

Guia dos Algoritmos de Mascaramento

Como cada algoritmo transforma o dado, com que parâmetros, e o que esperar na saída.

31

ALGORITMOS

9

CATEGORIAS

62

INSTÂNCIAS BUILT-IN

Índice

Os algoritmos estão agrupados pelas mesmas categorias usadas na barra lateral do Algorithm Tester. Todos os pares entrada → saída deste guia foram gerados executando o algoritmo de verdade — não são ilustrativos.

PARTE 1 · DADOS PESSOAIS

1.1	Email	email.Email
1.2	Phone	phone.Phone
1.3	Name	name.Name
1.4	Full Name	name.FullName
1.5	Financial ID BR (CPF/CNPJ)	financialId.FinancialIdBr

PARTE 2 · DATAS

2.1	Date Shift	dateAlgorithms.DateShift
2.2	Date Shift Discrete	dateAlgorithms.DateShiftDiscrete
2.3	Date Replacement	dateAlgorithms.DateReplacement
2.4	Min/Max Date/Time	minMax.MinMaxLocalDateTime

PARTE 3 · NUMÉRICO

3.1	Numeric Mapping	characterMapping.NumericMapping
3.2	Min/Max BigDecimal	minMax.MinMaxBigDecimal
3.3	Numeric Expression	expression.NumericExpression
3.4	Repeat First Digit	repeatFirstDigit.RepeatFirstDigit

PARTE 4 · STRING

4.1	Character Mapping	characterMapping.CharacterMapping
4.2	Character Replacement	characterReplacement.CharacterReplacement
4.3	Segment Mapping	segmentMapping.SegmentMapping
4.4	Regex Decompose	decompose.RegexDecompose
4.5	String Algorithm Chain	stringAlgorithmChain.StringAlgorithmChain
4.6	Shuffle	shuffle.Shuffle

PARTE 5 · TEXTO ABERTO

5.1	Free Text Redaction	freeTextRedaction.FreeTextRedaction
5.2	Redact	redact.Redact

PARTE 6 · FINANCEIRO

6.1	Payment Card	characterMapping.PaymentCard
6.2	IBAN	iban.IBAN

PARTE 7 · LOOKUP & MAPEAMENTO

7.1	Secure Lookup	secureLookup.SecureLookup
7.2	Null-Safe Secure Lookup	nullSecureLookup.NullSecureLookup
7.3	Data Cleansing	dataCleansing.DataCleansing
7.4	Mapping	mapping.Mapping

PARTE 8 · MULTI-COLUMN

8.1	Multi-Column Condition	conditional.MultiColumnCondition
8.2	Multi-Column Address	address.MultiColumnAddress

PARTE 9 · OUTROS

9.1	Check Digit	checkdigit.Checkdigit
9.2	Tokenization	tokenization.Tokenization

APÊNDICES

A	Conceitos transversais: determinismo, chave, referências
B	Catálogo de instâncias built-in (dlpx-core:)
C	Limitações do runner standalone

Dados Pessoais

Algoritmos que reconhecem a semântica do campo — e-mail, telefone, nome, CPF/CNPJ — e geram substitutos sintéticos que continuam parecendo (e validando como) dados reais.

1.1 Email

algorithm.plugin.email.Email

DETERMINÍSTICO

Mascara um endereço de e-mail tratando as duas metades separadamente: a parte antes do @ (o nome) e o domínio depois dele. Cada metade tem sua própria estratégia, o que permite, por exemplo, anonimizar completamente o usuário mas preservar o domínio para manter a distribuição por empresa nos relatórios.

FORMATO DE ENTRADA

Endereço de e-mail válido, com @ e domínio. Ex.: joao.silva@empresa.com.br . Entradas fora do formato caem no `errorHandlingAction` .

ENTRADA → SAÍDA

ENTRADA		SAÍDA
joao.silva@empresa.com.br	→	TZW6C7VX6U4E0AWDXVGCD3XIZFNA7QGP2C4AFMSE3ANRQXHTVLGA@example.com
joao.silva@empresa.com.br	→	TZW6C7VX6U4E0AWDXVGCD3XIZFNA7QGP2C4AFMSE3ANRQXHTVLGA@empresa.com.br

Primeira linha com `domainAction: REPLACEMENT` ; segunda com `domainAction: PRESERVE` . Note que o nome gerado é idêntico nos dois casos — ele depende só do input e da chave.

PARÂMETROS

nameAction *	Como mascarar a parte do nome. UNIQUE — gera um identificador longo e único por input (garante que dois e-mails diferentes nunca colidam). LOOKUP — sorteia um nome de um arquivo de lookup. APPLY_ALGORITHM — passa o nome por outro algoritmo. APPLY_FIRSTNAME_AND_LASTNAME_ALGORITHMS — divide o nome e aplica algoritmos de primeiro nome e sobrenome separadamente, gerando algo como ana.silva@... .
domainAction *	Como tratar o domínio. REPLACEMENT — troca por <code>domainReplacementString</code> . APPLY_ALGORITHM — passa o domínio por outro algoritmo. PRESERVE — mantém o domínio original intacto.
domainReplacementString	O domínio substituto, usado apenas quando <code>domainAction = REPLACEMENT</code> . Ex.: example.com .
errorHandlingAction	O que fazer quando a entrada não é um e-mail válido. EXCEPTION — interrompe com erro. CHARACTER_MAPPING — aplica um mascaramento genérico caractere a caractere. PRESERVE — devolve o valor original sem alterar.

Quando usar qual. Se o objetivo é apenas impedir o envio acidental de e-mails, `domainAction: REPLACEMENT` para um domínio que você controla é o mais seguro. Se analistas precisam continuar segmentando por empresa, use `PRESERVE` — mas lembre que o domínio pode ser identificador em bases pequenas.

1.2 Phone

algorithm.plugin.phone.Phone **DETERMINÍSTICO**

Gera um número de telefone sintético preservando exatamente o formato do original: parênteses, espaços, hífen e a quantidade de dígitos permanecem no lugar. Apenas os dígitos mudam — e nem todos: o algoritmo tende a preservar prefixos que identificam o formato (DDD, o 9 inicial de celular).

FORMATO DE ENTRADA

Telefone em qualquer formatação. A pontuação é mantida posicionalmente na saída. Ex.: (11) 99999–8888 , 11987654321 .

ENTRADA → SAÍDA

ENTRADA		SAÍDA
(11) 99999–8888	→	(11) 99468–0822
11987654321	→	11984152108

PARÂMETROS

isPhoneUnique * Quando verdadeiro, o algoritmo garante que dois telefones de origem diferentes nunca produzam o mesmo número mascarado. Isso é importante quando o telefone é usado como chave de deduplicação ou junção. Quando falso, colisões são possíveis, mas os números gerados ficam mais "naturais".

1.3 Name

algorithm.plugin.name.Name

DETERMINÍSTICO

REQUER ARQUIVO

Substitui um nome simples — só o primeiro nome, ou só o sobrenome — por outro sorteado de um arquivo de lookup. O sorteio é um hash de (valor + chave), então o mesmo nome sempre vira o mesmo substituto: "João" será sempre "Ana" em todas as tabelas do projeto, o que preserva junções por nome. Para nomes compostos, use o **Full Name** (§1.4).

FORMATO DE ENTRADA

Uma única palavra, sem separadores. Ex.: João , Silva , Maria .

ENTRADA → SAÍDA

ENTRADA

SAÍDA

João

→

Ana

MARIA

→

LUCAS

Com `maskedValueCase: PRESERVE_INPUT` — a entrada em caixa alta produziu saída em caixa alta, mesmo o arquivo contendo "Lucas".

PARÂMETROS

lookupFile *

Arquivo de texto com um nome por linha. É a fonte dos substitutos. Quanto mais linhas, menor a chance de dois nomes diferentes receberem o mesmo substituto. Pode conter qualquer lista — primeiros nomes, sobrenomes, nomes masculinos ou femininos separadamente.

maskedValueCase

Capitalização do resultado. **PRESERVE_LOOKUP_FILE** — exatamente como está no arquivo. **PRESERVE_INPUT** — copia o padrão de caixa do input. **ALL_LOWER** / **ALL_UPPER** — força minúsculas ou maiúsculas.

particlesToRemoveFile

Arquivo com partículas (uma por linha) removidas do input *antes* de calcular o hash. Serve para que "da Silva" e "Silva" produzam o mesmo substituto, em vez de tratá-los como nomes distintos.

particlesToPreserveFile

Arquivo com partículas que devem reaparecer no resultado. O substituto gerado recebe de volta as partículas que o input original tinha.

maxLengthOfMaskedName

Comprimento máximo em caracteres. Nomes do arquivo que excedem o limite são descartados no sorteio. Use quando a coluna de destino tem restrição de tamanho e você não quer truncamento.

maxNumberNames

Máximo de nomes retornados em modo multi-valor. Para uma coluna simples, deixe vazio.

filterAccent

Quando verdadeiro, remove acentos antes de calcular o hash — fazendo "José" e "Jose" produzirem o mesmo substituto. Recomendado em bases brasileiras onde a acentuação é inconsistente.

inputCaseSensitive

Quando verdadeiro, "João" e "JOÃO" são inputs distintos e podem receber substitutos diferentes. O padrão (falso) ignora a caixa ao comparar.

1.4 Full Name

algorithm.plugin.name.FullName

DETERMINÍSTICO

Quebra um nome completo em primeiro(s) nome(s) e sobrenome, e aplica um algoritmo diferente em cada parte. É um orquestrador: ele não mascara nada sozinho, apenas decide onde termina o nome e começa o sobrenome, e delega cada pedaço ao algoritmo que você indicar.

FORMATO DE ENTRADA

Nome completo separado por espaços. Ex.: João da Silva , Maria Oliveira Santos .

ENTRADA → SAÍDA

ENTRADA

João da Silva Santos

SAÍDA

→ Vyvind zouhair Vesna

PARÂMETROS

lastNameAtTheEnd	Onde está o sobrenome. true — é a última palavra (padrão brasileiro: "João da Silva" → sobrenome "Silva"). false — é a primeira (padrão de bases que gravam "Silva, João").
ifSingleWordConsiderAsLastName	Desempate para input de uma palavra só. true — trata como sobrenome. false — trata como primeiro nome. Define qual dos dois algoritmos será chamado.
firstNameAlgorithmRef	Algoritmo aplicado ao(s) primeiro(s) nome(s). Ex.: <code>dlpx-core:FirstName</code> . Se omitido, os primeiros nomes ficam <i>sem mascaramento</i> .
lastNameAlgorithmRef	Algoritmo aplicado ao sobrenome. Ex.: <code>dlpx-core:LastName</code> . Se omitido, o sobrenome fica sem mascaramento.
lastNameSeparators	Separadores adicionais além do espaço. Ex.: <code>["-"]</code> faz "Maria-Silva" ser lido como nome "Maria" + sobrenome "Silva".
maxLengthOfMaskedName	Limite de caracteres do nome completo mascarado, para respeitar a largura da coluna de destino.
maxNumberFirstNames	Quantos primeiros nomes mascarar. Com valor <code>1</code> , "João Pedro Carlos Silva" tem só "João" mascarado — "Pedro Carlos" passa intacto.

Atenção aos padrões. Os dois `...AlgorithmRef` são opcionais, e quando ficam vazios a parte correspondente **não é mascarada**. É fácil configurar só o sobrenome e deixar os primeiros nomes vazando em produção — confira sempre os dois.

1.5 Financial ID BR (CPF/CNPJ)

algorithm.plugin.financialId.FinancialIdBr

DETERMINÍSTICO

Mascara CPF e CNPJ gerando números sintéticos que continuam **matematicamente válidos** — os dígitos verificadores são recalculados. O tipo é detectado automaticamente pela quantidade de dígitos: 11 é CPF, 14 é CNPJ. A formatação de entrada (pontos, barra, hífen) é preservada na saída.

FORMATO DE ENTRADA

CPF ou CNPJ, com ou sem formatação. Ex.: 123.456.789-09 , 12345678909 , 11.222.333/0001-81 , 11222333000181 .

ENTRADA → SAÍDA

ENTRADA	SAÍDA
123.456.789-09	→ 210.747.284-08
11.222.333/0001-81	→ 60.628.464/0001-79
11222333000181	→ 60628464000179
12345678000190	→ Erro: dígitos verificadores inválidos (maskInvalidInput = false)

As linhas 2 e 3 mostram o mesmo CNPJ com e sem pontuação: os dígitos gerados são idênticos, só o formato muda.

PARÂMETROS

maskInvalidInput	O que fazer quando o CPF/CNPJ de entrada não passa na validação dos dígitos verificadores. false (padrão) — lança erro e interrompe. true — mascara mesmo assim, ignorando a invalidade. Bases legadas costumam ter documentos inválidos gravados; se for o seu caso, ative isto ou configure o fallbackAlgorithm .
cmNumericRef	Algoritmo usado internamente para embaralhar os dígitos antes do recálculo do verificador. Se vazio, usa o Character Mapping numérico embutido. Informe uma instância do catálogo, ex.: dlp-core:CM Digits .
fallbackAlgorithm	Algoritmo acionado quando o valor não é reconhecido como CPF nem CNPJ — campo em branco, texto livre, comprimento inesperado. Sem ele, esses casos viram erro.

Datas

Quatro estratégias distintas para datas: deslocar preservando intervalos, deslocar por valores discretos, substituir por completo, ou apenas limitar a uma faixa.

2.1 Date Shift

`algorithm.plugin.dateAlgorithms.DateShift`

DETERMINÍSTICO

Desloca a data por uma quantidade sorteada dentro de `[minRange, maxRange]` . O sorteio é determinístico pela chave, então a mesma data sempre recebe o mesmo deslocamento — o que **preserva a ordem cronológica e as distâncias** entre registros de uma mesma entidade. É o algoritmo de escolha quando análises dependem de intervalos ("dias entre pedido e entrega").

FORMATO DE ENTRADA

ISO 8601: `yyyy-MM-dd` ou `yyyy-MM-ddTHH:mm:ss` . A saída sempre inclui a componente de hora.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
2024-03-15	→ 2024-08-09T00:00
2024-03-15T14:30:00	→ 2024-12-17T14:30
2024-01-31	→ 2024-05-31T00:00

As duas primeiras com `±365 DAYS` ; a terceira com `±12 MONTHS` . Note que a hora original é sempre preservada.

PARÂMETROS

<code>minRange</code>	Deslocamento mínimo, na unidade de <code>unit</code> . Negativo permite recuar no tempo. Ex.: <code>-365</code> com <code>DAYS</code> permite voltar até um ano.
<code>maxRange</code>	Deslocamento máximo. Positivo permite avançar. Um intervalo estreito preserva melhor a plausibilidade dos dados; um intervalo largo aumenta a proteção.
<code>unit</code>	Unidade do deslocamento: <code>SECONDS</code> , <code>MINUTES</code> , <code>HOURS</code> , <code>DAYS</code> , <code>MONTHS</code> , <code>YEARS</code> .
<code>roll</code>	Só importa com <code>MONTHS</code> ou <code>YEARS</code> , quando o resultado cairia em data inexistente (31 de janeiro + 1 mês = 31 de fevereiro). true — encolhe para o último dia válido do mês (28/fev). false — transborda para o mês seguinte (3/mar). Na dúvida, <code>false</code> .

Preservação de intervalos. Como o deslocamento depende da data de origem, dois registros com datas diferentes recebem deslocamentos diferentes — a distância entre eles **não é** preservada exatamente. Se o requisito for manter distâncias intactas, o deslocamento precisa ser fixo por entidade, o que se obtém com `dlpx-core:Date Shift Fixed` .

2.2 Date Shift Discrete

algorithm.plugin.dateAlgorithms.DateShiftDiscrete **DETERMINÍSTICO**

Variante do Date Shift em que o deslocamento não vem de um intervalo contínuo, mas de um **conjunto finito de valores possíveis** definido em arquivo de configuração. Útil quando o negócio exige deslocamentos padronizados (por exemplo, apenas múltiplos de 7 dias, para preservar o dia da semana).

FORMATO DE ENTRADA

ISO 8601: yyyy-MM-dd ou yyyy-MM-ddTHH:mm:ss .

ENTRADA → SAÍDA

ENTRADA	SAÍDA
2024-03-15	→ 2024-03-07T00:00

PARÂMETROS

Sem parâmetros expostos no schema — o conjunto de deslocamentos vem da configuração embutida do plugin.

2.3 Date Replacement

algorithm.plugin.dateAlgorithms.DateReplacement **DETERMINÍSTICO**

Descarta a data original e sorteia uma data **absoluta** dentro de [minDate, maxDate] . Diferente do Date Shift, aqui não há relação alguma entre entrada e saída além do determinismo — a ordem cronológica original é destruída. Use quando a data em si é sensível e nenhuma análise temporal depende dela.

FORMATO DE ENTRADA

ISO 8601 com hora: yyyy-MM-ddTHH:mm:ss . Ex.: 1985-07-20T00:00:00 .

ENTRADA → SAÍDA

ENTRADA	SAÍDA
1985-07-20T00:00:00	→ 1998-03-21T00:00

PARÂMETROS

minDate	Data mínima possível na saída, no formato yyyy-MM-ddTHH:mm:ss . Define o piso da janela de sorteio.
maxDate	Data máxima possível, mesmo formato. Escolha uma janela plausível para o domínio — datas de nascimento em 1970-2000, por exemplo.
unit	Granularidade do sorteio: SECONDS , MINUTES , HOURS ou DAYS . Com DAYS , a componente de hora fica zerada.

2.4 Min/Max Date/Time

algorithm.plugin.minMax.MinMaxLocalDateTime

Não é bem um mascaramento, e sim um **truncamento de faixa** (clamping): datas dentro do intervalo passam intactas; datas fora são puxadas para o limite mais próximo. O uso típico é suprimir outliers que identificam indivíduos — o cliente centenário, a data de 1900 usada como sentinela.

FORMATO DE ENTRADA

ISO 8601. Ex.: 2024-03-15T14:30:00 .

ENTRADA → SAÍDA

ENTRADA		SAÍDA
1985-06-15T08:00:00	→	1985-06-15T08:00
1950-01-01T00:00:00	→	1970-01-01T00:00
2024-05-10T12:00:00	→	2000-12-31T23:59:59

Faixa 1970-01-01 a 2000-12-31T23:59:59 . A primeira data está dentro e passa inalterada; a segunda é anterior ao piso; a terceira é posterior ao teto.

PARÂMETROS

minDate *	Piso do intervalo. Qualquer data anterior é substituída por este valor.
maxDate *	Teto do intervalo. Qualquer data posterior é substituída por este valor.
nonConformingDataDefaultValue	Valor devolvido quando a entrada não é uma data/hora válida. Se ficar vazio, o algoritmo lança erro de dado não-conforme e interrompe o job.

Isto não anonimiza. Valores dentro da faixa saem **idênticos** à entrada. Min/Max é uma ferramenta de supressão de outliers, não de mascaramento — nunca use sozinho em uma coluna sensível.

Numérico

Transformações sobre valores numéricos: mapeamento determinístico para uma faixa, limitação de intervalo, expressões Java arbitrárias e uma regra fixa de repetição de dígitos.

3.1 Numeric Mapping

`algorithm.plugin.characterMapping.NumericMapping`

DETERMINÍSTICO

Mapeia um número para outro dentro de `[minValue, maxValue]`, de forma determinística. Cada valor de origem recebe consistentemente o mesmo destino, o que preserva junções e contagens distintas — mas não a ordem nem a magnitude.

FORMATO DE ENTRADA

Número inteiro positivo, sem pontuação nem casas decimais. Ex.: `12345`.

ENTRADA → SAÍDA

ENTRADA

SAÍDA

12345

→

91472

98765

→

89966

11111

→

34588

PARÂMETROS

`minValue`

Menor valor que a saída pode assumir. Escolha um piso que respeite a semântica da coluna (ex.: `10000` para garantir sempre 5 dígitos).

`maxValue`

Maior valor da saída. A largura da faixa determina a chance de colisão: faixas estreitas fazem valores distintos colidirem no mesmo destino.

3.2 Min/Max BigDecimal

`algorithm.plugin.minMax.MinMaxBigDecimal`

A contraparte numérica do Min/Max Date/Time: limita o valor a uma faixa, deixando passar intacto o que já está dentro dela. Serve para achatar outliers — salários muito altos, saldos negativos extremos — que sozinhos identificam a pessoa.

FORMATO DE ENTRADA

Número decimal ou inteiro. Ex.: `5000.50` , `3.14` .

ENTRADA → SAÍDA

ENTRADA		SAÍDA
5000.50	→	5000.50
250	→	1000
15000	→	9999

Faixa `1000` - `9999` . Note que a escala decimal do valor dentro da faixa é preservada.

PARÂMETROS

<code>minValue</code> *	Limite inferior. Valores menores são elevados a este número.
<code>maxValue</code> *	Limite superior. Valores maiores são rebaixados a este número.
<code>nonConformingDataDefaultValue</code>	Valor devolvido quando a entrada não é numérica. Vazio faz o algoritmo lançar erro de dado não-conforme.

Isto não anonimiza. Assim como o Min/Max de datas, valores dentro da faixa saem idênticos. Combine com outro algoritmo se a coluna for sensível.

3.3 Numeric Expression

`algorithm.plugin.expression.NumericExpression`

O algoritmo mais aberto do conjunto: avalia uma **expressão Java de uma linha** sobre o valor de entrada. A expressão recebe duas variáveis — `input` (o valor como `BigDecimal`) e `seed` (um `long` derivado da chave, para mascaramento determinístico) — além de quaisquer constantes que você declarar.

FORMATO DE ENTRADA

Número inteiro ou decimal. Ex.: `1000`, `3.14`.

ENTRADA → SAÍDA

ENTRADA · EXPRESSÃO	SAÍDA
<code>1234.56</code> <code>input.setScale(0, HALF_UP)</code>	→ <code>1235</code>
<code>99.4</code> <code>input.setScale(0, HALF_UP)</code>	→ <code>99</code>
<code>1234.56</code> <code>new BigDecimal(seed % 9000 + 1000)</code>	→ <code>3701</code>
<code>1000</code> <code>input.multiply(new BigDecimal(taxa))</code>	→ <code>800.0000000000000444089209850062616169452667236328125000</code>

PARÂMETROS

expression *	Expressão Java que retorna <code>BigDecimal</code> . Variáveis disponíveis: <code>input</code> e <code>seed</code> . Classes precisam de nome totalmente qualificado — <code>new java.math.BigDecimal(...)</code> , <code>java.math.RoundingMode.HALF_UP</code> .
inputType	Como interpretar a entrada antes de expor em <code>input</code> : <code>DOUBLE</code> , <code>LONG</code> ou <code>BIG_DECIMAL</code> (padrão).
constants	Lista de constantes nomeadas acessíveis na expressão. Cada uma tem <code>name</code> e <code>value</code> (sempre string). Ex.: <code>name="taxa"</code> , <code>value="0.8"</code> , usada como <code>new java.math.BigDecimal(taxa)</code> .
nonConformingDataDefaultValue	Valor devolvido quando a entrada não é numérica. Vazio faz lançar erro.

Cuidado com ponto flutuante. A quarta linha do exemplo devolveu `800.0000000000000444...` em vez de `800`: a constante `"0.8"` passou por `double` antes de virar `BigDecimal`. Para aritmética exata, use o construtor de string — `new java.math.BigDecimal("0.8")` — e feche com `.setScale(2, java.math.RoundingMode.HALF_UP)`.

3.4 Repeat First Digit

`algorithm.plugin.repeatFirstDigit.RepeatFirstDigit`

Regra fixa e sem configuração: pega os **4 dígitos finais** do número e substitui todos pelo primeiro deles, repetido quatro vezes. O restante do número fica intacto. É um mascaramento fraco, adequado a campos de baixa sensibilidade onde só se quer quebrar o valor exato.

FORMATO DE ENTRADA

String numérica com exatamente **4, 9, 10 ou 14 dígitos**, sem pontuação. Outros comprimentos são rejeitados.

ENTRADA → SAÍDA

ENTRADA		SAÍDA
1234	→	1111
123456789	→	123456666

No segundo caso, os 5 primeiros dígitos são preservados e os 4 últimos (**6789**) viram **6666** .

PARÂMETROS

Nenhum. O comportamento é fixo.

String

Os algoritmos de propósito geral para texto estruturado. Aqui estão as ferramentas mais usadas do plugin — e as mais configuráveis.

4.1 Character Mapping

algorithm.plugin.characterMapping.CharacterMapping

DETERMINÍSTICO

Troca cada caractere por outro **do mesmo grupo**. Você define os grupos (letras minúsculas, maiúsculas, dígitos...) e o algoritmo garante que uma letra vire letra e um dígito vire dígito, preservando o comprimento e o "formato visual" do dado. Caracteres que não pertencem a nenhum grupo — espaços, acentos, pontuação — passam intactos.

FORMATO DE ENTRADA

Qualquer string. Ex.: João Silva , ABC123 .

ENTRADA → SAÍDA

ENTRADA	SAÍDA
João Silva123	→ Qiãz Hfroy869
ABC123	→ BAG992
Maria	→ Rjewk
João Silva123 (outra chave)	→ Fnãx Gsjgn414

O ã e o espaço sobreviveram — não estão em nenhum grupo configurado. A última linha mostra o efeito da chave: mesmo input, chave diferente, resultado diferente.

PARÂMETROS

characterGroups	Lista de strings; cada string é um conjunto de caracteres intercambiáveis entre si. Ex.: ["abcdefghijklmnopqrstuvwxyz", "0123456789"] cria dois grupos isolados — letras só viram letras, dígitos só viram dígitos. Caracteres ausentes de todos os grupos nunca são mascarados.
caseSensitive	Quando verdadeiro, maiúsculas e minúsculas são tratadas como grupos separados, preservando a capitalização do original. Requer que você declare os dois conjuntos separadamente.
minMaskedPositions	Número mínimo de posições que precisam efetivamente mudar. Impede que o algoritmo devolva um valor quase idêntico ao original por coincidência do sorteio.
preserveRanges	Lista de trechos a manter intactos, cada um com start , length e direction . Serve para preservar prefixos ou sufixos com significado — código de agência, dígito de controle.
preserveLeadingZeros	Quando verdadeiro, zeros à esquerda são mantidos. Essencial em códigos numéricos gravados como texto, onde 007 e 7 não são equivalentes.

Por que os acentos não mudam. Se caracteres acentuados precisam ser mascarados, inclua-os explicitamente em um grupo: "aáãääëéêííóóôôúú" . Do contrário eles ficam visíveis no dado mascarado e podem ajudar a reidentificar o registro.

4.2 Character Replacement

`algorithm.plugin.characterReplacement.CharacterReplacement`

Aplica regras de substituição caractere a caractere: cada regra declara *quais* caracteres detectar e *por qual* caractere trocá-los. Diferente do Character Mapping, aqui a substituição é fixa (não sorteada) — todos os caracteres filtrados viram o mesmo símbolo. Pode opcionalmente rodar depois de outro algoritmo, via `stringAlgorithm`.

FORMATO DE ENTRADA

Qualquer string. Ex.: `Exemplo de texto`.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
Exemplo de texto	→ <code>*s*jnv* c* n*pd*</code>
Maria Oliveira	→ <code>H*q** *s*****s*</code>
João Coração (<code>filterAccents: INPUT</code>)	→ <code>H*** Y***y**</code>

Regra: vogais → `*`. As consoantes também mudaram porque o algoritmo aplica um mascaramento próprio antes das regras. Na terceira linha, `filterAccents: INPUT` converteu `ã` e `ç` para ASCII antes de processar.

PARÂMETROS

<code>stringAlgorithm</code>	Algoritmo aplicado ao input <i>antes</i> das regras de substituição. O resultado dele é que passa pelas <code>replacementRules</code> . Permite compor: mascare com um algoritmo forte e depois normalize caracteres problemáticos.
<code>replacementRules</code>	Lista de regras aplicadas em sequência. Cada regra é um par (conjunto de caracteres a detectar, caractere substituto).
↳ <code>filteredCharacters</code>	Os caracteres que esta regra detecta. Forma simples, usada quando entrada e saída compartilham o mesmo conjunto.
↳ <code>replacementCharacter</code>	O caractere único que substitui cada ocorrência encontrada.
↳ <code>inputFilteredCharacters</code>	Forma avançada: caracteres detectados no input, quando você quer conjuntos diferentes para leitura e escrita.
↳ <code>inputReplacementCharacter</code>	Substituto aplicado às correspondências de <code>inputFilteredCharacters</code> .
↳ <code>outputFilteredCharacters</code>	Caracteres que, se aparecerem na <i>saída</i> do <code>stringAlgorithm</code> , também devem ser substituídos.
↳ <code>outputReplacementCharacter</code>	Substituto aplicado às correspondências de <code>outputFilteredCharacters</code> .
<code>requireInputChange</code>	Quando verdadeiro, exige que ao menos uma substituição tenha ocorrido — se nenhuma regra mudou nada, o algoritmo lança erro. Protege contra configurações que silenciosamente não mascaram nada.
<code>filterAccents</code>	Quando remover acentos. INPUT — antes de aplicar as regras. OUTPUT — no resultado final. BOTH — nas duas etapas. NONE — nunca (padrão).

4.3 Segment Mapping

algorithm.plugin.segmentMapping.SegmentMapping

DETERMINÍSTICO

Divide a string em segmentos de comprimento fixo e trata cada um de forma independente — mascarar, preservar, ou substituir por constante. É o algoritmo certo para documentos de formato rígido onde partes têm significado diferente: CPF, CNPJ, CEP, código de barras, número de conta com agência embutida.

FORMATO DE ENTRADA

String de formato fixo. Com `autoIgnoreCharacters` ativo, separadores (pontos, hífen, barras) são detectados e reposicionados automaticamente. Ex.: `123.456.789-09`.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
123.456.789-09	→ 383.473.782-82
987.654.321-00	→ 423.695.820-82

Segmentos de 3-3-3-2 dígitos, todos `MASK_NUMERIC`, com os separadores preservados nas posições originais.

PARÂMETROS

<code>segments *</code>	Lista ordenada de segmentos, na sequência em que aparecem no valor (desconsiderando caracteres ignorados). A soma dos comprimentos deve bater com o tamanho do dado.
<code>length *</code>	Quantos caracteres este segmento ocupa. Não conta os caracteres ignorados.
<code>segmentType *</code>	MASK_NUMERIC — troca por dígitos. MASK_ALPHANUMERIC — troca por caracteres alfanuméricos. PRESERVE — mantém o original. CONSTANT — substitui pelo valor fixo de <code>maskValues</code> .
<code>inputValues</code>	Conjunto de caracteres aceitos neste segmento no input, como string contínua. Ex.: <code>"0123456789"</code> . Vazio aceita qualquer caractere.
<code>maskValues</code>	Pool de caracteres usado na substituição. Ex.: <code>"123456789"</code> (sem o zero) impede que o segmento comece com <code>0</code> . Vazio usa o pool padrão do tipo.
<code>ignoreCharacters</code>	Códigos ASCII dos separadores a pular na contagem de posições — <code>46</code> ponto, <code>45</code> hífen, <code>47</code> barra. Eles voltam à saída na posição original.
<code>autoIgnoreCharacters</code>	Quando verdadeiro, detecta sozinho todos os caracteres não-alfanuméricos e os ignora. Dispensa listar códigos ASCII manualmente — recomendado para CPF, CNPJ e CEP.
<code>allowShortSegments</code>	Quando verdadeiro, aceita input menor que a soma dos segmentos, processando o que houver. O padrão (falso) lança erro.
<code>processPreserveBeforeIgnore</code>	Ordem de operação entre remover ignorados e calcular segmentos <code>PRESERVE</code> . Ative quando um separador cai dentro de um segmento preservado e as posições estão saindo deslocadas.

4.4 Regex Decompose

algorithm.plugin.decompose.RegexDecompose

O algoritmo mais flexível para texto estruturado. Você define padrões regex; o primeiro que casar com a string **inteira** é aplicado, e cada grupo de captura (parênteses) recebe uma ação independente — preservar, apagar, redigir ou passar por outro algoritmo. O texto *entre* os grupos é preservado automaticamente.

FORMATO DE ENTRADA

Qualquer string. Os padrões são testados na ordem declarada, até um casar. Não casando nenhum, aplica-se o `fallbackAction`.

ENTRADA → SAÍDA

ENTRADA · REGEX	SAÍDA
usuario@empresa.com.br ([^@]+) (@[^\s]+) → REDACT, PRESERVE	→ ***@empresa.com.br
000001999191111 (\d{6}) (\d{9}) → PRESERVE, REDACT "X"	→ 000001XXXXXXXXX
"000001999191111" " mesmo padrão, trimInput: true	→ "000001XXXXXXXXX" "
123456789 (\d{3}) (\d+) → PRESERVE, TRUNCATE	→ 123
ABC sem fallbackAction	→ Erro: No pattern matched and no fallbackAction is defined
ABC fallback REDACT "[INVALIDO]"	→ [INVALIDO]

PARÂMETROS

maskPatterns	Lista de padrões testados em ordem . O primeiro cujo regex casar com a string inteira é o usado — os demais são ignorados. É esta ordenação que permite roteamento condicional (ver nota abaixo).
↳ regex	Expressão regular que precisa casar com a string inteira (ancorada implicitamente). Os grupos de captura delimitam as partes que recebem ações.
↳ actions	Uma ação por grupo de captura, na mesma ordem dos parênteses. Dois grupos exigem exatamente duas ações.
↳ actions.type	PRESERVE — mantém o trecho. TRUNCATE — remove o trecho (vira string vazia). REDACT — substitui por texto ou caractere fixo. APPLY_ALGORITHM — passa o trecho por outro algoritmo.
↳ actions.redactString	Texto fixo que substitui o grupo <i>inteiro</i> , independentemente do tamanho original. Ex.: <code>***</code> . Só com <code>REDACT</code> .
↳ actions.redactCharacter	Caractere único que substitui <i>cada</i> caractere do grupo, preservando o comprimento. Ex.: <code>"X"</code> transforma 9 dígitos em <code>XXXXXXXXX</code> . Mutuamente exclusivo com <code>redactString</code> .
↳ actions.algorithm	Instância de algoritmo aplicada ao grupo, quando o tipo é <code>APPLY_ALGORITHM</code> . Aceita nomes do catálogo built-in (apêndice B) ou de testes salvos no Tester.
fallbackAction	Ação aplicada ao valor inteiro quando nenhum padrão casa. Tem os mesmos quatro tipos, com <code>redactString</code> , <code>redactCharacter</code> e <code>algorithm</code> próprios.

<code>trimInput</code>	Remove espaços das extremidades <i>antes</i> de tentar casar. O padding é restaurado na saída (ver terceira linha da tabela). Essencial para colunas <code>CHAR(n)</code> , que vêm preenchidas com espaços à direita.
<code>requireMask</code>	Quando ativo, lança erro se nenhum padrão casar, em vez de usar o fallback. Use quando valores fora do formato devem ser rejeitados em vez de passarem adiante.
<code>maxLength</code>	Comprimento máximo aceito na entrada. Valores maiores viram erro. Vazio não impõe limite.

Dois erros comuns.

- ① `NullPointerException ... action.type is null` — ao adicionar uma ação pelo formulário, o campo **Tipo de ação** começa vazio; selecione-o explicitamente.
- ② `Fallback action may not be PRESERVE when requireMask is set` — `requireMask` tem padrão **true**; para usar `fallbackAction: PRESERVE`, defina `requireMask: false` explicitamente.

Roteamento condicional por conteúdo. Como os padrões são testados em ordem, dá para desviar o valor para algoritmos diferentes conforme o que ele contém. Para aplicar um algoritmo quando há `@` e outro quando não há:

```
{ "maskPatterns": [
  { "regex": "(.+@.+)",
    "actions": [{ "type": "APPLY_ALGORITHM", "algorithm": { "name": "dlpx-core:EmailSL" } } ] },
  { "regex": "(.+)",
    "actions": [{ "type": "APPLY_ALGORITHM", "algorithm": { "name": "dlpx-core:FirstName" } } ] }
]
```

O primeiro padrão só casa com valores que tenham `@`; todo o resto cai no segundo, que funciona como catch-all.

4.5 String Algorithm Chain

`algorithm.plugin.stringAlgorithmChain.StringAlgorithmChain`

Encadeia algoritmos em sequência: a saída de um vira a entrada do próximo. Exige no mínimo dois. Serve para compor transformações que nenhum algoritmo isolado oferece — mascarar e depois normalizar, ou aplicar duas camadas de substituição.

FORMATO DE ENTRADA

String compatível com o *primeiro* algoritmo da cadeia. Os seguintes recebem o que o anterior produziu.

ENTRADA → SAÍDA

ENTRADA

Joao Silva

→

SAÍDA

Jeroen

Cadeia `FirstName` → `LastName` : o primeiro algoritmo produziu um nome, e o segundo tratou esse resultado como se fosse um sobrenome.

PARÂMETROS

`algorithmReferences`

Lista ordenada de referências a instâncias, **mínimo 2**. Ex.: `[{"name":"dlpx-core:FirstName"}, {"name":"dlpx-core:LastName"}]`. Os nomes vêm do catálogo built-in (apêndice B) ou de testes salvos no Tester.

A ordem importa e o encaixe também. Cada algoritmo precisa aceitar o formato que o anterior produziu. Encadear um algoritmo de data depois de um de nome, por exemplo, falha — o segundo recebe texto que não consegue interpretar.

4.6 Shuffle

algorithm.plugin.shuffle.Shuffle

⚠ NÃO DETERMINÍSTICO

MODO LOTE

Redistribui os valores **entre** os registros: cada linha recebe o valor que pertencia a outra. Nenhum valor é inventado — o conjunto permanece idêntico, só as associações mudam. Isso preserva perfeitamente a distribuição estatística da coluna, o que o torna ideal para colunas usadas em agregações.

FORMATO DE ENTRADA

Múltiplos valores de uma vez (modo lote). Cada valor precisa ter comprimento $\geq$ `minimumShuffleSize`.

ENTRADA → SAÍDA

LOTE DE ENTRADA		LOTE DE SAÍDA
Maria Silva	→	Pedro Lima
João Costa	→	Ana Santos
Pedro Lima	→	João Costa
Ana Santos	→	Carlos Pereira
Carlos Pereira	→	Maria Silva

PARÂMETROS

`minimumShuffleSize`

Comprimento mínimo para um valor participar do embaralhamento (padrão 3).
Valores mais curtos ficam de fora e passam sem alteração.

Não é determinístico — de propósito. A cada execução a permutação muda. Isso é uma decisão de segurança: uma permutação reproduzível permitiria reexecutar o shuffle e reverter a anonimização. A consequência prática é que o Shuffle **não preserva integridade referencial** entre tabelas nem entre execuções.

Texto aberto

Para campos de texto livre — observações, laudos, comentários — onde o dado sensível está embutido em meio a texto que precisa continuar legível.

5.1 Free Text Redaction

`algorithm.plugin.freeTextRedaction.FreeTextRedaction`

Varre um texto livre procurando entidades sensíveis — por expressão regular e/ou por uma lista de termos em arquivo — e substitui apenas os trechos encontrados. Todo o resto do texto é preservado, mantendo o documento legível e útil para análise.

FORMATO DE ENTRADA

Texto livre de qualquer tamanho. Ex.: Contate João pelo e-mail joao@empresa.com ou CPF 123.456.789-09.

ENTRADA → SAÍDA

ENTRADA

Contate João pelo e-mail joao.silva@empresa.com.

SAÍDA

→

Contate João pelo e-mail [REDACTED].

PARÂMETROS

regularExpressions	Lista de objetos <code>{patternString}</code> com as regex que identificam trechos a redigir. Cada padrão é aplicado ao texto inteiro, em todas as ocorrências.
isDenyList	true — lista de bloqueio: redige o que <i>casa</i> com os padrões. false — lista de permissão: redige tudo que <i>não</i> casa. A segunda opção é mais segura para textos imprevisíveis, mas costuma destruir a legibilidade.
regexRedactValue	Texto que substitui os trechos capturados pelas expressões regulares. Ex.: [REDACTED].
lookupFile	Arquivo com termos literais, um por linha, buscados no texto. Serve para nomes próprios e termos que regex não descreve bem.
lookupFileRedactValue	Texto que substitui as ocorrências vindas do arquivo. É independente do <code>regexRedactValue</code> , permitindo marcar visualmente a origem de cada redação.

5.2 Redact

`algorithm.plugin.redact.Redact`

Versão mais simples e direta da redação: um mapa de `regex` → `texto de substituição`. Cada chave do mapa é um padrão, e o valor correspondente é o que entra no lugar. Sem `regex` configurada, devolve o valor de entrada sem mascaramento algum.

FORMATO DE ENTRADA

Qualquer string. Trechos que casarem com as `regex` são substituídos.

ENTRADA → SAÍDA

ENTRADA

SAÍDA

Contate João pelo e-mail joao.silva@empresa.com. → Contate João pelo e-mail [EMAIL].

PARÂMETROS

`regexRedact`

Mapa de `{regex → texto_substituição}`. Permite marcadores diferentes por tipo de dado — `[EMAIL]`, `[CPF]`, `[TELEFONE]` — em uma única configuração.

Configuração vazia não mascara. Sem nenhuma `regex` em `regexRedact`, o algoritmo devolve a entrada intacta e **não** emite aviso. Verifique sempre que o mapa foi preenchido.

Financeiro

Instrumentos financeiros com estrutura validável: cartões com dígito Luhn e IBANs com checksum de país.

6.1 Payment Card

`algorithm.plugin.characterMapping.PaymentCard`

DETERMINÍSTICO

Mascara números de cartão preservando o **BIN** (os primeiros dígitos, que identificam bandeira e emissor) e, opcionalmente, os últimos dígitos usados em conferências. O número gerado mantém o **dígito verificador Luhn válido**, então continua passando em validações de formulário e de sistema.

FORMATO DE ENTRADA

Número de cartão com ou sem espaços/hífens. Ex.: `4111 1111 1111 1111`.

ENTRADA → SAÍDA

ENTRADA

SAÍDA

`4111111111111111`

→

`411106277755578`

`5500000000000004`

→

`5500836779524256`

`4111111111111111` (`preserve: 0`)

→

`9393500626048800`

Nas duas primeiras o BIN (`4111` , `5500`) foi preservado automaticamente. Na terceira, com `preserve: 0` , até o BIN mudou — a bandeira do cartão deixa de ser identificável.

PARÂMETROS

`preserve`

Quantos dígitos do *final* do cartão preservar. Tipicamente `4` , para manter os últimos quatro que aparecem em extratos e telas de confirmação.

`minMaskedPositions`

Número mínimo de posições que devem efetivamente mudar. Garante que o cartão mascarado não fique parecido demais com o original.

Preservar os 4 finais tem custo. Últimos-4 mais BIN mais data de transação costuma ser suficiente para reidentificar um cartão em bases pequenas. Use `preserve: 4` só quando o processo de negócio realmente depender disso.

6.2 IBAN

algorithm.plugin.iban.IBAN

DETERMINÍSTICO

Mascara um IBAN preservando o código do país e recalculando o dígito verificador, de modo que o resultado continue sendo um IBAN estruturalmente válido. Você controla quantos caracteres da parte nacional são embaralhados.

FORMATO DE ENTRADA

IBAN no formato padrão, sem espaços. Ex.: GB29NWBK60161331926819 .

ENTRADA → SAÍDA

ENTRADA		SAÍDA
GB29NWBK60161331926819 (mask 20)	→	GB59DNLT98906202195739
GB29NWBK60161331926819 (mask 8)	→	GB18NWBK60161374219890

Com numCharsToMask: 8 o código do banco (NWBK) e a agência sobrevivem; com 20 , praticamente só o país permanece. O GB é sempre preservado e o checksum recalculado.

PARÂMETROS

validateInput *	Quando verdadeiro, valida o checksum do IBAN antes de mascarar e rejeita entradas inválidas. Desligue apenas se a base tiver IBANs sabidamente malformados que ainda assim precisam ser processados.
numCharsToMask *	Quantos caracteres embaralhar, contados a partir do fim da parte nacional. Valores baixos preservam banco e agência; valores altos mascaram tudo depois do país.

Lookup & Mapeamento

Algoritmos que substituem valores consultando uma fonte externa — um arquivo de substitutos, uma tabela de-para, ou um banco de mapeamentos persistente.

7.1 Secure Lookup

algorithm.plugin.secureLookup.SecureLookup

DETERMINÍSTICO

⚠ EXCETO COM RANDOMIZE

REQUER ARQUIVO

Substitui o valor por uma linha de um arquivo de lookup, escolhida pelo hash de (valor + chave). O mesmo input sempre seleciona a mesma linha, o que dá consistência referencial entre tabelas sem precisar de banco de mapeamento. É o algoritmo de lookup mais usado do plugin.

FORMATO DE ENTRADA

Qualquer string não nula. O conteúdo do arquivo determina o domínio da saída.

ENTRADA → SAÍDA

ENTRADA

SAÍDA

João da Silva

→

Pedro

Maria Souza

→

Rafael

João da Silva (ALL_UPPER)

→

PEDRO

A terceira linha mostra que `maskedValueCase` só afeta a capitalização — a linha selecionada do arquivo continua a mesma.

PARÂMETROS

lookupFile *

Arquivo com um valor substituto por linha. O número de linhas define a diversidade da saída: um arquivo com 20 nomes fará muitos valores distintos colidirem no mesmo substituto.

hashMethod

Como derivar o índice da linha. **SHA256** — hash criptográfico, determinístico pela chave (recomendado). **LEGACY** — método antigo, mantido para compatibilidade com dados já mascarados. **RANDOMIZE** — seleção aleatória, *não* determinística: cada execução muda o resultado.

maskedValueCase

Capitalização da saída. **PRESERVE_LOOKUP_FILE** — como no arquivo. **PRESERVE_INPUT** — copia o padrão do input. **ALL_LOWER** / **ALL_UPPER**.

inputCaseSensitive

Quando verdadeiro, "João" e "JOÃO" produzem hashes distintos e podem receber substitutos diferentes. Deixe falso para tratar variações de caixa como o mesmo valor.

trimWhitespaceFromInput

Remove espaços das extremidades do input antes do hash. Faz " João " e "João" caírem no mesmo substituto — importante em colunas `CHAR(n)`.

trimWhitespaceInLookupFile

Remove espaços das extremidades de cada linha do arquivo ao carregá-lo, evitando que linhas com espaço sobrando virem valores distintos.

7.2 Null-Safe Secure Lookup

`algorithm.plugin.nullSecureLookup.NullSecureLookup`

LIMITADO NO RUNNER

Variante do Secure Lookup com tratamento explícito de valores nulos: input nulo devolve nulo, em vez de erro. Não expõe parâmetros — usa o arquivo de lookup embutido no plugin.

FORMATO DE ENTRADA

Qualquer string, ou nulo.

ENTRADA → SAÍDA

ENTRADA

SAÍDA

`valor-sensivel`

→ `null` (no runner standalone)

PARÂMETROS

Nenhum.

No runner standalone sempre devolve `null`. O algoritmo depende do contexto do Masking Engine para resolver o arquivo de lookup embutido. O resultado `null` aqui é esperado e não indica erro de configuração.

7.3 Data Cleansing

algorithm.plugin.dataCleansing.DataCleansing

REQUER ARQUIVO

Substitui valores segundo uma tabela de-para **explícita**: você declara exatamente qual valor vira qual. Ao contrário do Secure Lookup, não há hash nem sorteio. Na prática é mais uma ferramenta de padronização que de mascaramento — normalizar siglas, unificar grafias divergentes.

FORMATO DE ENTRADA

String com correspondência no arquivo. Sem correspondência, o valor original passa **sem alteração**.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
SP	→ São Paulo
rj	→ Rio de Janeiro
XX	→ XX (sem correspondência)

A segunda linha casou apesar da caixa diferente porque `caseSensitive` está falso.

PARÂMETROS

lookupFile *	Arquivo com um mapeamento por linha, no formato <code>original{delimitador}substituto</code> . Ex.: <code>SP,São Paulo</code> .
delimiter	Separador entre original e substituto. Ex.: <code>,</code> para CSV, <code>;</code> , ou tabulação. Omitido, usa tabulação.
caseSensitive	Quando verdadeiro, <code>SP</code> e <code>sp</code> exigem entradas separadas no arquivo. Falso é o mais prático na maioria dos casos.
trimWhitespace	Remove espaços das extremidades do input e das linhas do arquivo antes de comparar, evitando falhas de correspondência por padding do banco.

Valores sem correspondência passam intactos. Isso significa que uma tabela de-para incompleta deixa dados originais vazarem **silenciosamente**. Se a coluna é sensível, valide a cobertura do arquivo antes de rodar em produção.

7.4 Mapping

algorithm.plugin.mapping.Mapping

NÃO FUNCIONA NO RUNNER

Mantém um mapeamento persistente 1-para-1 em banco de dados: cada valor original recebe um substituto único, gravado e reutilizado em todas as tabelas e execuções futuras. É a garantia mais forte de **consistência referencial** do plugin — e a única que sobrevive entre jobs distintos.

FORMATO DE ENTRADA

Qualquer string. O algoritmo consulta o mapping set e, se o valor for novo, cria e persiste um substituto.

ENTRADA → SAÍDA

ENTRADA

cliente@email.com

SAÍDA

→ Erro: Mapping set references are not supported

PARÂMETROS

mappingSet *	Referência ao conjunto de mapeamento que armazena as correspondências.
↳ algorithmName *	Nome do mapping set no Masking Engine — identifica qual conjunto usar. Ex.: <code>client-name-mapping</code> .
↳ host	Host do banco onde o mapping set está armazenado, quando remoto.
↳ port	Porta do banco do mapping set remoto.
↳ database	Nome do banco de dados remoto.
↳ schema	Schema do banco remoto.
↳ isRemote	Quando verdadeiro, usa os dados de conexão acima. Falso usa a instância local do Engine.
↳ mappingLookupKey	Chave de partição que permite ao mesmo mapping set servir múltiplos contextos isolados — por cliente, por ambiente.
↳ propertiesRef	Arquivo de propriedades com a configuração de conexão, alternativa a preencher host/porta/banco/schema individualmente.
ignoreCharacters	Códigos ASCII a remover do input antes da consulta. Ex.: <code>45</code> hífen, <code>46</code> ponto — faz CPF com e sem formatação apontar para o mesmo mapeamento.

Indisponível no Algorithm Tester. O runner standalone não tem banco de mapeamento; qualquer teste devolve `Mapping set references are not supported`. Este algoritmo só pode ser validado no Masking Engine.

Multi-Column

Algoritmos que recebem a linha inteira, não um valor isolado — permitindo que o mascaramento de uma coluna dependa do conteúdo de outra.

8.1 Multi-Column Condition

algorithm.plugin.conditional.MultiColumnCondition

DETERMINÍSTICO

MULTI-COLUNA

Escolhe qual algoritmo aplicar a cada coluna **conforme o valor de uma coluna condicional**. O caso clássico: se a coluna de gênero disser "F", mascarar o nome com uma lista de nomes femininos; se disser "M", com nomes masculinos — mantendo a coerência interna do registro.

FORMATO DE ENTRADA

Uma linha com colunas nomeadas. Obrigatória: `key` (a coluna condicional). Opcionais: `string1 ... string10`, `numeric1 ... numeric3`, `date1 ... date3`, `binary1 ... binary3`.

ENTRADA → SAÍDA

LINHA DE ENTRADA

`key = "F"`
`string1 = "Maria"`

LINHA DE SAÍDA

→ `key = "F"`
`string1 = "Jalisa"`

A coluna `key` não é mascarada — ela só decide qual condição se aplica. Apenas `string1` tinha algoritmo configurado.

PARÂMETROS

conditions	Lista de condições avaliadas contra o valor de <code>key</code> . Cada condição declara os valores que a ativam e quais algoritmos aplicar a quais slots de coluna.
↳ key	Lista de valores da coluna condicional que ativam esta condição. Ex.: <code>["F", "Female"]</code> ativa para qualquer um dos dois.
↳ string1...string10	Algoritmo aplicado à coluna <code>stringN</code> quando a condição é ativada. Ex.: <code>{"name": "dlpx-core:FirstName"}</code> . Slots sem algoritmo passam intactos.
↳ numeric1...numeric3	Algoritmo aplicado às colunas numéricas (<code>BigDecimal</code>).
↳ date1...date3	Algoritmo aplicado às colunas de data (<code>LocalDateTime</code>).
↳ binary1...binary3	Algoritmo aplicado às colunas binárias (<code>ByteBuffer</code>).
fallbackAlgo	Algoritmo aplicado às colunas string quando <i>nenhuma</i> condição casa. Sem ele, os valores passam sem mascaramento.
fallbackKey	Valor assumido como chave quando a coluna <code>key</code> está nula ou ausente na linha.
keyCaseSensitive	Quando verdadeiro, a comparação de <code>key</code> com as listas das condições diferencia maiúsculas de minúsculas. Padrão: falso.
filterLength	Usa apenas os primeiros (ou últimos) <code>N</code> caracteres de <code>key</code> na comparação. Útil quando a coluna condicional tem prefixo significativo e sufixo variável.
filterDirection	De onde contar os caracteres de <code>filterLength</code> : <code>LEFT</code> (do início) ou <code>RIGHT</code> (do fim).

De onde vêm os nomes `key`, `string1` ... São **slots fixos** do algoritmo, não nomes de colunas do seu banco. A tradução entre a coluna real (`GENERO`, `NOME`) e o slot (`key`, `string1`) é feita no **inventário** do Masking Engine. No Algorithm Tester você simula esse mapeamento preenchendo a tabela de entrada manualmente.

Colunas sem algoritmo não são mascaradas. Se uma condição declara apenas `string1`, todas as demais colunas da linha passam intactas — mesmo contendo dado sensível. Configure `fallbackAlgo` ou declare cada slot explicitamente.

8.2 Multi-Column Address

algorithm.plugin.address.MultiColumnAddress **REQUER ARQUIVO DE ENDEREÇOS**

Mascara campos de endereço espalhados por várias colunas — logradouro, número, bairro, cidade, estado, CEP — gerando um endereço sintético **coerente entre si**. Sem ele, mascarar cada coluna isoladamente produziria combinações impossíveis (rua de São Paulo com CEP do Amazonas).

FORMATO DE ENTRADA

Colunas de endereço da linha. Exige um arquivo de lookup de endereços no formato específico do Delphix.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
Rua das Flores, 123	→ Erro: FileReference nulo – arquivo de endereços não configurado

PARÂMETROS

Não documentados neste guia — o algoritmo não inicializa sem o arquivo de endereços, o que impede inspecionar seu schema no runner.

Não testável no runner standalone. O algoritmo falha na inicialização sem o arquivo de lookup de endereços, que não acompanha o plugin. Configure-o e valide diretamente no Masking Engine.

Outros

Dois algoritmos especializados: recálculo genérico de dígito verificador e tokenização reversível.

9.1 Check Digit

algorithm.plugin.checkdigit.Checkdigit

DETERMINÍSTICO

Mascara números que carregam dígito verificador e **recalcula o verificador** depois, para que o resultado continue passando na validação. É genérico: qualquer esquema de soma ponderada + módulo pode ser descrito por seus parâmetros — código de barras, EAN, boleto, matrícula, inscrição estadual.

FORMATO DE ENTRADA

String numérica sem pontuação, incluindo o dígito verificador na posição configurada. Ex.:

7891000315507 (EAN-13).

ENTRADA → SAÍDA

ENTRADA

123456789012

→

SAÍDA

299460400954

PARÂMETROS

weightList *	Pesos aplicados a cada dígito na soma ponderada, um por dígito de dados. Ex.: EAN-13 usa <code>[1, 3, 1, 3, 1, 3, 1, 3, 1, 3, 1, 3]</code> . O tamanho da lista deve ser igual a <code>numDigitsForCheckdigitCalculation</code> .
modulusNumber *	Divisor do módulo. O verificador é normalmente <code>(módulo - resto) % módulo</code> . EAN-13 usa <code>10</code> ; CNPJ usa <code>11</code> .
checkDigitIndex *	Posição do dígito verificador na string, contada a partir de <code>0</code> à esquerda. Num código de 13 dígitos com verificador no fim, informe <code>12</code> .
calculateChecksumRightToLeft *	Direção em que os pesos são aplicados. true — direita para esquerda (boletos, CNPJ). false — esquerda para direita (EAN, UPC).
numDigitsForCheckdigitCalculation *	Quantos dígitos entram na soma, excluindo o próprio verificador. EAN-13 tem 12 dígitos de dados.
swapModulusForZeroRemainder	Quando o resto é zero, usa o próprio <code>modulusNumber</code> como verificador em vez de <code>0</code> . Alguns padrões (CNPJ) entre eles adotam essa regra.
checksumCalculationType	STANDARD — soma ponderada módulo N (padrão). TFN — variante australiana (Tax File Number), com lógica própria.
numericAlgorithm	Algoritmo que embaralha os dígitos que não são o verificador. Omitido, usa o Character Mapping numérico embutido.
alphaNumericAlgorithm	Algoritmo usado quando a entrada contém letras além de dígitos. Sem ele, entradas alfanuméricas podem falhar conforme o <code>characterHandling</code> .
fallbackAlgorithm	Algoritmo acionado com entrada inválida quando <code>invalidInputHandling = FALLBACK_MASK</code> . Recebe o valor original inteiro.
preserveRegex	Regex que identifica partes a preservar — prefixos fixos, códigos de país. Os trechos que casam ficam intactos e só o restante é mascarado.
inputHandlingConfig	Bloco com o tratamento da entrada antes do mascaramento.
↳ characterHandling	NUMERIC_ONLY — aceita só <code>0–9</code> . STANDARD — letras usam seu valor ASCII. ASCII_VALUE_MINUS_48 — letras usam <code>(ASCII - 48)</code> , usado por padrões que intercalam letras e dígitos.

↳ invalidInputHandling	ERROR — lança exceção (padrão). FALLBACK_MASK — delega ao <code>fallbackAlgorithm</code> .
↳ shortInputHandling	Entrada mais curta que o esperado: FALLBACK delega, PAD_LEFT / PAD_RIGHT completam com <code>padCharacter</code> .
↳ padCharacter	Caractere de preenchimento das entradas curtas. Normalmente <code>0</code> .
↳ trimWhitespace	Remove espaços das extremidades antes de processar. Necessário para colunas <code>CHAR(n)</code> com padding.

9.2 Tokenization

algorithm.plugin.tokenization.Tokenization

REVERSÍVEL

⚠ NÃO DETERMINÍSTICO POR PADRÃO

O único algoritmo **reversível** do conjunto. Cifra o valor com AES e devolve um token; com a mesma chave e configuração, o valor original pode ser recuperado (no Tester, pelo botão *Detokenizar* — modo REIDENTIFY). É a escolha quando o dado precisa voltar ao original em algum ponto do fluxo.

FORMATO DE ENTRADA

String alfanumérica. Caracteres fora do conjunto tokenizável — símbolos, espaços, hífens — acionam o `fallback`.

ENTRADA → SAÍDA

ENTRADA	SAÍDA
4111111111111111	→ AN0xIV5riitfgy/WeQAd4M7pZgrIDox0
AN0xIV5riitfgy/WeQAd4M7pZgrIDox0 (REIDENTIFY)	→ 4111111111111111
4111-1111-1111-1111 (com hífens)	→ r/KCnIICoKdHrWGITHHCpypp77gZgLBt0fZB

A segunda linha demonstra a reversão exata. Note que o token é **mais longo** que o original — ele carrega o vetor de inicialização.

PARÂMETROS

<code>fallback</code>	O que fazer com caracteres não tokenizáveis. NONE — lança erro. CHARACTER_MAPPING — aplica mascaramento genérico nesses caracteres e segue.
<code>ivLength</code>	Tamanho do vetor de inicialização AES em bytes (padrão 8). É este parâmetro que decide se o algoritmo é determinístico. Com qualquer valor maior que zero, um IV aleatório é sorteado a cada execução: a mesma entrada com a mesma chave gera um token diferente toda vez. Com 0 , não há IV e o token passa a ser sempre o mesmo. Valores maiores aumentam a aleatoriedade, mas consomem mais espaço no resultado.
<code>cmCharacterGroups</code>	Só com <code>fallback = CHARACTER_MAPPING</code> . Define quais caracteres são intercambiáveis no fallback. Vazio usa os grupos padrão.
<code>cmMinMaskedPositions</code>	Só com <code>fallback = CHARACTER_MAPPING</code> . Mínimo de posições que o fallback deve mascarar, evitando tokens em que quase nada mudou.

⚠ **Não determinístico com a configuração padrão.** Com `ivLength` maior que zero — e o padrão é 8 — cada execução sorteia um vetor de inicialização novo, então a mesma entrada com a mesma chave produz um token diferente toda vez. Todos reverterem corretamente, mas **não servem para preservar joins**: o mesmo valor em duas tabelas vira dois tokens distintos. Se precisar que o mesmo valor sempre gere o mesmo token, use `ivLength: 0` — aí a saída é determinística e continua reversível.

O token não preserva o formato. Apesar de ser descrito como *format-preserving*, o resultado observado é uma string Base64 mais longa que a entrada — 4111111111111111 (16 caracteres) virou 32. Dimensione a coluna de destino com folga, ou o job falhará por truncamento.

A chave é o segredo. Quem tiver a chave reverte qualquer token. Trate-a com o mesmo rigor de uma chave de produção: fora do código, fora do repositório, com rotação controlada — e lembre que rotacionar invalida todos os tokens já emitidos.

Conceitos transversais

Comportamentos que atravessam vários algoritmos e costumam causar confusão quando encontrados pela primeira vez.

DETERMINISMO E O PAPEL DA CHAVE

A maioria dos algoritmos é **determinística**: o mesmo valor de entrada, com a mesma chave, sempre produz a mesma saída. É isso que preserva junções — se João vira Ana na tabela de clientes, vira Ana também na de pedidos.

A chave é o que torna o resultado imprevisível para quem não a possui. Trocá-la muda toda a saída, como visto em §4.1. As duas consequências práticas: **a mesma chave precisa ser usada em todo o projeto, e trocar a chave invalida a consistência com dados já mascarados.**

COMPORTAMENTO	ALGORITMOS
Determinístico por chave	Character Mapping, Numeric Mapping, Segment Mapping, Payment Card, IBAN, Check Digit, Date Shift, Date Replacement, Secure Lookup, Name, Full Name, Email, Phone, Financial ID BR
⚠ Não determinístico	Shuffle (§4.6) — sempre; permutação diferente a cada execução. Tokenization (§9.2) — com <code>ivLength</code> maior que zero, e o padrão é 8; use <code>ivLength: 0</code> para saída determinística. Secure Lookup (§7.1) — apenas com <code>hashMethod: RANDOMIZE</code> .
Independente de chave	Min/Max (ambos), Redact, Free Text Redaction, Data Cleansing, Repeat First Digit, Numeric Expression sem seed

ALGORITMOS QUE PODEM NÃO MASCARAR NADA

Vários algoritmos devolvem o valor original silenciosamente em certas condições. Nenhum deles emite aviso — a verificação é sua.

ALGORITMO	QUANDO O DADO PASSA INTACTO
Min/Max BigDecimal · Date/Time	Sempre que o valor já está dentro da faixa
Data Cleansing	Valor sem correspondência no arquivo de-para
Redact	<code>regexRedact</code> vazio, ou nenhum padrão casando
Regex Decompose	<code>fallbackAction: PRESERVE</code> com valor que não casa nenhum padrão
Full Name	<code>firstNameAlgorithmRef</code> ou <code>lastNameAlgorithmRef</code> não configurado
Multi-Column Condition	Slot de coluna sem algoritmo, ou nenhuma condição casando sem <code>fallbackAlgo</code>
Character Mapping	Caracteres fora de todos os <code>characterGroups</code> (acentos, pontuação)

COLONAS CHAR(N) E O PADDING INVISÍVEL

Colunas `CHAR(n)` preenchem o valor com espaços à direita até o tamanho declarado. Um CPF de 11 dígitos numa coluna `CHAR(15)` chega ao algoritmo como `"12345678909 "`. Como `\d` não casa com espaço, regex que funcionam no Tester falham em produção com mensagens como `No pattern matched` ou `did not conform to the expected format`.

A correção é ativar a opção de trim do algoritmo: `trimInput` no Regex Decompose, `trimWhitespace` no Check Digit e no Data Cleansing, `trimWhitespaceFromInput` no Secure Lookup. O padding é

restaurado na saída.

REFERÊNCIAS ENTRE ALGORITMOS

Muitos parâmetros pedem uma "referência a algoritmo" — `firstNameAlgorithmRef`, `actions.algorithm`, `numericAlgorithm`, `fallbackAlgo`. O valor esperado é `{"name": "<instância>"}`, onde a instância pode ser:

① um nome do catálogo built-in, prefixado por `dlpx-core:` (apêndice B); ② o nome de um teste salvo no próprio Algorithm Tester; ③ no Masking Engine, qualquer instância de algoritmo configurada.

Nomes inexistentes produzem `Sub-algorithm not found`.

Catálogo de instâncias built-in

As 62 instâncias que acompanham o plugin, utilizáveis em qualquer parâmetro de referência.

Prefixe com `dlpx-core:` — por exemplo `dlpx-core:FirstName`. Nomes com espaço funcionam normalmente.

ABARoutingNumber SL	IBAN	Legacy SchoolNameLookup
Age SL	Japan Corporate Number	Legacy USStateCodesLookup
BR – Financial ID	Japan Drivers License	Legacy USStatesLookup
BloodType SL	Japan My Number	Legacy UsCitiesLookup
Brazil CNPJ	JobTitle SL	Legacy UsCountiesLookup
Brazil CPF	Language SL	Legacy WebURLsLookup
CM Alpha-Numeric	LastName	MaritalStatus SL
CM Digits	Lat_Long Coordinates	MedicalGenericDrug SL
CM Numeric	Legacy AccNoLookup	NationalOrigin SL
Countries SL	Legacy AddrLine2Lookup	Null Secure Lookup
Credit Card	Legacy AddrLookup	Phone US
Date Shift Discrete	Legacy BusinessLegalEntityLookup	Phone Unique
Date Shift Fixed	Legacy CommentLookup	PoliticalOrientation SL
Date Shift Variable	Legacy DrivingLicenseNoLookup	Redact Digits-Zero
Department SL	Legacy DummyHospitalNameLookup	ReligiousOrientation SL
Email SL	Legacy EmailLookup	Repeat First Digit
Email Unique	Legacy FirstNameLookup	SexualOrientation SL
Ethnicity SL	Legacy FullNMLookup	Shuffle
FirstName	Legacy LastCommaFirstLookup	SwiftCode SL
FullName	Legacy LastNameLookup	TimeRange
Gender SL	Legacy RandomValueLookup	

Sufixo SL indica *Secure Lookup* — instâncias pré-configuradas com arquivos de lookup temáticos embutidos (profissões, países, estado civil). São a forma mais rápida de mascarar colunas categóricas sem montar arquivo próprio.

Limitações do runner standalone

O Algorithm Tester executa os algoritmos fora do Masking Engine. Alguns recursos dependem do contexto do Engine e não funcionam localmente.

RECURSO	SITUAÇÃO
<code>FileReference</code>	Suportado. Use URI <code>file:///caminho/absoluto</code> . Requer <code>commons-codec</code> em <code>lib/</code> . Os arquivos são gerenciados em <i>Configurações</i> → <i>Arquivos</i> .
<code>MappingSetReference</code>	Não suportado. O algoritmo <i>Mapping</i> (§7.4) falha com <code>Mapping set references are not supported</code> — depende de banco de mapeamento.
<code>EmbeddedGeneratorReference</code>	Não suportado.
<code>MaskValueMetadata</code>	Retorna sempre <code>null</code> .
Multi-Column Address (§8.2)	Não inicializa sem o arquivo de lookup de endereços do Delphix.
Null-Safe Secure Lookup (§7.2)	Devolve sempre <code>null</code> — depende do arquivo embutido resolvido pelo Engine.

Sobre as saídas deste guia. Todos os pares entrada → saída foram gerados executando os algoritmos no `AlgorithmRunner` com o plugin `delphix-algorithm-plugin 2026.3.0-SNAPSHOT`. Algoritmos determinísticos reproduzem exatamente estes valores com a mesma chave; o Shuffle, por natureza, produzirá uma permutação diferente a cada execução.