para cada paciente ou díade individualmente. Schöller et al. (2018) desenvolveu uma plataforma na qual dados de pacientes podem ser imputados e a plataforma retorna uma série temporal daquele paciente. Tais informações podem oferecer *insights* clínicos relevantes e orientar a prática do psicoterapeuta. Por exemplo, estudos que aplicaram estes tipos de modelagem identificaram que trajetórias distantes das mais comuns não necessariamente implicam em um desfecho negativo (Schiepek et al., 2020), suplementando o argumento de que em muitos casos o processo psicoterapêutico ocorre de forma não linear e singular. Assim, ao invés de procurar desvios das trajetórias padrão como precursores de deteriorações, terapeutas podem passar a procurar instabilidades críticas e outros precursores de transições para aplicar os princípios genéricos de mudança, uma vez que foi observado que estes eventos tendem a preceder ganhos ou perdas súbitas (Olthof et al., 2019a). Este cuidado permite encaixar intervenções precisas correspondentes a esta fase do processo (e.g., Basto et al., 2018; Gumz et al., 2012; Olthof et al., 2019b; Olthof et al., 2019a; Schiepek et al., 2020), tornando o processo de mudança o foco principal do trabalho terapêutico, esta perspectiva é coerente com modelos psicoterapêuticos que já vem sendo propostos (e.g., Stefan G. Hofmann, Curtiss, & Hayes, 2020).

Finalmente, a aprendizagem de máquina mostrou-se uma técnica eficiente para detectar padrões e realizar predições em amostras grandes (e.g., preditores de desistência da terapia; de casos não responsivos à terapia; níveis de aliança; risco de suicídio e níveis de sofrimento), bem como na redução de dimensionalidade e seleção

de variáveis com maior poder preditivo a serem usadas em outras etapas das pesquisas (Lutz et al., 2019; Lutz et al., 2018; Solomonov et al., 2020). A aprendizagem de máquina, mais especificamente o uso de modelos hierárquicos permite analisar a amostra em diferentes níveis (e.g., comparar pacientes de um mesmo terapeuta com pacientes de outros terapeutas; pacientes não responsivos com pacientes responsivos), demonstrando o efeito de subgrupos da amostra sobre o processo psicoterápico e seu desfecho (e.g., Li & Kivlighan Jr, 2019; Li et al., 2020; Shapira et al., 2021; Syzdek, 2020).

Um terço dos estudos da amostra (n = 13) foi de estudos híbridos, ou seja, tiveram influência de métodos guiados por teoria e por dados. É interessante observar que em 9 dos 13 estudos híbridos a sequência de técnicas empregadas na análise dos dados foi: derivar das variáveis iniciais (e.g., escores de aliança) medidas ancoradas na teoria dos sistemas dinâmicos (e.g., nível de complexidade) e, então, verificar seu poder preditivo e/ou a significância das associações com outras variáveis de interesse, como, por exemplo, escores de escalas de desfecho psicoterápico, através de técnicas de aprendizagem de máquina. A análise destas medidas derivadas pode lançar luz sobre mecanismos da psicoterapia indisponíveis em uma análise limitada às métricas originais concretas.

O uso de técnicas computacionais para analisar dados de pesquisas de processo em psicoterapia é uma intersecção de três áreas (pesquisa de processo em psicoterapia, métodos computacionais guiados por teoria e métodos computacionais guiados por dados). Ao conduzir esta revisão, observou-se um grande desafio de comunicação e mesmo de compreensão dos conceitos envolvidos nos estudos. Para manipular o objeto coerentemente, ficou evidente que são necessários conhecimentos de todas as áreas envolvidas. Uma vez que todas elas são complexas e densas, este exercício evoca uma coordenação precisa entre especialistas de cada área. Utilizando esta revisão como exemplo, decompor as técnicas dos estudos em diferentes seções de forma coesa, conceitualmente adequada e acessível para a comunidade da psicologia, da aprendizagem de máquina e dos sistemas dinâmicos, exigiu um trabalho hercúleo.

Como visto na introdução da presente dissertação, a abordagem cientifica tradicional se mostra limitada para abraçar a complexidade do fenômeno que é a psicoterapia (Gelo & Salvatore, 2016; Stefan G. Hofmann et al., 2020; Stefan G. Hofmann & Hayes, 2019). O conjunto de variáveis, seu entrelaçamento e sua

interação bidirecional faz com que o número de possiblidades em uma única sessão de psicoterapia seja infinito. Para ilustrar, consideremos uma partida de xadrez, existem 315 bilhões de maneiras possíveis de se realizar os quatro primeiros movimentos do jogo, uma única sessão de psicoterapia, por sua vez, excede em muito o xadrez em nível de complexidade e quantidade de possibilidades das interações, configurando-se com um fenômeno extremamente desafiador de ser compreendido. Isto posto, abordagens desenvolvidas pelas ciências da complexidade, como entropia e grau de complexidade, podem nos dar alternativas úteis no lugar de estudar as relações variável a variável.

Também é um grande desafio, nessa área, definir com precisão o que é um método computacional. A rigor, qualquer análise de dados que possa ser feita com computadores poderia entrar nesse estudo, o que colocaria praticamente todos os estudos mais modernos na revisão, acabando com sua utilidade. Optamos por termos que capturassem representantes dos principais grupos de métodos reconhecidos como tipicamente computacionais por terem se desenvolvido ou requererem para sua execução, ao menos na prática, do poder computacional. Por um lado, tal delineamento permitiu a realização da presente revisão, por outro, cria algumas limitações, como a possibilidade de exclusão de técnicas potencialmente computacionais. Por exemplo, muitos métodos estatísticos atualmente também requerem computadores na prática, especialmente quando grandes quantidades de dados estão envolvidas, e, portanto, poderiam entrar nessa revisão. Entretanto, a inclusão de tais termos colocaria praticamente todas as pesquisas de processo em psicoterapia que tiveram seus dados analisados quantitativamente.

A distinção entre abordagem orientada teoricamente por dados é outro ponto controverso e de difícil conceituação e operacionalização. Alguns autores propõem que o primeiro é mecanístico, focado em descrever um processo, e construída com base em conhecimentos prévios enquanto o segundo se estrutura com base nos dados da amostra investigada, sem se ocupar primariamente com mecanismo (Bennett et al., 2019; Huys et al., 2016). Também é proposto que modelagem por sistemas dinâmicos e aprendizagem de máquina seriam os principais representantes de cada tradição, respectivamente (Bennett et al., 2019; Huys, Browning, Paulus, & Frank, 2020; Huys et al., 2016). Entretanto, tanto os objetivos e princípios quanto as ferramentas acima associadas a tais tradições se misturam na prática, não havendo tal pureza de tais tradições e a linha que divide uma da outra é um tanto arbitrária

(Bennett et al., 2019; Huys et al., 2016). Ainda assim, considerar representantes das duas abordagens foi importante para que a revisão não deixasse de fora representantes de métodos computacionais que vem sendo usado para estudar processo em psicoterapia caso os termos usados nas buscas tivessem se limitado aos usados apenas por uma das tradições.

Em relação a direções futuras, seriam interessantes atualizações desta revisão e outras revisões mais específicas. Acredita-se que com o aumento crescente em pesquisas desta natureza, os métodos computacionais sejam cada vez mais validados e a área possa passar a ter impacto não só na condução de pesquisas, mas também na prática clínica e formação de psicoterapeutas. Em nossa amostra não tivemos nenhum estudo que realizou análise computadorizada gravações de vídeo de sessões e este é um campo promissor a ser explorado.

Em síntese, é possível concluir que, em linhas gerais, a intersecção destas duas áreas (computação e pesquisa de processo), apesar de ser recente, tem tido um rápido crescimento nos últimos anos. Em termos quantitativos, entre as técnicas de aprendizagem de máquinas, de sistemas dinâmicos e de processamento de linguagem, a primeira tem se sobressaído. Com relação à tradição dos métodos dos estudos (abordagens orientadas teoricamente, por dados e estudos híbridos) a distribuição foi heterogênea e, surpreendentemente, a quantidade de estudos híbridos foi expressiva (33%). As técnicas de processamento de linguagem natural mostraram-se uma maneira eficiente para automatizar alguns processos da pesquisa em psicoterapia e para relacionar propriedades dos diálogos com processos psicoterapêuticos, enquanto a teoria dos sistemas dinâmicos se revelou como uma abordagem interessante para modelar a evolução da psicoterapia no tempo. Por fim, a aprendizagem de máquinas indicou aptidão para analisar grandes quantidades de dados. Tais achados apontam para uma promissora linha de pesquisas no estudo dessa complexa e importante modalidade terapêutica que é a psicoterapia.

## REFERÊNCIAS


APA, A. P. A. (2016). Understanding psychotherapy and how it works. *Washington, DC: American Psychiatric Association*.

Atzil-Slonim, D., Juravski, D., Bar-Kalifa, E., Gilboa-Schechtman, E., Tuval-Mashiach, R., Shapira, N., & Goldberg, Y. (2021). Using topic models to identify clients' functioning levels and alliance ruptures in psychotherapy. *Psychotherapy, 58*(2), 324-339. doi:10.1037/pst0000362

Barbosa, E., Sousa, M., Montanha, C. C., Pinto-Gouveia, J., & Salgado, J. (2020). Flexibility between immersion and distancing: A dynamic pattern with effect on depressive symptoms. *Psychotherapy Research, 31*(4), 493-506.

Basto, I., Stiles, W. B., Bento, T., Pinheiro, P., Mendes, I., Rijo, D., & Salgado, J. (2018). Fluctuation in the assimilation of problematic experiences: A case study of dynamic systems analysis. *Frontiers in Psychology, 9*, 1119.

Beck, A. T., Ward, C. H., Mendelson, M., Mock, J., & Erbaugh, J. (1961). An inventory for measuring depression. *Archives of General Psychiatry, 4*(6), 561-571.

Bennett, D., Silverstein, S. M., & Niv, Y. (2019). The Two Cultures of Computational Psychiatry. *JAMA Psychiatry, 76*(6), 563-564. doi:10.1001/jamapsychiatry.2019.0231

Blei, D. M., Ng, A. Y., & Jordan, M. I. (2003). Latent dirichlet allocation. *Journal of machine Learning research, 3*(Jan), 993-1022.

Bohart, A. C., & Wade, A. G. (2013). The client in psychotherapy. *Bergin and Garfield's handbook of psychotherapy and behavior change, 6*, 219-257.

Borsboom, D. (2017). A network theory of mental disorders. *World Psychiatry, 16*(1), 5-13.

Borsboom, D., & Cramer, A. (2013). Network Analysis: An Integrative Approach to the Structure of Psychopathology. *Annual Review of Clinical Psychology, 9*, 91-121. doi:10.1146/annurev-clinpsy-050212-185608

Braakmann, D. (2015). Historical paths in psychotherapy research. In *Psychotherapy Research* (pp. 39-65): Springer.

Brent, D. A., & Kolko, D. J. (1998). Psychotherapy: Definitions, mechanisms of action, and relationship to etiological models. *Journal of Abnormal Child Psychology, 26*(1), 17-25.

Bruijniks, S. J., DeRubeis, R. J., Lemmens, L. H., Peeters, F. P., Cuijpers, P., & Huibers, M. J. (2021). The relation between therapy quality, therapy processes and outcomes and identifying for whom therapy quality matters in CBT and IPT for depression. *Behaviour Research and Therapy, 139*, 103815.

Chowdhury, G. G. (2003). Natural language processing. *Annual Review of Information Science and Technology, 37*(1), 51-89. doi:https://doi.org/10.1002/aris.1440370103

Crits-Christoph, P., Gibbons, M. B. C., & Mukherjee, D. (2013). Psychotherapy process-outcome research. In *Bergin and Garfield's handbook of psychotherapy and behavior change* (pp. 298-340): John Wiley and Sons.

Crossley, S. A., Kyle, K., & McNamara, D. S. (2017). Sentiment Analysis and Social Cognition Engine (SEANCE): An automatic tool for sentiment, social cognition, and social-order analysis. *Behav Res Methods, 49*(3), 803-821. doi:10.3758/s13428-016-0743-z

Cuijpers, P. (2019). Targets and outcomes of psychotherapies for mental disorders: an overview. *World Psychiatry, 18*(3), 276-285. doi:https://doi.org/10.1002/wps.20661

Dwyer, D. B., Falkai, P., & Koutsouleris, N. (2018). Machine Learning Approaches for Clinical Psychology and Psychiatry. *Annual Review of Clinical Psychology, 14*, 91-118. doi:10.1146/annurev-clinpsy-032816-045037

Gaut, G., Steyvers, M., Imel, Z. E., Atkins, D. C., & Smyth, P. (2015). Content Coding of Psychotherapy Transcripts Using Labeled Topic Models. *IEEE journal of biomedical and health informatics, 21*(2), 476-487.

Gelo, O. C. G., & Salvatore, S. (2016). A dynamic systems approach to psychotherapy: A meta-theoretical framework for explaining psychotherapy change processes. *Journal of counseling psychology, 63*(4), 379.

Goldberg, S. B., Flemotomos, N., Martinez, V. R., Tanana, M. J., Kuo, P. B., Pace, B. T., . . . Imel, Z. E. (2020). Machine learning and natural language processing in psychotherapy research: Alliance as example use case. *Journal of counseling psychology, 67*(4), 438.

Gumz, A., Bauer, K., & Brähler, E. (2012). Corresponding instability of patient and therapist process ratings in psychodynamic psychotherapies. *Psychotherapy Research, 22*(1), 26-39.

Hamilton, M. (1960). A rating scale for depression.

Hardy, G. E., & Llewelyn, S. (2015). Introduction to psychotherapy process research. In *Psychotherapy Research* (pp. 183-194): Springer.

Hartkamp, N., & Schmitz, N. (1999). Structures of introject and therapist–patient interaction in a single case study of inpatient psychotherapy. *Psychotherapy Research, 9*(2), 199-215.

Hayes, A. M., & Strauss, J. L. (1998). Dynamic systems theory as a paradigm for the study of change in psychotherapy: An application to cognitive therapy for depression. *Journal of Consulting and Clinical Psychology, 66*(6), 939-947. doi:10.1037/0022-006X.66.6.939

Hayes, A. M., & Yasinski, C. (2015). Pattern destabilization and emotional processing in cognitive therapy for personality disorders. *Frontiers in Psychology, 6*.

Hofmann, S. G., Curtiss, J., & McNally, R. J. (2016). A complex network perspective on clinical science. *Perspectives on psychological science, 11*(5), 597-605.

Hofmann, S. G., Curtiss, J. E., & Hayes, S. C. (2020). Beyond linear mediation: Toward a dynamic network approach to study treatment processes. *Clinical Psychology Review, 76*, 101824-101824.

Hofmann, S. G., & Hayes, S. C. (2019). The Future of Intervention Science: Process-Based Therapy. *Clinical Psychological Science, 7*(1), 37-50. doi:10.1177/2167702618772296

Holmes, E. A., Ghaderi, A., Harmer, C. J., Ramchandani, P. G., Cuijpers, P., Morrison, A. P., . . . Craske, M. G. (2018). The Lancet Psychiatry Commission on psychological treatments research in tomorrow's science. *The Lancet Psychiatry, 5*(3), 237-286. doi:10.1016/S2215-0366(17)30513-8

Huys, Q. J., Browning, M., Paulus, M. P., & Frank, M. J. (2020). Advances in the computational understanding of mental illness. *Neuropsychopharmacology, 46*(1), 3-19.

Huys, Q. J., Maia, T. V., & Frank, M. J. (2016). Computational psychiatry as a bridge from neuroscience to clinical applications. *Nature neuroscience, 19*(3), 404.

Imel, Z. E., Caperton, D. D., Tanana, M., & Atkins, D. C. (2017). Technology-enhanced human interaction in psychotherapy. *Journal of counseling psychology, 64*(4), 385.

Imel, Z. E., Steyvers, M., & Atkins, D. C. (2015). Computational psychotherapy research: Scaling up the evaluation of patient–provider interactions. *Psychotherapy, 52*(1), 19.

Indurkhya, N., & Damerau, F. J. (2010). *Handbook of natural language processing* (Vol. 2): CRC Press.

Johansson, P., & Høglend, P. (2007). Identifying mechanisms of change in psychotherapy: Mediators of treatment outcome. *Clinical Psychology & Psychotherapy, 14*(1), 1-9.

Kazdin, A. E. (2007). Mediators and mechanisms of change in psychotherapy research. *Annu Rev Clin Psychol, 3*, 1-27. doi:10.1146/annurev.clinpsy.3.022806.091432

Kazdin, A. E. (2014). Evidence-based psychotherapies I: qualifiers and limitations in what we know. *South African Journal of Psychology, 44*(4), 381-403. doi:10.1177/0081246314533750

Krause, M., De la Parra, G., Arístegui, R., Dagnino, P., Tomicic, A., Valdés, N., . . . Altimir, C. (2007). The evolution of therapeutic change studied through generic change indicators. *Psychotherapy Research, 17*(6), 673-689.

Laskoski, P. B., Serralta, F. B., Passos, I. C., & Hauck, S. (2019). Machine-learning approaches in psychotherapy: a promising tool for advancing the understanding of the psychotherapeutic process. *Brazilian Journal of Psychiatry, 41*(6), 568-569.

Levis, M., Westgate, C. L., Gui, J., Watts, B. V., & Shiner, B. (2020). Natural language processing of clinical mental health notes may add predictive value to existing suicide risk models. *Psychological medicine, 51*(8), 1382-1391.

Li, X., & Kivlighan Jr, D. M. (2019). Examining therapy dynamics and session outcome using differential equations model and multilevel data disaggregation. *Psychotherapy Research, 30*(5), 604-621.

Li, X., Kivlighan Jr, D. M., & Hill, C. E. (2020). Follow you or follow me? Examining therapist responsiveness to client and responsiveness to self, using differential equations model and multilevel data disaggregation from an interpersonal theory framework. *Journal of counseling psychology, 67*(5), 608-621. doi:10.1037/cou0000406

Liddy, E. D. (2001). Natural language processing.

Lutz, W., Rubel, J. A., Schwartz, B., Schilling, V., & Deisenhofer, A.-K. (2019). Towards integrating personalized feedback research into clinical practice: Development of the Trier Treatment Navigator (TTN). *Behaviour Research and Therapy, 120*, 103438.

Lutz, W., Schwartz, B., Hofmann, S. G., Fisher, A. J., Husen, K., & Rubel, J. A. (2018). Using network analysis for the prediction of treatment dropout in patients with mood and anxiety disorders: A methodological proof-of-concept study. *Scientific reports, 8*(1), 1-9.

Malandrakis, N., & Narayanan, S. S. (2015). *Therapy language analysis using automatically generated psycholinguistic norms.* Paper presented at the Sixteenth Annual Conference of the International Speech Communication Association.

McGowan, J., Sampson, M., Salzwedel, D. M., Cogo, E., Foerster, V., & Lefebvre, C. (2016). PRESS peer review of electronic search strategies: 2015 guideline statement. *Journal of clinical epidemiology, 75*, 40-46.

Miller, S. D., Duncan, B., Brown, J., Sparks, J., & Claud, D. (2003). The outcome rating scale: A preliminary study of the reliability, validity, and feasibility of a brief visual analog measure. *Journal of brief Therapy, 2*(2), 91-100.

Mohr, D. C., Ho, J., Hart, T. L., Baron, K. G., Berendsen, M., Beckner, V., . . . Duffecy, J. (2014). Control condition design and implementation features in controlled trials: a meta-analysis of trials evaluating psychotherapy for depression. *Transl Behav Med, 4*(4), 407-423. doi:10.1007/s13142-014-0262-3

Mohr, D. C., Spring, B., Freedland, K. E., Beckner, V., Arean, P., Hollon, S. D., . . . Kaplan, R. (2009). The selection and design of control conditions for randomized controlled trials of psychological interventions. *Psychotherapy and Psychosomatics, 78*(5), 275-284.

Moyers, T., Martin, T., Manuel, J., Miller, W., & Ernst, D. (2007). Revised global scales: Motivational interviewing treatment integrity 3.0 (MITI 3.0). *University of New Mexico, Center on Alcoholism, Substance Abuse and Addictions (CASAA), 28*.

Munn, Z., Peters, M. D. J., Stern, C., Tufanaru, C., McArthur, A., & Aromataris, E. (2018). Systematic review or scoping review? Guidance for authors when choosing between a systematic or scoping review approach. *BMC Medical Research Methodology, 18*(1), 1-7. doi:10.1186/s12874-018-0611-x

Murphy, K. P. (2012). *Machine learning: a probabilistic perspective*: MIT press.

Neogi, P. P. G., Das, A. K., Goswami, S., & Mustafi, J. (2020). Topic modeling for text classification. In *Emerging technology in modelling and graphics* (pp. 395-407): Springer.

Nitti, M., Ciavolino, E., Salvatore, S., & Gennaro, A. (2010). Analyzing psychotherapy process as intersubjective sensemaking: An approach based on discourse analysis and neural networks. *Psychotherapy Research, 20*(5), 546-563.

Olthof, M., Hasselman, F., Strunk, G., Aas, B., Schiepek, G., & Lichtwarck-Aschoff, A. (2019b). Destabilization in self-ratings of the psychotherapeutic process is associated with better treatment outcome in patients with mood disorders. *Psychotherapy Research, 30*(4), 520-531.

Olthof, M., Hasselman, F., Strunk, G., van Rooij, M., Aas, B., Helmich, M. A., . . . Lichtwarck-Aschoff, A. (2019a). Critical fluctuations as an early-warning signal for sudden gains and losses in patients receiving psychotherapy for mood disorders. *Clinical Psychological Science, 8*(1), 25-35.

Orlinsky, D., Heinonen, E., & Hartmann, A. (2015). *Psychotherapy Process Research* (Second Edi ed. Vol. 19): Elsevier.

Orlinsky, D. E., Ronnestad, M. H., & Willutzki, U. (2004). Fifty years of psychotherapy process-outcome research: Continuity and change. *Bergin and Garfield's handbook of psychotherapy and behavior change, 5*, 307-389.

Orsucci, F. F., Musmeci, N., Aas, B., Schiepek, G., Reda, M. A., Canestri, L., . . . de Felice, G. (2016). Synchronization analysis of language and physiology in human dyads. *Nonlinear Dynamics, Psychology, and Life Sciences, 20*(2), 167-191.

Oualline, S., & Oualline, G. (2018). Using Google Sheets. In *Practical Free Alternatives to Commercial Software* (pp. 389-404): Springer.

Ouzzani, M., Hammady, H., Fedorowicz, Z., & Elmagarmid, A. (2016). Rayyan—a web and mobile app for systematic reviews. *Systematic reviews, 5*(1), 210.

Peters, M., Godfrey, C., McInerney, P., Munn, Z., Tricco, A., & Khalil, H. (2020). Chapter 11: Scoping Reviews (2020 version). *Joanna Briggs Institute Reviewer's Manual, JBI*.

Rubel, J. A., Zilcha-Mano, S., Giesemann, J., Prinz, J., & Lutz, W. (2019). Predicting personalized process-outcome associations in psychotherapy using machine learning approaches—A demonstration. *Psychotherapy Research, 30*(3), 300-309.

Sadeh-Sharvit, S., & Hollon, S. D. (2020). Leveraging the Power of Nondisruptive Technologies to Optimize Mental Health Treatment: Case Study. *JMIR Mental Health, 7*(11), e20646.

Safran, J. D., & Muran, J. C. (2006). Has the concept of the therapeutic alliance outlived its usefulness? *Psychotherapy: Theory, Research, Practice, Training, 43*(3), 286.

Salvatore, S., & Tschacher, W. (2012). Time dependency of psychotherapeutic exchanges: the contribution of the theory of dynamic systems in analyzing process. *Frontiers in Psychology, 3*, 253.

Schiepek, G., Gelo, O., Viol, K., Kratzer, L., Orsucci, F., de Felice, G., . . . Schöller, H. (2020). Complex individual pathways or standard tracks? A data-based discussion on the trajectories of change in psychotherapy. *Counselling and Psychotherapy Research, 20*(4), 689-702.

Schiepek, G., Kowalik, Z., Schütz, A., Köhler, M., Richter, K., Strunk, G., . . . Elbert, T. (1997). Psychotherapy as a chaotic process I. Coding the client-therapist interaction by means of Sequential Plan Analysis and the search for chaos: a stationary approach. *Psychotherapy Research, 7*(2), 173-194.

Schöller, H., Viol, K., Aichhorn, W., Hütt, M.-T., & Schiepek, G. (2018). Personality development in psychotherapy: a synergetic model of state-trait dynamics. *Cognitive Neurodynamics, 12*(5), 441-459.

Shapira, N., Lazarus, G., Goldberg, Y., Gilboa-Schechtman, E., Tuval-Mashiach, R., Juravski, D., & Atzil-Slonim, D. (2021). Using computerized text analysis to examine associations between linguistic features and clients' distress during psychotherapy. *Journal of counseling psychology, 68*(1), 77.

Solomonov, N., Lee, J., Banerjee, S., Flückiger, C., Kanellopoulos, D., Gunning, F. M., . . . Alexopoulos, G. S. (2020). Modifiable predictors of nonresponse to psychotherapies for late-life depression with executive dysfunction: a machine learning approach. *Molecular Psychiatry, 26*(9), 5190-5198. doi:10.1038/s41380-020-0836-z

Soma, C. S., Baucom, B. R. W., Xiao, B., Butner, J. E., Hilpert, P., Narayanan, S., . . . Imel, Z. E. (2019). Coregulation of therapist and client emotion during psychotherapy. *Psychotherapy Research*, No Pagination Specified-No Pagination Specified.

Strunk, G., & Lichtwarck-Aschoff, A. (2019). Therapeutic Chaos. *Journal for person-oriented research, 5*(2), 81-100. doi:10.17505/jpor.2019.08

Syzdek, B. M. (2020). Client and Therapist Psychotherapy Sentiment Interaction Throughout Therapy. *Psychological Studies, 65*(4), 520-530.

Thelen, E. (2005). Dynamic systems theory and the complexity of change. *Psychoanalytic Dialogues, 15*(2), 255-283.

Thelen, E., & Smith, L. B. (1998). Dynamic systems theories.

Tomicic, A., Martínez, C., Pérez, J. C., Hollenstein, T., Angulo, S., Gerstmann, A., . . . Krause, M. (2015). Discourse-voice regulatory strategies in the

psychotherapeutic interaction: a state-space dynamics analysis. *Frontiers in Psychology, 6*, 378.

Touboul, J., Romagnoni, A., & Schwartz, R. (2017). On the dynamical interplay of positive and negative affects. *Neural computation, 29*(4), 897-936.

Tricco, A. C., Lillie, E., Zarin, W., O'Brien, K. K., Colquhoun, H., Levac, D., . . . Straus, S. E. (2018). PRISMA extension for scoping reviews (PRISMA-ScR): Checklist and explanation. *Annals of Internal Medicine, 169*(7), 467-473. doi:10.7326/M18-0850

Tschacher, W., & Haken, H. (2019). Causation and chance: Detection of deterministic and stochastic ingredients in psychotherapy processes. *Psychotherapy Research*, No Pagination Specified-No Pagination Specified.

Villmann, T., Liebers, C., Bergmann, B., Gumz, A., & Geyer, M. (2008). Investigation of psycho-physiological interactions between patient and therapist during a psychodynamic therapy and their relation to speech using in terms of entropy analysis using a neural network approach. *New Ideas in Psychology, 26*(2), 309-325.

Wiegersma, S., Nijdam, M. J., van Hessen, A. J., Truong, K. P., Veldkamp, B. P., & Olff, M. (2020). Recognizing hotspots in Brief Eclectic Psychotherapy for PTSD by text and audio mining. *European journal of psychotraumatology, 11*(1), 1726672.

Xiao, B., Imel, Z. E., Georgiou, P. G., Atkins, D. C., & Narayanan, S. S. (2015). "Rate my therapist": Automated detection of empathy in drug and alcohol counseling via speech and language processing. *PLoS ONE, 10*(12).

Zilcha-Mano, S., Errázuriz, P., Yaffe-Herbst, L., German, R. E., & DeRubeis, R. J. (2019). Are there any robust predictors of “sudden gainers,” and how is sustained improvement in treatment outcome achieved following a gain? *Journal of Consulting and Clinical Psychology, 87*(6), 491.

# APÊNDICES

## Apêndice I

Data 19/03/21
Palavras-chave base:

(psychotherap* OR "clinical psychology" OR "counseling" OR "behavior therapy" OR "behaviour therapy" OR "behavioral therapy" OR "behavioural therapy" OR "cognitive therapy" OR psychodynamic* OR psychoanal*) AND (computation* OR "machine learning" OR "neural network" OR "neural networks" OR "deep learning" OR "data mining" OR "dynamic system" OR "dynamic systems" OR "dynamical system" OR "dynamical systems" OR "natural language process" OR "natural language processing" OR "NLP" OR "sentiment analysis" OR "difference equation" OR "difference equations" OR "differential equation" OR "differential equations")

Web of science:
filters: Article / Correction / Correction, Addition / Data Paper / Early Access (Web of Science Core Collection only) / Editorial Material / Excerpt / Item About an Individual / Letter / Note / Proceedings Paper / Retracted Publication / Retraction

Termos de busca:
TS=(psychotherap* OR "clinical psychology" OR "counseling" OR "behavior therapy" OR "behaviour therapy" OR "behavioral therapy" OR "behavioural therapy" OR "cognitive therapy" OR psychodynamic* OR psychoanal*) AND TS=(computation* OR "machine learning" OR "neural network" OR "neural networks" OR "deep learning" OR "data mining" OR "dynamic system" OR "dynamic systems" OR "dynamical system" OR "dynamical systems" OR "natural language process" OR "natural language processing" OR "NLP" OR "sentiment analysis" OR "difference equation" OR "difference equations" OR "differential equation" OR "differential equations")
Retorno N = 850

(TS=(psychotherap* OR "clinical psychology" OR "counseling" OR "behavior therapy" OR "behaviour therapy" OR "behavioral therapy" OR "behavioural therapy" OR

"cognitive therapy" OR psychodynamic* OR psychoanal*) AND TS=(computation* OR "machine learning" OR "neural network" OR "neural networks" OR "deep learning" OR "data mining" OR "dynamic system" OR "dynamic systems" OR "dynamical system" OR "dynamical systems" OR "natural language process" OR "natural language processing" OR "NLP" OR "sentiment analysis" OR "difference equation" OR "difference equations" OR "differential equation" OR "differential equations")) AND DOCUMENT TYPES: (Article OR Correction OR Correction, Addition OR Data Paper OR Early Access OR Editorial Material OR Excerpt OR Item About an Individual OR Letter OR Note OR Proceedings Paper OR Retracted Publication OR Retraction) Indexes=SCI-EXPANDED, SSCI, A&HCI, CPCI-S, CPCI-SSH, ESCI Timespan=All years

Pubmed:
Filters applied: Clinical Study, Clinical Trial, Editorial, Journal Article, Letter, Observational Study, Randomized Controlled Trial, Retracted Publication, Retraction of Publication, English.
535 for
(("psychotherap*"[Title/Abstract] OR "clinical psychology"[Title/Abstract] OR "counseling"[Title/Abstract] OR "behavior therapy"[Title/Abstract] OR "behaviour therapy"[Title/Abstract] OR "behavioral therapy"[Title/Abstract] OR "behavioural therapy"[Title/Abstract] OR "cognitive therapy"[Title/Abstract] OR "psychodynamic*"[Title/Abstract] OR "psychoanal*"[Title/Abstract]) AND ("computation*"[Title/Abstract] OR "machine learning"[Title/Abstract] OR "neural network"[Title/Abstract] OR "neural networks"[Title/Abstract] OR "deep learning"[Title/Abstract] OR "data mining"[Title/Abstract] OR "dynamic system"[Title/Abstract] OR "dynamic systems"[Title/Abstract] OR "dynamical system"[Title/Abstract] OR "dynamical systems"[Title/Abstract] OR "natural language process"[Title/Abstract] OR "natural language processing"[Title/Abstract] OR "NLP"[Title/Abstract] OR "sentiment analysis"[Title/Abstract] OR "difference equation"[Title/Abstract] OR "difference equations"[Title/Abstract] OR "differential equation"[Title/Abstract] OR "differential equations"[Title/Abstract])) AND ((clinicalstudy[Filter] OR clinicaltrial[Filter] OR editorial[Filter] OR journalarticle[Filter]

OR letter[Filter] OR observationalstudy[Filter] OR randomizedcontrolledtrial[Filter] OR retractedpublication[Filter] OR retractionofpublication[Filter]) AND (english[Filter]))

ACM DL:

262 Results for: [[[Publication Title: psychotherap*] OR [Publication Title: "clinical psychology"] OR [Publication Title: "counseling"] OR [Publication Title: "behavior therapy"] OR [Publication Title: "behaviour therapy"] OR [Publication Title: "behavioral therapy"] OR [Publication Title: "behavioural therapy"] OR [Publication Title: "cognitive therapy"] OR [Publication Title: psychodynamic*] OR [Publication Title: psychoanal*]] AND [[Publication Title: computation*] OR [Publication Title: "machine learning"] OR [Publication Title: "neural network"] OR [Publication Title: "neural networks"] OR [Publication Title: "deep learning"] OR [Publication Title: "data mining"] OR [Publication Title: "dynamic system"] OR [Publication Title: "dynamic systems"] OR [Publication Title: "dynamical system"] OR [Publication Title: "dynamical systems"] OR [Publication Title: "natural language process"] OR [Publication Title: "natural language processing"] OR [Publication Title: "nlp"] OR [Publication Title: "sentiment analysis"] OR [Publication Title: "difference equation"] OR [Publication Title: "difference equations"] OR [Publication Title: "differential equation"] OR [Publication Title: "differential equations"]]] OR [[[Abstract: psychotherap*] OR [Abstract: "clinical psychology"] OR [Abstract: "counseling"] OR [Abstract: "behavior therapy"] OR [Abstract: "behaviour therapy"] OR [Abstract: "behavioral therapy"] OR [Abstract: "behavioural therapy"] OR [Abstract: "cognitive therapy"] OR [Abstract: psychodynamic*] OR [Abstract: psychoanal*]] AND [[Abstract: computation*] OR [Abstract: "machine learning"] OR [Abstract: "neural network"] OR [Abstract: "neural networks"] OR [Abstract: "deep learning"] OR [Abstract: "data mining"] OR [Abstract: "dynamic system"] OR [Abstract: "dynamic systems"] OR [Abstract: "dynamical system"] OR [Abstract: "dynamical systems"] OR [Abstract: "natural language process"] OR [Abstract: "natural language processing"] OR [Abstract: "nlp"] OR [Abstract: "sentiment analysis"] OR [Abstract: "difference equation"] OR [Abstract: "difference equations"] OR [Abstract: "differential equation"] OR [Abstract: "differential equations"]]] OR [[[Keywords: psychotherap*] OR [Keywords: "clinical psychology"] OR [Keywords: "counseling"] OR [Keywords: "behavior therapy"] OR [Keywords: "behaviour therapy"] OR [Keywords: "behavioral therapy"] OR [Keywords: "behavioural therapy"] OR [Keywords: "cognitive therapy"] OR [Keywords: psychodynamic*] OR [Keywords: psychoanal*]] AND [[Keywords: computation*] OR [Keywords: "machine learning"] OR [Keywords: "neural network"]

OR [Keywords: "neural networks"] OR [Keywords: "deep learning"] OR [Keywords: "data mining"] OR [Keywords: "dynamic system"] OR [Keywords: "dynamic systems"] OR [Keywords: "dynamical system"] OR [Keywords: "dynamical systems"] OR [Keywords: "natural language process"] OR [Keywords: "natural language processing"] OR [Keywords: "nlp"] OR [Keywords: "sentiment analysis"] OR [Keywords: "difference equation"] OR [Keywords: "difference equations"] OR [Keywords: "differential equation"] OR [Keywords: "differential equations"]]]

IEEE:

10 for ("Document Title":psychotherap* OR "Document Title":"clinical psychology" OR "Document Title":"counseling" OR "Document Title":"behavior therapy" OR "Document Title":"behaviour therapy" OR "Document Title":"behavioral therapy" OR "Document Title":"behavioural therapy" OR "Document Title":"cognitive therapy" OR "Document Title":psychodynamic* OR "Document Title":psychoanal*) AND ("Document Title":computation* OR "Document Title":"machine learning" OR "Document Title":"neural network" OR "Document Title":"neural networks" OR "Document Title":"deep learning" OR "Document Title":"data mining" OR "Document Title":"dynamic system" OR "Document Title":"dynamic systems" OR "Document Title":"dynamical system" OR "Document Title":"dynamical systems" OR "Document Title":"natural language process" OR "Document Title":"natural language processing" OR "Document Title":"NLP" OR "Document Title":"sentiment analysis" OR "Document Title":"difference equation" OR "Document Title":"difference equations" OR "Document Title":"differential equation" OR "Document Title":"differential equations")

13 for ("Author Keywords":psychotherap* OR "Author Keywords":"clinical psychology" OR "Author Keywords":"counseling" OR "Author Keywords":"behavior therapy" OR "Author Keywords":"behaviour therapy" OR "Author Keywords":"behavioral therapy" OR "Author Keywords":"behavioural therapy" OR "Author Keywords":"cognitive therapy" OR "Author Keywords":psychodynamic* OR "Author Keywords":psychoanal*) AND ("Author Keywords":computation* OR "Author Keywords":"machine learning" OR "Author Keywords":"neural network" OR "Author Keywords":"neural networks" OR "Author Keywords":"deep learning" OR "Author Keywords":"data mining" OR "Author Keywords":"dynamic system" OR "Author Keywords":"dynamic systems" OR "Author

Keywords":"dynamical system" OR "Author Keywords":"dynamical systems" OR "Author Keywords":"natural language process" OR "Author Keywords":"natural language processing" OR "Author Keywords":"NLP" OR "Author Keywords":"sentiment analysis" OR "Author Keywords":"difference equation" OR "Author Keywords":"difference equations" OR "Author Keywords":"differential equation" OR "Author Keywords":"differential equations")

86 for ("Abstract":psychotherap* OR "Abstract":"clinical psychology" OR "Abstract":"counseling" OR "Abstract":"behavior therapy" OR "Abstract":"behaviour therapy" OR "Abstract":"behavioral therapy" OR "Abstract":"behavioural therapy" OR "Abstract":"cognitive therapy" OR "Abstract":psychodynamic* OR "Abstract":psychoanal*) AND ("Abstract":computation* OR "Abstract":"machine learning" OR "Abstract":"neural network" OR "Abstract":"neural networks" OR "Abstract":"deep learning" OR "Abstract":"data mining" OR "Abstract":"dynamic system" OR "Abstract":"dynamic systems" OR "Abstract":"dynamical system" OR "Abstract":"dynamical systems" OR "Abstract":"natural language process" OR "Abstract":"natural language processing" OR "Abstract":"NLP" OR "Abstract":"sentiment analysis" OR "Abstract":"difference equation" OR "Abstract":"difference equations" OR "Abstract":"differential equation" OR "Abstract":"differential equations")

PsychNet:

557 Results for (Title: psychotherap* OR Title: "clinical psychology" OR Title: "counseling" OR Title: "behavior therapy" OR Title: "behaviour therapy" OR Title: "behavioral therapy" OR Title: "behavioural therapy" OR Title: "cognitive therapy" OR Title: psychodynamic* OR Title: psychoanal*) AND (Title: computation* OR Title: "machine learning" OR Title: "neural network" OR Title: "neural networks" OR Title: "deep learning" OR Title: "data mining" OR Title: "dynamic system" OR Title: "dynamic systems" OR Title: "dynamical system" OR Title: "dynamical systems" OR Title: "natural language process" OR Title: "natural language processing" OR Title: "NLP" OR Title: "sentiment analysis" OR Title: "difference equation" OR Title: "difference equations" OR Title: "differential equation" OR Title: "differential equations") OR (Keywords: psychotherap* OR Keywords: "clinical psychology" OR Keywords: "counseling" OR Keywords: "behavior therapy" OR Keywords: "behaviour therapy" OR

Keywords: "behavioral therapy" OR Keywords: "behavioural therapy" OR Keywords: "cognitive therapy" OR Keywords: psychodynamic* OR Keywords: psychoanal*) AND (Keywords: computation* OR Keywords: "machine learning" OR Keywords: "neural network" OR Keywords: "neural networks" OR Keywords: "deep learning" OR Keywords: "data mining" OR Keywords: "dynamic system" OR Keywords: "dynamic systems" OR Keywords: "dynamical system" OR Keywords: "dynamical systems" OR Keywords: "natural language process" OR Keywords: "natural language processing" OR Keywords: "NLP" OR Keywords: "sentiment analysis" OR Keywords: "difference equation" OR Keywords: "difference equations" OR Keywords: "differential equation" OR Keywords: "differential equations") OR (Abstract: psychotherap* OR Abstract: "clinical psychology" OR Abstract: "counseling" OR Abstract: "behavior therapy" OR Abstract: "behaviour therapy" OR Abstract: "behavioral therapy" OR Abstract: "behavioural therapy" OR Abstract: "cognitive therapy" OR Abstract: psychodynamic* OR Abstract: psychoanal*) AND (Abstract: computation* OR Abstract: "machine learning" OR Abstract: "neural network" OR Abstract: "neural networks" OR Abstract: "deep learning" OR Abstract: "data mining" OR Abstract: "dynamic system" OR Abstract: "dynamic systems" OR Abstract: "dynamical system" OR Abstract: "dynamical systems" OR Abstract: "natural language process" OR Abstract: "natural language processing" OR Abstract: "NLP" OR Abstract: "sentiment analysis" OR Abstract: "difference equation" OR Abstract: "difference equations" OR Abstract: "differential equation" OR Abstract: "differential equations") AND Document Type: Editorial OR Erratum/Correction OR Journal Article OR Letter OR Retraction AND Peer-Reviewed Journals only