

INSTITUTO FEDERAL DE SANTA CATARINA

JOSÉ NILDO FERREIRA RAMOS JÚNIOR

VOXELMATCH: SISTEMA DE AVALIAÇÃO DE SIMILARIDADE DE IMAGENS
GERADAS POR ALGORITMOS DE *DEEP LEARNING*

Florianópolis

2025

JOSÉ NILDO FERREIRA RAMOS JÚNIOR

VOXELMATCH: SISTEMA DE AVALIAÇÃO DE SIMILARIDADE DE IMAGENS
GERADAS POR ALGORITMOS DE *DEEP LEARNING*

Dissertação submetida ao Programa de Pós-Graduação em Proteção Radiológica do Departamento Acadêmico de Saúde e Serviços do Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina – *Campus* Florianópolis, como requisito para obtenção do título de Mestre em Proteção Radiológica.

Orientadora: Profa. Dra. Andrea Huhn

Linha de pesquisa: Desenvolvimento de Tecnologias

Florianópolis

2025

CDD 616.0757

R175v

Ramos Júnior, José Nildo Ferreira

VoxelMatch: sistema de avaliação de similaridade de imagens geradas por algoritmos de Deep Learning [DIS] / José Nildo Ferreira Ramos Júnior; orientação de Andrea Huhn – Florianópolis, 2025.

1 v.: il.

Dissertação de Mestrado (Proteção Radiológica) – Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina.

Inclui referências.

1. Radioterapia. 2. VoxelMatch. 3. Autossegmentação. 4. Deep Learning. 5. Inteligência artificial. I. Huhn, Andrea. II. Título.

Sistema de Bibliotecas Integradas do IFSC

Biblioteca Dr. Hercílio Luz – Campus Florianópolis

Catalogado por: Ana Paula F. Rodrigues - CRB 14/1117

VOXELMATCH: SISTEMA DE AVALIAÇÃO DE SIMILARIDADE DE IMAGENS
GERADAS POR ALGORITMOS DE *DEEP LEARNING*

JOSÉ NILDO FERREIRA RAMOS JÚNIOR

Este trabalho foi julgado adequado para obtenção do título de Mestre e aprovado na
sua forma final pela comissão avaliadora abaixo indicada.

Florianópolis, 31 de outubro de 2025

Dra. Andréa Huhn
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina

Dra. Gerusa Ribeiro
Instituto Federal de Educação, Ciência e Tecnologia de Santa Catarina

Dr. Morise de Gusmao Malheiros
Universidade FACENE

Me. Pedro Argôlo Piedade
Docente externo

A Deus, à Nossa Senhora e a Jesus Cristo, dedico este trabalho, pois foi a fé que sempre iluminou meus caminhos e me deu força para superar os desafios que surgiram ao longo dessa jornada.

Ao meu querido avô, que, mesmo não estando mais entre nós, deixou um legado de perseverança e amor pelo conhecimento, incentivando-me a estudar e a buscar meus sonhos, mesmo diante de toda e qualquer dificuldade.

Sua sabedoria e exemplo continuam vivos em meu coração.

À minha amada avó, que está presente em minha vida, me apoiando e incentivando a cada dia, mostrando-me que a dedicação e o amor são os pilares para alcançar grandes conquistas.

Às minhas amadas tias, que sempre estiveram ao meu lado, oferecendo apoio incondicional e acreditando em meu potencial.

Aos meus filhos, Ariane Ramos e Nyckollas Gabriel, que são minha maior inspiração e razão de seguir em frente, representando a alegria e o sentido da minha vida.

À minha mãe, mulher forte e batalhadora, que me ensinou a enfrentar a vida com coragem e determinação

E a toda a minha família, que, de alguma forma, contribuiu para que eu chegasse até aqui, meu profundo agradecimento.

Esta conquista é fruto do amor, do apoio e da união de todos vocês.

Agradecimentos

À minha orientadora, Profa. Dra. Andrea Huhn, que, mesmo enfrentando desafios pessoais durante o período do meu Mestrado, sempre me guiou com dedicação, sabedoria e afeto, tornando essa jornada possível. Sua resiliência e apoio foram fundamentais para a conclusão deste trabalho.

À RT Medical System, em especial a Carlos Queiroz, por acreditar no meu potencial e me proporcionar o espaço, o tempo e os recursos necessários para a coleta de dados e a realização dos estudos que embasaram esta pesquisa. Sua confiança em meu trabalho foi um dos pilares para o sucesso desta etapa.

À equipe da Radioterapia São Sebastião, pelo apoio técnico e profissionalismo.

Ao Instituto Federal de Santa Catarina, instituição que se dedica à excelência no serviço público, e ao Mestrado Profissional em Proteção Radiológica, pelo suporte acadêmico e pela estrutura que possibilitou a realização deste projeto.

Aos professores do Mestrado, pela transmissão de conhecimentos, pela paciência e pelo carinho com que me acolheram ao longo dessa trajetória. Cada ensinamento e palavra de incentivo foram peças fundamentais para o meu crescimento acadêmico e profissional.

Por fim, a todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu sincero agradecimento. Esta conquista é fruto do esforço coletivo e do apoio de pessoas que acreditaram em mim e no meu potencial.

“Mesmo que o caminho seja árduo e as tempestades pareçam insuperáveis, nunca abandone a luta, pois é na persistência que se forja a vitória.”

Próprio autor

RESUMO

Com o objetivo de aprimorar a precisão e a eficiência no planejamento de radioterapia, este estudo concentrou-se no desenvolvimento de um sistema de avaliação de similaridade de imagens geradas por algoritmos de *deep learning* na avaliação de três sistemas de autosegmentação. O estudo foi direcionado especificamente para a região anatômica da próstata, devido à alta incidência de neoplasias, que demandam um planejamento de tratamento preciso e personalizado. Foram selecionados 15 imagens de tomografia computadorizada de pacientes com características semelhantes, a fim de garantir a eficiência do software e uma comparação consistente e confiável entre os sistemas. A escolha de pacientes com perfis semelhantes foi importante para minimizar variáveis que pudessem interferir nos resultados, permitindo uma análise mais precisa do desempenho dos sistemas de autosegmentação. Para realizar a análise, foi desenvolvido o VoxelMatch, que se trata de um Sistema de Avaliação de Similaridade de Imagens Binárias Geradas por Deep Learning, que utiliza métricas como o Coeficiente de Similaridade de Dice (DSC) e a Distância de Hausdorff (HD) para avaliar a precisão das segmentações automáticas em relação às manuais, realizadas por especialistas em oncologia radioterápica. Os resultados demonstraram que os sistemas de deep learning têm potencial para melhorar a eficiência e a consistência no planejamento de radioterapia, na região da próstata, reduzindo o tempo de segmentação e aumentando a precisão dos contornos. As métricas de avaliação escolhidas foram o Coeficiente de Similaridade de Dice e a Distância de Hausdorff, que permitiram quantificar a sobreposição e a discrepância espacial entre os contornos. Os resultados também demonstraram que os três softwares apresentaram valores médios de DSC entre 0,88 e 0,94 e valores de HD que variaram, de maneira consistente, em torno de 3 a 4,5 mm para os órgãos avaliados (próstata, reto, bexiga e cabeças femorais bilaterais). Tais resultados, sugerem que a autosegmentação baseada em deep learning pode reduzir significativamente o tempo de delineamento, diminuir a variabilidade interobservador e oferecer uma precisão comparável à segmentação manual. O estudo, portanto, reforça a relevância da integração de tecnologias baseadas em deep learning ao planejamento radioterápico, demonstrando que os algoritmos de autosegmentação podem atuar como ferramentas de apoio altamente eficazes para os profissionais da área. Além de otimizar o tempo de delineamento e reduzir a variabilidade interobservador, essas soluções contribuem para o aprimoramento da qualidade do tratamento, assegurando maior precisão anatômica, reprodutibilidade e segurança ao paciente. Assim, a incorporação de sistemas inteligentes de autosegmentação representa um avanço significativo rumo à radioterapia de alta precisão e à personalização terapêutica baseada em evidências científicas.

Palavras-chave: VoxelMatch, autosegmentação, radioterapia, deep learning, inteligência artificial, neoplasia de próstata, coeficiente de similaridade Dice, distância de hausdorff.

Lista de figuras

Figura 1 - Anatomia da pélve.	17
Figura 2 - Anatomia da próstata.	18
Figura 3 - Tumor cancerígeno.	19
Figura 4 - Fluxograma do diagnóstico da neoplasia de próstata	21
Figura 5 Interface do voxelMatch	31
Figura 6 - Fluxograma de entradas e saídas do processo de segmentação automática.	32
Figura 7 - Gráfico Comparação do DSC por Software e Órgão	34
Figura 8 - Gráfico Comparação do HD por Software e Órgão	35
Figura 9 - Layout da tela do RT Connect	36
Figura 10 - Layout da tela do AutoContour	36
Figura 11 - Layout da tela do Elements	37
Figura 12 - Layout da tela do Elements	37
Figura 13 - Órgãos segmentados	38

Lista de tabela

Tabela 1 - Comparação dos valores médios de DSC e HD para os órgãos avaliados	33
--	----

Anexos**ANEXO 1** - Registro de software

46

SUMÁRIO

1 INTRODUÇÃO	13
1.1 Objetivo geral	16
1.2 Objetivos específicos	16
2 REVISÃO DE LITERATURA	16
2.1 Anatomia e morfologia da próstata	16
2.2 NEOPLASIA DE PRÓSTATA	18
2.2.2 Diagnostico do câncer de próstata	19
2.2.3 Tratamento de neoplasia prostática	21
3 PLANEJAMENTO DO TRATAMENTO DE PRÓSTATA POR RADIOTERAPIA	22
3.1 Segmentação manual	24
3.2 Autossegmentação	25
4 METODOLOGIA	27
4.1 Tipo de estudo	27
4.2 Materiais e Métodos	27
4.2.1 Coeficiente de Similaridade de Dice (DSC):	28
4.2.2 Distância de Hausdorff (HD)	29
5 DESENVOLVIMENTO DO SOFTWARE VOXELMATCH	30
5.1 Aspectos éticos	32
6 RESULTADOS	33
7 ANÁLISE E DISCUSÃO DOS RESULTADOS	38
8 CONCLUSÃO	39
9 REGISTRO VOXELMATCH	40
ANEXOS	46
ANEXO A – Registro de software	46

1 INTRODUÇÃO

A neoplasia de próstata é o tipo de neoplasia mais frequente entre os homens e representa um importante problema de saúde pública mundial. Segundo estimativas do *World Cancer Research Fund* (2024), foram registrados cerca de 1,47 milhão de novos casos em 2022, o que corresponde a aproximadamente 7,3% de todos os diagnósticos oncológicos masculinos. Esse número poderá quase dobrar até 2040, ultrapassando 2,9 milhões de novos casos anuais, devido ao envelhecimento populacional e à ampliação das estratégias de rastreamento. Tais dados evidenciam a magnitude do câncer de próstata no cenário global e reforçam a necessidade de políticas de prevenção, diagnóstico precoce e ampliação do acesso a terapias avançadas, segundo a International Agency for Research on Cancer (IARC, 2024).

No Brasil, a situação segue a mesma tendência mundial. O Instituto Nacional de Câncer estima a ocorrência de 71.730 novos casos anuais para o triênio 2023-2025, com uma taxa ajustada de 55,5 casos por 100 mil homens, sendo a neoplasia mais incidente entre o público masculino, excluindo os carcinomas de pele não melanoma (INCA, 2023). Além disso, a taxa de mortalidade no país permanece em torno de 13,7 óbitos por 100 mil homens (RIBEIRO et al., 2024). Isso demonstra a importância das estratégias da radioterapia que é uma das modalidades terapêuticas mais utilizadas no tratamento de neoplasias, sendo empregada em mais de 50% dos casos oncológicos (WHO, 2023).

O principal objetivo da radioterapia consiste na utilização de radiação ionizante para destruição seletiva de células neoplásicas, preservando ao máximo os tecidos saudáveis circundantes, como reto, bexiga, uretra e cabeças femurais (Sharp et al., 2014). Isso exige um planejamento minucioso e personalizado, que começa com a definição precisa dos volumes-alvo e dos órgãos de risco (Santos et al., 2022). O volume-alvo refere-se ao conjunto de tecidos que deve receber a dose prescrita de radiação, abrangendo diferentes sub-volumes definidos em guias como os relatórios da International Commission on Radiation Units and Measurements (ICRU). Os órgãos de risco são estruturas de tecido normal próximas ao volume-alvo cuja tolerância à radiação é limitada. A correta delimitação e proteção desses órgãos são fundamentais para minimizar os efeitos adversos e preservar os tecidos saudáveis (ICRU, 2010).

O processo de planejamento inicia-se com a aquisição de imagens tomográficas e/ou de ressonância magnética do paciente, realizadas em posição de tratamento, a fim de obter dados anatômicos que servirão de base para o delineamento e o cálculo da dose (INCA, 2022). O médico radioterapeuta é responsável pelo delineamento dos volumes de interesse, incluindo o Volume Alvo Clínico (CTV) e o Volume Alvo Planejado (PTV), além da delimitação dos órgãos de risco. Esse processo de segmentação de imagens, ou seja, a identificação e separação digital das estruturas anatômicas nas imagens de tomografia ou ressonância magnética é uma etapa importante para o sucesso do tratamento, sendo que a dose tolerável de radiação para órgãos de risco é estabelecida por diretrizes internacionais, como as da ICRP (International Commission on Radiological Protection) e QUANTEC (Quantitative Analyses of Normal Tissue Effects in the Clinic), que fornecem limites específicos para cada estrutura (Marcos e Bailey, 2015).

Tradicionalmente, a segmentação era realizada manualmente, o que demandava tempo e estava sujeita a variações interobservadores. Com os avanços tecnológicos, surgiram métodos automatizados e semiautomatizados baseados em inteligência artificial (IA) e aprendizado profundo (deep learning) com treinamento de algoritmos. Esses algoritmos são treinados com grandes bancos de dados de imagens médicas, aprendendo padrões anatômicos capazes de distinguir tecidos normais e tumorais. A utilização da IA nesse contexto reduz o tempo de planejamento, aumenta a padronização dos contornos e melhora a reprodutibilidade entre diferentes profissionais (AMARAL; PEREIRA; SILVA, 2023).

Após o delineamento, inicia-se o processo de cálculo da dose de radiação, comumente realizado por um físico médico ou dosimetrista. Esse profissional utiliza parâmetros físicos e geométricos para determinar a quantidade e a distribuição da radiação a ser administrada. Embora o cálculo seja auxiliado por softwares de planejamento tridimensional, a dosimetria manual continua sendo utilizada como forma de verificação independente, assegurando que o plano automatizado esteja dentro dos limites aceitáveis de precisão.

Posteriormente, o físico médico realiza uma conferência do plano de tratamento, verificando se as doses prescritas estão adequadamente distribuídas e se os órgãos de risco estão protegidos conforme os limites estabelecidos pelas normas técnicas da Comissão Nacional de Energia Nuclear (CNEN, 2021) e pelas

diretrizes internacionais da Agência Internacional de Energia Atômica (IAEA, 2021). Nessa etapa, o processo de planejamento pode ser complementado por softwares de otimização baseados em inteligência artificial (IA), que utilizam algoritmos para ajustar automaticamente o plano de tratamento, equilibrando a dose entre o volume-alvo e os tecidos adjacentes. Esses sistemas integram dados clínicos e anatômicos para sugerir configurações personalizadas, aprimorando a precisão da distribuição de dose, a proteção dos órgãos de risco e a segurança do paciente (AMARAL; PEREIRA; SILVA, 2023).

A integração entre o planejamento manual, a conferência física e a inteligência artificial representa um avanço significativo na radioterapia moderna. Essa combinação garante maior precisão na entrega da dose, preservação dos órgãos de risco e melhoria dos resultados clínicos, consolidando a radioterapia como uma modalidade terapêutica segura e eficaz no manejo da neoplasia prostática. As tecnologias de automação e IA tornam o processo mais eficiente e padronizado, contribuindo para a qualidade e segurança dos tratamentos. Os sistemas de planejamento automatizados geram planos com cobertura e conformidade comparáveis ou superiores ao planejamento manual, enquanto reduzem significativamente o tempo de produção e padronizam a qualidade (SHI et al., 2023).

No entanto, mesmo que a tecnologia prometa revolucionar o planejamento de radioterapia é fundamental que a implementação de qualquer sistema seja acompanhada por uma avaliação clínica rigorosa, incluindo validação local, monitoramento contínuo da performance, governança robusta de integração e escolha de sistemas adequados a fim de assegurar a eficácia antes da adoção em larga escala na prática clínica (HU et al., 2023).

As tecnologias têm sido amplamente testadas em diferentes contextos clínicos, com foco especial em regiões anatômicas complexas, como a pelve masculina, onde a neoplasia de próstata é uma das condições mais comuns e desafiadoras (Kazemifar et al., 2020). A próstata e suas estruturas adjacentes, exigem uma segmentação precisa para garantir a eficácia do tratamento e minimizar os efeitos colaterais, como incontinência urinária e disfunção sexual (Men et al., 2017).

A avaliação da qualidade das segmentações automáticas é realizada por meio de métricas quantitativas, como o Coeficiente de Similaridade de Dice (DSC) e a Distância de Hausdorff (HD) (Taha e Hanbury, 2015). O DSC mede a sobreposição

entre as segmentações automáticas e manuais, variando de 0 (nenhuma sobreposição) a 1 (sobreposição completa), enquanto a HD avalia a distância máxima entre os contornos, fornecendo uma medida da discrepância espacial (Huttenlocher et al., 1993). Essas métricas são amplamente utilizadas na literatura para comparar o desempenho de diferentes sistemas de autosegmentação e validar sua aplicabilidade clínica (Vaassen et al., 2020).

No entanto, a generalização dos modelos para diferentes instituições e protocolos de imagem ainda é limitada, exigindo ajustes e validações específicas para cada contexto clínico (Isensee et al., 2021). Outro ponto é a integração dos sistemas aos fluxos de trabalho existentes, que muitas vezes envolvem softwares e equipamentos heterogêneos (Osman, 2019). Sendo assim, a autosegmentação baseada em deep learning representa um avanço significativo na radioterapia, com potencial para transformar o planejamento de tratamento e melhorar a qualidade de vida dos pacientes (SHARP et al., 2014).

Nesse sentido esse estudo se justifica, já que se propõe a realizar uma análise comparativa entre sistemas de autosegmentação baseados em deep learning para o tratamento de neoplasias de próstata e pelos desafios técnicos devido à proximidade da próstata com estruturas como reto, bexiga, uretra e cabeças femurais.

1.1 Objetivo geral

O objetivo geral deste estudo é desenvolver um sistema de avaliação de similaridade de imagens geradas por algoritmos de *deep learning*.

1.2 Objetivos específicos


Desenvolver um sistema de avaliação da similaridade entre imagens geradas por algoritmos de *deep learning*, aplicado à radioterapia de neoplasias prostáticas. Selecionando séries de imagens de pacientes com neoplasias de próstatas semelhantes, e comparar o desempenho de sistemas comerciais de autosegmentação baseados em deep learning para auto segmentação da próstata.

2 REVISÃO DE LITERATURA

2.1 Anatomia e morfologia da próstata

A próstata é uma glândula exócrina do sistema reprodutor masculino, localizada inferiormente à bexiga urinária e anteriormente ao reto. Em condições normais, apresenta forma de castanha ou pirâmide invertida, pesando entre 15 e 25 gramas em adultos jovens. Está atravessada pela uretra prostática, que constitui o segmento inicial da uretra masculina. Anatomicamente, a próstata é envolvida por uma cápsula fibromuscular densa, de onde partem septos que se estendem ao interior da glândula, dividindo-a em lóbulos ou zonas. (Moore, Dalley & Agur, 2018; Netter, 2023).

Figura SEQ Figura 1* ARABIC 1 - Anatomia da pélve.



Fonte: Adaptado de <https://medivizor.com/blog/wp-content/uploads/2019/07/prostate.jpg>.


A morfologia prostática é tradicionalmente descrita em cinco lobos: anterior, médio, posterior e dois laterais. No entanto, a classificação zonal proposta por McNeal (1981) é atualmente a mais aceita, dividindo a glândula em zona periférica (70%), zona central (25%), zona de transição (5%) e zona anterior fibromuscular. A zona periférica é a principal sede do adenocarcinoma prostático, enquanto a zona de transição é comumente afetada pela hiperplasia prostática benigna (HPB). (McNeal, 1981; Junqueira & Carneiro, 2013).

Do ponto de vista fisiológico, a próstata desempenha papel fundamental na fertilidade masculina. Suas glândulas secretam um fluido levemente alcalino, rico em ácido cítrico, fosfatase ácida prostática (PAP), antígeno prostático específico (PSA) e enzimas proteolíticas, responsáveis por liquefazer o sêmen após a ejaculação. O

fluido prostático contribui para a viabilidade e motilidade dos espermatozoides, neutralizando o ambiente ácido da uretra e da vagina. A secreção é regulada por estímulos androgênicos, sendo a testosterona convertida em dihidrotestosterona (DHT) pela enzima 5α -redutase, a qual atua diretamente nos receptores nucleares das células epiteliais, promovendo crescimento e atividade secretora. (Guyton & Hall, 2021).

O formato da próstata é alterado com o avanço da idade. Em homens mais velhos é comum a hipertrofia prostática benigna (HPB), onde a glândula aumentada pode atingir entre 30 g e 80 g e ocasionalmente de até 120 g (Figura 2) (OLDER; WATSON, 1996; TANAGHO, 1994). Ainda, com o avançar da idade, alterações hormonais e inflamatórias podem resultar em hiperplasia prostática benigna, caracterizada pelo aumento do volume glandular, principalmente na zona de transição, podendo comprimir a uretra prostática e causar sintomas urinários obstrutivos. Por outro lado, o adenocarcinoma prostático, a neoplasia maligna mais comum em homens, origina-se predominantemente na zona periférica, o que explica sua detecção por toque retal e exames de imagem. (Moore et al., 2018; Kumar, Abbas & Aster, 2021).

Figura SEQ Figura 1* ARABIC 2- Anatomia da próstata.



Fonte: https://static.medicoresponde.com.br/imagens/img/pr/os/prostata_c.jpg

2.2 NEOPLASIA DE PRÓSTATA


No Brasil a neoplasia de próstata é atualmente a neoplasia maligna mais incidente entre os homens, excluídos os casos de câncer de pele não melanoma. Segundo o Instituto Nacional de Câncer (INCA), para o triênio 2023–2025 são

estimados 71.730 novos casos anuais, correspondendo a um risco de 67,86 casos para cada 100 mil homens (INCA, 2023). Esses dados reforçam a magnitude do impacto da doença sobre a saúde pública masculina no país e a importância de estratégias de rastreamento e diagnóstico precoce.

A distribuição regional da incidência mostra variações importantes. As maiores taxas ocorrem nas regiões Sudeste (77,89/100 mil) e Nordeste (73,28/100 mil), seguidas pelas regiões Centro-Oeste (61,60/100 mil), Sul (57,23/100 mil) e Norte (28,40/100 mil) (INCA, 2023). Essas diferenças refletem não apenas fatores genéticos e ambientais, mas também desigualdades no acesso aos serviços de saúde e aos programas de prevenção e diagnóstico precoce.

O perfil epidemiológico mostra que o risco da doença aumenta consideravelmente com a idade, sendo mais prevalente em homens acima dos 60 anos. Outros fatores de risco incluem histórico familiar positivo, etnia negra e exposição a dietas ricas em gordura animal e pobre em vegetais (INCA, 2023; ONCOGUIA, 2024). Homens com antecedentes familiares de primeiro grau (pai ou irmão) diagnosticados antes dos 60 anos apresentam risco até duas vezes maior de desenvolver a doença (INCA, 2023)

Figura SEQ Figura 1* ARABIC 3 - Tumor cancerígeno.



Fonte: https://static.medicoresponde.com.br/imagens/img/pr/os/prostata_c.jpg Acesso em março de 2025

2.2.2 Diagnóstico da neoplasia de próstata

O diagnóstico da neoplasia de próstata envolve uma abordagem integrada, que combina avaliação clínica, exames laboratoriais, técnicas de imagem, biópsia e,

quando necessário, análise genética, para garantir a maior precisão diagnóstica e orientar o planejamento terapêutico. Ou seja, sendo a neoplasia de próstata uma das neoplasias malignas mais comuns entre homens, o diagnóstico precoce é fundamental para o sucesso do tratamento e melhora do prognóstico (MOTTET et al., 2023).

O exame físico, especialmente o exame digital retal (EDR), permite a detecção de nódulos endurecidos ou irregularidades na próstata, sendo considerado um componente essencial na investigação clínica (MOTTET et al., 2023).


Paralelamente, o antígeno prostático específico (PSA) é utilizado como marcador laboratorial para rastreamento e monitoramento da doença. Valores de PSA acima de 4 ng/mL são considerados sugestivos, mas é necessário interpretar os resultados considerando idade, volume prostático e a presença de condições benignas ou inflamatórias. Métodos como PSA livre versus total e densidade do PSA podem aumentar a acurácia diagnóstica (CATALONA et al., 1991).

A imagem desempenha papel relevante na detecção e localização de lesões suspeitas. A ultrassonografia transretal (TRUS) auxilia na avaliação do tamanho da próstata e na orientação da biópsia, enquanto a ressonância magnética multiparamétrica (mpMRI) é indicada em pacientes com PSA elevado e biópsia prévia negativa, proporcionando mapeamento mais preciso das áreas suspeitas (PANEBIANCO et al., 2020).

A biópsia prostática constitui o padrão-ouro para confirmação diagnóstica, sendo realizada por via transretal ou transperineal. Normalmente, são coletadas doze amostras sistemáticas, podendo ser guiadas por imagem, especialmente em casos de mpMRI. O material histopatológico é avaliado pelo escore de Gleason, essencial para a estratificação prognóstica e definição da conduta terapêutica (EPSTEIN et al., 2016).

Em situações selecionadas, testes genéticos e biomarcadores moleculares podem auxiliar no diagnóstico e na decisão de biópsia. Entre eles, destacam-se testes para mutações BRCA1/2 e HOXB13, bem como marcadores urinários como PCA3 e PHI, ainda em fase de utilização clínica complementar (TOMLINS et al., 2011).

Figura 4 - Fluxograma do diagnóstico da neoplasia de próstata



Fonte: Próprio autor.

2.2.3 Tratamento de neoplasia prostática

Os tratamentos para as neoplasias de próstata evoluíram significativamente nas últimas décadas, oferecendo um espectro de abordagens que vão desde a simples observação até terapias de alta tecnologia. A escolha do tratamento mais adequado depende de diversos fatores, incluindo o estágio da doença, a agressividade do tumor, a idade e o estado geral de saúde do paciente (VILLA-LOBOS et al., 2024).

Quando a neoplasia está restrita à próstata, as opções de tratamento são direcionadas para a cura. A vigilância ativa é uma estratégia cada vez mais utilizada para tumores de baixo risco, em que o paciente é monitorado de perto por meio de

exames periódicos, como PSA e biópsias, evitando o tratamento invasivo e seus efeitos colaterais (RIBEIRO, 2015).

A prostatectomia radical, que é a remoção cirúrgica da próstata, é uma das opções mais tradicionais e eficazes. Além da cirurgia robótica e a videolaparoscopia que são técnicas minimamente invasivas e que oferecem uma recuperação mais rápida com menos complicações (INSTITUTO ONCOGUIA, 2025).

A radioterapia permanece como uma das principais modalidades terapêuticas para o tratamento do câncer de próstata, apresentando elevada eficácia e consolidação clínica. Essa abordagem pode ser conduzida por meio da radioterapia externa, na qual feixes de alta energia são direcionados precisamente à região tumoral, promovendo a destruição das células neoplásicas. Entre as técnicas modernas, destaca-se a radioterapia de intensidade modulada (IMRT), que possibilita uma distribuição mais homogênea da dose, reduzindo a exposição de órgãos adjacentes e preservando tecidos sadios (GOMES, 2023).

Outra alternativa amplamente utilizada é a braquiterapia, que consiste na inserção de fontes radioativas — conhecidas como “sementes” — diretamente no interior da próstata, permitindo o controle local da doença com mínima invasão (GOMES, 2023).

Recentemente, a incorporação da inteligência artificial (IA) tem promovido uma transformação expressiva no diagnóstico e no planejamento radioterápico. Modelos multimodais de IA, capazes de integrar imagens de ressonância magnética e ultrassonografia, têm demonstrado desempenho superior na identificação de lesões clinicamente significativas quando comparados à interpretação manual de radiologistas. Esses avanços tecnológicos consolidam um novo paradigma no manejo do câncer prostático, oferecendo terapias mais precisas, personalizadas e menos agressivas, o que se traduz em melhor controle tumoral e maior preservação da qualidade de vida dos pacientes (Jahanandish et al., 2025).

3 PLANEJAMENTO DO TRATAMENTO DE PRÓSTATA POR RADIOTERAPIA

A integração de inteligência artificial no planejamento radioterápico tem permitido maior precisão na delimitação dos órgãos de risco, reduzindo a variabilidade interobservador e melhorando os resultados clínicos (Sharp et al., 2019).

A proteção dos órgãos de risco deve ser um dos pilares fundamentais na oncologia radioterápica, garantindo tratamentos eficazes sem comprometer a função dos tecidos saudáveis (Santos et al., 2022). Nesse sentido, os avanços tecnológicos permitiram a criação de métodos de segmentação e planejamento mais precisos. As técnicas modernas incluem tomografia computadorizada (TC) e ressonância magnética (RM), que são utilizadas para mapear com exatidão os órgãos-alvo antes de uma intervenção terapêutica (Van Herk, 2014).

O diagnóstico das neoplasias pélvicas envolve a combinação de diferentes técnicas de inteligência artificial com métodos tradicionais, visando melhorar a reprodutibilidade e confiabilidade dos resultados (Litjens et al., 2017). Um fator importante no diagnóstico e tratamento das neoplasias pélvicas é a individualização da terapia baseada em biomarcadores. A identificação de marcadores moleculares pode guiar tratamentos mais eficazes e personalizados (Smith et al., 2022).

Ainda, a implementação de protocolos padronizados na aquisição de imagens contribui para a redução de variabilidades interobservadores, garantindo maior confiabilidade nos achados radiológicos (Clark et al., 2019).

A integração de bancos de dados clínicos com inteligência artificial representa um avanço significativo, possibilitando a criação de modelos preditivos baseados em aprendizado profundo para identificar padrões sutis de progressão tumoral. Nesse contexto da radioterapia, a precisão na delimitação dos órgãos-alvo está diretamente relacionada à taxa de sucesso do tratamento. (Schmidt et al., 2021).

A incorporação da inteligência artificial na segmentação de órgãos-alvo é uma tendência crescente, contribuindo para uma maior precisão e eficiência na análise de imagem médica. Algoritmos treinados com bancos de dados extensos permitem o reconhecimento automático de padrões anatômicos e patológicos (Feng et al., 2020).

A adoção de novas tecnologias tem reduzido significativamente os erros no planejamento radioterápico. Isso é essencial para evitar danos colaterais a tecidos sadios e garantir a eficácia do tratamento (Kazemifar et al., 2020). Ou seja, a aplicação de técnicas de aprendizado de máquina melhora a segmentação automática dos órgãos-alvo, reduzindo erros Humanos e padronizando o delineamento das estruturas anatômicas (Isensee et al., 2021).

Os tratamentos para as neoplasias de próstata evoluíram significativamente nas últimas décadas, oferecendo um espectro de abordagens que vão desde a

simples observação até terapias de alta tecnologia. A escolha do tratamento mais adequado depende de diversos fatores, incluindo o estágio da doença, a agressividade do tumor, a idade e o estado geral de saúde do paciente (VILLA-LOBOS et al., 2024).

A radioterapia é uma opção muito bem consolidada. Pode ser realizada por meio de radiação externa, que utiliza feixes de alta energia para destruir as células cancerosas. Técnicas avançadas, como a radioterapia de intensidade modulada (IMRT), permitem atingir o tumor com maior precisão, preservando os tecidos saudáveis próximos (GOMES, 2023). A braquiterapia, por sua vez, consiste na implantação de "sementes" radioativas diretamente na próstata (GOMES, 2023).

Além disso, a utilização de inteligência artificial (IA) tem revolucionado o diagnóstico e planejamento terapêutico. Modelos multimodais de IA, que integram imagens de ressonância magnética e ultrassonografia, têm demonstrado superioridade na detecção de lesões significativas de câncer de próstata em comparação com a interpretação realizada por radiologistas. Esses avanços representam um progresso significativo no tratamento do câncer de próstata avançado, proporcionando opções terapêuticas mais eficazes e com menor impacto na qualidade de vida dos pacientes (Jahanandish et al., 2025).

3.1 Segmentação manual

A segmentação manual é o método tradicional utilizado no planejamento de radioterapia para delimitar os volumes-alvo e os órgãos de risco em imagens médicas, como tomografias computadorizadas (TC) e ressonâncias magnéticas (RM) (Vinod et al., 2016). A segmentação manual já foi considerada o padrão-ouro para a definição de volumes de tratamento, pois permite a adaptação precisa às características individuais de cada paciente (Segedin e Petric, 2016).

No entanto, a segmentação manual é um processo demorado e sujeito a variações intra e interobservador. O tempo necessário para segmentar manualmente as estruturas anatômicas pode variar de 30 minutos a várias horas, dependendo da complexidade do caso e da experiência do profissional (Vinod et al., 2016).

Além disso, a variabilidade entre diferentes especialistas na definição dos contornos pode levar a inconsistências no planejamento do tratamento, impactando

a eficácia terapêutica e aumentando o risco de efeitos colaterais (Schick et al., 2011). Por exemplo, em casos de neoplasias de próstata, a proximidade de estruturas, como reto, bexiga, uretra e cabeças femurais, exige uma segmentação extremamente precisa para evitar danos aos tecidos saudáveis (Men et al., 2017).

Essa variabilidade refere-se às diferenças nos contornos traçados pelo mesmo especialista em momentos diferentes, enquanto uma variabilidade interobservador ocorre quando diferentes especialistas delineiam as mesmas estruturas de maneiras distintas (Segedin e Petric, 2016). Essas variações podem ser influenciadas por fatores como a qualidade das imagens, a experiência do profissional e a complexidade anatômica da região a ser segmentada (Vinod et al., 2016). Em um estudo realizado por Schick et al. (2011), foi demonstrado que a concordância entre diferentes especialistas na segmentação de órgãos em risco pode variar significativamente, com coeficientes de similaridade de Dice (DSC) inferiores a 0,7 em alguns casos.

Apesar dessas limitações, a segmentação manual continua sendo amplamente utilizada na prática clínica, os sistemas de autossegmentação não estão disponíveis ou não são confiáveis (Cardenas et al., 2019). No entanto, a busca por métodos mais eficientes e consistentes levou ao desenvolvimento de técnicas semiautomáticas e, mais recentemente, totalmente automáticas, baseadas em inteligência artificial e deep learning (Ronneberger et al., 2015). Essas tecnologias prometem reduzir o tempo de segmentação, minimizar a variabilidade Humana e aumentar a precisão dos contornos, especialmente em regiões anatômicas complexas, como a próstata (Kazemifar et al., 2020).

Em resumo, a segmentação manual desempenha um papel importante no planejamento de radioterapia, mas suas limitações em termos de tempo e variabilidade destacam a necessidade de métodos alternativos, como a autossegmentação baseada em deep learning. A transição para técnicas automatizadas pode melhorar a eficiência e a consistência do processo, mas é essencial que essas tecnologias sejam rigorosamente validadas em comparação com o padrão-ouro manual antes de sua implementação clínica (Vaassen et al., 2020).

3.2 Autossegmentação

A autossegmentação pode ser dividida em duas categorias principais: baseada em atlas e baseada em modelos. A segmentação baseada em atlas utiliza imagens de referência (atlas) previamente segmentadas para mapear as estruturas anatômicas em novas imagens, utilizando técnicas de registro deformável (Rohlfing et al., 2015). Por outro lado, a autossegmentação baseada em modelos emprega modelos estatísticos de forma e aparência para identificar e contornar automaticamente os órgãos, adaptando-se às variações anatômicas (Cardenas et al., 2019). Ambos os métodos têm limitações, como a dependência da qualidade do atlas ou do modelo e a dificuldade em lidar com variações anatômicas significativas (Isensee et al., 2021).

Com o avanço da inteligência artificial, especialmente do deep learning, a autossegmentação evoluiu significativamente. Algoritmos como a U-Net, proposta por Ronneberger, Fischer e Brox (2015), revolucionaram a segmentação de imagens médicas, permitindo a extração automática de características e a geração de contornos precisos com base em grandes volumes de dados de treinamento (Hu et al., 2023). Esses modelos foram treinados com conjuntos de dados anonimizados, em imagens de TC ou RM com estruturas segmentadas manualmente por especialistas, permitindo que o algoritmo aprenda padrões e características específicas das estruturas anatômicas (Litjens et al., 2017).

A autossegmentação demonstrou várias vantagens em comparação com a segmentação manual. Em primeiro lugar, ela reduz significativamente o tempo de planejamento, permitindo que os profissionais de saúde se concentrem em outras tarefas críticas (Vaassen et al., 2020). Além disso, ela minimiza a variabilidade humana, garantindo maior consistência e reprodutibilidade nos contornos (Segedin e Petric, 2016). Em casos complexos, como neoplasias de próstata, a autossegmentação pode melhorar a precisão do delineamento de estruturas críticas, como a reto, bexiga, uretra e cabeças femurais, reduzindo o risco de efeitos colaterais (Kazemifar et al., 2020).

Apesar dos avanços, a autossegmentação ainda enfrenta desafios significativos. Um dos principais é a dependência de grandes volumes de dados de treinamento, que devem ser representativos da população-alvo (Litjens et al., 2017). Além disso, a generalização dos modelos para diferentes instituições e protocolos de

imagem ainda é limitada, exigindo ajustes e validações específicas, que necessitam avaliação, realizadas por métricas quantitativas, para cada contexto clínico (Isensee et al., 2021). Outro desafio é a integração desses sistemas aos fluxos de trabalho existentes, que muitas vezes envolvem softwares e equipamentos heterogêneos (Osman, 2019).

A qualidade das segmentações automáticas é avaliada por meio de métricas quantitativas, como o Coeficiente de Similaridade de Dice (DSC) e a Distância de Hausdorff (HD). O DSC mede a sobreposição entre as segmentações automáticas e manuais, variando de 0 (sem sobreposição) a 1 (sobreposição completa), enquanto a HD avalia a distância máxima entre os contornos, fornecendo uma medida da discrepância espacial (Taha e Hanbury, 2015). Essas métricas são amplamente utilizadas na literatura para comparar o desempenho de diferentes sistemas de autossegmentação e validar sua aplicabilidade clínica (Vaassen et al., 2020).

4 METODOLOGIA

4.1 Tipo de estudo

O estudo consiste em uma pesquisa quantitativa voltada ao desenvolvimento tecnológico de uma ferramenta que visa desenvolver um sistema de avaliação de similaridade de imagens geradas por algoritmos de deep learning para comparar estruturas segmentadas por inteligência artificial.

Cada imagem de TC foi submetida à autossegmentação utilizando três softwares distintos, os que foram utilizadas de forma intencional pois era o que a empresa dispunha para criação do modelo para comparação para, finalmente gerar a ferramenta de calculo, por meio do coeficiente dice e distância de hausdorff (VOXEL MATCH).

Os softwares utilizados foram : O Elements , versão 3,2,1,50 (BrainLab AG, Munich, Alemanha); O AutoContour versão 2,57 (Radformation, Nova Iorque, Estados Unidos) e o RT Connect versão 1.0.1 (RT Medical Systems, Florianópolis, Brasil)

O banco de imagens cedido pela empresa possui exames com planejamento de tratamento e isso inclui contorno manual, e contornos gerados automaticamente por softwares.O banco de dados da empresa é privado e composto por tres

softwares de autosegmentação e por isso foram selecionados, intencionalmente . As métricas utilizadas foram o Coeficiente de Similaridade de Dice (DSC) e Distância de Hausdorff (HD).

4.2 Materiais e Métodos

A amostra foi composta por um total de 15 séries tomográficas de pacientes com neoplasia de próstata com perfis clínicos e anatômicos semelhantes, visando reduzir a variabilidade externa e garantir uma comparação mais homogênea entre os métodos de segmentação. A escolha da parte anatômica se deu por ser a estrutura com maior número de imagens disposta no banco de imagens, bem como a escolha dos softwares, que são os disponíveis na empresa onde foi realizado o estudo. Ou seja, foram escolhidos por intencionalidade.

Cada uma das séries, já possuía estruturas segmentadas, as quais foram utilizadas como referência para comparação entre os três softwares. As estruturas foram as seguintes: próstata, reto, bexiga e cabeças femorais bilaterais.

Após a coleta de todas as séries de TC, estas foram importadas para os três softwares de segmentação, e para cada caso foi gerado um arquivo DICOM-RTSTRUCT contendo apenas os contornos da próstata, reto, bexiga e cabeças femorais bilaterais. Em seguida, procedeu-se à comparação entre essas estruturas automáticas e as segmentações de referência, que já haviam sido realizadas previamente por físicos ou dosimetristas clínicos. Não é possível afirmar qual profissional fez o desenho manual, pois o banco de imagens não possui essa informação. No entanto, essa questão não influencia o resultado do estudo.

Cada série de imagens de TC foi submetida à autosegmentação utilizando três softwares distintos: Elements , versão 3.2.1.50 (BrainLab AG, Munich, Alemanha); AutoContour, versão 2.57 (Radformation, Nova Iorque, Estados Unidos) e RT Connect versão 1.0.1 (RT Medical Systems, Florianópolis, Brasil).

Para cada caso, os contornos gerados automaticamente foram comparados com os contornos manuais. As métricas utilizadas foram:

4.2.1 Coeficiente de Similaridade de Dice (DSC):

Mede a sobreposição entre os volumes segmentados automaticamente e os manuais, variando de 0 (sem sobreposição) a 1 (sobreposição completa). DSC é um índice simples de sobreposição espacial e uma métrica de validação de reprodutibilidade, proposta pela primeira vez por Dice em 1945 (Dice, 1945). É a métrica mais frequentemente usada na literatura para quantificar a sobreposição espacial entre dois resultados de segmentação binária (Sharp, G. et al, 2016). Dado dois volumes de interesse, X e Y, o DSC é definido como:

$$(1) \quad DSC = \frac{2|X \cap Y|}{|X| + |Y|}$$

onde X e Y são os dois volumes em comparação, e $X \cap Y$ é a união dos dois volumes. Utilizando a definição de verdadeiro positivo (TP), falso positivo (FP) e falso negativo (FN), isso pode ser reescrito como:

$$(2) \quad DSC = \frac{2TP}{2TP + FP + FN}$$

4.2.2 Distância de Hausdorff (HD)

Quantifica a discrepância máxima entre as superfícies dos contornos, onde valores menores indicam maior concordância espacial, ela mede o quão distantes dois subconjuntos de um espaço métrico estão um do outro. Matematicamente, ela é definida como a máxima distância de um conjunto ao ponto mais próximo no outro conjunto. A HD entre dois conjuntos finitos de pontos X e Y é definida como:

$$(3)$$

onde $h(X, Y)$ é a distância direcionada de Hausdorff de X para Y, dada por:

(4)

Onde $\|x - y\|$ é a normal, comumente a distância euclidiana (Taha, et al. 2016).

A análise estatística incluiu o cálculo de médias e desvios-padrão para as métricas DSC e HD de cada órgão segmentado (próstata, reto, bexiga e cabeças femorais bilaterais).

5 DESENVOLVIMENTO DO SOFTWARE VOXELMATCH

O VoxelMatch, é uma ferramenta de avaliação de similaridade de imagens binárias geradas por algoritmos de deep learning. O software foi concebido como um produto tecnológico, servindo como base para a análise de desempenho dos sistemas de autossegmentação avaliados.

O sistema foi desenvolvido, com auxílio de um programador de sistemas, utilizando as linguagens C++, JavaScript, HTML, CSS e Node.js,. As principais funcionalidades incluem:

Importação e leitura de estruturas anatômicas segmentadas; Cálculo automatizado das métricas DSC e HD; Comparação entre segmentações automáticas e manuais;

Geração de relatórios em formato tabular e gráfico.

O VoxelMatch realiza a leitura de arquivos no formato DICOM RT Structure, processando estruturas segmentadas e calculando métricas de similaridade, como o Coeficiente de Dice (DSC) e a Distância Hausdorff (HD), amplamente utilizadas para validar métodos de segmentação (Taha & Hanbury, 2022; Fortin et al., 2023).

Os avanços em segmentação de imagens médicas com o uso de redes neurais convolucionais, como a U-Net, têm contribuído para a automação e padronização das avaliações radiológicas, reduzindo as incertezas no delineamento das lesões neoplásicas, otimizando a identificação de padrões suspeitos e melhorando a precisão diagnóstica. A automação dessas análises é essencial para padronizar avaliações de modelos de deep learning aplicados à radioterapia, reduzindo tempo e erros humanos.(Sharp et al., 2014; Isensee et al., 2021).

O VoxelMatch, foi desenvolvido como ferramenta de avaliação da similaridade entre contornos segmentados de softwares, foi treinado em três softwares utilizados na radioterapia: AutoContour, Elements e RT Connect, comparando-os a segmentação manual. Quando importados para VoxelMatch, foram calculadas automaticamente as métricas DSC e HD, que embasaram a análise quantitativa apresentada. O Coeficiente de Dice (DSC), utilizado para medir a sobreposição volumétrica entre as máscaras automática e manual das estruturas da próstata e a Distância de Hausdorff (HD), para identificar discrepâncias máximas entre as superfícies de contorno. Ou seja, o VoxelMatch, que automatiza a leitura e comparação dos arquivos DICOM RT Struct e realiza o cálculo do DICE e Hausdorff para cada estrutura.

Figura SEQ Figura 1* ARABIC 5 Interface do voxelMatch

Voxel Match

Arquivo 1

RTSTRUC_REF.dcm

×

Arquivo 2

RTSTRUCT_SF1.dcm

×

Arquivo 3

RTSTRUCT_SF2.dcm

×

Arquivo 4

RTSTRUCT_SF3.dcm

×

Comparação de Estruturas

DICOM RTSTRUCT

Calcular

Estruturas (Arquivo 1)	Estruturas (Arquivo 2)	Estruturas (Arquivo 3)	Estruturas (Arquivo 4)	Dice HD95 A1-A2	Dice HD95 A1-A3	Dice HD95 A1-A4
> ☐ Body	Body	Body	Body	0.949 2.3	0.901 4.7	0.825 9.0
> ☐ Prostate	Prostate	Prostate	Prostate	0.946 2.8	0.874 6.6	0.823 9.1
> ☐ Bladder	Bladder	Bladder	Bladder	0.946 2.5	0.864 6.8	0.912 9.8
> ☐ Femur_L	Femur_L	Femur_L	Femur_L	0.938 3.1	0.858 7.5	0.809 9.8
> ☐ Femur_R	Femur_R	Femur_R	Femur_R	0.926 3.8	0.857 6.8	0.909 3.2
> ☐ Rectum	Rectum	Rectum	Rectum	0.924 3.5	0.848 7.2	0.935 3.0
> ☐ Bone_Pelvic	-	-	-	-	-	-
> ☐ PenileBulb	-	-	-	-	-	-
> ☐ Paciente CB	-	-	-	-	-	-

Items per page: 09


1-09 of 100 items

1 of 1 pages

◀ ▶

Fonte: Próprio autor.

Figura SEQ Figura * ARABIC 6 - Fluxograma de entradas e saídas do processo de segmentação automática.



Fonte: Autoria própria.

5.1 Aspectos éticos

Em virtude de as imagens utilizadas pertencerem ao banco de dados de uma empresa privada e terem sido empregadas exclusivamente para fins de pesquisa e

desenvolvimento do presente estudo, não houve necessidade de submissão ao Comitê de Ética em Pesquisa. As imagens foram disponibilizadas pela empresa de forma autorizada, com garantia de total anonimização e sigilo dos dados, assegurando o respeito aos princípios éticos de confidencialidade e privacidade dos pacientes.

6 RESULTADOS

Os resultados obtidos pelo VoxelMatch demonstraram que os três softwares de autosegmentação apresentaram desempenho semelhante na segmentação dos órgãos de risco. A seguir, apresenta-se uma tabela comparativa com os valores médios de DSC e HD para cada órgão, obtidos a partir dos 15 casos analisados:


Tabela 1 - Comparação dos valores médios de DSC e HD para os órgãos avaliados

Órgão	Software	DSC (média $\pm$ DP)	HD (mm) (média $\pm$ DP)
Próstata	Elements	0,93 $\pm$ 0,02	3,1 $\pm$ 0,4
	AutoContour	0,92 $\pm$ 0,03	3,3 $\pm$ 0,5
	RT Connect	0,94 $\pm$ 0,02	3,2 $\pm$ 0,3
Reto	Elements	0,87 $\pm$ 0,03	4,2 $\pm$ 0,6
	AutoContour	0,88 $\pm$ 0,02	4,1 $\pm$ 0,5
	RT Connect	0,89 $\pm$ 0,03	4,0 $\pm$ 0,4
Bexiga	Elements	0,90 $\pm$ 0,02	3,9 $\pm$ 0,4
	AutoContour	0,91 $\pm$ 0,02	3,7 $\pm$ 0,5
	RT Connect	0,90 $\pm$ 0,03	3,8 $\pm$ 0,4
Cabeça femoral (Dir)	Elements	0,91 $\pm$ 0,02	3,6 $\pm$ 0,3
	AutoContour	0,90 $\pm$ 0,03	3,5 $\pm$ 0,4


	RT Connect	0,92 ± 0,02	3,4 ± 0,3
Cabeça femoral (Esq)	Elements	0,90 ± 0,03	3,8 ± 0,4
	AutoContour	0,89 ± 0,03	3,9 ± 0,5
	RT Connect	0,91 ± 0,02	3,7 ± 0,4

DP: Desvio padrão.

Figura SEQ Figura * ARABIC 7 - Gráfico Comparação do DSC por Software e Órgão



Fonte (Autoria própria, 2024)


Figura SEQ Figura 1* ARABIC 8 - Gráfico Comparação do HD por Software e Órgão

Fonte: (Autoria própria, 2024)


Observou-se que, de forma geral, os três softwares apresentaram valores de DSC elevados, indicando uma boa sobreposição entre os contornos automáticos e os manuais. Os valores de HD, que refletem a distância máxima entre os contornos, ficaram dentro de intervalos compatíveis com a precisão requerida na prática clínica, corroborando a eficácia dos métodos de autosegmentação testados.

Foram registradas pequenas variações nos resultados entre os softwares, que podem ser atribuídas a diferenças nos algoritmos de deep learning empregados e nos conjuntos de treinamento utilizados. Entretanto, essas diferenças foram mínimas e não comprometeram a aplicabilidade clínica dos sistemas avaliados.

Figura 9 - Layout da tela do RT Connect




Fonte: (Autoria própria, 2024)




Fonte: (Autoria própria, 2024)

Figura 11 - Layout da tela do Elements



Fonte: (Arquivo do autor, 2024)


Figura SEQ Figura 1* ARABIC 12 - Layout da tela do Elements



Fonte: (Arquivo do autor, 2024)

Abaixo um exemplo da saída dos órgãos segmentados manualmente do Elements

Figura 13 - Órgãos segmentados



Fonte: (Arquivo do autor, 2024)

7 ANÁLISE E DISCUSÃO DOS RESULTADOS

A análise dos resultados evidencia que os três sistemas de autosegmentação testados – Elements, AutoContour e RT Connect – apresentam desempenho bastante similar na segmentação de órgãos de risco em tratamentos de câncer de próstata. Os valores elevados de DSC (entre 0,87 e 0,94) demonstram que os contornos automáticos se sobrepõem significativamente aos contornos manuais, enquanto os baixos valores de HD reforçam a precisão dos algoritmos utilizados.

Esses achados estão em consonância com os resultados reportados na literatura, onde estudos apontam para a capacidade dos sistemas baseados em deep learning de reduzir o tempo de segmentação sem comprometer a qualidade dos contornos (D'aviero et al., 2022; Radici et al., 2022). A utilização de um banco de dados padronizado, conforme descrito por Thompson et al. (2023), permite a obtenção de resultados homogêneos e comparáveis, minimizando a influência de variáveis anatômicas e técnicas.

O estudo demonstrou ainda, por meio de análises quantitativas, que os softwares de autosegmentação Elements, AutoContour e RT Connect apresentam desempenho comparável na segmentação de órgãos de risco em pacientes submetidos à radioterapia para câncer de próstata. Os altos valores de DSC e os baixos valores de HD evidenciam a eficácia dos algoritmos de deep learning empregados, indicando que essas ferramentas podem reduzir significativamente o tempo de delineamento e a variabilidade interobservador.

Por fim, os resultados apontam para o potencial de implementação clínica desses sistemas, que, se combinados com avaliações qualitativas por especialistas, podem contribuir para um planejamento radioterápico mais rápido, preciso e seguro. Assim, a autosegmentação emerge como uma estratégia promissora para otimizar os processos de delineamento, permitindo a alocação mais eficiente de recursos.

8 CONCLUSÃO

O potencial dos algoritmos de deep learning surgiram para revolucionar o planejamento radioterápico, otimizando o fluxo de trabalho e permitindo que os profissionais se concentrem na personalização terapêutica, sempre garantindo que a automação complemente, e não substitua, a expertise dos profissionais.

Apesar dos resultados promissores, é importante destacar algumas limitações do estudo. Primeiramente, a amostra de imagens de 15 pacientes, embora suficiente para uma análise exploratória, é relativamente pequena para uma validação clínica abrangente. A homogeneidade dos casos também pode ter contribuído para a similaridade dos resultados entre os softwares, de modo que a inclusão de imagens de pacientes com variações anatômicas mais acentuadas poderia revelar diferenças mais marcantes. Além disso, a avaliação dos contornos automáticos foi realizada por meio de métricas quantitativas, o que, embora importante, não substitui a revisão clínica qualitativa realizada por especialistas.

Outro ponto a ser considerado é a necessidade de integração dos sistemas de autosegmentação com outros recursos de imagem, como a ressonância magnética, que pode oferecer informações adicionais sobre a morfologia dos tecidos e melhorar ainda mais a precisão dos contornos.

Futuras investigações devem ampliar a amostra, incorporar diferentes modalidades de imagem e explorar a integração de sistemas híbridos, visando

aperfeiçoar ainda mais a automação do contorno e validar a aplicabilidade dos algoritmos em contextos clínicos diversos. Também, ressalta-se que os dados apresentados servem para exemplificar o potencial e as limitações dos sistemas de autossegmentação na prática radioterápica.

Além disso, a tecnologia do VoxelMatch, pode ser utilizada para treino de estudantes, como residentes, e profissionais que desejem comparar seu contorno manual com o realizado pela IA, e assim aprimorar seus conhecimentos.

9 REGISTRO VOXELMATCH

O software VoxelMatch foi registrado junto ao Instituto Nacional da Propriedade Industrial (INPI), sob o Processo nº BR512025004354-6, publicado em 05/09/2025 e expedido em 16/09/2025. O registro foi concedido sob os titulares RT Medical Systems e Instituto Federal de Santa Catarina – IFSC, com o nome completo:

VoxelMatch – Sistema de Avaliação de Similaridade de Imagens Binárias Geradas por Deep Learning.(ANEXO A)

REFERÊNCIAS

- AMERICAN ASSOCIATION OF PHYSICISTS IN MEDICINE (AAPM). *Site Oficial*. Disponível em: <https://www.aapm.org>. Acesso em: 10 out. 2023.
- AMERICAN SOCIETY FOR RADIATION ONCOLOGY (ASTRO). *Site Oficial*. Disponível em: <https://www.astro.org>. Acesso em: 10 out. 2023.
- ARXIV. *Site Oficial*. Disponível em: <https://arxiv.org>. Acesso em: 10 out. 2023.
- AUTOSEG CHALLENGE DATASET. *Site Oficial*. Disponível em: <https://autoseg2021.grand-challenge.org>. Acesso em: 10 out. 2023.
- AYYALUSAMY, A. et al. Auto-segmentation of head and neck organs at risk in radiotherapy and its dependence on anatomic similarity. *Radiation Oncology Journal*, v. 37, p. 134-142, 2019.
- BRAINLAB. *Site Oficial*. Disponível em: <https://www.brainlab.com>. Acesso em: 10 out. 2023.
- BROUWER, C. L. et al. 3D variation in delineation of head and neck organs at risk. *Radiation Oncology*, v. 7, p. 32, 2012.
- BROUWER, C. L. et al. CT-based delineation of organs at risk in the head and neck region: DAHANCA, EORTC, GORTEC, HKNPCSG, NCIC CTG, NCRI, NRG Oncology and TROG consensus guidelines. *Radiotherapy and Oncology*, v. 117, p. 83-90, 2015.
- BROUWER, C. L. et al. Machine learning applications in radiation oncology: Current use and needs to support clinical implementation. *Physics and Imaging in Radiation Oncology*, v. 16, p. 144-148, 2020.
- CARDENAS, C. E.; YANG, J.; ABC, L. B. K. Advances in auto-segmentation. *Seminars in Radiation Oncology*, v. 29, n. 3, p. 185-197, 2019.
- COUGHLAN, S. et al. Qualitative evaluation of auto-segmented structures for radiotherapy planning using peer review guidelines. *Limbus-BIR-2022*. [dados internos]. Acesso em: 17 fev. 2025.
- D'AVIERO, A. et al. Clinical validation of a deep-learning segmentation software in head and neck: An early analysis in a developing radiation oncology center. *International Journal of Environmental Research and Public Health*, 2022. Disponível em: <https://doi.org/10.3390/ijerph19159057>. Acesso em: 17 fev. 2025.
- DEEPMIND HEALTH. *Site Oficial*. Disponível em: <https://deepmind.com/health>. Acesso em: 10 out. 2023.
- EUROPEAN SOCIETY FOR RADIOTHERAPY AND ONCOLOGY (ESTRO). *Site Oficial*. Disponível em: <https://www.estro.org>. Acesso em: 10 out. 2023.
- FENG, M. et al. Deep learning for automatic segmentation of organs at risk in radiotherapy: A review. *Frontiers in Oncology*, v. 10, p. 573, 2020.
- FLETCHER, R. H.; FLETCHER, S. W.; WAGNER, E. H. *Epidemiologia Clínica: Elementos Essenciais*. 3. ed. Porto Alegre: Artmed, 2003.
- GEETS, X. et al. Inter-observer variability in the delineation of pharyngo-laryngeal tumor, parotid glands and cervical spinal cord: Comparison between CT-scan and MRI. *Radiotherapy and Oncology*, v. 77, p. 25-31, 2005.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge: MIT Press, 2016.
- GOOGLE AI BLOG. *Site Oficial*. Disponível em: <https://ai.googleblog.com>. Acesso em: 10 out. 2023.
- HADDAD, N. *Metodologia de Estudos em Ciências da Saúde*. 1. ed. São Paulo: Roca, 2004.

- HU, Y. et al. Clinical assessment of a novel machine learning automated contouring tool for radiotherapy planning. *Journal of Applied Clinical Medical Physics*, v. 24, n. 7, p. e13949, 2023.
- HUTTENLOCHER, D. P.; KLANDERMAN, G. A.; RUCKLIDGE, W. J. Comparing images using the Hausdorff distance. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 15, n. 9, p. 850-863, 1993.
- IEEE XPLORE DIGITAL LIBRARY. *Site Oficial*. Disponível em: <https://ieeexplore.ieee.org>. Acesso em: 10 out. 2023.
- INTERNATIONAL ATOMIC ENERGY AGENCY (IAEA). *Site Oficial*. Disponível em: <https://www.iaea.org>. Acesso em: 10 out. 2023.
- INTERNATIONAL COMMISSION ON RADIOLOGICAL PROTECTION (ICRP). *Site Oficial*. Disponível em: <https://www.icrp.org>. Acesso em: 10 out. 2023.
- ISENSE, F. et al. nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation. *Nature Methods*, v. 18, n. 2, p. 203-211, 2021.
- KAZEMIFAR, S. et al. Segmentation of the prostate and organs at risk in male pelvic CT images using deep learning. *Biomedical Physics & Engineering Express*, v. 6, n. 1, p. 015003, 2020.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, v. 521, n. 7553, p. 436-444, 2015.
- LITJENS, G. et al. A survey on deep learning in medical image analysis. *Medical Image Analysis*, v. 42, p. 60-88, 2017.
- LUSTBERG, T. et al. Clinical evaluation of atlas-based auto-segmentation for delineation of organs at risk in head and neck cancer. *Radiotherapy and Oncology*, v. 127, n. 2, p. 217-223, 2018.
- MEN, K. et al. Deep learning for fully automated atlas-based contouring of organs at risk in head and neck cancer. *Radiotherapy and Oncology*, v. 123, n. 2, p. 293-298, 2017.
- MIR, R. et al. Organ at risk delineation for radiation therapy clinical trials: Global Harmonization Group consensus guidelines. *Radiotherapy and Oncology*, v. 150, p. 30-39, set. 2020. DOI: 10.1016/j.radonc.2020.05.038.
- NATIONAL CANCER INSTITUTE (NCI). *Site Oficial*. Disponível em: <https://www.cancer.gov>. Acesso em: 10 out. 2023.
- NVIDIA HEALTHCARE. *Site Oficial*. Disponível em: <https://www.nvidia.com/en-us/healthcare>. Acesso em: 10 out. 2023.
- OSMAN, A. Radiation oncology in the era of big data and machine learning for precision medicine. *Journal of Radiation Oncology*, v. 8, n. 2, p. 123-134, 2019.
- PIRAS, A. et al. Hypofractionated radiotherapy in head and neck cancer elderly patients: A feasibility and safety systematic review for the clinician. *Frontiers in Oncology*, v. 11, p. 761393, 2021.
- PITA FERNÁNDEZ, S.; PÉRTEGAS DÍAZ, S. Investigación cuantitativa y cualitativa. *Cad Aten Primaria*, v. 9, p. 76-78, 2002.
- PUBMED CENTRAL. *Site Oficial*. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc>. Acesso em: 10 out. 2023.
- QUEIROZ, C. et al. Comparação entre softwares de autosegmentação para órgãos de risco em tratamentos de próstata. In: *CONGRESSO DA ALATRO (ASSOCIAÇÃO LATINO-AMERICANA DE TERAPIA RADIANTE ONCOLÓGICA)*, 9., 2024, Rio de Janeiro. *Anais*. Rio de Janeiro: ALATRO, 2024.
- QUEIROZ, C. et al. Desenvolvimento de software cross-platform para análise de estruturas geradas por autosegmentação utilizando electron. In: *CONGRESSO DA*

- ALATRO (ASSOCIAÇÃO LATINO-AMERICANA DE TERAPIA RADIANTE ONCOLÓGICA), 9., 2024, Rio de Janeiro. *Anais*. Rio de Janeiro: ALATRO, 2024.
- RADFORMATION. *Site Oficial*. Disponível em: <https://www.radformation.com>. Acesso em: 10 out. 2023.
- RADICI, L. et al. Implementation of a commercial deep learning-based auto segmentation software in radiotherapy: Evaluation of effectiveness and impact on workflow. *Life*, v. 12, p. 2088, 2022. Disponível em: <https://doi.org/10.3390/life12122088>. Acesso em: 17 fev. 2025.
- RAMOS JÚNIOR, J. N. F. Avaliação clínica da autosegmentação baseada em deep learning para radioterapia em pacientes com neoplasia. 2023.
- RAMOS JÚNIOR, J. N. F.; QUEIROZ, C.; PIEDADE, P. A.; HUHN, A. Efficacy of commercial auto-segmentation software for anatomical contouring in prostate radiotherapy: A multi-patient study. In: *CONGRESSO DA SOCIEDADE BRASILEIRA DE RADIOTERAPIA*, 25., 2023, Rio de Janeiro. *Anais*. Rio de Janeiro: Sociedade Brasileira de Radioterapia, 2023.
- RAMOS JÚNIOR, J. N. F.; QUEIROZ, C.; PIEDADE, P. A.; HUHN, A. Software development for Dice coefficient and Hausdorff distance calculation to evaluate auto-segmented structures. In: *CONGRESSO DA SOCIEDADE BRASILEIRA DE RADIOTERAPIA*, 25., 2023, Rio de Janeiro. *Anais*. Rio de Janeiro: Sociedade Brasileira de Radioterapia, 2023.
- RATTAN, R. et al. Artificial intelligence in oncology, its scope and future prospects with specific reference to radiation oncology. *BJR|Open*, v. 1, n. 1, p. 20180031, 2019.
- RADIATION THERAPY ONCOLOGY GROUP (RTOG). *Site Oficial*. Disponível em: <https://www.rtog.org>. Acesso em: 10 out. 2023.
- ROHLFING, T. et al. *Handbook of Biomedical Image Analysis*. Boston, MA: Springer, 2005.
- RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional networks for biomedical image segmentation. *Medical Image Analysis*, v. 39, p. 234-241, 2015.
- RT MEDICAL SYSTEMS. *Site Oficial*. Disponível em: <https://www.rtmedicalsistemas.com>. Acesso em: 10 out. 2023.
- SCHICK, K. et al. An assessment of OAR delineation by the radiation therapist. *Radiotherapy and Oncology*, v. 17, n. 3, p. 183-187, 2011.
- SCIENCEDIRECT. *Site Oficial*. Disponível em: <https://www.sciencedirect.com>. Acesso em: 10 out. 2023.
- SEGEDIN, B.; PETRIC, P. Uncertainties in target volume delineation in radiotherapy – are they relevant and what can we do about them? *Radiology and Oncology*, v. 50, n. 3, p. 254-262, 2016.
- SHARP, G. et al. Vision 20/20: Perspectives on automated image segmentation for radiotherapy. *Medical Physics*, v. 41, n. 5, p. 050902, 2014.
- SPRINGERLINK. *Site Oficial*. Disponível em: <https://link.springer.com>. Acesso em: 10 out. 2023.
- STRUCTSEG DATASET. *Site Oficial*. Disponível em: <https://structseg2019.grand-challenge.org>. Acesso em: 10 out. 2023.
- TAHA, A. A.; HANBURY, A. Metrics for evaluating 3D medical image segmentation: Analysis, selection, and tool. *BMC Medical Imaging*, v. 15, p. 29, 2015.
- THE CANCER IMAGING ARCHIVE (TCIA). *Site Oficial*. Disponível em: <https://www.cancerimagingarchive.net>. Acesso em: 10 out. 2023.
- THOMPSON, R. F. et al. Stress-testing pelvic autosegmentation algorithms using anatomical edge cases (prostate anatomical edge cases) (Version 1) [Data set]. *The*

Cancer Imaging Archive, 2023. Disponível em: <https://doi.org/10.7937/QSTF-ST65>. Acesso em: 17 fev. 2025.

VAASSEN, F. et al. Evaluation of measures for assessing time-saving of automatic organ-at-risk segmentation in radiotherapy. *Physics and Imaging in Radiation Oncology*, v. 13, p. 1-6, 2020.

VINOD, S. K. et al. Uncertainties in volume delineation in radiation oncology: A systematic review and recommendations for future studies. *Radiotherapy and Oncology*, v. 121, n. 2, p. 169-179, 2016.

WANG, C. et al. A review of deep learning in medical imaging: Applications, challenges, and future directions. *Journal of Digital Imaging*, v. 34, n. 1, p. 1-15, 2021.

WORLD HEALTH ORGANIZATION (WHO). *Site Oficial*. Disponível em: <https://www.who.int>. Acesso em: 10 out. 2023.

YORKE, A. A.; McDONALD, G. C.; SOLIS, D.; GUERRERO, T. Pelvic reference data (Version 1) [Data set]. *The Cancer Imaging Archive*, 2019. Disponível em: <https://doi.org/10.7937/TCIA.2019.WOSKQ500>.

ANEXOS

ANEXO A – Registro de software



REPÚBLICA FEDERATIVA DO BRASIL
MINISTÉRIO DO DESENVOLVIMENTO, INDÚSTRIA, COMÉRCIO E SERVIÇOS
INSTITUTO NACIONAL DA PROPRIEDADE INDUSTRIAL
DIRETORIA DE PATENTES, PROGRAMAS DE COMPUTADOR E TOPOGRAFIAS DE CIRCUITOS

Certificado de Registro de Programa de Computador

Processo Nº: **BR512025004354-6**

O Instituto Nacional da Propriedade Industrial expede o presente certificado de registro de programa de computador, válido por 50 anos a partir de 1º de janeiro subsequente à data de 05/09/2025, em conformidade com o §2º, art. 2º da Lei 9.609, de 19 de Fevereiro de 1998.

Título: VoxelMatch - Sistema de Avaliação de Similaridade de Imagens Binárias Geradas por Deep Learning

Data de publicação: 05/09/2025

Data de criação: 10/02/2024

Titular(es): RT MEDICAL SYSTEMS; INSTITUTO FEDERAL DE SANTA CATARINA - IFSC

Autor(es): CARLOS EDUARDO BORGES DE QUEIROZ; PEDRO ARGOLO PIEDADE; JOSÉ NILDO FERREIRA RAMOS JÚNIOR; ANDRÉA HUHN

Linguagem: C++; HTML; JAVA SCRIPT; CSS; NODEJS

Campo de aplicação: IF-04; SD-06

Tipo de programa: GI-04; IA-01; SO-01; SO-02

Algoritmo hash: SHA-512

Resumo digital hash:
18cf567552d3911c9b9a025881c0c0574a79ed6a3981aa7106a3ee540808eff4079e2e13bc72307f9a03e96e06a50bbf4ad
07985d7894a4248e86a7a23a7959e

Expedido em: 16/09/2025



de Novembro
REPÚBLICA FEDERATIVA DO BRASIL
de 1889

Aprovado por:

Alexandre Gomes Ciancio
Coordenador Geral da COGTI